arXiv:2603.02582v1 [cs.CV] 3 Mar 2026

用于高分辨率材料参数重建的神经电磁场

Zhe Chen[1] Peilin Zheng[1] Wenshuo Chen[2] Xiucheng Wang[1] Yutao Yue[2] Nan Cheng[1]
[1]西安电子科技大学 [2]香港科技大学

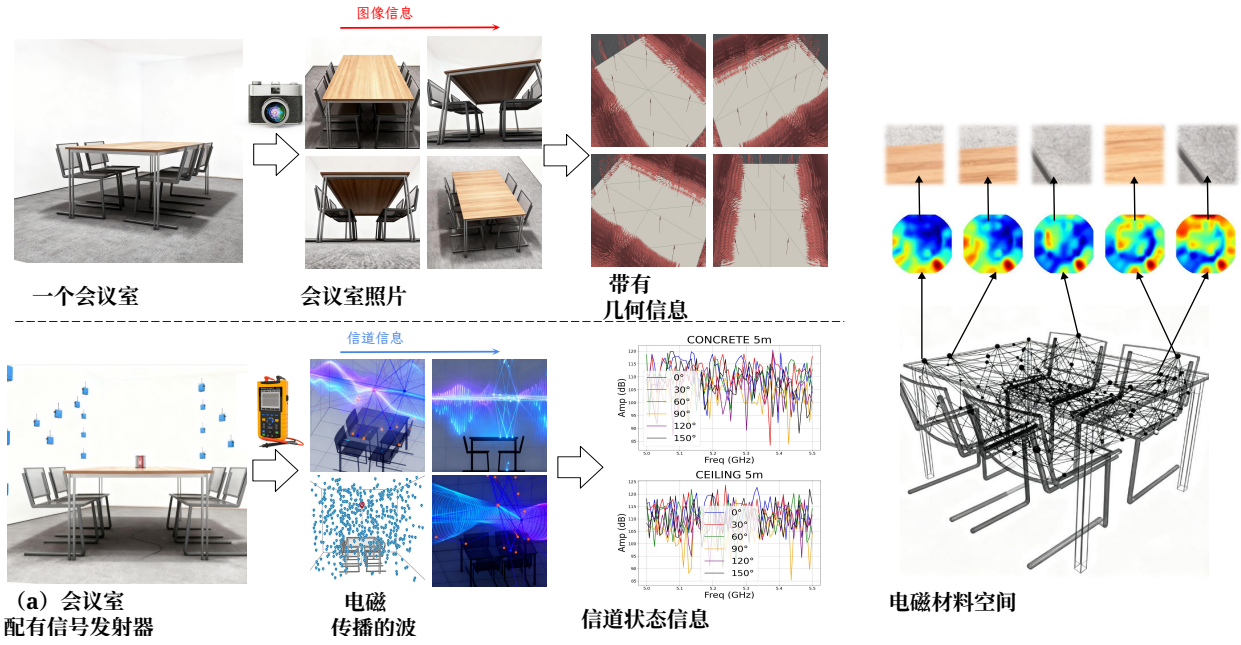


图 1. NEMF 框架概览，展示了用于功能性数字孪生的多模态融合。

摘要

创建功能性数字孪生——可模拟真实世界的三维复制体——是计算机视觉领域的一项核心挑战。*NeRF* 等现有方法能够生成视觉效果丰富的孪生体，但在功能上并不完整。关键障碍在于缺乏底层材料属性（例如介电常数、电导率）。通过非接触式、无创感知获取场景中每个点的这些信息，是一项首要目标，但这需要解决一个以难以适定著称的物理反演问题。图像和射频（*RF*）等标准远程信号，将未知的几何结构、环境场和目标材料深度耦合在一起。我们提出 *NEMF*，这是一种旨在构建功能性数字孪生的全新稠密无创物理反演框架。我们的核心洞见是一种系统化的解耦策略。*NEMF* 利用图像提供的高保真几何结构作为强有力的锚点，首先由此实现对环境场的解析场。只利用非侵入式数据约束几何结构与场，原本适定性不佳的问题便转化为适定的物理监督学习任务。这一转变使我们的核心反演模块——解码器——成为可能。在环境射频信号以及融入物理反射模型的可微层引导下，解码器能够学习并显式输出场景底层材料参数的连续空间变化场。我们在高保真合成数据集上验证了该框架。实验表明，我们的非侵入式反演方法能够高准确度地重建这些材料分布图，而由此生成的功能孪生体可支持高保真物理仿真。这一进展超越了被动的视觉复制体，使我们能够创建真实可用且可仿真的物理世界模型。

1. 引言

利用多视图图像重建高保真、可交互的三维“数字孪生”，是现代计算机视觉与图形学的重要研究目标。近年来，神经辐射场（NeRF） [24] 及其众多变体 [2, 13, 26,34] 彻底革新了这一领域。NeRF 擅长从二维图像中学习连续的体积表示，从而能够合成逼真的视觉孪生体，达到前所未有的保真度。这为视图合成、场景重建和增强现实提供了强大的工具。

尽管这些表示在视觉上颇为惊艳，但它们**并非“功能性”物理模型**。NeRF 的参数是从数据中隐式学习得到的，用于再现光学效应；这些参数并未受到物理定律的明确约束，也未映射到具体的材料属性。例如，NeRF 可以完美渲染墙壁的外观，但其内部权重无法用于模拟墙壁如何阻挡或反射电磁波。视觉外观与物理功能之间的这一根本差距，阻碍了诸如预测室内 WiFi 覆盖以支持增强现实，或在机器人学中实现非视距（NLOS）感知等应用。

要创建真正“功能性”的数字孪生，我们必须将底层**物理属性**融入这些三维场景中。本文聚焦于**电磁（EM）属性**（例如介电常数 ϵ_r 和电导率 σ），以应对这一挑战。探测这些属性的唯一可扩展、非侵入式方法，是利用无处不在的射频（RF）信号，尤其是信道状态信息（CSI）。**然而，仍存在一个关键难题：**仅凭 CSI 反演物理参数，是一个众所周知的不适定逆问题。接收信号是未知几何结构、未知材质和多径传播效应共同作用后形成的复杂纠缠结果。

为此，我们提出了神经电磁场（NEMF），这是一种旨在系统性地解耦这些相互耦合未知量的框架。我们的核心洞见是，若利用多模态数据依次求解未知量，原本适定性不佳的物理问题便可转化为适定问题。NEMF 首先从图像中重建高保真几何骨架。随后，这一几何先验将作为强有力的约束，使我们的框架能够求解复杂的入射场（f_θ）。在几何结构和入射场均得到有效约束后，原始问题便不再适定。这一转变促成了我们的核心贡献：一种物理监督反演模块（g_ϕ）。该模块采用一种新颖的监督信号进行训练，该信号通过将预测的入射场与反向传播测量值配对计算得到，从而通过可微物理层显式求解最终的材料参数（ϵ_r，σ）。

我们在高保真合成数据集上验证了我们的框架，因为对于已知真实值进行严格的定量验证而言，这一选择至关重要。实验结果表明，我们的联合优化框架不仅能够以高准确度重建三维电磁参数图，而且由此得到的功能性数字孪生还可用于高保真**下游仿真任务**（例如信道预测），性能显著优于相关基线方法。

本文的主要贡献总结如下：

- 我们提出了 NEMF，这是一种新颖的多模态框架，可通过视觉和射频信号构建可运行、可仿真的数字孪生，实现密集、非侵入式的物理反演。
- 我们提出了一种系统性的解耦方法，将基于图像的几何结构作为强有力的锚点；这使得环境场得以求解，进而将原本适定性不佳的问题转化为适定的物理监督学习任务。
- 我们通过实验验证了该框架，结果表明，我们的反演能够准确重建连续的材料参数图（ϵ_r，σ），从而支持高保真度的物理仿真，并显著优于相关基线方法。

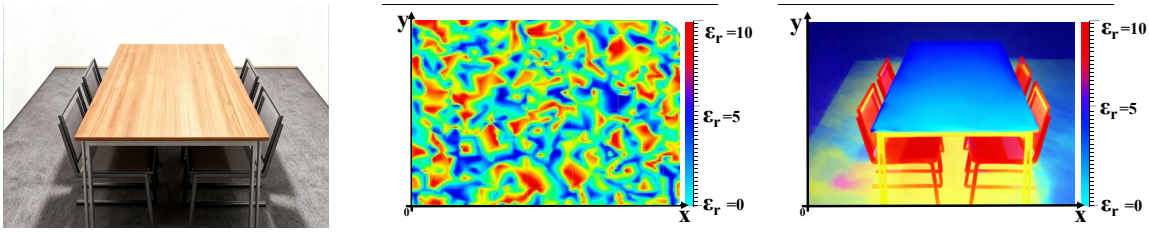
2. 相关工作

我们的工作处于三个主要领域的交叉点：计算机视觉中的神经场景表示、无线通信中的神经辐射场，以及物理学中的传统电磁反演。

尽管神经辐射场（NeRF） [24]及其众多在速度 [9, 13, 26], 、保真度 [2, 34, 46], 和几何结构 [28, 37, 40] 方面的变体擅长视觉重建，但其隐式参数并不具备物理意义。NeRF 中渲染出的墙面对物理模拟器而言，在功能上是不透明的。近期的相关研究已开始整合照明和材质等物理属性 [27, 44] ，或进行系统辨识 [17]。我们的工作利用这些几何先验，但将目标拓展至电磁物理功能。

“神经场”概念最近被扩展到了射频领域 [18, 25, 47]。后续框架将其形式化应用于信道预测 [22], 、可重构表面 [36], 、泛化能力 [21], 以及与 3D高斯泼溅 [4] 或射线追踪 [7]的结合。这些方法都成功地将 NeRF架构应用于求解正向 问题：根据稀疏的 c_i^{obs}测量值插值得到总辐射场。**然而，仍存在一个关键缺口：** 这些黑箱模型无法将场分解为其组成部分（入射场 E_{inc}、材料属性 Γ）。它们的目标是插值，而非我们所追求的物理反演。

在物理学与工程学领域，传统的材料参数反演方法已相当成熟。这些基于经典电动力学的方法 [11, 12], 旨在



(a) NeRF 视觉孪生体（非功能性） (b) 病态电磁反演（无几何结构） (c) NEMF（本文方法）：功能孪生体

图2. 研究动机。(a) 标准神经辐射场（NeRF）可创建逼真的视觉 孪生体，但其参数是隐式且不符合物理规律的。(b) 仅根据稀疏信号反演电磁（EM）参数是一个高度病态的问题。(c) 我们提出的 NEMF 融合了两种模态（视觉几何结构 + 物理信号），以创建具有明确、可仿真材料属性的功能性 数字孪生。

通过严格的物理模型求解逆问题。典型方法包括全波有限元法（FEM） [41]以及对比源反演（CSI）等迭代优化技术 [19,45]。然而，正如基础教材所总结的 [8]，，这些方法通常存在极强的非凸性。此外，它们需要密集且经过校准的测量数据（这在天线理论中是一项重大挑战 [1]），对初始化和噪声高度敏感 [10]（通常需要采用全变分等强正则化方法 [31]），并且在大规模三维场景中计算成本高得难以承受。近年来，深度学习已被应用于这些物理问题，包括物理信息神经网络（PINN） [30]。这一范式已专门用于电磁仿真 [14]和波传播问题 [32]，，也用于逆向设计 [43]，及其他深度学习反演技术 [6, 38]，，其中包括近期针对毫米波信号的逆向渲染研究 [15]。尽管这些方法功能强大，却往往缺乏视觉领域稳健的几何先验，也缺少我们框架所利用的强大基于坐标的表示。

我们的工作也受到新兴概念“6G网络数字孪生”的启发 [20, 39]，该概念展望了这样一个未来：无线网络由可仿真、具备物理感知能力的虚拟副本映射 [35]。其目标是利用大型信道模型 [42]创建可仿真环境 [33]和高保真射频地图 [5]，以预测射频传播。与这些通常依赖统计方法或简化射线追踪 [23]，的工作不同，我们的 NEMF 提供了一种**显式反演** 底层物理材料属性的方法。这弥合了视觉场景采集与真正具备物理感知能力的功能仿真之间的差距，从而实现新一类数字孪生。

3. 方法论

重建三维电磁参数图是一项极具挑战性且适定性差的逆问题。其难点在于以下因素的耦合作用：未知几何、未知入射场和未知材料属性。为解决这一问题，我们提出了神经电磁场（NEMF），这是一种创新框架，可将该问题系统地分解为三个不同阶段：(1) 几何先验重建，(2) 环境场重建，以及 (3) 物理监督材料反演。如图3所示，我们首先分离出几何结构，然后分离出场，从而将最终的材料反演从适定性差的问题转变为适定的监督学习任务。我们将依次详细介绍各个阶段。

3.1. 问题定义

电磁波的正向传播由麦克斯韦方程控制， [12]，在频域中可简化为矢量亥姆霍兹方程 [1, 12]：

$$\nabla^2\mathbf{E}+k^2\mathbf{E}=0, \quad \text{where} \quad k^2=\omega^2\mu_0\left(\epsilon_0\epsilon_r-j\frac{\sigma}{\omega}\right) \tag{1}$$

此处，复波数 k 由材料参数（ϵ_r、σ）直接调制。在我们基于表面的反射模型中，物理过程分为两个阶段。首先，入射矢量场 E_{inc} 与表面相互作用，该表面由反射算子 J（琼斯矩阵 [1, 3]）定义，从而产生反射场 E_{ref}：

$$\vec{E}_{ref}=J\cdot\vec{E}_{inc}(x,\omega) \tag{2}$$

其次，反射场从表面传播 x至位于 x_{rx} 的接收器，传播过程通过传播算子 $\mathcal{P}$实现。该算子考虑了自由空间传播的路径损耗（自由空间路径损耗，公式 4）和相位。随后，接收器捕获最终的标量测量值 c_i^{obs}。这一捕获过程是传播后的场矢量与接收器天线固定且已知的极化矢量之间的点积，我们将其定义为 $\vec{h}_{rx}$（例如，$[1,0]^T$对于 p极化接收器）。由此得到最终的信道状态信息（CSI）：

$$\begin{aligned} c_i^{obs} &= \mathcal{P}(\vec{E}_{ref},d,\vec{h}_{rx}) \\ &= \vec{h}_{rx}\cdot\left(\vec{E}_{ref}\cdot 10^{-PL_{free}/20}\cdot e^{-j(2\pi df/c)}\right) \end{aligned} \tag{3}$$

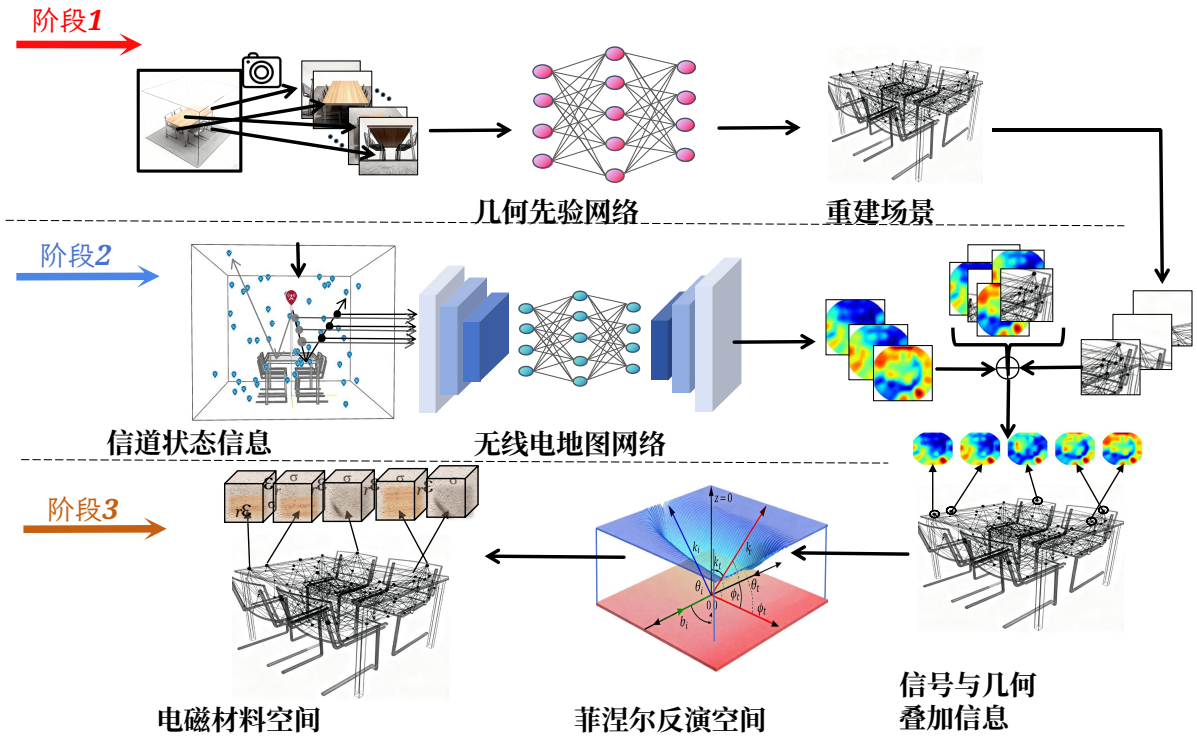


图3. 我们的框架将具有挑战性且适定性差的电磁逆问题系统地解耦为三个不同阶段。(1) 第一阶段以高保真度重建几何支架（G）。(2) 阶段 2 重建环境无线电场（f_θ）。(3) 阶段 3 将冻结的 G和 f_θ 用作先验，执行最终的物理监督反演，以求得材料属性（g_ϕ）。

$$PL_{free} = 20\log_{10}(4\pi df/c) \tag{4}$$

因此，该逆问题高度耦合：c_i^{obs}取决于 G（其定义了 d 和 θ_i）、J（其定义了材料的 ϵ_r，σ）以及 E_{inc}，而这些全都是未知的。我们的框架旨在依次解耦这些未知量。

3.2. 第一阶段：几何先验重建

在第一阶段，我们的目标是从多视角拍摄的图像中解耦并固定场景的几何结构。我们采用 **instant-ngp-bound**框架 [26], ，该框架以高保真度训练神经符号距离函数（符号距离函数）。该网络由 f_{sdf} 参数化，使用多分辨率哈希网格，高效地将三维空间坐标 x 映射到其符号距离值$f_{sdf}(x)$。训练完成后，我们提取其零水平集 $\mathcal{S}$ $=\{x|f_{sdf}(x) = 0\}$作为表面，并将其梯度 $\nabla f_{sdf}(x)$作为表面法向量$\mathbf{n}$。二者共同构成固定的几何先验 $G = (\mathcal{S},\mathbf{n})$。该先验至关重要，因为它为后续物理计算提供了精确的表面边界、交互点位置（x_{refl}）以及几何基础（例如入射平面、入射角 θ_i）。

3.3. 阶段 2：环境场重建

在几何结构 G 冻结后，第二阶段旨在重建环境入射场 E_{inc}。我们使用无线电地图网络 f_θ来表示该场。该网络旨在学习随空间变化的入射场的连续表示，并基于 NeWRF [22]实现为多层感知机（多层感知机）。它作为一个可查询网络 f_θ（x，$\mathbf{d}$），用于预测从任意方向 $\mathbf{d}$到达任意位置 x的复电场矢量 $\vec{E}_{inc}^{pred}$ 。

为了以逻辑一致的方式训练 f_θ，我们必须使用其预期目标对其进行监督。利用合成数据集，我们可以在任意六维查询点计算**真实值入射电场**，$\vec{E}_{inc}^{GT}(x,\ \mathbf{d})$。随后，我们以完全监督的方式训练$f_\theta$，使其复现这一真实入射场。在优化过程中，我们针对一批采样点 P 最小化 L2 损失：

$$\mathcal{L}_{field} = \frac{1}{|P|}\sum_{(x,\mathbf{d})\in P} \|f_\theta(x,\mathbf{d}) - \vec{E}_{inc}^{GT}(x,\mathbf{d})\|_2^2 \tag{5}$$

我们还引入一个正则化项，以确保预测场的空间连续性：

$$\mathcal{L}_{reg} = \lambda\mathbb{E}_{(x,\mathbf{d})}\left[\|\nabla f_\theta(x,\mathbf{d})\|_2^2\right] \tag{6}$$

总损失为 $\mathcal{L}_{total} = \mathcal{L}_{field} + \lambda_{reg}\mathcal{L}_{reg}$，其中 λ_{reg} 是一个超参数。一旦该损失收敛，f_θ 网络即被冻结。此时它作为最终阶段中确定性且可查询的入射场先验。在最终阶段，几何结构 G与场 f_θ 均被冻结后，我们使用解码器 g_ϕ求解材料参数。该阶段利用前两个阶段的输出，构成一个适定的监督学习任务。

3.4. 阶段 3：物理监督材料反演

在最后阶段，几何结构 G 和场 f_θ均被冻结后，我们使用解码器 g_ϕ求解材料参数。此阶段利用前两个阶段的输出，构建一个定义良好的监督学习任务。

首先计算目标标签，$\mathbf{\Gamma}_{GT}$。对于给定的反射点 x 及其对应的测量值 c_i^{obs}，我们查询冻结的无线电地图网络，获得 $\vec{E}_{inc}^{pred}$。与此同时，我们对测量值 c_i^{obs}应用算子 $\mathcal{P}^{-1}$，该算子通过逆转自由空间中的传播过程来反转传播模型，从而计算反射场$\vec{E}_{ref}^{comp}$。已知这两个场后，我们求解公式2中的线性系统，计算该点和频率对应的目标琼斯矩阵 $\mathbf{\Gamma}_{GT}$。

我们的解码器 g_ϕ 并非简单的多层感知机，而是一种专门设计的网络架构，旨在将几何点映射到其底层物理属性，这些属性与频率无关。其输入是由几何先验提供的点 $P1$ 的三维坐标x。该坐标经过一种复杂的并行编码方案处理。此方案结合了经典的正弦基函数（用于捕获低频空间上下文）和高容量多分辨率哈希网格。哈希网格对此任务至关重要，因为它通过插值多个不同分辨率层级的哈希表条目，学习将坐标映射为丰富的特征表示。这种设计使网络能够高效捕获精细的几何细节和空间变化。两个编码器生成的特征经过拼接后，输入深层残差多层感知机。随后，该解码器输出一个四维潜向量（a，b，c，d）。使用 Sigmoid 函数的边界层可确保这些参数处于物理上合理的范围内。

该潜向量使用幂律关系对材料的物理频率色散进行建模。具体而言，a 和 b 对介电常数 ϵ_r进行建模，而 c 和d 对电导率 σ进行建模，两者均为频率 f的函数：

$$\hat{\epsilon}_r(f) = a \cdot f^b \tag{7}$$

$$\hat{\sigma}(f) = c \cdot f^d \tag{8}$$

该潜向量（a，b，c，d），连同几何角度θ_i 和特定查询频率 f_c，随后由我们的可微反射层 $\mathcal{R}_{Frl}$ 解析。该层

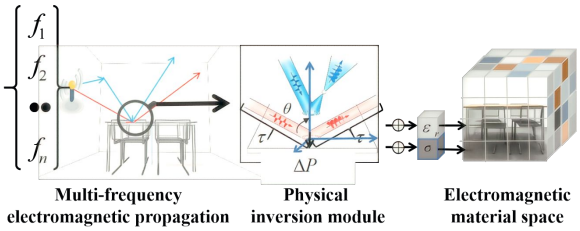


图 4. 菲涅尔反演空间。反射与材料参数（ϵ_r，σ）之间复杂的非线性关系凸显了逆问题的歧义性。利用多个频率的数据，可以稳健地约束我们 $\mathcal{L}_{total}$的解。

不可训练，负责执行正向物理计算。首先，它会计算给定频率下的材料属性：$\hat{\epsilon}_r(f_c)$ 和 $\hat{\sigma}(f_c)$，使用公式 7 和 8。随后，它将这些值代入可微菲涅耳方程：

$$r_p = \frac{\eta_2 \cos\theta_i - \eta_1 \cos\theta_t}{\eta_2 \cos\theta_i + \eta_1 \cos\theta_t} \tag{9}$$

$$r_s = \frac{\eta_1 \cos\theta_i - \eta_2 \cos\theta_t}{\eta_1 \cos\theta_i + \eta_2 \cos\theta_t} \tag{10}$$

其中，阻抗 η 是根据依赖于频率的预测属性计算得出的：$\eta = \sqrt{\mu/(\hat{\epsilon}_r(f_c) - j\hat{\sigma}(f_c)/(\omega\epsilon_0))}$。虽然我们的解码器学习（$a$，$b$，$c$，$d$），但它也可以学习交叉极化项（$\hat{r}_{ps}$，$\hat{r}_{sp}$）。该层组装出完整的琼斯矩阵 $\mathbf{\Gamma}_{pred}$，它不是对角矩阵：

$$\mathbf{\Gamma}_{pred}(f_c) = \mathcal{R}_{Frl}(g_\phi(x), \theta_i, f_c) = \begin{pmatrix} r_p & \hat{r}_{ps} \\ \hat{r}_{sp} & r_s \end{pmatrix} \tag{11}$$

最终优化损失是通过计算该预测 $\mathbf{\Gamma}_{pred}(f_c)$ 与我们计算得到的真实值 $\mathbf{\Gamma}_{GT}(f_c)$ 之间的差异得出的。总损失 $\mathcal{L}_{total}$ 将主要物理目标与正则化项相结合，以确保训练稳定，并防止高容量哈希网格发生过拟合。主要损失 $\mathcal{L}_{NMSE}$ 是**归一化均方误差**，对所有频率 ω求和：

$$\mathcal{L}_{NMSE} = \sum_{\omega} \frac{\|\mathbf{\Gamma}_{GT} - \mathbf{\Gamma}_{pred}\|_F^2}{\|\mathbf{\Gamma}_{GT}\|_F^2} \tag{12}$$

为控制哈希网格的复杂度，我们对其嵌入权重施加 L2正则化 $\mathcal{L}_{hash}$，并对其层级门控施加L1稀疏正则化 $\mathcal{L}_{gate}$。最终的组合损失函数为：

$$\mathcal{L}_{total} = \mathcal{L}_{NMSE} + \lambda_{hash}\mathcal{L}_{hash} + \lambda_{gate}\mathcal{L}_{gate} \tag{13}$$

其中，λ_{hash} 和 λ_{gate} 是用于平衡保真度与正则化的超参数。通过优化这一损失，梯度会流经可微反射层，并

通过残差多层感知机和哈希网格进行反向传播。这一监督过程促使网络 g_ϕ 找到可解释的参数（a， b， c，d），这些参数与频率无关且基于物理学，能够最充分地解释观测到的反射行为。

4. 实验

我们开展了一系列全面的实验，以严格验证 NEMF 框架。首先，我们证明了该框架在材料反演准确度方面显著优于“黑盒”多层感知机基线方法。随后，我们通过系统的消融研究，剖析哈希网格框架中的具体架构选择如何定量影响多个场景下的性能。最后，我们探索了 LBFGS 微调和加权损失等先进优化策略，以进一步提高反演的物理准确度。

4.1. 实验设置

几何先验（第一阶段）。我们首先使用 **instant-ngp-bound** 框架，基于每个场景多个视角拍摄的 100 张图像，训练高保真的符号距离函数（SDF）模型。这为我们的第二阶段物理反演提供了所需的高分辨率固定几何先验 G（表面点 P1、法线）。

数据集。我们的物理反演实验采用三个室内场景的高保真合成数据集：办公室、卧室和会议室，如图5所示。每个场景的近似体积为5米 $\times$ 4米 $\times$ 3米，并包含多种物理材质，包括混凝土、木材和玻璃，因而具有多样的材料参数（ϵ_r 和 σ）。数据生成过程采用基于 MATLAB 的模拟器进行严格的射线追踪，并考虑高频下的多次反射和复杂衍射效应。该过程仅在一个固定发射器（TX）对应的 500 个随机接收器（RX）位置采集稀疏 CSI测量（G_{true}）。生成的数据集具有高度稀疏性，准确体现了实际非侵入式测量场景中的挑战。数据始终以 8 个离散频率（2.4–5.8 GHz）进行采样。

评估指标。 虽然我们的模型采用复数均方误差损失进行训练，以便于梯度传播，但有效的评估需要使用工程师易于理解的物理指标。我们采用分层指标体系。第一层针对潜在空间，报告中间物理参数的平均绝对误差（**ABCD平均绝对误差**）。最终也是最关键的指标用于量化解码后的材料属性：**介电常数（ϵ_r 平均相对误差）**和**电导率（σ 平均相对误差）**。这些最终指标采用平均相对误差，因为 ϵ_r 和 σ 在不同材质中的目标值跨越多个数量级，因此相对比较对于公平评估物理保真度至关重要。

实现细节。所有模型均使用 PyTorch 实现 [29]，并在单张 NVIDIA RTX 4090 GPU 上训练。我们使用 Adam优化器 [16]，批量大小为 32768。除非另有说明（在消融实验中），我们的 NEMF 模型均采用**Arch-0** 配置（见表2），MLP 的学习率为 1.0×10^{-3}，哈希网格的学习率为 5.0×10^{-4}，并由`ReduceLROnPlateau`进行调度。

4.2. 主要结果：框架比较

我们首先将 NEMF 框架与“黑盒”MLP 基线进行比较。

基线方法（MLP）。MLP 基线代表标准的神经场方法。它们将坐标与频率拼接后的向量经过位置编码后作为输入。随后，使用单个 MLP 直接预测复响应 G_{pred}。这种“纠缠式”架构只能通过一组权重，同时学习空间几何结构以及依赖频率的物理特性。我们测试了多种配置，并报告性能最强的变体：一个八层、八频率的模型。

我们的模型（NEMF）。如第3节所详述，我们的模型将这个问题解耦。强大的哈希网格学习空间特征 $f(\mathbf{x})$，随后由多层感知机将其映射为物理参数（a， b， c， d），这些参数与频率无关。最后，非可训练层会计算响应 $G_{\text{pred}} = \mathcal{P}(a,\ b,\ c,\ d,\ f_c)$，该响应则取决于频率。

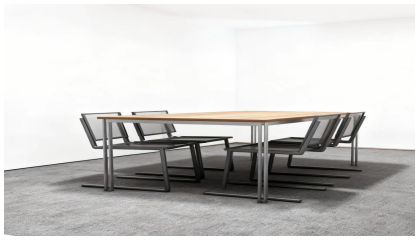
定量比较。**表1** 按场景细分展示了定量比较结果。结果明确无疑。我们的 NEMF 框架（采用强大的 **Opt-B**配置）在所有关键物理指标上均显著优于最强的 MLP 基线。基线的平均 *Eps* 平均相对误差为 0.078，而我们的物理解耦框架将误差降低了七倍以上，降至 0.011。*Sigma* 平均相对误差也有大幅改善，我们的模型将误差从 0.639 降至 0.317，减少了一半以上。这证实了我们的假设：纠缠式“黑箱”架构从根本上不适用于这一问题，而我们的物理解耦框架则显著且稳定地提升了准确度。



(a) 办公室场景



(b) 卧室场景



(c) 会议室

图 5. 合成数据集中使用的三个室内场景。我们使用这些高保真几何模型，通过射线追踪生成第一阶段所需的多视角图像，以及阶段 2 所需的稀疏 CSI 数据。

表 1. 按场景细分，与最强多层感知机基线的主要定量比较。我们的解耦 NEMF 框架在所有测试环境中均显著且持续地降低了材料反演误差。

模型	会议室 Eps 平均相对误差 ↓	会议室 Sigma 平均相对误差 ↓	卧室 Eps 平均相对误差 ↓	卧室 Sigma 平均相对误差 ↓	办公室 Eps 平均相对误差 ↓	办公室 Sigma 平均相对误差 ↓
MLP 基线（8 层，8 个频率）	0.071	0.497	0.102	0.774	0.062	0.647
我们的方法（NEMF，Opt-B）	**0.021**	**0.164**	**0.004**	**0.114**	**0.007**	**0.672**

4.3. 深入消融研究

在确认我们的框架在宏观层面具有优越性后，我们开展了系统的消融研究，以剖析 NEMF 的内部组件。

架构组件（Arch-0 至 Arch-7）。我们首先分析“静态”架构选择的影响。我们建立了一个中等容量基线（**Arch-0**），并系统地每次只改变一个组件。三个场景的结果详见**表2**。分析该表可发现若干细微之处，而这些发现都在各个场景中表现出显著的一致性。首先，**PE 频率(Arch-1)** 的影响并不一致：办公室和卧室场景的*Eps* 平均相对误差略有改善，而会议室场景则有所退化。这表明哈希网格是主要的特征提取器，因此模型对 PE 带宽不太敏感。**至关重要的是，容量消融实验也反映了几何先验的质量**。其次，我们探究了**哈希容量**。提高容量，尤其是采用（**Arch-6**）这类极端组合，在更复杂的会议室(0.013 → 0.006) 和卧室(0.029 → 0.011) 场景中带来了显著提升。这凸显了模型容量与场景复杂度之间明显的权衡：更好的哈希编码能够更准确地提取表面法线。最后，我们验证了**关键机制**。禁用门控机制（**架构-7**）或跳跃连接（未显示）都会导致性能持续下降，证实了它们的必要性。

优化策略（Opt-A 至 Opt-F）。接下来，我们分析“动态”训练策略，其在所有场景中的结果汇总于表 3。这些结果揭示了几个重要见解。首先，也是最重要的一点，使用 LBFGS 进行微调（Opt-B）相比仅使用 Adam 的基线（Opt-A），带来了显著且稳定的提升。在会议室中，Eps 平均相对误差降低了 ∼42%，在卧室中更是大幅降低 ∼83%，在办公室中降低了 ∼59%。这表明，尽管我们的损失景观较为复杂，但通过二阶优化可以获得极大收益。其次，对比 Opt-B 与 Opt-F 可见，仅微调多层感知机几乎没有任何收益，甚至会导致性能下降。这证明 LBFGS 带来的提升源于对整个网络进行微调，尤其是对哈希网格嵌入进行微调。第三，极端容量（Opt-C）的结果喜忧参半：在卧室场景中，其表现不及标准的 Opt-B，说明 Opt-B 在模型容量与优化之间达到了最佳平衡。最后，加权损失策略（Opt-E）未能带来预期收益，表现逊于 Opt-B 基线，说明这是一个需要谨慎权衡的因素。

4.4. 定性分析与局限性

定性结果。 我们的定性分析为定量结果提供了明确的视觉验证。我们观察到，MLP 基线完全失效。其预测结果充满噪声、空间分布不均匀，与底层几何结构毫无对应关系。这证明了它无法学习物理与几何耦合。相比之下，我们的 NEMF 框架（采用 Opt-B 配置）重建出的材料图具有空间一致性，在材料界面处呈现清晰的边界，并且符合物理规律。这些重建图与真实值高度吻合。至关重要的是，我们模型中的残余预测误差并非随机产生，而是几乎完全局限于

表 2. NEMF 架构组件的消融研究。我们报告了全部三个场景中的关键物理指标。基线（**Arch-0**）已突出显示。禁用核心组件（Arch-1、7、8）会持续导致性能严重下降。

ID	组件	配置	会议室 Eps 平均相对误差 ↓	会议室 Sigma 平均相对误差 ↓	卧室 Eps 平均相对误差 ↓	卧室 Sigma 平均相对误差 ↓	办公室 Eps 平均相对误差 ↓	办公室 Sigma 平均相对误差 ↓
架构-0	**基线配置。**	**位置编码 L=16, L=10, 分辨率=24, 特征=8, 门控=开启**	**0.013**	**0.447**	**0.029**	**0.837**	**0.013**	**0.710**
架构-1	PE 频率	位置编码 L=10	0.015	0.552	0.027	0.816	0.008	0.705
架构-2	哈希层	L=12	0.007	0.353	0.025	0.818	0.015	0.690
架构-3	哈希分辨率	基础分辨率=32	0.012	0.467	0.027	0.811	0.014	0.708
架构-4	架构-2 + 架构-3	L=12, 残差=32	0.012	0.556	0.015	0.399	0.016	0.704
架构-5	哈希特征	特征=16	0.011	0.509	0.023	0.806	0.007	0.634
架构-6	架构-2 + 架构-5	L=12, 特征=16	**0.006**	**0.335**	**0.011**	**0.367**	0.017	0.697
架构-7	门控	门控=关闭	0.017	0.569	0.027	0.809	0.015	0.705

表 3. 优化策略的消融研究。我们报告所有场景中最终的 *Eps* (ϵ_r) 平均相对误差 和 *Sigma* (σ) 平均相对误差 。

ID	配置	策略	会议室 Eps 平均相对误差 ↓	会议室 Sigma 平均相对误差 ↓	卧室 Eps 平均相对误差 ↓	卧室 Sigma 平均相对误差 ↓	办公室 Eps 平均相对误差 ↓	办公室 Sigma 平均相对误差↓
Opt-A	中等容量	基线（W256/D6）	0.036	0.334	0.024	0.763	0.017	0.713
Opt-B	**高容量**	**+ LBFGS微调**	**0.021**	**0.164**	**0.004**	**0.114**	**0.007**	**0.672**
Opt-C	极端容量	+渐进式解冻	0.021	0.145	0.025	0.847	0.015	0.680
Opt-D	中等容量	+ 渐进式解冻	0.046	0.352	0.023	0.773	0.013	0.708
Opt-E	高容量（B）	+ 高频损失权重	0.020	0.123	0.037	0.348	0.015	0.681
Opt-F	中等容量	+ LBFGS（仅多层感知机）	0.035	0.331	0.028	0.781	0.015	0.708

复杂的几何边界和尖角区域。这一视觉证据证实，残余误差的主要来源是这些困难区域中局部法向量（$\mathbf{n}$）推导的几何不稳定性，而不是核心材料反演逻辑失效。这一视觉确认进一步强化了消融研究所展示的模型对法向量精度的敏感性。

局限性。 尽管取得了出色的结果，我们的框架仍存在局限性。首先，阶段 2 反演的性能高度依赖于第一阶段提供的几何先验的准确度。从推导得到的法向量（$\mathbf{n}$）或入射角（θ_i）中的任何误差，都会通过菲涅耳方程非线性地传播，导致局部预测失效。其次，目前我们的验证基于高保真的合成数据。真实世界的 CSI 测量值会引入更复杂的噪声特征、硬件校准误差以及更严重的多径效应，这些问题留待未来工作解决。

5. 结论

在本文中，我们提出了神经电磁场（NEMF），这是一种利用多种模态重建功能性数字孪生的新框架。我们从非侵入式视觉信号和射频信号中反演电磁材料属性。我们表明，通过系统地解耦这一不适定的逆问题，我们以高保真的几何结构锚定该过程，从而解析环境场。这将任务转化为由物理学监督的适定学习问题。我们的核心贡献包括用于解耦的序贯流水线以及可微的反射层，能够精确恢复连续材料图（ϵ_r， σ）。

在多种合成场景中开展的实验表明，NEMF 在材料反演准确度方面显著优于基线方法，误差降低了一个数量级。由此得到的功能孪生体能够高保真地支持下游类型的仿真，从而弥合视觉外观与物理交互之间的差距。

尽管我们的框架推动了非侵入式物理建模的发展，但其验证仍依赖合成数据。未来的工作将拓展至真实世界的测量值，并纳入对噪声的鲁棒性以及与新兴 6G感知协议的集成。这将为机器人学、增强现实/虚拟现实和无线优化领域的应用开辟新途径，推动构建真正可仿真的数字世界。

参考文献

[1] Constantine A. Balanis. 《天线理论：分析与设计》. John Wiley & Sons，第4版，2015年。 3[2] Jonathan T. Barron、Ben Mildenhall、Matthew Tancik、Peter Hedman、Ricardo Martin-Brualla 和 Pratul P. Srinivasan。Mip-NeRF：用于抗锯齿神经辐射场的多尺度表示。载于国际计算机视觉大会，第5855–5864页，2021年。 2[3] M. Born 和 E. Wolf。《光学原理：光传播、干涉与衍射的电磁理论》。剑桥大学出版社，第7版，1999年。 3[4]Andrew Carlson、Jialin Lv、Hao Wu、Mohsen Soltani、Zhaoyang Wang 和 Danijela Cabric。RF-3DGS：利用无线电辐射场和 3D 高斯泼溅进行无线信道建模。arXiv预印本 arXiv:2411.19420，2024年。 2[5] L. Cazzella、F. Linsalata、D. Badini、M. Matteucci、M. Magarini 和 U. Spagnolini。高保真射频映射：评估6G网络数字孪生中的环境建模。arXiv预印本 arXiv:2507.19173，2025年。 3

[6] Y. Chen 和 Z. Wang。人工电磁材料的逆向深度学习方法与基准。Nanoscale，14(10):1234–1245，2022年。3[7] Z. Chen、Y. Guo、A. Al-Dhelaan 和 M. Al-Farabi。利用神经对象表示进行射频射线追踪。arXiv预印本 arXiv:2411.18635，2024年。2[8] David Colton 和 Rainer Kress。《反问题声学与电磁散射理论》。Springer，第4版，2019年。3[9] Sara Fridovich-Keil、Alex Yu、Matthew Tancik、Qinhong Chen、Benjamin Recht 和 Angjoo Kanazawa。Plenoxels：无需神经网络的辐射场。载于 CVPR，第5501–5510页，2022年。2[10] E. Haber 和 U. Ascher。用于大型稀疏参数估计问题的预条件整体求解方法。Inverse Problems，20(6):1847–1864，2004年。3[11] Eugene Hecht。《光学》。Pearson，第5版，2017年。2[12] J. D. Jackson。《经典电动力学》。John Wiley & Sons，第3版，1999年。2, 3[13] Bernhard Kerbl、Georgios Kopanas、Thomas Leimk¨uhler 和 George Drettakis。用于实时辐射场渲染的3D高斯泼溅。载于 ACM TOG，2023年。2[14] H. Kim 和 S. Park。用于电磁仿真的物理信息图神经网络。Engineering Applications of Artificial Intelligence，120:105678，2025年。3[15] S. Kim 和 J. Lee。用于材料属性的近场毫米波MIMO雷达逆向渲染。IEEE Transactions on Microwave Theory and Techniques，2025年。3[16] Diederik P. Kingma 和 Jimmy Ba。Adam：一种随机优化方法。载于 ICLR，2015年。6[17] Xuan Li、Yi-Ling Qiao、Peter Yichen Chen、Krishna Murthy Jatavallabhula、Ming Lin、Chenfanfu Jiang、Chuang Gan 和 Florian Shkurti。PAC-NeRF：用于几何无关系统辨识的物理增强连续神经辐射场。载于 ICLR，2023年。2[18] X. Li、J. Yu、Y. Jin 等。NeRF2：神经射频辐射场。载于第29届年度国际移动计算与网络会议（MobiCom）论文集，2023年。2[19] Y. Li 和 J. Wang。一种改进的对比源反演方法，用于乳腺电磁成像。Journal of Electromagnetic Waves and Applications，36(12):1–20，2022年。3[20] Y. Lin、G. Feng、J. Wang、F. Dressler 和 C. You。迈向6G：愿景、需求、关键技术与测试平台。IEEE Communications Surveys & Tutorials，25(2):905–974，2023年。3[21] Zifan Long、Wei Lu、Jannes Vattheuer 和 Gregory W. Wornell。GWRF：可泛化无线辐射场。arXiv预印本 arXiv:2407.03943，2024年。2[22] W. Lu、J. Vattheuer、Y. Yang 和 G. W. Wornell。NeWRF：用于无线辐射场重建和信道预测的深度学习框架。arXiv预印本 arXiv:2403.03241，2024年。2, 4[23] MathWorks。通信系统的射线追踪分析。MATLAB文档，未注明日期。访问日期：2025年11月12日。 [在线]。可访问：h
ttps://www.
mathworks.com/help/comm/ref/raytrace.html。3
[24] B. Mildenhall、P. P. Srinivasan、M. Tancik 等。NeRF：将场景表示为用于视图合成的神经辐射场。《ACM通讯》，65(1):99–106，2021年。2[25] Maximilian S. Muehlhaus、Simon Baesch、Kilian Frohnholzer、Matthias Hollick 等。Radio-NeRF：通过神经辐射场验证测距。在第16届ACM无线与移动网络安全和隐私会议（WiSec）论文集，2023年。2[26] Thomas M¨uller、Alex Evans、Christoph Schied 和 Alexander Keller。采用多分辨率哈希编码的即时神经图形基元。在 ACM TOG，2022年。2，4[27] Jacob Munkberg、Jo n Hasselgren、Tianchang Shen、Jun Gao、Wenzheng Chen、Alex Evans、Thomas M¨uller 和 Sanja Fidler。从图像中提取三角形3D模型、材质和照明。在 CVPR，第8280–8290页，2022年。2[28] Jeong Joon Park、Peter Florence、Julian Straub、Richard Newcombe 和 Steven Lovegrove。DeepSDF：学习用于形状表示的连续有符号距离函数。在 CVPR，第165–174页，2019年。2[29] Adam Paszke、Sam Gross、Francisco Massa、Adam Lerer、James Bradbury、Gregory Chanan、Trevor Killeen、Zeming Lin、Natalia Gimelshein、Luca Antiga、Alban Desmaison、Andreas Kopf、Edward Yang、Zachary DeVito、Martin Raison、Alykhan Tejani、Sasank Chilamkurthy、Benoit Steiner、Lu Fang、Junjie Bai 和 Soumith Chintala。PyTorch：一种命令式风格的高性能深度学习库。在 NeurIPS，2019年。6[30] M. Raissi、P. Perdikaris 和 G. E. Karniadakis。物理信息神经网络：用于求解涉及非线性偏微分方程的正向和逆向问题的深度学习框架。《计算物理学杂志》，378:686–707，2019年。3[31] L. I. Rudin、S. Osher 和 E. Fatemi。基于非线性全变分的去噪算法。《物理学D：非线性现象》，60(1-4):259–268，1992年。3[32] A. Smith 和 B. Johnson。用于电磁波传播的统一、可验证神经模拟器。arXiv预印本 arXiv:2404.00545，2024年。3[33] P. Testolina、M. Polese、M. Matteucci、M. Magarini 和 U. Spagnolini。BostonTwin：用于6G网络光线追踪的波士顿数字孪生。arXiv预印本 arXiv:2403.12289，2024年。3[34] Dor Verbin、Peter Hedman、Ben Mildenhall、Todd Zickler、Jonathan T. Barron 和 Pratul P. Srinivasan。Ref-NeRF：神经辐射场的结构化视角相关外观。在 CVPR，第5481–5490页，2022年。2[35] J. Wang、Y. Zhang、L. Liu、Y. Zhao 和 X. Sun。基于无线电环境知识池构建面向6G的数字孪生信道。arXiv预印本 arXiv:2312.10287，2023年。3[36] J. Wang、Y. Zhang、L. Liu、Y. Zhao 和 X. Sun。R-NeRF：用于建模 RIS赋能的电磁场的神经辐射场。arXiv预印本 arXiv:2405.11541，2024年。2[37] Peng Wang、Lingjie Liu、Yuan Liu、Christian Theobalt、Taku Komura 和 Wenping Wang。NeuS：通过体渲染学习用于多视图重建的神经隐式表面。在 NeurIPS，第27171–27183页，2021年。2

[38] X. Wang 和 Y. Chen。物理信息深度对比源反演：用于逆散射问题的统一框架。arXiv预印本 arXiv:2508.10555，2025年。3[39] X. Wang、Y. Chen 和 M. Li。面向6G及未来的网络数字孪生：跨多域网络生态系统的端到端视角。arXiv预印本 arXiv:2506.01609，2025年。3[40] Lior Yariv、Jiatao Gu、Yoni Kasten 和 Yaron Lipman。神经隐式表面的体渲染。在 NeurIPS，第4805–4815页，2021年。2[41] K. Yee。涉及麦克斯韦方程的初始边值问题的数值解，适用于各向同性介质。IEEE天线与传播汇刊，14(3):302–307，1966年。3[42] J. Yu、Z. Shi、M. Li 和 Y. Chen。ChannelGPT：用于生成面向6G环境智能的数字孪生信道的大型模型。arXiv预印本 arXiv:2410.13379，2024年。3[43] H. Zhang 和 M. Li。基于嵌入式解析模型的物理信息神经网络电磁周期结构逆向设计方法。IEEE天线与传播汇刊，2024年。3[44] Kai Zhang、Fujun Li、Zhe Luan、Ziyang Li、Sai Bi、Baining Wang、Wenguan Chen、Jue S 和 Jian Chang。PhysG：基于物理材质和激光雷达的逆向渲染。在 CVPR，2021年。2[45] L. Zhang 和 H. Liu。ICSI：一种改进的电磁逆散射对比源反演方法。《光学快报》，31(4):5426–5440，2023年。3[46] Xiuming Zhang、Pratul P. Srinivasan、Boyang Deng、Paul Debevec、Ben Mildenhall 和 Jonathan T. Barron。Nerfactor：未知照明下形状与反射率的神经因式分解。ACM TOG，40(6):1–18，2021年。2[47] Yuedong Zhang、Mohammed Abumuaileq、Athanasios Kakkavas、Anas S. Chekkouri、Henk Wymeersch 和 Giuseppe Caire。Signal-NeRF：在三维空间中重建无线通信信号。在 IEEE 国际通信会议（ICC）研讨会论文集，2023年。2