arXiv:2611.33042v1 [cs.CV] 24 Nov 2026

SPECTRIFY：使用计算机图形学进行高光谱图像生成的框架

Yasin Mamedov[1,2] Daniil Vladimirov[1,2,3] Sofiia Dorogova[1,2]Bakhtiyar Khalfin[1,2] Egor Ershov[1,2,3]1MIRAI，莫斯科，俄罗斯 2颜色重现与合成研究所，莫斯科，俄罗斯3AXXX，莫斯科，俄罗斯

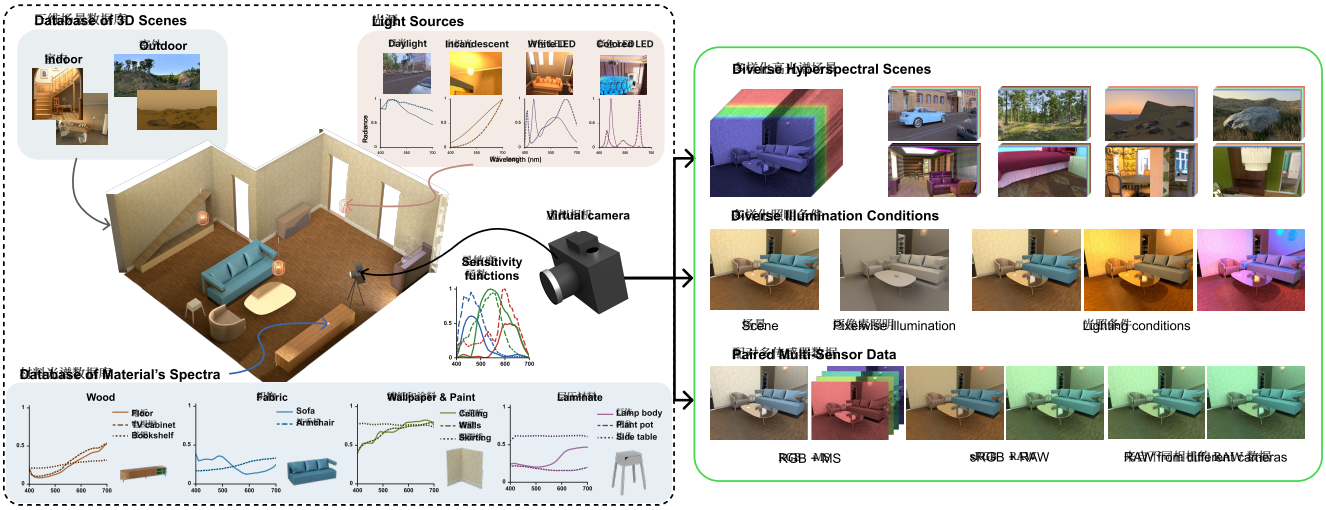

图 1。**SPECTRIFY 概览**。SPECTRIFY 将现有的室内和室外三维场景渲染为高光谱图像。每个物体部件都会从我们的库中获取其材料类别对应的实测反射光谱（左下），每盏灯和天空则会获取相应的发射光谱，例如日光、白炽光或 LED 灯光（顶部）。路径追踪用于渲染场景，将生成的高光谱图像通过相机的光谱灵敏度进行投影，即可得到该相机的 RAW 图像。因此，光谱渲染能够为众多应用合成训练数据，包括高光谱图像、逐像素照明图，以及不同传感器的对齐图像（右侧）。

摘要

高光谱图像（*HSI*）记录每个像素处的完整光谱，因此，将 *HSI* 投影到相机的光谱灵敏度上，即可得到该相机的 *RAW* 图像；单幅 *HSI* 也可为高光谱重建和相机成像管线方法提供训练数据。然而，真实高光谱图像采集缓慢且成本高昂，规模最大的数据集也仅包含约 *1,000* 幅图像。高层视觉通常会用从三维场景渲染的图像来替代稀缺的真实数据。但低层任务需要物理上准确的光谱，这要求对场景中的每种材料都使用测量所得的光谱进行光谱渲染；现有的光谱渲染仅涵盖少数几个场景，而且大多采用简化的成像模型。我们提出

SPECTRIFY，这是一个将三维场景数据集转换为高光谱图像的框架，并配套提供一个反射光谱库，其中的光谱按材料标注，汇编自近距离高光谱数据集和分光光度计测量值。在SPECTRIFY中，光谱随材料而定：每个物体都会根据其材料类别获得一个基于物理的光学模型，以及测量所得的反射光谱或光学常数；每盏灯都配有与其类型对应的发射光谱，天空则采用建模得到的日光光谱；*Mitsuba 3* 会按波长对每个场景的完整光传输进行路径追踪。我们展示了，仅使用我们合成的高光谱图像训练的高光谱重建网络，能够泛化到未见过的真实数据集

其网络在大多数测试集上优于在最大规模真实值高光谱图像数据集上训练的网络，并且，与仅按颜色分配光谱相比，按材料类别分配光谱能够提升这种迁移效果

在每个测试集上均是如此。从我们的高光谱图像投影得到的 *RAW* 图像同样可作为颜色恒常性的训练数据，其表现与现有的合成 *RAW* 生成器相当。我们发布了 *4,500* 张渲染的高光谱图像、SPECTRIFY 的代码及其带材料标签的反射光谱库。

1. 引言

学习型低层视觉方法需要大量训练集，而对于处理 RAW 图像的方法，这些训练集与特定相机绑定。相机记录的 RAW 值由其光学系统决定，即镜头、滤光片和传感器；它们共同形成的光谱响应由光谱灵敏度函数（SSFs）描述。因此，光学系统不同的相机具有不同的 SSFs，对于相同场景和照明条件，也会记录不同的 RAW 值 [53], , 所以在一台相机的数据上训练的模型迁移到另一台相机时，性能会下降。因此，必须为每台相机收集训练数据：每有一台新设备，就要用它重新拍摄相同的场景 [36]。手机相机每年都会更新，因此每推出一款新机型，都必须重复这一数据采集过程。

为避免针对每台相机重新采集数据，先前的工作通过反转图像信号处理（ISP）处理流程，从现有 sRGB 图像合成 RAW 训练数据，这种方法称为反处理 [13, 53]。它通过简单的参数化操作撤销 ISP 的每个步骤，将 sRGB 图像还原到目标相机的线性 RAW 空间。这些逆操作假设处理流程单一且已知，但真实的 sRGB 图像经过了多样且未知的照片后期处理，因此这种反转无法可靠地恢复场景参考线性信号 [36]。RawGen [36]则通过扩散模型学习这种映射，将 sRGB 图像或根据文本提示生成的图像转换为线性 CIE XYZ，再由校准矩阵转换到相机的 RAW 空间。然而，扩散先验可能会幻觉出内容 [38, 49], , 而且仅凭三个通道无法解决同色异谱问题：在 XYZ 中看起来相同的光谱，对相机而言可能有所不同 [34]。

高光谱图像提供了更可控的传感器数据源。高光谱图像保留了场景中的波长分辨光，因此通过任意相机的光谱灵敏度函数进行投影，就能模拟该相机的 RAW 图像 [34, 59], , 而一幅高光谱图像便可适用于所有光谱灵敏度函数已知的传感器 [35]。然而，真实的高光谱图像比 RAW 数据还要稀缺 [5–7, 18, 21, 28, 43, 50, 64, 68]：扫描式高光谱相机需要拍摄静态场景，每次采集可能需要几十秒到几分钟 [17, 37]。ARAD 1K [7], 是规模最大的自然场景数据集之一，也是光谱重建的标准基准，其中约有一千张图像，对于现代学习方法而言，作为训练集规模仍然偏小 [27, 65]。由于高光谱采集成本高昂，此类数据集通常由单台相机在一个地区拍摄，因此涵盖的内容和光照范围都很有限。

光谱渲染可以消除这一瓶颈。高层视觉已经依赖带有精确逐像素标签的渲染数据集 [51, 52, 63, 67]。逐波长追踪光线的基于物理的渲染器（例如 Mitsuba 3 [33], ）同样可以生成任意三维场景的高光谱图像，并呈现光谱着色、相互反射和混合照明 [31]。这类渲染器所需、而三维场景数据集所缺少的，是每种材料、纹理和光源的光谱。Graphics2RAW [53]提到，光谱渲染是合成 RAW 图像的另一种方法，但认为这种方法复杂得多，因为它需要整个场景的光谱以及目标相机的光谱灵敏度函数（SSFs）。因此，渲染得到的合成高光谱图像数据集规模仍然很小，光谱仅根据有限颜色集分配 [31]，或在少数专门构建的场景中按材料分配 [41, 54]。然而，仅按颜色分配光谱并不足够，因为相同颜色的表面可能具有不同的光谱 [24],，此时颜色匹配可能会选中错误材料的光谱。

在本文中，我们提出了 SPECTRIFY，这是一个通过对现有三维场景数据集进行基于物理的光谱渲染来生成高光谱图像的框架。它读取三维资产中存储的材料信息，并利用这些信息从我们编制的大型带材质标签的库中选择实测反射光谱，因此无需手动指定光谱，也无需仅根据颜色推断反射率。灯具和天空会获得物理上合理的发射光谱，光谱路径追踪则将每个场景渲染为高光谱图像，并据此生成任意已知光谱灵敏度函数相机的对齐 RAW 图像（图1）。在该数据上训练的模型能够迁移到真实图像上的两个下游任务：高光谱重建和颜色恒常性。

总而言之，我们的贡献如下：

- SPECTRIFY：一个通过基于物理的光谱渲染将现有三维场景数据集转换为高光谱图像的框架，并利用材料类别分配光学模型和选择实测反射光谱。
- 对渲染数据在高光谱重建和基于 RAW 图像的颜色恒常性任务上的评估。对于高光谱重建，在我们的数据上训练的模型对未见过的真实数据集具有更好的泛化能力，优于在先前合成数据上训练的模型；在大多数测试集上，其表现也优于在最大规模真实高光谱图像数据集上训练的模型，并且按材料类别分配光谱能够改善这种迁移。对于颜色恒常性，由我们的高光谱图像投影得到的 RAW 图像与现有合成 RAW 生成器的表现相当。
- 发布了使用 SPECTRIFY 渲染的4,500幅室内和室外场景高光谱图像，以及 SPECTRIFY 的代码和其带材料标签的反射光谱库。

2. 相关工作

合成数据生成器 大多数用于低层视觉的合成训练数据都源自现有的 sRGB 图像。UPI [13] 通过逆转 ISP 流水线，将 sRGB 图像转换为 RAW；Graphics2RAW [53] 则利用相机的 DNG 元数据，将图形图像映射到特定相机的 RAW 空间。Buzzelli 等人。 [14]将相同的思路应用于光谱，用来自 Munsell [45]或 RidiQulous [48]等集合的最相似反射率替换每个 sRGB 像素。这些方法假设存在一个已知的照片后期处理流程；Raw-Gen [36]通过训练扩散模型，将同一场景经过不同照片后期处理得到的 sRGB 版本映射到一幅线性 CIE XYZ 图像，从而消除了这一假设。然而，所有这些方法都从现有图像的三个通道中推断 RAW 值或光谱。

渲染 3D 场景数据集 [51] 避免了对现有图像的依赖，并提供多样的真实标注 [20],，但为每个数据集准备光谱渲染所需的光谱十分耗时。以往的光谱生成器因此要么不考虑材料而直接选取光谱，要么只在少数场景中为每种材料分配光谱。MIST [31] 从少量实测光谱中，为每种颜色选取色度最接近的光谱。HyViD [54]从高光谱数据集 [5], 中手动裁剪纹理；而在 SWR [41]中，编码代理构建了少数几个世界，其光谱取自带有材料标签的 ECOSTRESS [44]和 USGS [39] 光谱库。SPECTRIFY 会自动为每个表面生成与其材料对应的光谱，因此可以转换整个 3D 场景数据集，而不只是少数几个场景。

光谱渲染 大多数渲染引擎旨在生成视觉上逼真的图像，并在三刺激值颜色空间中计算光传输；这种方法通过三通道值的乘积近似光谱乘积，因此无法在所有光源与材料组合下实现物理精确 [56, 57]。基于物理的引擎 PBRT [46],ART [61], Hydra [25], 和 Mitsuba 3 [33]则可以在采样波长处追踪光线，并输出光谱辐亮度。这些引擎能够求解光传输，但将材料和光源的光谱留给用户指定。我们使用 Mitsuba 3，因为它的所有材质模型都支持光谱渲染，而且其 Python API 允许我们通过代码构建场景。

反射率库 为颜色研究、同色异谱研究和遥感收集了实测反射光谱。颜色研究领域的收集库规模从 Barnard 等人的 1,995 个表面光谱等人 [8], 包括孟塞尔色片 [45], 到 Zhang等人 [66] 为研究同色异谱失配而收集的 2,500 万个不同反射率，以及 RidiQulous [48],的 4,300 万个光谱（另有 700 万和 11.4 万个光谱的精简版本）。这些收集库不会按材料标注其光谱，因此只能根据颜色从中选取光谱。USGS [39]和 ECOSTRESS [44] 按材料标注其光谱，SOCS [55] 则按物体类型标注，但这些库规模较小，且涵盖的材质类别很少。现有库要么规模庞大，要么按材料标注，但无法兼具二者。我们的库既规模庞大，又按材料标注。

3. SPECTRIFY 框架

SPECTRIFY 接收一个三维场景，其中包含物体的排列与纹理，以及光源的布置；随后为每个物体赋予一种光谱材料，并为每个光源赋予一个发射光谱。每个物体部件的材料类别取决于其所属的物体。该类别决定部件所采用的光学模型，以及可供其接收的实测光谱库；纹理则从该库中选择光谱。

图 2 展示了该处理流程。我们首先编制一个按材料类别标注的实测反射光谱库（第3.1节）。然后，根据三维场景中的物体名称和材料名称确定材料类别并分配光学模型，同时为场景中的每个光源赋予一个发射光谱（第 3.2节）。接着，每个表面从其所属类别中获取与其源颜色匹配的反射光谱（第 3.3节）。最后，Mitsuba 3 通过光谱路径追踪渲染该场景（第 3.4节）。

3.1. 带材料标签的反射光谱库

每个材料类别都需要足够多的带标签光谱，以覆盖其在三维场景中呈现的颜色。近距离高光谱图像可以提供大量此类数据，但大多没有标签；而分光光度计测量值虽然带有标签，却数量较少，因此我们将两者结合使用：从 70 个数据集中获取约 16,600 张近距离高光谱图像和 2.9 万条分光光度计测量值。我们从现有的带材料标签的数据集中选取了 63 个材料类别 [1, 2, 11, 58]。分光光度计测量值和带注释的高光谱数据集自带标签，我们将这些标签映射到上述类别。对于无注释的高光谱图像，我们先将其渲染为 RGB 图像，再使用 Segment Anything 模型 3 [16], , 并将类别名称作为文本提示进行分割。每张高光谱图像中的每个带标签像素以及每条测量值都对应一条光谱，总计约 3.7 亿条。所有光谱都经过重采样，转换为 31 个渲染波段（第 3.4 节）。光谱以绝对反射率形式存储在 $[0, 1]$, 中，未归一化至单位峰值，因此材料既保留了其亮度，也保留了其光谱形状。库的统计信息和源数据集列表见第 A 节。

3.2. 材料与光照分配

此步骤将源场景中的物体和灯具转换为用于光谱渲染的材料和光源：每个物体部件都会被赋予一个材料类别，以确定其光学模型；每盏灯都会被赋予一个发射光谱。我们将其应用于 3D-FRONT [26]室内场景，以及使用第三方资源集合 [1, 2]构建的城市场景和自然场景。

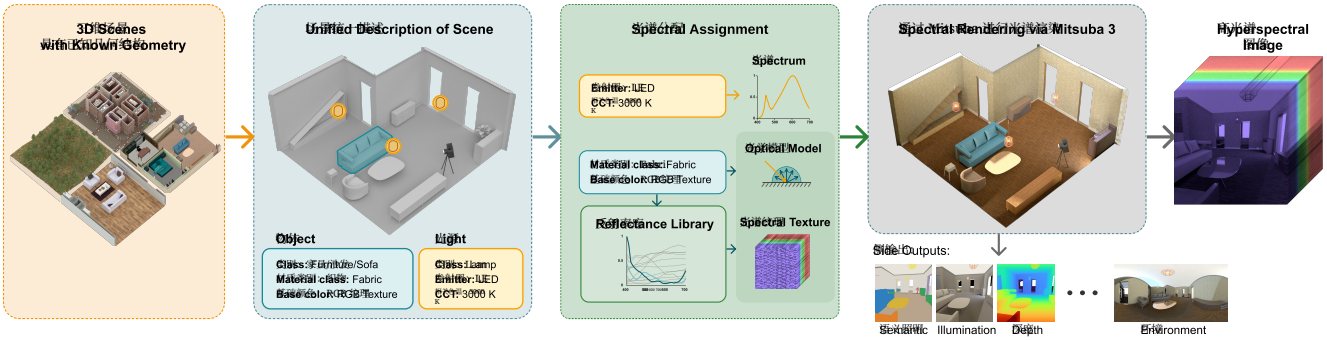

图 2. SPECTRIFY 处理流程。 三维场景被读取并转换为对其中物体和光源的描述。每个物体都会被分配一个材料类别，该类别决定其光学模型以及可供其选用的光谱库范围，而物体的纹理颜色则决定从该范围内选取哪些光谱。每个光源都会被分配一个发射光谱，随后 Mitsuba 3 通过光谱路径追踪渲染出一幅 31 波段高光谱图像。

材料类别 物体可能由多个具有不同材料的部件组成，例如带有木制框架和织物座椅的椅子，因此每个部件都会获得自己的类别。该类别通过一个映射表确定：映射表根据每个数据集中的材料名称和物体名称，将其对应到我们的类别。当名称无法提供类别信息时，则根据物体类别的材料先验分布进行采样；例如，一把椅子有 0.5 的概率为木材，0.3 的概率为织物，0.2 的概率为金属。

光学模型 该类别还决定 BSDF 模型，因为表面如何散射光取决于其材质。大多数类别采用粗糙涂层模型，即在漫反射基底上覆盖介电涂层；而哑光类别（例如，灰泥、织物）则采用漫反射模型。在这两种模型中，测得的反射光谱决定漫反射分量；对于涂层模型，镜面反射则仅由涂层的折射率决定。金属采用粗糙导体模型，其波长相关折射率和消光系数取自对 39 种金属的测量 [47],，因此其颜色来源于测得的光学常数，而非反射光谱。对于闭合网格，透明类别采用粗糙介电体；对于开放网格，则采用薄介电体，其标量折射率取自测量值或由类别设定。

光源 我们使用源场景中的灯具，并为每盏灯指定一种灯具类型：白色和有色 LED、荧光灯、白炽光、卤素灯或高压放电灯。白色 LED 的相关色温范围为 2700 至 7000 K。有色 LED 灯具采用窄带 LED 芯片的实测光谱 [12]。通过流明法 [30]，根据房间类型选择目标照度，并据此确定灯具功率。日光数据取自光谱太阳与天空辐亮度图目录；这些图由 libRadtran [22]针对不同太阳位置和大气条件（包括气溶胶与云）计算得出。

3.3. 从 RGB 生成光谱纹理

纹理承载着三维场景中的大量视觉细节，例如木纹、织物图案和印刷图案，因此我们将每张 RGB 纹理转换为光谱纹理，而不是为表面指定单一光谱。转换需满足两个要求：每个纹素的光谱均由该表面材料类别的实测光谱构成，并且保留纹素之间的颜色差异，例如渐变和图案。我们分三步为每个纹素赋予该材料实测光谱的混合结果：

(i) 计算该类别的光谱库在 D65 光源下的 CIE XYZ 颜色，并通过 Delaunay 三角剖分将其划分为四面体；(ii) 找到包含纹理元素颜色的四面体，并将该颜色表示为其四个顶点颜色的加权和，权重非负且总和为一；(iii) 为该纹素赋予对应四个顶点光谱的相同加权和。

光谱加权和的颜色等于其颜色的加权和，因此纹素会保留其颜色，而其光谱仅由其材料的真实光谱组成。混合权重也会随颜色连续变化，因此颜色相近的纹素（例如沿木纹分布的相邻纹素）会获得相似的光谱，从而保留渐变和图案。对于材料在我们的测量中从未呈现过的纹素颜色（例如木材上的饱和蓝色），它位于所有四面体之外，因此会被移至最近的四面体中；这保留了材料特性，但会牺牲一定的颜色准确度。纹理在场景光源下的外观由这些光谱决定，而非由 RGB 值决定。

3.4. 渲染

对于非自发光表面点 $\mathbf{x}$，朝向相机的光谱辐亮度为

$$L_o(\mathbf{x}, \omega_o, \lambda) = \int f_s(\mathbf{x}, \omega_i, \omega_o, \lambda)\, L_i(\mathbf{x}, \omega_i, \lambda)\, |\cos\theta_i|\, \mathrm{d}\omega_i, \tag{1}$$

其中 L_i 是来自方向ω_i的入射光谱辐亮度，ω_o 是观察方向，而 θ_i 是ω_i 与表面法线之间的夹角。双向散射分布函数（BSDF）f_s 是第 3.2节中指定给材料类别的模型，其中每个波长对应的光谱反射率或测得的光学常数作为输入。由于积分是在每个波长下计算的，因此有色表面之间的相互反射，以及灯具与日光的混合效果，在光谱上都是准确的。

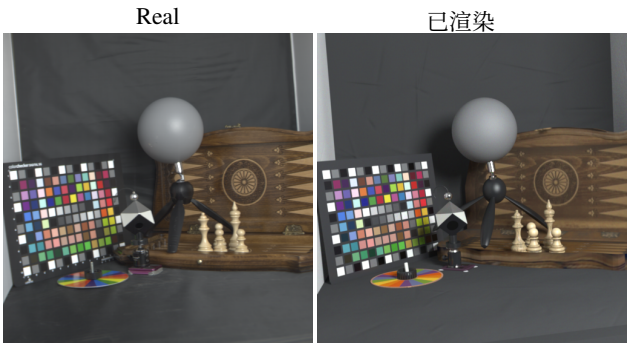

图3. **真实场景及其渲染结果**。桌面场景的照片，其中包括一张色卡、一个灰色球体和若干木质物体（左）；以及我们对其三维模型的渲染结果，光谱由人工指定（右）。

我们使用 Mit- suba 3 [33] 的光谱路径追踪器对其进行评估，采用库中的 31 个波段，范围为 400 至 700 nm，步长为 10 nm；分辨率为 512×512 像素，与广泛使用的 Specim IQ 高光谱相机 [10]的分辨率相同。室内场景的渲染采样数为每像素 10,240 次，室外场景为每像素 1024 次；在一块 NVIDIA A100 GPU 上渲染每个场景约需 3 分钟，GPU显存约为 15 GB。

SPECTRIFY 还可以输出语义标签、深度、环境图和照明图。图3 展示了一幅真实桌面场景的照片及其三维模型的渲染结果，我们为该模型手动指定了光谱；图4展示了使用 SPECTRIFY 渲染的代表性场景。

4. 实验

我们在两个以不同方式使用我们渲染的高光谱图像的下游任务上评估 SPECTRIFY。在高光谱重建中，网络从 RAW 图像恢复高光谱图像，因此高光谱图像既作为目标，也在经相机光谱灵敏度函数投影后作为输入；该任务检验的是渲染光谱本身。在颜色恒常性任务中，网络从 RAW 图像估计场景光源，因此只使用光谱的投影。两个任务均使用同一组 4,500 张渲染的高光谱图像，并采用相同的训练集、验证集和测试集划分。在一个数据集上训练的高光谱重建网络难以泛化到其他数据集，因为每个数据集涵盖的场景很少 [27]。因此，我们测试模型对训练期间未见的四个真实数据集的泛化能力，并将我们的方法与真实数据以及 Buzzelli 等人的 7,022 张合成高光谱图像进行比较。 [14]，我们还通过将基于材料的光谱分配替换为仅按颜色赋值，来衡量前者的贡献。对于颜色恒常性，我们在 NUS [19]和 Cube++ [23] 上进行测试；这两个真实数据集都包含来自 Canon EOS 600D 的图像。我们将我们的方法与不对光谱建模、而是直接生成 RAW 图像的 RawGen [36], 进行比较，也与 Buzzelli 等人的方法进行比较；后者的高光谱图像通过与我们相同的光谱灵敏度函数投影为 RAW 图像。

4.1. 从 RGB 进行高光谱重建的跨数据集泛化

高光谱重建（HSR）网络从成对的 RGB 图像和高光谱图像（HSIs）中学习，而现有的此类成对数据集仅涵盖少量场景、光源和成像设备。这种有限的多样性是将 HSR 应用于真实世界图像的主要障碍 [6, 27, 65]。

我们使用了四个在内容和照明条件方面存在差异的真实数据集。ARAD 1K [7] 和 ICVL [5] 由同一团队采集，主要包含日光场景。BJTU-UVA [21]包含在不同天气、照明条件和时间段下采集的城市与自然场景。Doomer [50] 将卤素灯和窄带 LED 灯照明下的室内场景，与主要处于阴天天空下的室外场景混合在一起。每个数据集既作为训练来源，也作为测试集。作为合成训练来源，我们使用 SPECTRIFY 以及 Buzzelli 等人提出的处理流程。 [14], 该流程将测量得到的反射光谱分配给 sRGB 照片中的像素。在进行渲染之前，我们从反射光谱库中移除四个真实数据集的所有光谱（第3.1节），因此该光谱库不包含来自测试集的任何光谱。

所有高光谱图像均通过尼康 D700 相机的光谱灵敏度投影至 RAW RGB，并采用相同的噪声模型进行扰动；每个数据源均用于训练相同的 MST++网络 [15] （详情见第B节）。在每个真实数据集的测试集划分上，测试由单个数据源训练的网络。当训练集和测试集来自同一数据集时，结果属于域内结果，并作为该测试集的参考。我们报告峰值信噪比、光谱角映射和归一化光谱误差（NSE） [50]。

表1 显示，真实数据集之间的迁移效果较差：在一个真实数据集上训练的网络，在任何其他数据集上的峰值信噪比都会下降数分贝。使用我们的数据进行训练，在大多数测试集和评估指标上都取得了最佳域外结果，在其余情况下则排名第二。

在 ICVL 上，使用 ARAD 1K 训练得到的光谱角映射和



图4。**使用 SPECTRIFY 渲染的场景，以 sRGB 显示**。不同光照条件下的自然、城市和室内场景。

表1。**高光谱重建的跨数据集泛化**。MST++ 在每个源数据集（行）上进行训练，并在每个真实数据集（列组）的测试集划分上进行测试；所有高光谱图像均通过 NikonD700 的光谱灵敏度投影到 RAW。阴影单元格为域内结果，作为各测试集的参考值，不参与排名。粗体表示每列中最优的域外结果，下划线表示次优的域外结果。在 SPECTRIFY 上训练，在大多数测试集和评估指标上取得最佳域外结果，在其余测试集和评估指标上取得次优结果。箭头表示数值越高或越低越好。

	训练集	ARAD 1K			Doomer			ICVL			BJTU-UVA		
		峰值信噪比，dB↑	光谱角映射，°↓	归一化光谱误差，%↓	峰值信噪比，dB↑	光谱角映射，°↓	归一化光谱误差，%↓	峰值信噪比，dB↑	光谱角映射，°↓	归一化光谱误差，%↓	峰值信噪比，dB↑	光谱角映射，°↓	归一化光谱误差，%↓
Real	ARAD 1K	40.44	3.90	7.87	27.88	13.42	25.31	37.47	**3.74**	**5.57**	30.53	10.08	15.68
	Doomer	33.61	8.71	13.11	35.90	4.54	8.21	36.29	4.65	6.69	31.42	9.40	15.01
	ICVL	32.99	11.32	23.46	27.14	14.03	30.15	43.83	1.71	3.10	**32.86**	9.45	19.02
	BJTU-UVA	30.98	11.50	15.29	26.50	13.84	22.93	33.33	7.67	10.13	42.67	2.11	4.72
Synthetic	Buzzelli	29.98	12.79	16.85	28.08	11.29	18.27	33.97	6.50	9.47	27.16	16.21	25.25
	Ours	**36.99**	**6.54**	**10.54**	**28.19**	**11.21**	**18.19**	**37.55**	4.13	6.12	31.51	**8.79**	**13.69**

归一化光谱误差低于使用我们的数据训练的结果，而我们的峰值信噪比略高。这两个数据集来自同一团队，包含相似的场景，因此对于 ICVL 而言，ARAD1K 属于接近域内的数据。

在真实数据上训练的网络迁移到 Doomer 时表现最差，因为其 LED照明室内场景在其他真实数据集中的对应场景很少，甚至没有。两种合成数据源迁移到 Doomer 的效果都优于任何真实数据源，而且二者都包含窄带 LED光谱，这可能是其中的原因。然而，在其他三个测试集上，Buzzelli等落后于大多数真实数据源，而我们的数据始终位居第一或第二。由于除高光谱图像外的所有内容都是共享的，因此这部分差距可能源于将光谱分配给表面的方式，我们将在第4.2节对此进行测试。其他高光谱重建方法的结果见补充材料（第B节）。图5 展示了两幅 ARAD 1K 测试图像的逐像素误差。

4.2. 基于材料的光谱分配的效果

为验证应按材料类别分配光谱（第3.2节），我们比较了两个 SPECTRIFY 版本；两者的唯一区别在于表面如何获得其光谱。在默认的材料 +颜色分配方式下，光谱的

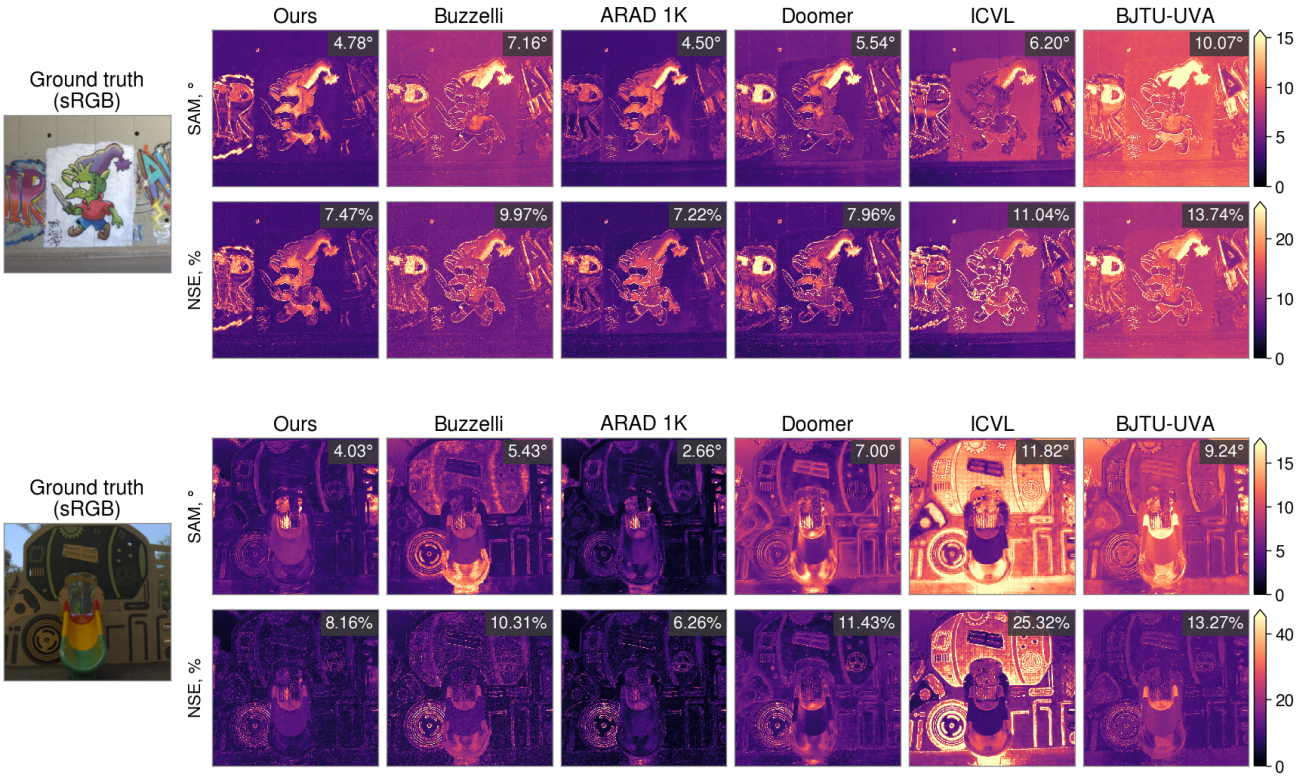

图 5。在两个 ARAD 1K 测试图像上，针对每个数据集训练的 MST++ 的逐像素重建误差。对于每幅图像，首先给出真实值 sRGB 渲染图，随后是各网络的光谱角（SAM，上排）和归一化光谱误差（NSE，下排）。ARAD 1K 列为域内参考。每一行使用同一颜色刻度，颜色越深表示效果越好，角落处的数值为图像均值。在域外网络中，使用我们的数据进行训练在两幅图像上都取得了最低误差。

每个纹素都会在该表面材料类别的光谱库中，匹配其颜色对应的光谱。在仅按颜色分配的方式下，则会在整个光谱库中进行匹配，如 Buzzelli 等人所述。 [14]我们遵循与第 4.1节相同的流程。表 2显示，材料 +颜色分配提升了所有测试集上的迁移效果。在 ARAD 1K 上的提升较小，而在其他三个测试集上则较为显著。

4.3. 颜色恒常性

颜色恒常性模型基于某一相机的 RAW 图像进行训练，因此每种新相机都需要自己的训练数据。本实验检验：从我们的高光谱图像投影得到的 RAW 图像，能否像现有的合成 RAW 图像生成器所生成的数据一样，作为此类训练数据。我们使用来自三个合成源的 RAW 图像训练颜色恒常性模型：SPECTRIFY、RawGen [36] 和 Buzzelli 等。 [14], 并将使用同一相机的真实图像进行训练作为域内参考。

对于每个渲染视图，我们还会渲染一张照明图，记录到达每个可见表面点的光谱辐照度。具体做法是：在式（1）中，将第一个相机射线交点处的材料替换为白色朗伯反射体，而后续反弹仍保留场景材料，因此该图包含经有色表面反射的光。我们评估的方法会为每张图像估计一个光源，因此，与渲染图像的处理方式相同，我们通过相机的光谱灵敏度函数将照明图中的每个像素投影到 RAW 空间，并取整张图的中位数作为真实光源。

对于 RawGen，由于其原始训练数据和文本提示未公开，我们使用已发布的检查点，根据文本提示生成 3,000 张 RAW 图像，并按照 RawGen [36]和 Graphics2RAW [53]的方式构建训练数据。每张图像都会转换到相机在从已发布的光源集合中采样的光源下对应的 RAW 空间，该光源作为标签。对于 Buzzelli等人，我们遵循其处理流程 [14], , 将每张 sRGB 图像转换为反射光谱，并在一个光源光谱下进行渲染。渲染后的图像和光源光谱通过相同的光谱灵敏度函数投影到 RAW 空间，而投影后的光源则作为真实标注。

我们评估了四种颜色恒常性方法：Con- vMean [29], FC4 [32], FFCC [9] 和 SIIE [3], , 在两个真实值上。

表 2. **基于材料的光谱分配的效果**。 MST++ 在两个版本的 SPECTRIFY 上进行训练，这两个版本仅在光谱分配到表面的方式上有所不同，并按照表 1 中的方法进行评估。颜色匹配的是每个纹素在整个光谱库中的颜色，而材料 + 颜色仅在该表面材料类别对应的光谱库光谱中进行匹配。材料 + 颜色分配是 SPECTRIFY 中的默认设置，可改善在每个测试集上的迁移效果（每列中较好的结果以粗体显示）。

光谱分配	ARAD 1K			Doomer			ICVL			BJTU-UVA		
	峰值信噪比，dB↑ 光谱角映射，°↓ 归一化光谱误差，%↓			峰值信噪比，dB↑ 光谱角映射，°↓ 归一化光谱误差，%↓			峰值信噪比，dB↑ 光谱角映射，°↓ 归一化光谱误差，%↓			峰值信噪比，dB↑ 光谱角映射，°↓ 归一化光谱误差，%↓		
仅颜色	36.38	6.66	10.88	26.36	13.57	21.92	31.92	7.60	10.86	29.15	11.08	15.77
材料 + 颜色 (默认)	**36.99**	**6.54**	**10.54**	**28.19**	**11.21**	**18.19**	**37.55**	**4.13**	**6.12**	**31.51**	**8.79**	**13.69**

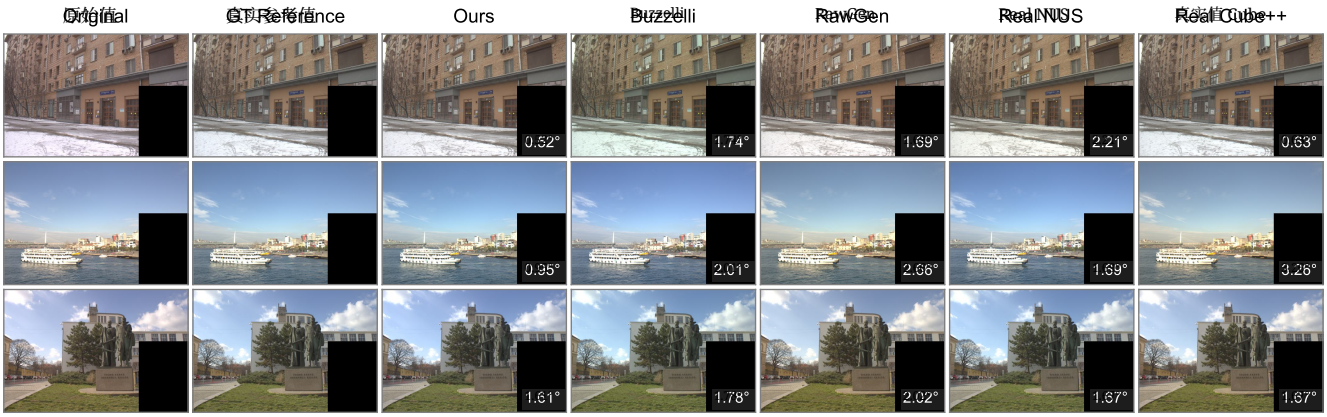

图6。**Cube 上的定性颜色恒常性结果++**。 使用在不同数据源上训练的 FC4 模型校正的三张测试图像。各列分别显示原始值图像、真实值白平衡参考和使用合成或真实数据训练的模型所生成的预测结果。数值表示每张图像的光源角误差，单位为度（数值越低越好）。Real Cube ++ 是域内参考。

数据集 NUS [19] 和 Cube++ [23]上评估了四种颜色恒常性方法：Con-vMean [19] FC++ [23]FFCC [34]以及 SIIE++。仅使用 Canon EOS 600D 拍摄的图像，该相机的光谱灵敏度函数来自 Cam-Spec [34]。对于每种方法和训练来源，我们从头开始分别训练一个模型，在其训练来源的验证集上进行选择，并在不进行微调的情况下对真实图像进行测试。域内参考模型在其所测试数据集的官方训练集划分上进行训练，所有模型均在 NUS 和 Cube++的官方测试集划分上进行测试。我们报告相机RGB空间中估计光源与真实光源之间的角度误差。NUS 为每张图像提供一个真实光源，而 Cube++为每张图像提供两个真实光源，分别来自 SpyderCube 目标物的左侧和右侧 [23]。遵循 Cogo 等人 [20], 的方法，Cube++上的误差是两个角度误差的平均值：一个是估计值与左侧光源之间的角度误差，另一个是估计值与右侧光源之间的角度误差。

表 3 显示，在这两个数据集上，合成数据源之间没有明显的优胜者，因为最佳数据源会随方法和数据集而变化。我们的数据在除一种情况外的所有情况下均排名第一或第二。图 6展示了 Cube 上的示例++。

表3。**真实 Canon EOS 600D 图像上的颜色恒常性**。模型分别从每个数据源（行）开始训练，并在 NUS 和 Cube++ 的官方测试集划分（列）上进行测试。数值为平均光源角误差，单位为度。Real 是域内参考，使用同一数据集进行训练和测试，因此不参与排名。粗体和下划线分别标示每列中最佳和次佳的合成数据源。

	NUS				立方体++			
训练集	ConvMean	FC4	FFCC	SIIE	ConvMean	FC4	FFCC	SIIE
RawGen	3.83	3.80	3.01	3.82	4.23	3.34	2.88	2.79
Buzzelli	**3.05**	**2.23**	**2.99**	3.23	5.32	2.72	2.99	3.01
Ours	3.39	2.75	3.18	**2.94**	**3.39**	**2.33**	**2.60**	**2.56**
Real	2.52	2.39	2.64	2.14	2.05	1.78	2.43	1.92

5. 结论

我们提出了 SPECTRIFY，这一框架通过按材料类别分配测得的反射光谱，并

使用光谱路径追踪渲染每个场景，从而将现有三维场景数据集转换为高光谱图像。仅使用我们的数据训练的高光谱重建网络，在大多数测试集上对未见过的真实数据集的泛化能力优于使用真实高光谱图像训练的网络；并且，与仅按颜色分配光谱相比，按材料类别分配光谱能在所有测试集上提升这种迁移效果。对于颜色恒常性，从我们的高光谱图像投影得到的 RAW 图像可作为有效的训练数据，其表现与现有合成 RAW 生成器相当。由于 RAW 图像是由高光谱图像投影得到的，因此同一批渲染数据可用于任何具有已知光谱灵敏度函数的相机，无需重新采集图像。然而，获取这些光谱灵敏度函数的成本较高 [34, 53]。将我们的数据与无需逐相机训练数据即可迁移到新相机的相机无关方法相结合 [3, 4], ，是一个自然的下一步；另一个方向是根据渲染得到的逐像素照明图进行多光源估计。我们将公开 4,500 张渲染的高光谱图像、SPECTRIFY 代码，以及带有材料标签的反射率库。

参考文献

[1] ambientCG：免费纹理、HDRI 和模型。https://ambientcg.com/，2018年。3[2] Poly Haven：公共 3D 资源库。https:// polyhaven.com/，2021年。3[3] Mahmoud Afifi 和 Michael S. Brown。面向 DNN 模型的传感器无关照明估计。载于 BMVC，2019年。7，9[4] Mahmoud Afifi、Jonathan T. Barron、Chloe LeGendre、Yun-Ta Tsai 和 Francois Bleibel。跨相机卷积颜色恒常性。载于 ICCV，第 1981–1990 页，2021年。9[5] Boaz Arad 和 Ohad Ben-Shahar。从自然 RGB 图像中稀疏恢复高光谱信号。载于 ECCV，第 19–34 页。Springer，2016年。2，3，5，13[6] Boaz Arad、Radu Timofte、Ohad Ben-Shahar、Yi-Tun Lin、Graham Finlayson、Shai Givati、Jiaojiao Li、Chaoxiong Wu、Rui Song、Yunsong Li 等。NTIRE 2020 RGB 图像光谱重建挑战赛。载于 CVPRW，第 1806–1822 页。IEEE，2020年。5[7] Boaz Arad、Radu Timofte、Rony Yahel、Nimrod Morag、Amir Bernat、Yuanhao Cai、Jing Lin、Zudi Lin、Haoqian Wang、Yulun Zhang 等。NTIRE 2022 光谱恢复挑战赛与数据集。载于 CVPRW，第 863–881 页，2022年。2，5，13[8] Kobus Barnard、Lindsay Martin、Brian Funt 和 Adam Coath。用于颜色研究的数据集。《色彩研究与应用》，27(3)：147–151，2002年。3[9] Jonathan T. Barron 和 Yun-Ta Tsai。快速傅里叶颜色恒常性。载于 CVPR，第 886–894 页，2017年。7[10]Jan Behmann、Kelvin Acebron、Dzhaner Emin、Simon Bennertz、Shizue Matsubara、Stefan Thomas、David Bohnenkamp、Matheus T Kuska、Jouni Jussila、Harri Salo 等。Specim IQ：新型微型手持式高光谱相机的评估及其在植物表型分析和疾病检测中的应用。《传感器》，18(2)：441，2018年。5[11] Sean Bell、Paul Upchurch、Noah Snavely 和 Kavita Bala。OpenSurfaces：包含丰富注释的表面外观目录。ACM TOG，32(4)：1–17，2013年。3[12]Harald Brendel。LED 的光谱功率分布。https : / / haraldbrendel . com / ledspd . html，2021 年。4[13] Tim Brooks、Ben Mildenhall、Tianfan Xue、Jiawen Chen、Dillon Sharlet 和 Jonathan T Barron。为学习式 RAW 降噪对图像进行反处理。载于 CVPR，第 11028–11037 页。IEEE，2019年。2，3[14] Marco Buzzelli、Mikhail K Tchobanou、Raimondo Schettini 和 Simone Bianco。用于生成逼真合成多光谱图像数据集的通用处理流程。载于色彩与成像会议，第 155–160 页。成像科学与技术学会，2023年。3，5，7，13[15] Yuanhao Cai、Jing Lin、Zudi Lin、Haoqian Wang、Yulun Zhang、Hanspeter Pfister、Radu Timofte 和 Luc Van Gool。MST++：用于高效光谱重建的多阶段逐光谱变换器。载于 CVPRW，第 744–754 页。IEEE，2022年。5，13，15[16] Nicolas Carion、Laura Gustafson、Yuan-Ting Hu、Shoubhik Debnath、Ronghang Hu、Didac Suris Coll-Vinent、Chai-Tanya Ryali, Kalyan Vasudev Alwala, Haitham Khedr, Andrew Huang 等。SAM 3：利用概念进行万物分割。载于 ICLR，页码 138846–138923，2026年。3, 13[17] Ayan Chakrabarti 和 Todd Zickler。真实世界高光谱图像的统计特性。载于 CVPR，页码 193–200。IEEE，2011年。2[18] Ayan Chakrabarti 和 Todd Zickler。真实世界高光谱图像的统计特性。载于 IEEE/CVF计算机视觉与模式识别会议论文集，页码 193–200，2011年。2[19] Dongliang Cheng、Dilip K Prasad 和 Michael S Brown。颜色恒常性的光源估计：空间域方法为何有效，以及颜色分布的作用。《Journal of the Optical Society of America A》，31(5):1049–1058，2014年。5, 8 [20] Luca Cogo、Gianmarco Corti、Simone Bianco 和 Raimondo Schettini。通过基于物理的合成数据进行密集光源估计的通用处理流程。arXiv预印本 arXiv:2610.06508，2026年。3, 8[21] Zhuoran Du、Shaodi You、Cheng Cheng 和 Shikui Wei。高光谱图像的自动光谱校准：方法、数据集与基准。载于 CVPR，页码 28081–28090。IEEE，2025年。2, 5, 13[22] Claudia Emde、Robert Buras-Schnell、Arve Kylling、Bernhard Mayer、Josef Gasteiger、Ulrich Hamann、Jonas Kylling、Bettina Richter、Christian Pause、Timothy Dowling 等。用于辐射传输计算的 libRadtran 软件包（2.0.1版）。《地球科学模型开发》，9(5):1647–1672，2016年。4[23] Egor Ershov、Alex Savchik、Illya Semenkov、Nikola Bani´c、Alexander Belokopytov、Daria Senshina、Karlo Ko˘s˘cevi´c、Marko Suba˘si´c 和 Sven Lon˘cari´c。Cube++照明估计数据集。《IEEE Access》，8:227511–227527，2020年。5, 8[24] David H Foster、Kinjiro Amano、S´ergio MC Nascimento 和 Michael J Foster。自然场景中同色异谱的发生频率。《Journal of the Optical Society of America A》，23(10):2359–2372，2006年。2[25] V Frolov、V Sanzharov、M Trofimov、D Pavlov 和 V Galaktionov。Hydra渲染器：开源GPU渲染系统，2018年。3[26] Huan Fu、Bowen Cai、Lin Gao、Ling-Xiao Zhang、Jiaming Wang、Cao Li、Qixun Zeng、Chengyue Sun、Rongfei Jia、Binqiang Zhao 等。3D-FRONT：具有布局和语义信息的三维家具布置房间。载于 ICCV，页码 10913–10922。IEEE，2021年。3[27] Qiang Fu、Matheus Souza、Eunsue Choi、Suhyun Shin、Seung-Hwan Baek 和 Wolfgang Heidrich。数据驱动光谱重建的局限性：一种光学感知分析。IEEE计算成像汇刊，2025年。2, 5[28] Ortal Glatt、Yotam Ater、Woo-Shik Kim、Shira Werman、Oded Berby、Yael Zini、Shay Zelinger、Sangyoon Lee、Heejin Choi 和 Evgeny Soloveichik。超越 RGB：面向移动设备多光谱成像的真实世界数据集。载于 IEEE/CVF冬季计算机视觉应用会议论文集，页码 4332–4342，2024年。2

[29] Han Gong。卷积均值：一种用于光源估计的简单卷积神经网络。arXiv预印本 arXiv:2001.04911，2020年。7[30] IES照明手册。IES照明手册。纽约：照明工程学会，1966年。4[31] Xiangpeng Hao 和 Brian Funt。多光源合成图像测试集。《色彩研究与应用》，45(6):1055–1066，2020年。2, 3[32] Yuanming Hu、Baoyuan Wang 和 Stephen Lin。FC4：采用置信度加权池化的全卷积颜色恒常性。载于 CVPR，页码 4085–4094，2017年。7[33] Wenzel Jakob、S´ebastien Speierer、Nicolas Roussel、Merlin Nimier-David、Delio Vicini、Tizian Zeltner、Baptiste Nicolet、Miguel Crespo、Vincent Leroy 和 Ziyi Zhang。Mitsuba 3渲染器，2022 2, 3, 5。[34] https://mitsuba-renderer.org。Jun Jiang、Dengyu Liu、Jinwei Gu 和 Sabine Susstrunk。数字彩色相机的光谱灵敏度函数空间是什么？载于 WACV，页码 168–179。IEEE，2013年。2, 8, 9, 13[35] Berk Kaya、Yigit Baran Can 和 Radu Ti mofte。迈向野外单张RGB图像的光谱估计。载于 ICCVW，页码 3546–3555。IEEE，2019年。2[36]Dongyoung Kim、Junyong Lee、Abhijith Punnappurath、Mahmoud Afifi、Sangmin Han、Alex Levinshtein 和 Michael S Brown。RawGen：学习相机原始图像生成。载于 ECCV，页码 37–55。Springer，2026年。2, 3, 5, 7[37] Min H Kim、Todd Alan Harvey、David S Kittle、Holly Rushmeier、Julie Dorsey、Richard O Prum 和 David J Brady。用于测量固体物体上高光谱图案的三维成像光谱学。ACM TOG，31(4):1–11，2012年。2[38]Seunghoi Kim、Chen Jin、Tom Diethe、Matteo Figini、Henry FJ Tregidgo、Asher Mullokandov、Philip Teare 和 Daniel C Alexander。利用局部扩散解决图像转换中的结构性幻觉问题。载于 ECCV，页码 87–103。Springer，2024年。2[39] Raymond F Kokaly、Roger N Clark、Gregg A Swayze、K Eric Livo、Todd M Hoefen、Neil C Pearson、Richard A Wise、William Benzel、Heather A Lowers、Rhonda L Driscoll 等。USGS光谱库第7版。技术报告，美国地质调查局，2017年。3[40] Firas Laakom、Jenni Raitoharju、Jarno Nikkanen、Alexandros Iosifidis 和 Moncef Gabbouj。Intel-tau：颜色恒常性数据集。IEEE Access，9:39560–39567，2021年。13[41] Chia-Ming Lee、Yu-Jou Hsiao、Ming-Ching Chang、Xin Li、Yu-Lun Liu 和 Chih-Chung Hsu。光谱世界渲染器：统一的三维高光谱解混。arXiv预印本 arXiv:2610.19520，2026年。2, 3[42] Jiaojiao Li、Chaoxiong Wu、Rui Song、Yunsong Li 和 Fei Liu。结合相机光谱灵敏度先验、用于RGB图像光谱重建的自适应加权注意力网络。载于 2020年 IEEE/CVF计算机视觉与模式识别会议研讨会（CVPRW），页码 1894–1903。IEEE，2020年。13, 15[43] Yuqi Li、Qiang Fu 和 Wolfgang Heidrich。利用深度展开网络进行多光谱照明估计。载于 IEEE/CVF国际计算机视觉会议论文集，页码 2652–2661，2021年。2

[44] Susan K Meerdink、Simon J Hook、Dar A Roberts 和 Elsa A Abbott。《ECOSTRESS光谱库》1.0版。《环境遥感》，230:111196，2019年。3[45] Jussi PS Parkkinen、Jarmo Hallikainen 和 Timo Jaaske-lainen。孟塞尔颜色的特征光谱。《Journal of the Optical Society of America A》，6(2):318–322，1989年。3[46] Matt Pharr、Wenzel Jakob 和 Greg Humphreys。《基于物理的渲染：从理论到实现》。爱思唯尔，第3版，2016年。3[47] Mikhail N Polyanskiy。Refractiveindex.info光学常数数据库。《科学数据》，11(1):94，2024年。4[48] Jueqin Qiu。高光谱图像的光谱反射率数据库——RidiQulous。https://ridiqulous.com/spectral-reflectance-database/，2016年。3[49]Weiming Ren、Raghav Goyal、Zhiming Hu、Tristan Ty Aumentado-Armstrong、Iqbal Mohomed 和 Alex Levinshtein。幻觉评分：旨在缓解生成式图像超分辨率中的幻觉现象。arXiv预印本 arXiv:2507.14367，2025年。2[50] Daniil Reutsky、Daniil Vladimirov、Yasin Mamedov、Georgy Perevozchikov、Nancy Mehta、Egor Ershov 和 Radu Timofte。调制与重建：从未对齐的智能手机视图中学习高光谱成像。arXiv预印本 arXiv:2507.01835，2025年。2，5[51] Mike Roberts、Jason Ramapuram、Anurag Ranjan、Atulit Kumar、Miguel Angel Bautista、Nathan Paczan、Russ Webb 和 Joshua M Susskind。Hypersim：用于整体室内场景理解的逼真合成数据集。载于 ICCV，第10892–10902页。IEEE，2021年。2，3[52] German Ros、Laura Sellart、Joanna Materzynska、David Vazquez 和 Antonio M Lopez。SYNTHIA数据集：用于城市场景语义分割的大型合成图像集。载于 CVPR，第3234–3243页，2016年。2[53] Donghwan Seo、Abhijith Punnappurath、Luxi Zhao、Abdelrahman Abdelhamed、Sai Kiran Tedla、Sanguk Park、Jihwan Choe 和 Michael S Brown。Graphics2RAW：将计算机图形图像映射到传感器原始图像。载于 ICCV，第12588–12597页。IEEE，2023年。2，3，7，9[54] Frank Sippel、J¨urgen Seiler 和 Andr´e Kaup。用于跨光谱重建和高光谱视频编码的合成高光谱阵列视频数据库。《Journal of the Optical Society of America A》，40(3):479–491，2023年。2，3[55] Johji Tajima、Hideaki Haneishi、Nobutoshi Ojima 和 Masato Tsukada。标准物体颜色光谱数据库（SOCS）的代表性数据选择。载于颜色与成像会议，第155–160页。成像科学与技术学会，2002年。3[56] Lucia T´odov´a 和 Alexander Wilkie。用于 HDR环境贴图的约束光谱提升。载于《计算机图形学论坛》，第 e15280 页。Wiley在线图书馆，2025年。3[57] Lucia T´odov´a、Alexander Wilkie 和 Luca Fascione。宽色域基于矩的约束光谱提升。载于《计算机图形学论坛》，第258–272页。Wiley在线图书馆，2022年。3

[58] Giuseppe Vecchio 和 Valentin Deschaintre。MatSynth：现代 PBR 材料数据集。载于 CVPR，第22109–22118页。IEEE，2024年。3[59] Poorvi L Vora、Joyce E Farrell、Jerome D Tietz 和 David H Brainard。图像采集：从高光谱图像模拟传感器响应。IEEE TIP，10(2):307–316，2001年。2[60] Xinying Wang、Zhixiong Huang、Sifan Zhang、Jiawen Zhu、Paolo Gamba 和 Lin Feng。GMSR：用于从 RGB 图像重建光谱的梯度集成 Mamba。《Neural Networks》，第108020页，2025年。13，15[61] Alexander Wilkie。The Advanced Rendering Toolkit。可从以下网址获取：https://cgg.mff.cuni.cz/ART，2018年。3[62] Jiqing Wu、Jonas Aeschbacher 和 Radu Timofte。为从 RGB 图像进行浅层学习光谱重建辩护。载于《2017年 IEEE 国际计算机视觉会议研讨会》（ICCVW），第471–479页。IEEE，2017年。13，15[63] Lihe Yang、Bingyi Kang、Zilong Huang、Z hen Zhao、Xiaogang Xu、Jiashi Feng 和 Hengshuang Zhao。Depth Anything V2。NeurIPS，37:21875–21911，2024年。2[64] Fumihito Yasuma、Tomoo Mitsunaga、Daisuke Iso 和 Shree K Nayar。广义混合像素相机：对分辨率、动态范围和光谱进行拍摄后控制。《IEEE 图像处理汇刊》，19 2253，2010 9 2241 2 ( ): – 。[65] Jingang Zhang、Runmu Su、Qiang Fu、Wenqi Ren、Felix Heide 和 Yunfeng Nie。关于从 RGB 到高光谱成像的计算光谱重建方法综述。《Scientific Reports》，12(1):11905，2022年。2，5[66] Xiandou Zhang、Brian Funt 和 Hamidreza Mirzaei。实践与理论中的同色异谱失配。《Journal of the Optical Society of America A》，33(3):A238–A247，2016年。3[67] Yinda Zhang、Shuran Song、Ersin Yumer、Manolis Savva、Joon-Young Lee、Hailin Jin 和 Thomas Funkhouser。利用卷积神经网络进行室内场景理解的基于物理的渲染。载于 CVPR，第5057–5065页。IEEE，2017年。2[68] Kailai Zhou、Lijing Cai、Yibo Wang、Mengya Zhang、Bihan Wen、Qiu Shen 和 Xun Cao。移动摄影中联合 RGB-光谱分解模型引导的图像增强。载于《欧洲计算机视觉会议论文集》，第19–36页，2024年。2

技术附录与补充材料

A. 带材料标签的反射光谱库

高光谱图像标注。 大多数近距离高光谱数据集都不提供材料标签，因此我们使用 Segment Anything Model 3（SAM 3）自动为图像像素添加标签 [16]。由于 SAM 3 适用于 RGB 图像，我们首先根据高光谱图像 400–700 nm 波段的数据，在 CIE D65 标准光源下将其渲染为 sRGB 图像。然后，针对每种材料类别，使用 SAM 3 对该图像进行一次分割。文本提示为类别名称，部分类别还会添加其他词语。我们仅保留置信度高于 0.8 的掩模。分光光度计测量值本身已有材料名称，我们针对每个来源表格，分别将这些名称映射到我们的类别。

材料类别。 该库定义了 63 种材料类别，以下列出其标识符：
沥青、树皮、骨头、砖、硬纸板、地毯、天花板瓷砖、陶瓷、黑板、混凝土、软木、灰尘、人造石、织物、布艺灯罩、火、枝叶、食品、毛皮、宝石、玻璃、玻璃窗、花岗岩、草、砾石、头发、冰、层压材料、皮革、油毡、大理石、金属、腐蚀金属、镜子、涂漆、纸、印刷纸、灰泥、透明塑料、亮面塑料、不透明塑料、抛光石材、屋面瓦、橡胶、沙子、皮肤、天空、雪、土壤、海绵、石头、泡沫塑料、赤陶、瓷砖、墙纸、水、蜡、白板、柳条、木材、木塑复合材料、木地板、上清漆本材。

仅使用类别名称会遗漏由该材料制成的典型物体，因此我们为类别添加了额外的提示词。例如，枝叶还会使用以下提示词：叶子、树、盆栽植物、灌木和草。表4 给出了各类别的光谱数量、源数据集数量和颜色覆盖范围。有些类别会保留在库中，但不用于渲染，例如金属，因为金属会使用测得的光学常数，以粗糙导体的形式进行渲染（第3.2节）。

颜色覆盖范围。我们通过将某个类别中的每条光谱投影到 D65 光源下的 CIE 1931xy 色度图上，展示该类别涵盖的颜色。某个类别的覆盖范围，是指其色度所覆盖的光谱轨迹内区域占比。作为参考，sRGB 色域覆盖了光谱轨迹的 33.7%，所有类别合计覆盖 60.8%。单个类别不太可能覆盖整个光谱轨迹，因为许多材料只会呈现有限范围的颜色。覆盖范围也取决于每个类别所包含的光谱，因此它反映的是库中收录的内容，而非某种材料完整的颜色范围。

图7 展示了八个类别的覆盖范围。类别枝叶、织物、不透明塑料和橡胶覆盖了光谱轨迹的 38–52%，超过 sRGB 色域；而木材、涂漆、纸和瓷砖覆盖了 24–31%。表4 给出了每个类别的覆盖范围。

数据可用性。该库及其源数据集列表将在接收录用通知后发布。

B. 与其他高光谱图像重建方法的跨数据集评估

为验证我们数据的优势并不取决于重建方法，我们使用另外三种类型的高光谱重建方法，重复第4.1 节中的跨数据集评估：基于字典的方法 A+ [62]、卷积神经网络 AWAN [42]和基于 Mamba 的 GMSR [60], ，以及表1中的基于 Transformer 的 MST++ [15] 。每种方法均保留其原始论文中的模型超参数，数据、RAW 渲染、数据划分和评估指标均采用第4.1节中的设置。

RAW 模拟。 所有高光谱图像均通过 Nikon D700 [34], 的光谱灵敏度投影为 RAW RGB，并进行缩放，使最大通道总和等于 1。随后，我们按照 NTIRE 2022 光谱恢复挑战赛 [7], 中的方法添加泊松散粒噪声，满阱容量设为 750 个光电子。噪声信号会在饱和水平处截断，并量化为 12 位。所有训练来源和测试集都经过相同的模拟处理。

数据划分。 每个数据集均划分为训练集、验证集和测试集，同一场景的所有图像都归入同一划分。ARAD 1K 挑战赛 [7]的测试标签未公开，因此我们使用其公开的 899 张训练图像进行训练，并将官方验证集中的 50 张图像平均分配到我们的验证集和测试集中。ICVL [5]的图像按地点和拍摄日期分组，再将整组图像分配到各个划分中，使验证集和测试集各约占图像总数的 10%。BJTU-UVA [21] 沿用其官方划分。Buzzelli 等人 [14] 的数据将同一 INTEL-TAU [40]场景由不同相机拍摄的所有渲染结果归入同一划分；我们的数据则按三维场景划分，因此同一场景的所有视图都归入同一划分。

结果。 表 5 表明，第 4.1 节的发现适用于全部四种方法。在一个真实数据集上训练的模型，在其他每个真实数据集上的三项评估指标均更差。对于 MST++、AWAN 和 GMSR，在我们的数据上训练的模型在每一列的域外结果中均为最佳或次佳，并且对所有方法而言，在每个单元格中都优于 Buzzelli 等人的合成高光谱图像。因此，我们的数据优势并不取决于重建方法。

表 4. **库中的材料类别**。 每个包含光谱的材料类别的光谱数量、源数据集数量和色度覆盖范围。Cov. 表示该类别颜色所覆盖的 xy 色度图的部分（第 A节）。

类别	光谱	数据集	覆盖范围，%
沥青	15.9M	11	18.2
bark	1.3M	10	12.8
bone	327.8K	7	8.7
砖	13.2M	11	11.1
硬纸板	602.1K	10	26.1
地毯	730.5K	6	25.6
天花板瓷砖	30.0K	2	0.5
陶瓷	17.2M	8	20.2
黑板	25.1K	3	2.6
混凝土	10.0M	12	10.6
cork	50.0K	3	2.9
dust	25	1	0.1
人造石	108.8K	2	1.8
织物	7.6M	21	43.8
布艺灯罩	55.8K	6	4.7
枝叶	18.5M	36	52.4
food	183.0M	29	35.1
宝石	127.6K	4	14.5
玻璃	5.8M	11	31.2
玻璃窗	6.4M	10	23.3

类别	光谱	数据集	覆盖率，%
花岗岩	900.7K	9	6.3
草	3.5M	10	26.2
砾石	325.0K	5	6.4
hair	463.9K	14	21.5
ice	56.1K	2	1.1
层压材料	30.0K	1	1.3
皮革	148.9K	5	7.3
大理石	488.0K	5	5.9
金属	7.7M	20	24.2
腐蚀金属	1.6M	10	18.6
镜子	554.1K	7	11.0
涂漆	2.4M	21	26.9
纸	2.7M	15	25.9
印刷纸	563.4K	9	20.4
灰泥	351.2K	4	3.5
透明塑料	3.1M	11	19.4
亮面塑料	265.1K	5	27.6
不透明塑料	7.9M	16	43.2
抛光石材	519.9K	4	4.2
橡胶	2.0M	15	38.2

类别	光谱	数据集	覆盖率，%
sand	696.0K	7	6.2
skin	2.6M	15	24.6
sky	14.5M	13	11.0
snow	6.3M	6	4.2
soil	3.2M	11	16.5
海绵	34.6K	3	5.0
石头	11.0M	22	20.8
泡沫塑料	57.8K	4	1.7
赤陶	1.0M	11	23.0
tile	5.9M	13	23.6
墙纸	72.5K	1	8.8
水	1.0M	12	17.6
wax	292.3K	5	16.0
白板	124.0K	4	2.7
柳条	15.1K	2	4.8
wood	3.3M	18	31.2
木塑复合材料	4.8M	27	26.2
木地板	603.2K	8	10.3
上清漆木材	401.0K	8	10.4

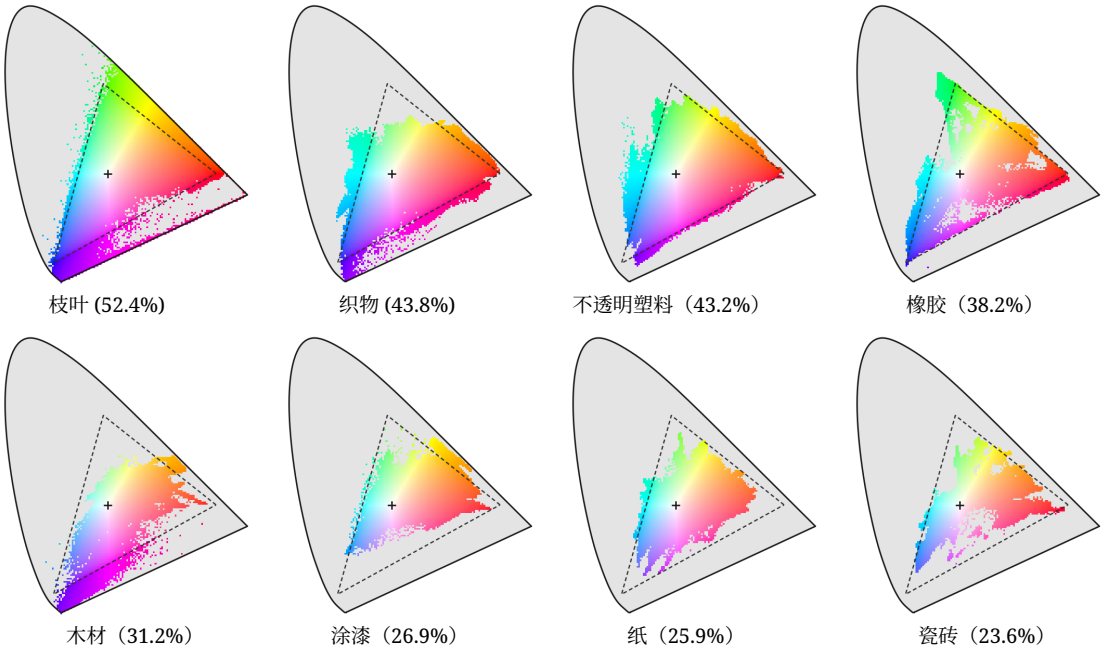

图 7. **材料类别的色度覆盖范围**。 每个面板显示一个类别所达到的 xy 色度，其覆盖范围以方括号标出。虚线三角形表示 sRGB 色域。

表 5. **不同高光谱图像重建方法之间的跨数据集泛化**。表格格式与表 1一致，每种方法（纵向标签）对应一个区块，MST++ [15] 区块重复表 1。粗体表示每种方法中各列最优的域外结果，下划线表示次优结果。箭头表示数值越高或越低越好。

	训练集	ARAD 1K			Doomer			ICVL			BJTU-UVA		
		峰值信噪比，dB↑	光谱角映射，°↓	归一化光谱误差，%↓	峰值信噪比，dB↑	光谱角映射，°↓	归一化光谱误差，%↓	峰值信噪比，dB↑	光谱角映射，°↓	归一化光谱误差，%↓	峰值信噪比，dB↑	光谱角映射，°↓	归一化光谱误差，%↓
MST++ [15]	ARAD 1K	40.44	3.90	7.87	27.88	13.42	25.31	37.47	**3.74**	**5.57**	30.53	10.08	15.68
	Doomer	33.61	8.71	13.11	35.90	4.54	8.21	36.29	4.65	6.69	31.42	9.40	15.01
	ICVL	32.99	11.32	23.46	27.14	14.03	30.15	43.83	1.71	3.10	**32.86**	9.45	19.02
	BJTU-UVA	30.98	11.50	15.29	26.50	13.84	22.93	33.33	7.67	10.13	42.67	2.11	4.72
	Buzzelli	29.98	12.79	16.85	28.08	11.29	18.27	33.97	6.50	9.47	27.16	16.21	25.25
	Ours	**36.99**	**6.54**	**10.54**	**28.19**	**11.21**	**18.19**	**37.55**	4.13	6.12	31.51	**8.79**	**13.69**
AWAN [42]	ARAD 1K	40.13	4.16	7.34	28.21	12.67	20.60	37.01	4.07	**5.77**	29.75	10.52	15.81
	Doomer	30.77	11.57	16.27	36.01	4.13	6.73	31.81	7.27	10.13	31.14	9.47	14.92
	ICVL	32.84	11.58	17.83	26.79	14.39	23.29	44.42	1.47	2.58	32.08	10.14	15.47
	BJTU-UVA	31.22	11.30	**14.88**	26.04	13.94	22.18	32.59	8.16	10.75	43.21	2.03	4.38
	Buzzelli	26.84	21.13	26.76	25.96	15.34	22.29	25.44	19.20	24.52	25.33	18.95	29.07
	Ours	**33.32**	**11.09**	15.78	**28.51**	**11.12**	**19.22**	**38.10**	**4.00**	5.90	**32.59**	**7.41**	**11.77**
GMSR [60]	ARAD 1K	38.04	5.42	9.91	**27.94**	13.47	26.10	36.73	4.25	**6.64**	32.10	8.95	12.83
	Doomer	31.98	11.71	17.60	32.35	7.53	13.17	33.85	5.85	8.93	31.08	9.42	16.21
	ICVL	33.02	9.93	21.10	26.59	15.32	32.62	40.54	2.60	4.58	32.40	9.74	17.87
	BJTU-UVA	30.68	11.95	16.52	25.91	14.76	23.84	32.29	8.73	11.77	40.71	2.84	5.97
	Buzzelli	28.38	16.91	21.49	26.38	14.13	21.78	29.78	10.17	13.61	26.39	16.88	26.24
	Ours	**33.67**	**8.84**	**13.76**	27.88	**11.55**	**19.09**	**36.78**	**3.88**	6.83	**33.17**	**7.21**	**11.74**
A+ [62]	ARAD 1K	32.80	8.40	16.95	25.22	15.29	27.36	**32.35**	7.09	12.39	26.42	14.57	24.62
	Doomer	**31.67**	11.92	**19.87**	28.39	11.45	20.58	32.35	7.51	12.49	**29.48**	**11.60**	**20.63**
	ICVL	30.19	15.09	26.20	25.19	15.95	29.05	34.03	4.81	9.59	26.74	14.65	26.68
	BJTU-UVA	27.73	16.33	25.26	22.92	18.98	31.40	28.26	12.88	19.18	34.32	5.60	11.58
	Buzzelli	26.94	20.65	29.52	24.10	17.55	27.78	26.60	14.89	21.97	28.66	13.10	21.11
	Ours	31.22	**11.64**	20.23	**26.74**	**13.23**	**23.33**	31.84	**6.97**	**12.26**	28.88	11.98	20.88