arXiv:2302.00087v1 [cs.GR] 31 Jan 2023

LM-GAN：照片级真实感全天候参数化天空模型

LUCAS VALENÇA，拉瓦尔大学，加拿大 IAN MAQUIGNAZ，拉瓦尔大学，加拿大 HADI MOAZEN，拉瓦尔大学，加拿大 RISHIKESH MADAN，拉瓦尔大学，加拿大 YANNICK HOLD-GEOFFROY，Adobe Research，美国 JEAN-FRANÇOIS LALONDE，拉瓦尔大学，加拿大

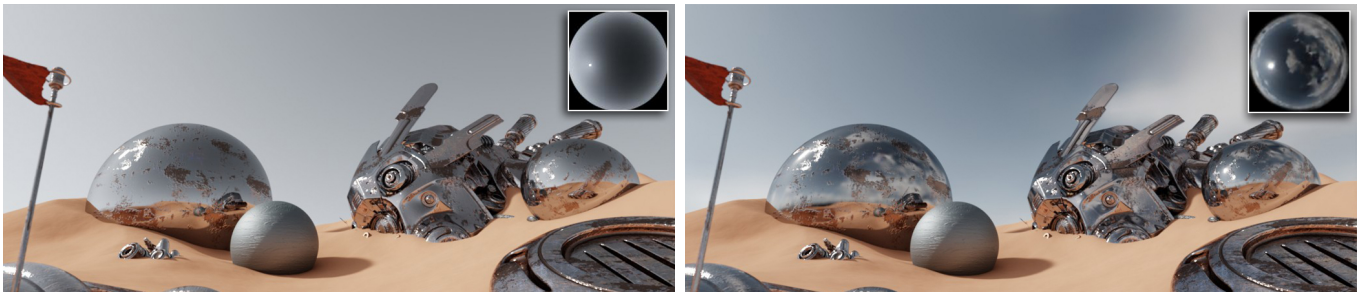

输入参数化天空　　生成的照片级真实感天空（我们的方法）

图 1。对于输入的参数化天空（左侧插图），我们的方法会生成照片级真实感的全天候 HDR环境贴图（右侧插图），同时连贯地保留参数化天空的照明。我们通过结合生成对抗流程与可微渲染损失实现这一映射。场景来自 Blender Studio，采用 CC0许可证，并添加了反射表面。

我们提出了 LM-GAN，这是一种 HDR天空模型，可生成包含多云天空的照片级真实感环境贴图。我们的天空模型保留了传统参数化模型的灵活性，能够再现天空视觉效果丰富多样、云层形态各异的照片级真实感全天候天空。为此，我们提供灵活直观的参数用户控制，包括太阳位置、天空颜色和大气浑浊度。我们的方法直接使用拟合至真实 HDR 天空的输入进行训练，以端到端的方式学习保留输入的照明，并使其与真实参考图的大气成分相关联。我们的主要贡献是一个同时基于天空外观和场景渲染损失进行训练的生成模型，以及一种新颖的天空参数拟合算法。我们证明，该拟合算法在准确性和天空保真度方面均优于现有方法；此外，我们还提供定量和定性分析，展示 LM-GAN 将参数化输入转换为照片级真实感全天候天空的能力。生成的 HDR环境贴图可直接用于 3D渲染引擎，并适用于广泛的基于图像的照明应用。

1 引言

自然光照是照片级真实感的重要组成部分，对人类感知有着显著影响。它是物理空间设计、城市建筑规划乃至媒体与电影感知视觉质量的重要方面。虚拟场景中的照片级真实感光照通常通过采用高动态范围（HDR）环境贴图来引导基于图像的照明（IBL）技术实现 [Debevec1998]。无论是通过物理方式捕获还是合成生成，HDR 图像（HDRI）通常被理解为所需天空穹顶的半球形映射，并投射到天空盒、等距柱状图或其他纹理表示中。尽管传统的低动态范围（LDR）图像可用于环境贴图，但高动态范围成像对于户外场景的照片级真实感渲染至关重要。对于物理方式捕获的 HDR 图像，估计需要22 档光圈的曝光范围，才能完整而忠实地捕获户外照明 [Stumpfel 等人 2006]。尽管对真实天空进行高动态范围成像所产生的输出在照片级真实感方面无可匹敌，但这并非灵活的解决方案，因为捕获的只是特定且无法控制的场景配置。

为克服实景拍摄的局限，过去四十年间，参数化天空模型取得了长足发展。最初，这些模型主要面向科学和工程应用（例如，[Moon 1940年；Perez 等人提出的 1993] 模型仅描述亮度）。Nishita 等人 [1993] 提出了首个颜色模型，旨在为太空飞行模拟器渲染地球的地外视景。随后，该模型扩展为包含大气中的多重散射事件和原始云 [（Nishita 等人） 1996], , 之后 Preetham 等人通过非线性最小二乘拟合对其进行了简化 [1999]。为在提高准确性的同时减少计算时间和内存占用，这些模型不断演进，最终发展为当前的 Hošek-Wilkie 系列模型 [2012；2013；2022年；2021]。这些模型是基于物理模拟数据拟合而成的数学近似，之后又通过实拍天空进行了验证。尽管这些模型在物理准确性方面表现出色，但它们只能恰当地近似理想的均匀天空，无法处理云等非均匀大气形态。

近年来，深度学习的出现催生了深空天空模型的提出，这些模型能够通过潜在参数自主发现特征

作者地址：Lucas Valença，拉瓦尔大学，加拿大，lucas.valenca@ulaval.ca；Ian Maquignaz，拉瓦尔大学，加拿大，ian.maquignaz.1@ulaval.ca；Hadi Moazen，拉瓦尔大学，加拿大，hadi.moazen.1@ulaval.ca；Rishikesh Madan，拉瓦尔大学，加拿大，rishikesh.madan.1@ulaval.ca；Yannick Hold-Geoffroy，Adobe Research，美国，holdgeof@adobe.com；Jean-François Lalonde，拉瓦尔大学，加拿大，jean-francois.lalonde@gel.ulaval.ca。

和模态。值得注意的是，这一概念已应用于光照估计 [Hold-Geoffroy 等人，2019，2017年；Yu 等人，2021a；Zhang 等人，2019b], ，其中 LDR 图像可用于引导生成高动态范围环境贴图，以便对虚拟物体和场景进行重新照明。尽管这些学习得到的表示往往照片级真实感不足，生成的天空也过于平滑，但它们能够相当准确地捕捉照明能量。近期，有研究提出了旨在重现云的生成对抗网络 [Hojdar，2019；Mirbauer 等人，2022年；Satilmis 等人， 2022],但这些方法要么无法捕捉照片级真实感纹理，要么缺乏完整的高动态范围能力。

在这项工作中，我们提出了一种学习得到的天空模型，能够生成照片级真实感的多云天空，并提供忠实且可控的 HDR 照明。我们的方法结合了参数化模型的灵活性与深度生成网络的真实感。我们利用 Lalonde-Matthews（LM）参数化照明模型 [Lalonde和Matthews 2014], ，该模型通过太阳位置、天空颜色和大气浑浊度等参数来表示室外天空。它也特别适用于对阴天进行建模，并且此前曾用于指导一种先进的全天候深度光照估计方法 [Zhang等人，2019b]。给定一组此类参数，我们首先使用 LM 方程渲染一个天空穹顶（见第 3.1 节），然后将生成的高动态范围图像输入一个深度卷积网络。该网络在对抗式设置下，使用来自公开 Laval HDR 天空数据集的超过 25,000 个高动态范围天空穹顶进行训练 [Lalonde 等人，2016；Lalonde和Matthews 2014]。该网络被命名为 *LM-GAN*，可以使用相同的参数进行控制，从而生成照片级真实感的多云 HDR 天空，并可直接用于任何现有的基于物理的渲染引擎（见图 1）。通过定量评估和消融研究，我们证明，所提出的 LM-GAN 保留了 LM 模型的参数化保真度，并在灵活性、保真度和照片级真实感方面超越了当前最先进的基于学习的模型。

2 相关工作

早期的太阳与大气照明模型，例如 [Moon 1940] 和 [Perez 等人 1993] ，主要面向科学和工程应用。随着数字时代的到来，基于图像的照明（IBL）技术 [Debevec 1998] 提出使用高动态范围成像（HDRI [Reinhard 等人 2010]），将合成对象渲染到真实和虚拟场景中。这一全新的应用范式重新激发了人们对天空建模的兴趣，并减轻了物理采集的负担。

2.1 参数化模型

为减少对阳光和天空光建模所需的计算资源，通常更适合通过数学模型近似其外观，并根据实际采集的天空进行评估 [Kider 等人 2014]。一种此类方法是开发数值模型，例如 [Bruneton 和 Neyret，2008；Elek 和 Kmoch，2010；Haber 等人，2005；Nishita 等人，1996、1993年；O'Neil 2005], 这些模型为复杂的大气系统推导出简化的数学表示。数值模型虽能降低计算开销，但通常仍然复杂、占用大量内存，且需要预计算步骤。

Perez 等人提出的另一种方法 [1993] 是根据大量天空数据拟合解析模型。这些更简单的模型可以拟合计算开销大、精度高且多样化的数据，这些数据来自复杂模型（例如，Preetham 等人的模型 [1999] 拟合于 [Nishita 等人 1996]）、路径追踪器 [Hošek 和 Wilkie，2012、2013；Wilkie 等人 2021], 或 libRadtran 等物理模拟 [Emde 等人 2016] （Bruneton 在评估中使用了该方法 [Bruneton 2017]）。此类模型以精度为代价，构建轻量、灵活且快速的参数化模型，从而支持广泛的应用 [Bruneton 2017]。

2.2 合成云生成

参数化模型虽然通过有限且直观的一组参数提供了灵活性，但通常仅适用于晴朗、多雾和阴天天空。为纳入云等更复杂的大气形态，参数化模型通常会通过各种实现方式，辅以体积云渲染 [Kallweit 等人 2017] 和/或云模拟 [Bouthors 等人 2008] 。尽管这种组合方法灵活且具有照片级真实感，但可能耗费大量人力、计算成本高昂且难以配置 [Hill 等人 2020]。

2.3 学习式参数化模型

近来，研究者提出了利用深度学习进行光照估计，以及将天空拟合到光照模型的方法。Hold-Geoffroy 等人，2017 [; Zhang 等人，2019b] 等人的工作通过回归参数化光照模型的参数（[Hošek 和 Wilkie，2012；Lalonde和Matthews 2014], ），分别利用单张视场有限的 LDR 图像，实现对虚拟物体/场景的高动态范围重新照明。其他方法 [Hold-Geoffroy 等人，2019；Yu 等人，2021a，b] 则专注于学习照明模型本身。这些方法在照片重新照明方面具有很高的保真度，但无法获得照片级真实感纹理；其目标是更好地应对前文提到的挑战，实现更强的泛化能力。

最近，研究者提出了为参数化天空添加照片级真实感云层的方法。Satilmis 等人 [2022] 提出了一种方法，可根据用户控制的云层位置为 Hošek-Wilkie [2012] 参数化天空添加云层。这与我们的模型有所不同：该方法要求用户提供一个用于定位云纹理的遮罩，而我们希望云层能够自然定位，直接源于从参数化输入到真实世界的学习映射。SkyGAN [Mirbauer 等人 2022] 提出将布拉格天空模型 [2021] 拟合到真实世界的照片，从而能够重新生成带有大气形态的布拉格天空，但其动态范围有限，因此在渲染场景中还需额外使用虚拟太阳灯。据我们所知，LM-GAN 是首个能够为基于图像的照明生成参数化、照片级真实感、全天候高动态范围天空穹顶的模型。

3 方法

下面简要概述我们的模型，并讨论如何将 Lalonde-Matthews（LM）模型的参数拟合到 HDR 图像。在本研究中，我们利用了公开的拉瓦尔 *HDR* 天空数据集 [Lalonde 等人 2016]。

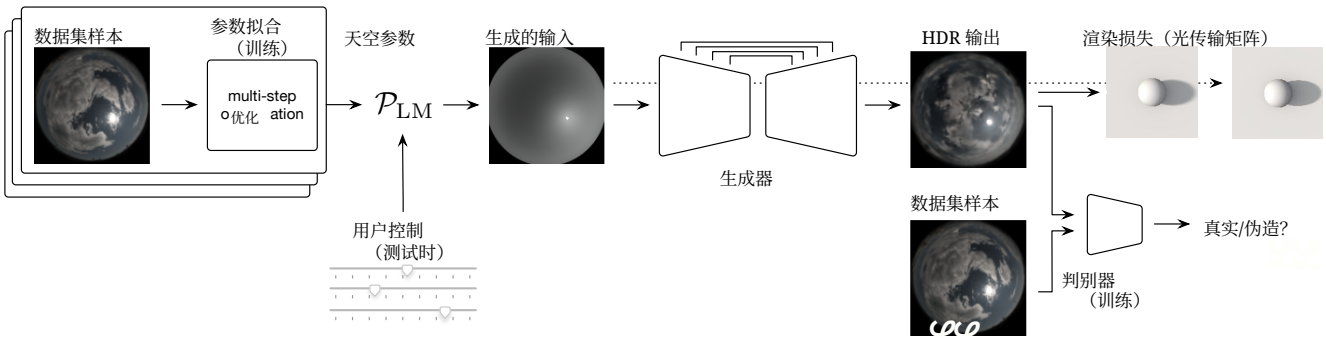

图 2. **我们的流程。**训练生成器，将参数化输入（通过对捕获的高动态范围天空拟合参数化模型得到）转换为照片级真实感

通过组合获得的风化高动态范围天空　　的风化高动态范围天空，并结合基于图块的判别器（生成对抗网络）损失、LPIPS（未显示）和可微渲染损失。

3.1 对真实天空进行参数化表示

以往研究（例如 [Hold-Geoffroy 等人，2017年；Mirbauer 等人 2022] ）使用了 Hošek-Wilkie 模型 [2012], ，而我们采用 LM [2014] 照明模型。该模型有 11 个参数，可用于近似室外照明，并能拟合真实的 HDR 天空。与传统的基于物理的模型相比，它的参数限制较少，因此已被证明非常适合基于学习的方法 [Lalonde 和 Matthews，2014；Zhang 等人，2019b]。

*Lalonde-Matthews（LM）模型。*LM模型是一个关于任意光照方向$\mathbf{l}$（以球坐标表示）的半球函数，可简洁地写成两个项之和：

$$f_{\mathrm{LM}}(\mathbf{l};\,\mathcal{P}_{\mathrm{LM}}) = f_{\mathrm{sun}}(\mathbf{l};\,\mathcal{P}_{\mathrm{sun}},\,\mathbf{l}_{\mathrm{sun}}) + f_{\mathrm{sky}}(\mathbf{l};\,\mathcal{P}_{\mathrm{sky}},\,\mathbf{l}_{\mathrm{sun}}) \qquad (1)$$

其中，$\mathbf{l}_{\mathrm{sun}} = [\theta_{\mathrm{sun}}\ \varphi_{\mathrm{sun}}]$ 是以球坐标表示的太阳角位置，而 P_* 表示各项对应的参数。式（1）中的天空项 f_{sky} 是 Preetham [1999] 天空模型f_{Pree}，以浑浊度 t 为参数，并与平均天空颜色$\mathbf{c}_{\mathrm{sky}} \in \mathbb{R}^3$逐通道相乘：

$$f_{\mathrm{sky}}(\mathbf{l};\,\mathcal{P}_{\mathrm{sky}},\,\mathbf{l}_{\mathrm{sun}}) = \mathbf{c}_{\mathrm{sky}}\ f_{\mathrm{Pree}}(\theta_{\mathrm{sun}},\,\gamma_{\mathrm{sun}},\,t) \qquad (2)$$

其中，γ_{sun} 是天空方向$\mathbf{l}$ 与太阳方向$\mathbf{l}_{\mathrm{sun}}$之间的夹角。式（1）中的太阳项$f_{\mathrm{sun}}$ 定义为：

$$f_{\mathrm{sun}}(\mathbf{l};\,\mathcal{P}_{\mathrm{sun}},\,\mathbf{l}_{\mathrm{sun}}) = \mathbf{c}_{\mathrm{sun}}\ \exp(-\beta\ \exp(-\kappa/\gamma_{\mathrm{sun}})) \qquad (3)$$

其中，(β, κ)控制太阳散射，而$\mathbf{c}_{\mathrm{sun}} \in \mathbb{R}^3$ 是平均太阳颜色。总而言之，LM模型使用以下11个参数表示HDR天空穹顶：

$$\mathcal{P}_{\mathrm{LM}} = \{\mathbf{c}_{\mathrm{sky}},\ t,\ \mathbf{c}_{\mathrm{sun}},\ \beta,\ \kappa,\ \mathbf{l}_{\mathrm{sun}}\} \qquad (4)$$

LM 拟合算法。 与 [Lalonde和Matthews 2014],类似，我们采用优化方案，将 LM 参数拟合到捕获的HDR半球天空。我们假设可以从捕获元数据（地理定位和时间戳）中获取太阳位置 $\mathbf{l}_{\text{太阳}}$，并通过简单的局部最大能量搜索（针对图像块，以处理阴天场景）进行微调。然后，我们将 $\mathbf{c}_{\text{太阳}}$ 和 $\mathbf{c}_{\text{天空}}$ 都初始化为目标天空图像的平均颜色。具体做法是遮挡太阳周围 30◦ 的圆形区域，这对晴天和阴天天空都足够适用。我们还排除天顶角超过 80◦ 的太阳，因为这些天空由于地理原因往往缺乏充足的日光。拟合通过以下四步策略实现：

(1) 通过粗网格搜索初始化散射参数 κ。在此步骤中，我们采用一个粗网格，其中包含 s_κ 个步长，范围为 $[\kappa_{min}, \kappa_{max}]$，并结合标准步长 S，分别用于 $\beta \in [\beta_{min}, \beta_{max}]$和 $t \in [t_{min}, t_{max}]$。我们采用两种损失：(a) L1平滑损失；用于衡量生成的 LM 天空与目标高动态范围图像之间的差异；(b) L1渲染损失；用于衡量生成的 LM 天空经预先计算的光传输矩阵 [Sloan等人 2002] 变换后，与由朗伯漫反射球体和地平面组成的场景之间的差异（见图2）。

(2) 通过细网格搜索确定散射参数 κ、β 和 t。使用相同的 L1 损失。在此步骤中，κ 初始化为上一步的最佳结果，现将 s_κ 步长缩放为 λ_κ，并在一个按比例缩小的范围内向两个方向扩展。参数 β 和 t 按之前的方式迭代。保存三个参数的最佳组合。

(3) 使用 Adam 优化器优化 ω_{sun} 和 ω_{sky} 参数 [Kingma 和 Ba 2015]，同时冻结散射参数 κ，β以及 t，共进行 n 次迭代。使用相同的 L1 损失，并在太阳或天空颜色衰减至零（或极端值）时，以及太阳或天空颜色既非近似灰度、红色也非蓝色时（后者仅适用于天空），加入固定的正则化惩罚项。

(4) 使用 Adam 优化器对除太阳位置以外的所有参数进行迭代微调，共训练 n 更多轮次。沿用步骤 3 中的正则化项和损失。有关可复现性以及常数和取值范围的详细信息，请参见第 3.3 节。

利用这一四步策略，我们已标注来自 *Laval HDR* 天空数据集 的超过 25,000 个天空。

3.2 生成照片级真实感天空

如图所示我们的生成流程以天空穹顶为输入（参见第 3.1 节），该穹顶由用户指定的参数或真实天空生成。随后，我们的模型会生成照片级真实感的风化天空，同时保留输入的 HDR 照明。

*保留 HDR 照明。*为保留动态范围，模型的输入经过预处理，压缩至 $[-1, 1]$

模型架构所偏好的区间。具体做法是：(1) 将输入天空图像分别除以其 99 百分位数 进行重新曝光；(2) 通过 $I\prime = \log_2(I+1)$进行色调映射；(3) 将输入移至 $[-1,1]$区间，并使用 $I\prime = 2I-1$进行偏移。生成后，反向执行此过程以恢复动态范围。通过图 fig. 4，我们展示了此过程能够保留输入照明的动态范围。

网络架构。该模型由一个 U-Net 组成 [Ronneberger 等人 2015] 采用固定更新初始化 [Zhang等人 2019a] 并使用 ReLU 激活。Dropout [Srivastava 等人 2014] 在训练和测试期间均于瓶颈层启用，以提高泛化能力 [Isola 等人 2017]。模型在每个下采样层都会将分辨率减半，并使特征数量加倍。对于输入 $s \times s$ 图像，它有($log_2(s) - 2$) 个下采样层，确保瓶颈层的分辨率为 4×4，并具有 $2s$ 个滤波器。训练数据通过 x 和y轴翻转及方位旋转进行增强，从而鼓励网络学习同一片天空的多种变化。

损失函数。 训练期间，网络结合了三种损失函数：基于图块的对抗损失 [Isola等人 2017], LPIPS感知损失 [Zhang等人 2018], 以及渲染损失。有关每种损失如何影响生成结果的更多详情，请参见第 4.3 节。

主要纹理损失是一个简单的 PatchGAN [Isola等人 2017] 损失，直接根据基于图块的判别器输出的图块特征向量计算均方误差，该判别器的感受野为 8×8 像素。判别器采用 ReLU 激活（最后一层使用 Sigmoid），并在整个网络中使用实例归一化。由于目标是学习通用的纹理和结构，因此输入判别器的每张图像都像上文一样进行了色调映射。

为了进一步促进细节和高频信息的建模，我们还采用了 LPIPS [Zhang等人 2018] 感知损失，该损失基于一个在 ImageNet [Simonyan和Zisserman 2015] 上训练的 VGG 网络 [Deng等人 2009]。据观察，这种损失有助于学习云纹理细节（见图 5）。与生成器一样，该网络接收的也是经过色调映射的图像。此损失的权重经过缩放，使其数值通常比 PatchGAN 损失小 10 倍，因此只有在网络学会模型的整体结构后，训练时才会关注它。

为确保保留光照，我们将生成器的输出转换回线性 RGB，并使用光传输矩阵在平面上渲染一个漫反射白色球体（如第 3.1节所示），再将其与由线性 LM 参数化输入照明的同一场景进行比较，以计算可微渲染的 L1 损失。该损失的权重设为 10 倍小于 LPIPS 损失，因此只有在视觉效果较为稳定时才会强调协调光照，否则可能出现 HDR 伪影。

3.3 实现细节

我们的实现使用 PyTorch，并基于 UNet FixUp [Griffithset al. 2022] 进行了调整，以适应我们的生成场景。光传输渲染引擎和 LM 渲染引擎，以及 LM 拟合算法，都是经过向量化并使用通用图形处理器的 PyTorch 脚本。模型一直训练到收敛（约 440个训练轮次），批量大小则选取为所使用训练 GPU 能够容纳的最大值。在单个 Titan X GPU 上， 128×128模型训练平均每个训练轮次耗时 15 分钟，并在批量大小为 32 时占用 11 GB 显存。对于拟合算法，我们分别采用了 (κ、 β、 t) 的搜索范围 $[0,1], [0,50], [2,20],$，这些范围是通过经验确定的，即寻找模型开始变得不连贯的点。我们的搜索使用了 $s_\kappa = \lambda_\kappa = 0.1$，其中 $S = 2$和 $n = 1000$。

4 实验

我们从天空外观和 HDR 光照保真度两方面，将本方法与最先进水平的方法进行比较。我们还评估了本方法的参数拟合效果与最先进的拟合方法相比如何。

4.1 方法

数据集。我们采用 Laval HDR 天空数据集 [Lalonde 等人 2016] 来评估所有方法，并从中抽取训练期间不可访问的测试集（参见第 3.1 节）。评估时，我们首先依据美国国家海洋和大气管理局天气预报描述 [海洋与大气管理局 2023], , 使用基于颜色的二值阈值法对测试集进行分组 [Heinle 等人 2010]。根据云层覆盖率，我们将测试集分类如下：天空中被云覆盖的比例为 0–1/8 的称为晴天（su）； 1/8–3/8 的为大部晴朗（ms）； 3/8–5/8 的为局部多云（pc）； 5/8–7/8 的为大部多云（mc）； 7/8–1 的为阴天（oc）。此外，由于颜色和光照配置不同，我们还将太阳位于地平线 20。范围内的天空单独归为日出/日落（ss）类别。为确保训练集和测试集不包含时间相邻的帧，测试集由完全不同的拍摄日期组成，这些日期在训练期间从未出现过。测试集中的每一天大致来自不同的月份，因此共有 2,580 个样本，与数据集中其余的 23,000 个样本完全分离。测试集中各类别的最终样本数为：晴天 565 个、大部晴朗 534 个、局部多云 380 个、大部多云 375 个、阴天 396 个、日出/日落 330 个。

度量指标。 为了评估天空模型的外观和多样性，我们采用 FID 度量指标 [Heusel 等人 2017] 来比较它们的外观分布。计算 FID 之前，先将天空重新曝光至其 99th 百分位数，再进行 $\gamma = 2.2$ 色调映射，最后将数值限制在 0 到 1之间。我们还采用 RMSE 度量指标及其尺度不变版本 si-RMSE [Grosse 等人 2009], , 并在生成的天空上进行计算。前者衡量天空中能量的绝对值，会惩罚强烈太阳值的缺失；后者则补偿强度不匹配，并侧重于正确的对比度。我们在使用预先计算的传输矩阵渲染的朗伯漫反射场景上计算 RMSE/si-RMSE 分数（参见第 3.1节）。

参数化模型。 我们首先考察三种参数化天空模型：太阳与天空组合模型 Hošek-Wilkie [2013]（使用 [Hold-Geoffroy 等人 2017]的算法拟合）；其扩展模型“布拉格天空模型” [Wilkie 等人 2021]（使用 [Mirbauer 等人 2022]的算法拟合）；以及 Lalonde-Matthews [2014]（使用我们定制的算法拟合，参见第 3.1节）。所有参数化模型都针对我们的高动态范围测试集进行了优化。

学习型模型。 我们还将其与深度天空模型 SkyNet [Hold-Geoffroy 等人 2019] 进行了比较，该模型与我们的模型使用相同的数据集进行训练；此外，还与当前最先进的神经天空模型 SkyGAN [Mir-bauer 等人 2022],进行了比较，该模型是我们根据相关信息重新实现的

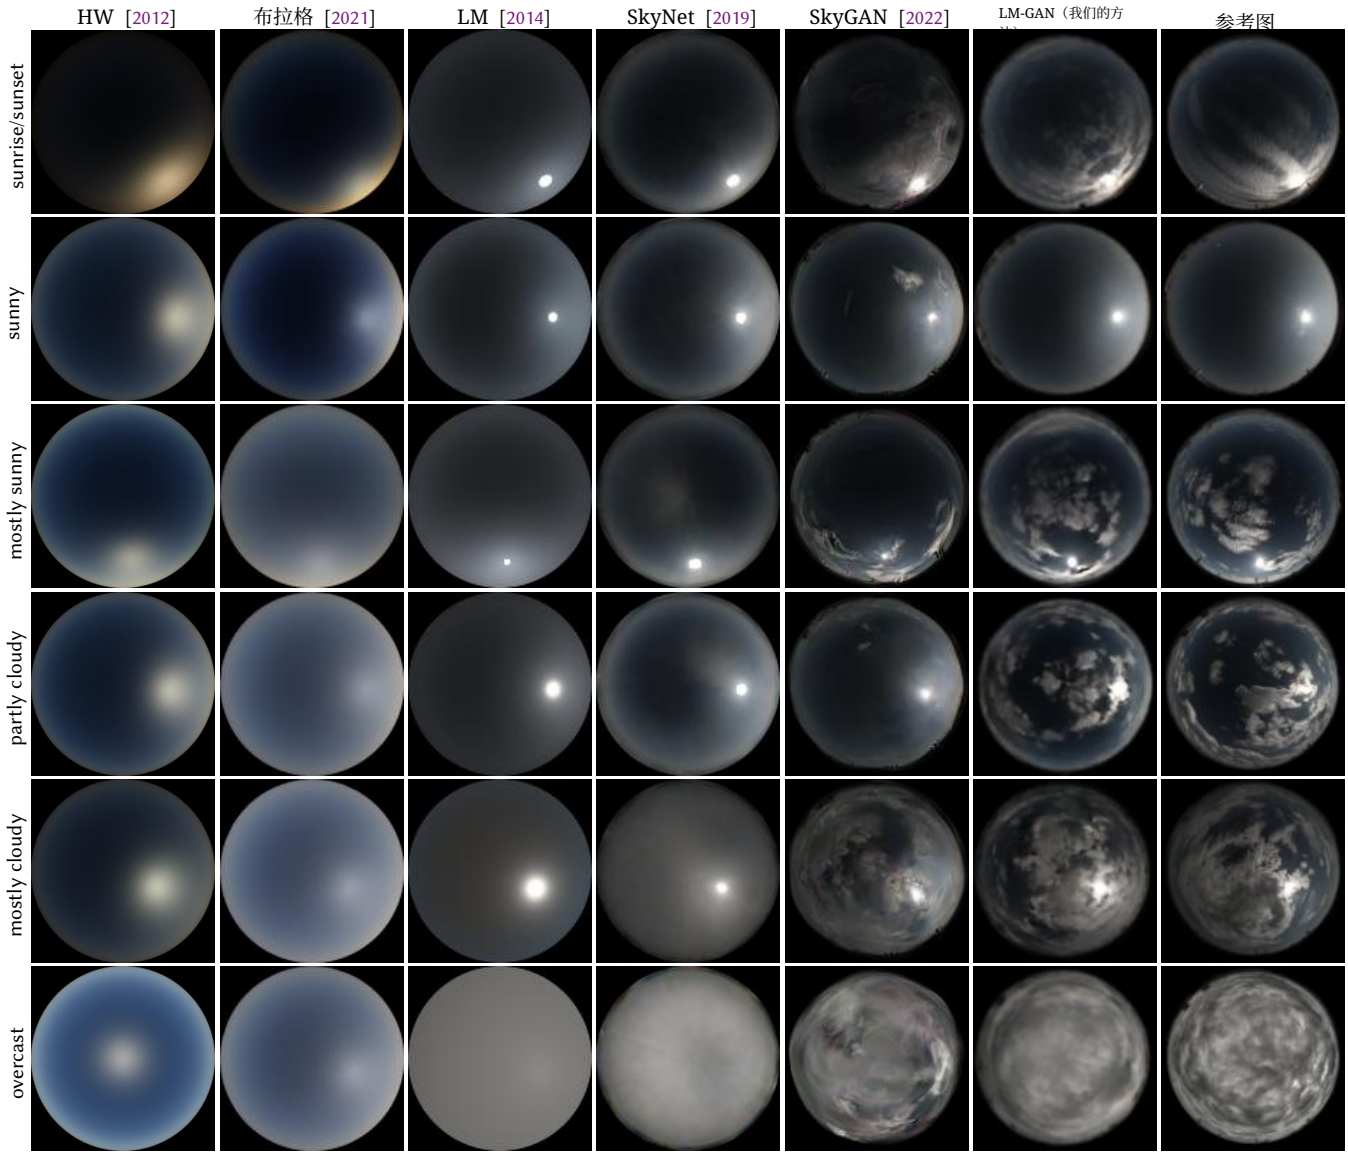

图 3. **不同天空光照模型的视觉比较**。虽然基于物理的参数化模型（[Hošek 和 Wilkie 2012], [Wilkie 等人 2021]）在物理上准确，但无法准确呈现具有多种大气条件的天空，例如有云的天空。LM [2014] 和 SkyNet [2019] 模型适用性更广，但生成的结果过于平滑。SkyGAN [2022] 生成的云不太真实。相比之下，我们的方法兼具参数化模型的灵活性和摄影参考图的照片级真实感。

这些信息来自论文，并且使用上述 Hošek-Wilkie 拟合作为输入，与我们的模型使用相同的数据集进行训练。

SkyGAN 基于 StyleGAN3 [Karras 等人 2021]，也能根据参数化输入生成逼真的天空。然而，SkyGAN 会生成一个残差，并将其 添加到参数化输入中。与 [Mirbauer 等人 2022], 的研究类似，我们也观察到，该模型无法保留输入中的高动态范围光照。

4.2 HDR 天空合成

定量评估。 我们首先在表1中，以天空角度格式的 HDR环境贴图测试集对所有技术进行比较。我们观察到，增加云层覆盖率会显著恶化参数化天空模型的 FID，其 FID 达到200以上。相比之下，我们的方法表现出始终如一的鲁棒性，在整个测试集分布上的数值低至 20，并且28 在最坏情况下为 38。46 总体而言，RMSE 度量指标呈现出不同的结果：随着云层覆盖率增加，误差反而降低，因为环境贴图中存在的

	模型	su	ms	pc	mc	oc	ss	all
FID	**HW** [2013]	142.83	200.17	208.81	202.53	175.36	188.08	175.29
	布拉格 [2021]	170.32	228.89	233.84	224.49	195.52	207.79	202.46
	LM [2014]	147.13	190.72	205.27	197.36	174.02	178.06	169.95
	SkyNet [2019]	126.24	187.22	209.72	214.07	190.65	167.61	165.83
	SkyGAN [2022]	40.95	38.94	46.27	55.12	71.23	73.96	34.89
	LM-GAN（我们的方法）	**29.57**	**28.03**	**29.15**	**30.38**	**38.59**	**38.46**	**20.28**
RMSE	**硬件** [2013]	29.02	19.74	12.78	5.75	2.89	7.89	14.61
	布拉格 [2021]	29.02	19.75	12.81	5.79	2.92	7.9	14.63
	LM [2014]	22.48	13.25	9.36	5.74	3.83	7.66	11.45
	SkyNet [2019]	26.62	18.24	12.79	6.27	**2.71**	7.84	13.82
	SkyGAN [2022]	28.98	19.72	12.77	5.73	2.86	7.86	14.59
	LM-GAN（我们的方法）	**21.71**	**12.56**	**8.70**	**4.97**	3.16	**7.18**	**10.76**
si-RMSE	**HW** [2013]	28.99	19.72	12.76	5.73	2.87	7.86	14.59
	布拉格 [2021]	29.02	19.74	12.78	5.75	2.89	7.89	14.62
	LM [2014]	20.18	11.43	7.50	3.31	1.43	6.59	9.43
	SkyNet [2019]	25.08	16.76	10.96	5.01	2.43	7.02	12.58
	SkyGAN [2022]	28.64	19.57	12.72	5.71	2.84	7.66	14.44
	LM-GAN（我们的方法）	**19.72**	**11.08**	**7.30**	**3.16**	**1.37**	**6.31**	**9.17**

表 1. **天空纹理误差**。 各列按照云量划分（参见第 4.1节），范围从晴天（su）到阴天（oc），以及日出/日落（ss）。“all”表示整个测试集上的度量指标平均值。

	模型	su	ms	pc	mc	oc	ss	all
RMSE (ref.)	**HW** [2013]	6417.78	4431.04	3138.49	2193.35	1898.95	1529.03	3591.46
	布拉格 [2021]	4767.83	3180.79	2348.25	1484.03	1248.14	1098.06	2596.64
	LM [2014]	**1163.16**	716.64	582.67	407.78	320.21	**120.11**	612.84
	SkyNet [2019]	2596.66	2236.56	2276.70	1562.40	970.81	995.53	1870.67
	SkyGAN [2022]	6235.02	4375.28	2959.59	1858.38	1432.77	1448.21	3382.92
	LM-GAN（我们的方法）	1175.01	**707.38**	**571.89**	**402.45**	**308.04**	125.21	**609.94**
si-RMSE (ref.)	**硬件** [2013]	2158.68	1591.31	1078.51	742.31	825.80	547。31	1265。88
	布拉格 [2021]	1958.56	1461.44	1150.64	918.86	895.20	509.38	1237.26
	LM [2014]	**158。29**	**113。75**	**107。58**	117。70	120.09	66.46	**118.12**
	SkyNet [2019]	311.97	284.94	238.47	196.44	144.37	177.05	235.80
	SkyGAN [2022]	1278.86	870.70	529.37	285.27	224.39	363.76	660.79
	LM-GAN（我们的方法）	171.05	121.78	112.15	**117.28**	**115.81**	**62.82**	122.06
RMSE	**SkyGAN** [2022]	506.93	526.74	606.77	742.99	1028.20	574.81	648.77
	LM-GAN（我们的方法）	234.16	**170.08**	**139.93**	**104.94**	**84.46**	**55.40**	**142.43**
si-RMSE	**SkyGAN** [2022]	319.59	329.63	360.12	381.01	484.37	313.51	361.10
	LM-GAN（我们的方法）	**95.53**	**78.62**	**69.46**	**58.94**	**53.88**	**42.03**	**69.65**

表 2。 **渲染场景中的光照误差**。 各列表示按照云量划分的数据子集（参见第 4.1 节），范围从晴天（su）到阴天（oc），以及日出/日落（ss）。“all”表示整个测试集的平均值。

能量会因云遮挡太阳而大幅减少。

我们还可以在表2中进一步看到能量对渲染结果的影响。与前一项实验类似，我们的方法取得了最先进的结果。有趣的是，在某些类别中，我们的方法甚至优于作为输入的 LM 环境贴图，展现了在更分散的照明配置下关联光照与纹理的优势。在此表中，还值得强调 LM模型的灵活性优势，它能够对真实全景图进行更精确的参数拟合。在表格的第一部分，所有度量指标均是根据相对于测试集中的参考真实环境贴图计算的。与参数化模型不同，SkyGAN 和我们的方法都无意于表示捕获的环境贴图，而是旨在保留其参数化输入中的外观和能量。因此，其参数化输入有限的表达能力构成了这些方法准确度的上限；我们认为，为了获得这些输入所提供的用户可编辑性，这样的代价很小。表2 的第二部分将各方法的渲染结果与其输入进行比较，以更忠实地展示这两种方法保留环境贴图能量的能力。对于更晴朗的天空，SkyGAN 展现出明显的改进，这可能归因于作为输入的参数化模型，以及重建输入这一任务；但这种改进在云量更多的天空中并不稳定。随着更多云层遮住太阳，我们的模型表现显著提升，再次表明它成功地将晴空参数化输入映射为全天候天空。

定性评估。 我们在图 3 中展示了参数化天空模型和学习型天空模型的视觉结果。对于所有云层覆盖率水平，我们的 LM-GAN 模型在生成云方面都能产生最逼真的纹理。虽然 SkyGAN 同样能够映射不同的云层覆盖率，但可以看到许多伪影，这与原始论文中展示的结果一致。在该图像中，使用 LM 模型作为输入的优势也显而易见：其多功能性使其能够通过改变晴空的颜色和太阳光衰减来模拟不同的云层覆盖率，几乎可以达到 SkyNet 自编码器的结果。我们进一步通过图 4 中展示的渲染结果评估天空模型的动态范围。在该实验中，我们使用每种方法的输出为三个具有不同反射特性的球体提供照明（镜面、朗伯、光泽），每个球体分别呈现环境的某个方面：纹理、能量，以及太阳区域周围的能量衰减。在这种情况下，我们 LM 拟合的稳健性变得非常明显；模型通过纹理对其进行视觉增强，这些纹理在反射中清晰可见。

	度量指标	LPIPS	LPIPS+生成对抗网络	完整模型（本文方法）
texture	**FID**	67.09	24.58	**20.28**
	RMSE	11.11	**10.44**	10.76
	尺度不变均方根误差	10.18	**9.04**	9.17
ref.	**RMSE**	1275.40	1094.30	**609.94**
	尺度不变均方根误差	602.24	261.41	**122.06**
input	**RMSE**	1215.82	911.99	**142.43**
	尺度不变均方根误差	617.76	261.34	**69.65**

表3。**消融误差**。在基于LPIPS的U-Net中加入GAN损失，显著提升了视觉质量。尺度不变光照精度也显著提高，表明纹理会影响对比度和图案。加入渲染损失有助于调节剩余的光照损失，同时提升视觉保真度。

4.3 消融研究

为确定各项损失对最终结果的贡献，我们使用相同的训练轮次训练另外两个模型：一个仅使用 LPIPS 损失进行训练 [Zhang等人。 2018], 另一个使用 LPIPS 和对抗性 PatchGAN 损失（不包含渲染损失）。所有

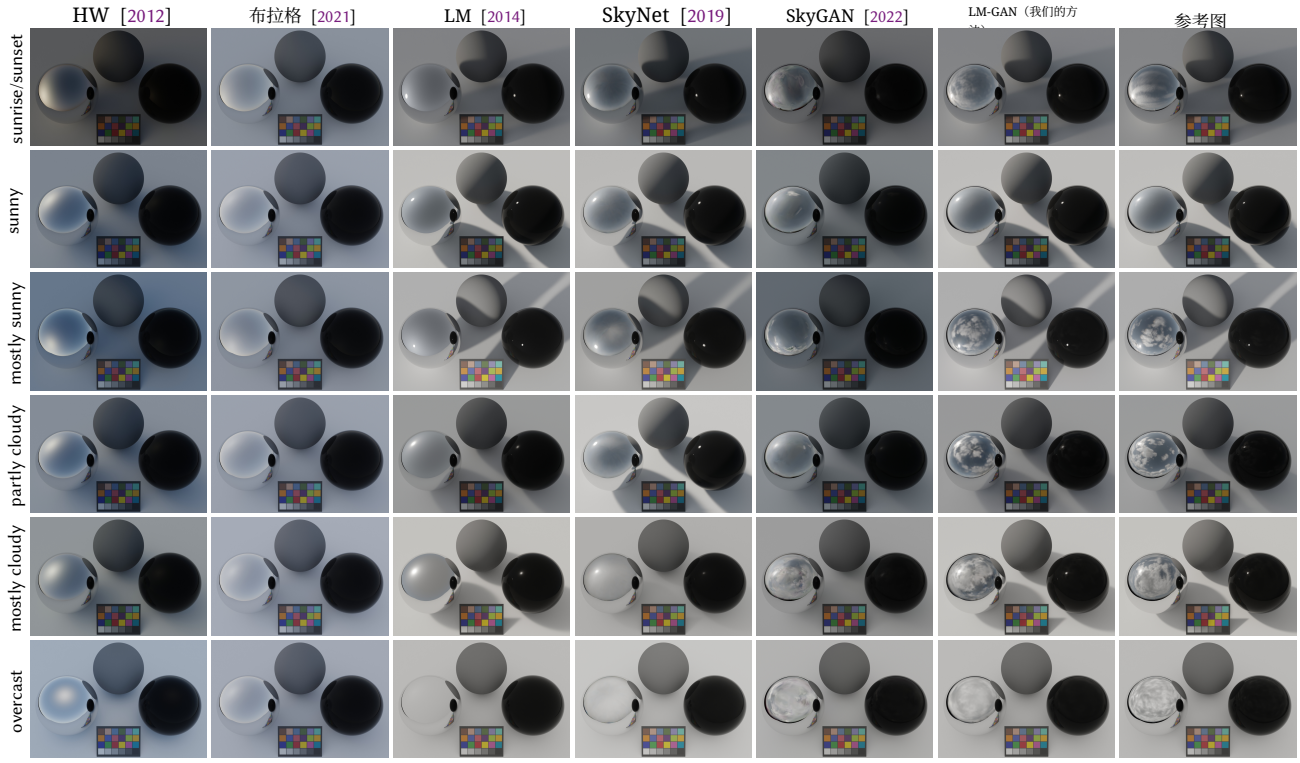

图 4. **使用不同光照模型渲染场景的视觉比较**。我们的方法在保持能量（明暗处理和阴影）恰当的同时，生成了高质量反射（光亮球体）。太阳可见时 HDR 能量的峰值可在黑色镜面球体中得到验证。

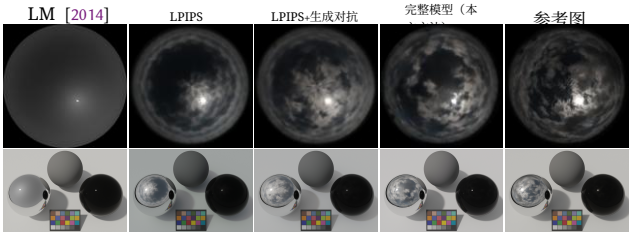

图5. **具有挑战性的天空上的消融示例**。使用 LPIPS 损失（第2列）时，模型能够学习高频云纹理，但无法学习整体结构。图块判别器（LPIPS+生成对抗网络）提升了结果（第3列），但高动态范围的上限仍然丢失。加入渲染损失（完整模型）（第4列）有助于关联照明（第1列）与纹理（第5列）。

模型均以 128 × 128 分辨率进行训练。图5 显示，LPIPS 模型能够在局部捕捉云层纹理，并像图案一样将其重复铺满图像，但无法同时生成具有照片级真实感和高动态范围的结果。结合 PatchGAN 足以获得良好的外观，但仍难以保留完整的高动态范围；通过恰当的纹理，仅改善了尺度不变结果（参见表。表。3）。加入渲染损失后，纹理和所需的光照属性进一步得到改善，并强化了所需的相关性。

5 结论

我们提出了 LM-GAN，这是一种通过学习生成照片级真实感天空环境贴图的 HDR 天空模型，可直接用于照亮虚拟场景和物体。我们的核心贡献在于，将天空和太阳的能量与纹理同时学习并整合到一个独立模型中，该模型直接使用实拍天空进行训练。我们的方法通过改进后的简洁 U-Net 架构实现，易于实现且运行高效。我们提出的模型以参数化天空模型为条件，使生成结果兼具表达能力和物理准确性。因此，该天空模型灵活且可由用户编辑，可用于多种应用。

尽管我们取得了最先进的结果，我们的方法仍存在一些局限。首先，由于生成式机器学习算法的局限以及当前可用硬件的限制，我们的方法无法提供与专业采集的高动态范围图像（通常为 12k × 24k）相同的分辨率。此外，尽管我们的模型具有若干可由用户编辑的特性，例如太阳位置和强度以及天空颜色，但我们提出的方法无法对云的外观和位置进行细粒度控制。

我们希望这项工作能为高质量的端到端环境建模铺平道路，捕捉自然天空的丰富多样性，最终在以照片级真实感为目标进行三维场景光照或图像编辑时，取代人工艺术家标注。

致谢

本研究得到了加拿大自然科学与工程研究理事会（NSERC）项目 ALLRP 557208-20、RGPIN-2020-04799 以及 Adobe 的资助。作者还感谢 Nvidia 捐赠 GPU；感谢 Tobias Rittig 和 Martin Mirbauer 在我们的数据集上运行他们的布拉格天空模型拟合代码；感谢 Jinsong Zhang、Henrique Weber 和 Aryan Garg 在代码的各个部分提供帮助；并感谢 Heitor Felix 参与有益的讨论。

参考文献

Antoine Bouthors、Fabrice Neyret、Nelson Max、Eric Bruneton 和 Cyril Crassin。2008年。云中的交互式多重各向异性散射。载于*2008*年交互式三维图形与游戏研讨会论文集。173–182。Eric Bruneton。2017年。对8种晴空模型的定性与定量评估。*IEEE*可视化与计算机图形学汇刊23, 12 (2017年), 2641–2655。Eric Bruneton 和 Fabrice Neyret。2008年。预计算大气散射。计算机图形论坛27, 4 (2008年), 1079–1086。Paul Debevec。1998年。将合成对象渲染到真实场景中：通过全局光照和高动态范围摄影，连接传统图形学与基于图像的图形学。载于*SIGGRAPH 98*论文集。189–198。邓嘉、董伟、Richard Socher、Li-Jia Li、李凯和李飞飞。2009年。ImageNet：大型层次化图像数据库。载于*IEEE* 计算机视觉与模式识别会议。248–255。Oskar Elek 和 Petr Kmoch。2010年。大型天然参与介质中的实时光谱散射。载于第*26*届计算机图形学春季会议论文集。77–84。C. Emde、R. Buras-Schnell、A. Kylling、B. Mayer、J. Gasteiger、U. Hamann、J. Kylling、B. Richter、C. Pause、T. Dowling 和 L. Bugliaro。2016年。用于辐射传输计算的 libRadtran 软件包（版本 2 9, 5 0 1 2016 1647 1672 . .）。地球科学模型开发( ), – 。David Griffiths、Tobias Ritschel 和 Julien Philip。2022年。OutCast：利用投射阴影对单幅图像进行重新照明。计算机图形论坛41, 2 (2022年), 179–193。Roger Grosse、Micah K Johnson、Edward H Adelson 和 William T Freeman。2009年。本征图像算法的真实值数据集与基准评估。载于*2009*年 *IEEE* 第*12*届国际计算机视觉会议。IEEE，2335–2342。Jörg Haber、Marcus Magnor 和 Hans-Peter Seidel。2005年。黄昏现象的基于物理的模拟。*ACM* 图形学汇刊 *(TOG)*24, 4 (2005年), 1353–1373。Anna Heinle、Andreas Macke 和 Anand Srivastav。2010年。全天空图像的自动云分类。大气测量技术3, 3 (2010年), 557–567。Martin Heusel、Hubert Ramsauer、Thomas Unterthiner、Bernhard Nessler 和 Sepp Hochreiter。2017年。采用双时间尺度更新规则训练的生成对抗网络收敛至局部纳什均衡。载于第*31*届神经信息处理系统国际会议论文集（长滩，加利福尼亚州，美国）*(NIPS'17)*。6629–6640。Stephen Hill、Stephen McAuley、Laurent Belcour、Will Earl、Niklas Harrysson、Sébastien Hillaire、Naty Hoffman、Lee Kerley、Jasmin Patry、Rob Pieké、Igor Skliar、Jonathan Stone、Pascal Barla、Mégane Bati 和 Iliyan Georgiev。2020年。理论与实践中的基于物理的着色。载于*ACM SIGGRAPH 2020* 课程。文章 11，共12页。Štěpán Hojdar。2019。利用神经网络生成逼真天空。(2019)。Yannick Hold-Geoffroy、Akshaya Athawale 和 Jean-François Lalonde。2019。用于单幅图像户外照明估计的深度天空建模。载于*IEEE/CVF* 计算机视觉与模式识别会议论文集。6927–6935。Yannick Hold-Geoffroy、Kalyan Sunkavalli、Sunil Hadap、Emiliano Gambaretto 和 Jean-François Lalonde。2017年。深度户外照明估计。载于*IEEE* 计算机视觉与模式识别会议论文集。7312–7321。Lukáš Hošek 和 Alexander Wilkie。2012年。全光谱天空穹顶辐亮度的解析模型。*ACM* 图形学汇刊 *(TOG)*31, 4 (2012年), 1–9。Lukáš Hošek 和 Alexander Wilkie。2013。为 Hošek-Wilkie 天空光模型添加太阳辐亮度函数。*IEEE* 计算机图形学与应用33, 3 (2013), 44–52。Phillip Isola、朱俊彦、周廷晖和Alexei A Efros。2017年。使用条件生成对抗网络进行图像到图像转换。载于*IEEE* 计算机视觉与模式识别会议论文集。1125–1134。Simon Kallweit、Thomas Müller、Brian McWilliams、Markus Gross 和 Jan Novák。2017年。深度散射：利用辐亮度预测神经网络渲染大气云。*ACM* 图形学汇刊（*SIGGRAPH Asia* 论文集）36, 6, 文章 231（2017年11月），共11页。Tero Karras、Miika Aittala、Samuli Laine、Erik Härkönen、Janne Hellsten、Jaakko Lehtinen 和 Timo Aila。2021年。无混叠生成对抗网络。载于神经信息处理系统进展。Joseph T. Kider、Daniel Knowlton、Jeremy Newlin、Yining Karl Li 和 Donald P. Greenberg。2014年。太阳与天空穹顶照明实验比较框架。*ACM* 图形学汇刊33, 6, 文章 180（2014年11月），共12页。Diederik P. Kingma 和 Jimmy Ba。2015年。Adam：一种随机优化方法。载于第三届国际表征学习会议，*ICLR*。JF Lalonde、LP Asselin、J Becirovski、Y Hold-Geoffroy、M Garon、MA Gardner 和 J Zhang。2016年。Laval HDR 天空数据库。Jean-François Lalonde 和 Iain Matthews。2014年。户外图像集中的照明估计。载于2014年第二届国际三维视觉会议，第1卷。IEEE，131–138。Martin Mirbauer、Tobias Rittig、Tomáš Iser、Jaroslav Krivánek 和 Elena Šikudová。2022年。SkyGAN：面向基于图像照明的逼真云图像生成。载于 Eurographics 渲染研讨会。欧洲图形学协会。Parry Moon。1940年。工程应用的建议标准太阳辐射曲线。富兰克林研究所期刊 230, 5 (1940年), 583–617。Tomoyuki Nishita、Yoshinori Dobashi 和 Eihachiro Nakamae。1996年。考虑多重各向异性散射与天空光的云显示。载于第23届计算机图形学与交互技术年度会议论文集。379–386。Tomoyuki Nishita、Takao Sirai、Katsumi Tadamura 和 Eihachiro Nakamae。1993年。考虑大气散射的地球显示。载于第20届计算机图形学与交互技术年度会议论文集。175–182。美国国家海洋和大气管理局。2023年。预报术语。https: // www.weather.gov/bgm/forecast_terms Sean O'Neil。2005年。精确的大气散射。GPU Gems 2 (2005年), 253–268。Richard Perez、Robert Seals 和 Joseph Michalsky。1993年。天空亮度分布全天候模型——初步配置与验证。太阳能 50, 3 1993 235 245 ( ), – 。Arcot J Preetham、Peter Shirley 和 Brian Smits。1999年。实用的日光解析模型。载于第26届计算机图形学与交互技术年度会议论文集。91–100。Erik Reinhard、Wolfgang Heidrich、Paul Debevec、Sumanta Pattanaik、Greg Ward 和 Karol Myszkowski。2010年。高动态范围成像：采集、显示与基于图像的照明。Morgan Kaufmann。Olaf Ronneberger、Philipp Fischer 和 Thomas Brox。2015年。U-net：用于生物医学图像分割的卷积网络。载于医学图像计算与计算机辅助干预国际会议。Springer，234–241。Pinar Satilmis、Demetris Marnerides、Kurt Debattista 和 Thomas Bashford-Rogers。2022年。云照明深度合成。IEEE 计算机图形学与应用 (2022年)。Karen Simonyan 和 Andrew Zisserman。2015年。用于大规模图像识别的超深卷积网络。载于第三届国际表征学习会议，ICLR。Peter-Pike Sloan、Jan Kautz 和 John Snyder。2002年。用于动态低频照明环境实时渲染的预计算辐射传输。载于第29届计算机图形学与交互技术年度会议论文集。527–536。Nitish Srivastava、Geoffrey Hinton、Alex Krizhevsky、Ilya Sutskever 和 Ruslan Salakhutdinov。2014年。Dropout：防止神经网络过拟合的简易方法。机器学习研究期刊 15, 1 (2014年), 1929–1958。Jessi Stumpfel、Andrew Jones、Andreas Wenger、Chris Tchou、Tim Hawkins 和 Paul Debevec。2006年。太阳与天空的直接高动态范围捕获。载于ACM SIGGRAPH 2006 课程。5–es。Petr Vévoda、Tom Bashford-Rogers、M Kolárová 和 Alexander Wilkie。2022年。宽光谱范围天空辐亮度模型。(2022)。Alexander Wilkie、Petr Vevoda、Thomas Bashford-Rogers、Lukáš Hošek、Tomáš Iser、Monika Kolářová、Tobias Rittig 和 Jaroslav Křivánek。2021年。用于真实大气的拟合辐亮度与衰减模型。ACM 图形学汇刊 (TOG) 40, 4 (2021年), 1–14。Piaopiao Yu、Jie Guo、Fan Huang、Cheng Zhou、Hongwei Che、Xiao Ling 和 Yanwen Guo。2021a。用于户外照明估计与编辑的分层解耦表征学习。载于IEEE/CVF 国际计算机视觉会议论文集。15313–15322。Piaopiao Yu、Jie Guo、Longhai Wu、Cheng Zhou、Mengtian Li、Chenchen Wang 和 Yanwen Guo。2021b。用于全天候户外照明估计的双重注意力自编码器。中国科学：信息科学 64 (2021年)。Hongyi Zhang、Yann N Dauphin 和 Tengyu Ma。2019a。Fixup 初始化：无需归一化的残差学习。arXiv 预印本 arXiv:1901.09321 (2019)。Jinsong Zhang、Kalyan Sunkavalli、Yannick Hold-Geoffroy、Sunil Hadap、Jonathan Eisenman 和 Jean-François Lalonde。2019b。全天候深度户外照明估计。载于IEEE/CVF 计算机视觉与模式识别会议论文集。10158–10166。Richard Zhang、Phillip Isola、Alexei A Efros、Eli Shechtman 和 Oliver Wang。2018年。深度特征作为感知度量的惊人效能。载于IEEE 计算机视觉与模式识别会议论文集。586–595。