

DeepTelecom: 适用于信道和 MIMO 应用的数字孪生深度学习数据集

Bohao Wang^{*†}, Zehua Jiang^{*}, Zhenyu Yang^{||}, Chongwen Huang^{*†}, Yongliang Shen[§], Siming Jiang^{‡‡}, Chen Zhu^{††}, Zhaohui Yang^{*}, Richeng Jin^{*}, Zhaoyang Zhang^{*}, Sami Muhaidat^{**}, and Mérouane Debbah[¶] *Fellow, IEEE*

^{*} College of Information Science and Electronic Engineering, Zhejiang University, 310027, Hangzhou, China

[†] State Key Laboratory of Integrated Service Networks, Xidian University, 710071, Xi'an, China

^{||} School of Earth Sciences, Zhejiang University, 310027, Hangzhou, China

[§] College of Computer Science and Technology, Zhejiang University, 310027, Hangzhou, China

^{‡‡} Guangdong Tobacco Maoming Co., Ltd., 525000, Maoming, China

^{††} Polytechnic Institute, Zhejiang University, 310015, Hangzhou, China

^{**} Computer and Communication Engineering, Khalifa University, P.O. Box: 127788, Abu Dhabi, UAE

[¶] KU 6G Research Center, Khalifa University of Science and Technology, P O Box 127788, Abu Dhabi, UAE

摘要—特定领域的数据集是释放人工智能 (AI) 驱动的无线创新的基础。然而, 现有的无线 AI 语料库生成速度慢, 提供的建模保真度有限, 并且仅涵盖狭窄的场景类型。为了解决这些挑战, 我们创建了 DeepTelecom, 这是一个三维数字孪生信道数据集。具体来说, 一个大型语言模型 (LLM) 辅助的流水线首先构建详细程度第三级 (LoD3) 的室外和室内场景, 带有可分割材料参数化的表面。然后, DeepTelecom 基于 Sionna 的光线追踪引擎模拟完整的无线电波传播效应。利用 GPU 加速, DeepTelecom 流式传输光路轨迹和实时信号强度热图, 并将它们编译成高帧率视频, 同时输出同步多视角图像、信道张量和多尺度衰落轨迹。通过高效地流式传输大规模、高保真度和多模态的信道数据, DeepTelecom 不仅为无线 AI 研究提供了一个统一的基准, 还提供了富含领域的训练基质, 使基础模型能够将大型模型智能与未来的通信系统紧密融合。

Index Terms—3D 数字孪生, 大型语言模型, 光线追踪, 无线 AI, 信道模型。

I. 介绍

受第六代 (6G) 移动通信快速发展的驱动, 无线系统正朝着超高速数据传输、超低延迟、极高可靠性和无处不在的覆盖范围迈进。与第五代 (5G) 不同, 6G 将通过在物理层嵌入人工智能 (AI) 原生、亚太赫兹以及现实和虚拟共设计的信号处理技术, 成为智能社会的核

心基础设施。AI, 特别是大型模型 (LMs) 与多模态学习的融合, 为实现这些目标提供了新的路径, 通过对庞大且异构的空间时间数据进行学习和推理, 使 6G 网络从连接性转向人工智能 [1]。

将 AI 和 LMs 集成到无线通信中, 从根本上依赖于构建高保真和大规模的训练数据集 [2]。光线追踪仍然是主流解决方案: 在一个三维 (3D) 数字孪生场景中, 它虚拟放置基站 (BSs)、移动终端 (MTs) 和可重构智能表面 (RISs), 然后确定性地跟踪电磁路径以得出逐点信道特性 [3]。尽管像华为 [4]、北邮 [5], [6]、东南大学的 PML-6GPCS 模拟器 [7], [8] 以及北京大学 [9] 这样的工业和学术先锋已经试点了无线-AI 数据集项目, 但它们仍然依赖于基于 CPU 的光线追踪器, 其数十亿光线运行速度慢、模式有限且需要费力校准, 导致数字孪生模型局限于第一级细节 (LoD1), 没有材料级别的标注。相比之下, 开源或商业工具链如 DeepMIMO [10]、ViWi [11]、WiThRay [12]、Ranplan 和 NVIDIA Sionna [13] 展示了 GPU 加速的多频段光线追踪和 3D 渲染, 但目前没有一个将材料感知重建与可微分的精确物理光线追踪在集成工作流中结合在一起。

为应对这些挑战, 我们生成了 DeepTelecom, 这是




图 1. 整体的 DeepTelecom 框架。

一个第三级细节 (LoD3) 的 3D 数字无线信道语料库，它吸收了 openstreetmap，并在整个工作流程中保留每面材料的语义。在大型语言模型 (LLM) 的指导下，该模型将文本标签转换为频率依赖的介电常数和磁导率张量，引擎参数化地配置发射器、接收器和 RIS，系统性地捕捉不同材料特性和操作条件下信道的多样性。它通过混合几何光学和几何衍射求解器解决传播问题，基于 Sionna 可微 GPU 追踪器处理镜面反射、折射、衍射和散射效应，在保持自动梯度能力的同时，支持超过 1000 万光线的吞吐量。对于每条路径，管道输出路径损耗、延迟、角度、相位、偏振和多普勒，并同时栅格化热图和 RGB 叠加层，最后将同步图像、MP4 视频、HDF5 信道张量和 CSV 清单封装在统一的场景索引下，从而提供融合视觉、张量和表格视图的完整开放多模态数据集，用于端到端的 6G AI 研究。该数据集和实现部分在线可用。¹

本文的其余部分组织如下。在第二节中，我们介绍了 DeepTelecom 框架的整体架构。在第三节中，我们提供了对其四个核心模块实现的详细描述。第四节展示了生成场景的通用性和所得数据集的多样性。最后，第五节总结了本文。

II. 框架概述

为了创建一个高保真的多模态 LoD3 GPU 加速光线追踪数据集**深电讯**，我们将数据集生成工作流分为四

个主要组件。完整的框架如图 1 所示，每个组件概述如下：

- **LLM 辅助的高保真多源场景建模：**我们开发了一个由 LLM 辅助的高精度场景建模管道，用于构建室内和室外环境的 LoD3 数字孪生。此模块集成了多种数据源（例如卫星图像、3D 数据集和激光雷达扫描）以生成与准确几何结构相结合的真实纹理，并导出到行业标准的 3D 格式。生成的室内模型捕捉复杂内部的细微细节，而室外模型可以高保真地覆盖城市区域。随后的一个基于 LLM 的后处理步骤将包含所有可区分物体的重建场景转换为结构化的 XML 描述。在此 XML 中，每个表面都明确定义并标注了其电磁材料属性。这种全面的场景表示紧密镜像现实世界的几何形状和电磁行为，为后续的光线追踪模拟提供了坚实的基础。
- **参数定义与配置：**环境建模之后，我们配置仿真参数，这些参数分为两类：定义硬件和设备的系统参数，以及控制数据生成过程的生成参数。系统配置涉及在特定三维位置部署 BSs 和 MTs，并且具有定义的方向和发射功率。为了捕捉现实的信道动态变化，可以模拟 MTs 的移动并引入时变噪声。BSs 和 MTs 都配备了可配置的多输入多输出 (MIMO) 天线阵列，其尺寸和元素间距对于准确建模空间信道特性至关重要。可选地，可以在场景中集成 RIS，配置为单束聚焦或多波束形成以智能控制信号传播。最后，定义系统的带宽，这决定了生成的信道

¹<https://project.veryengine.cn/publish/CGAQvTSeB/index.html>

脉冲响应（CIR）和信道频率响应（CFR）的时间和频率分辨率。

- **GPU 加速光线追踪仿真：**我们使用由 NVIDIA 的 Sionna 和 OptiX 库驱动的 GPU 加速光线追踪引擎生成我们的信道数据。此模拟非常高效，利用了大规模并行化和优化策略，例如早期光线终止（基于交互深度和功率阈值）。它准确地建模关键物理现象——包括反射、透射和衍射——并记录所有重要的路径相互作用，以产生基于物理的信道数据集。
- **信道数据提取与后处理：**从光线追踪路径中，我们得出关键信道指标并编译最终数据集。专用函数处理多径数据以计算标准信道表示，包括 CIR、CFR 以及每条路径的到达角（AoA）和离开角（AoD）等角度信息。在此阶段，我们还进行最终后处理，例如过滤掉无法到达的路径或无效链接，以确保数据质量。结果是在每个场景下具有高现实性和多样性的全面信道特征数据集。

总之，DeepTelecom 通过独特地结合大规模、场景多样性以及高保真的数字孪生准确性，代表了现有信道数据集的重大进步。它作为下一代智能无线通信研究的基础资产。

III. 详细描述

在本节中，我们提供了 DeepTelecom 数据集生成过程的详细描述，扩展了上述四个组成部分。每个子部分解释了框架某一特定部分的实现方式，包括技术细节和流程。

A. LLM 辅助的高保真多源场景建模

1) **室内场景重建：**我们利用网络物理数字孪生系统以 LoD3 的粒度重建复杂的室内场景。首先，配备 3D 激光雷达扫描仪的四足机器人对环境进行勘测。激光雷达捕获几何距离和反射强度，从而推断表面属性，如材料类型和颜色。然后将原始点云去噪、过滤，并转换为统一的三维坐标系统。在这里我们应用基于无迹卡尔曼滤波器（UKF）的 HDL 定位算法来实现这种统一，通过使用机器人估计的姿态 [14]，将每个激光雷达点从机器人的局部帧转换到全局参考帧。具体来说，如果在时间 t 时，UKF 为机器人提供了旋转 $\mathbf{R}(t)$ 和平移 $\mathbf{t}(t)$ ，那

么在一个机器人本地坐标系中测量的点 $\mathbf{p}_{\text{local}}$ 将映射到全局帧如下：

$$\mathbf{p}_{\text{global}}(t) = \mathbf{R}(t) \mathbf{p}_{\text{local}} + \mathbf{t}(t), \quad (1)$$

确保所有扫描在同一通用坐标系统中对齐。在统一框架中的汇总点云下，如墙壁和家具等室内结构的几何形状和空间布局逐渐显现出来 [15]。实现图示如图 2 所示。

一旦获得完整的点云，系统的 3D 建模模块将其转换为多边形网格并优化模型。我们执行网格提取和简化以减少冗余几何形状同时保留重要细节。支持实体建模、表面建模和线框建模技术的组合，满足不同类型对象的不同重建需求。然后应用纹理烘焙和光照烘焙，预先计算表面纹理和光照/阴影信息并将它们映射到网格上，从而获得逼真的外观。最终重建的室内模型，配备高分辨率纹理，可以导出为多种格式（例如，.obj 或 .fbx）用于可视化和其他用途。该模型作为真实室内空间的数字孪生体，捕捉其几何形状和视觉细节。




图 2. 室内数字场景实现图。

2) **户外场景重建：**对于户外环境，我们采用专业的三维建模工具和开放的地理空间数据来构建 LoD3 城市场景。实现示例如图 3 所示。

在我们的流程中，使用 Blender-Blosm 插件从 Google 3D Tiles 导入现实世界的模型。选择日本的一个密集城市区域作为测试地点。尽管这些导入的模型包括建筑形状、纹理和地形高程，但它们较为粗糙，表面不均匀且组件合并在一起。为了更高效的编辑，我们将模型导出为 .glTF 格式并输入到 SketchUp 中。通过应用诸如 Push/Pull 等建模工具，我们准确地重建了每一个关键元素，并确保与 Google Tiles 参考数据对齐，同

时系统地按类别组织对象并通过 SketchUp 的材质编辑器分配真实的材料（例如玻璃、混凝土）。




图 3. 户外数字场景实现图。

3) *LLM* 辅助场景优化：在构建了室内和室外场景模型之后，我们将完整的场景描述（包括所有对象及其材质）导出为结构化的 XML 格式以进行最终细化。在这个阶段，大型语言模型用于优化并验证材质标注的一致性。由于大型语言模型非常适合处理结构化文本操作，因此它们可以有效地处理基于 XML 的场景表示。为此，在建模过程中我们强制执行严格的命名约定（例如，“墙”、“窗户”、“门”、“路面”）。使用 XML 文件和电磁材料属性参考表，我们提示大型语言模型自动验证并批量分配适当的材质。例如，整个大场景中的所有“窗户”对象都可以统一更新为正确的电磁配置。这种由大型语言模型辅助的优化确保了整个场景具有一致且物理准确的材质定义，这对于实现逼真的光线追踪模拟至关重要。

最终结果是一个具有高几何保真度和详细材料规格的完全注释的 LoD3 室内或室外数字孪生，已准备好进行信道建模和仿真。

B. 参数定义与配置

一旦环境被建模，下一步是配置仿真参数。我们将这些参数分为两类：系统参数，定义设备和硬件，以及生成参数，定义仿真的运行方式及数据的收集方式。

以下是主要的模拟参数配置：

- **BS:** BSs 部署在场景中的合理位置（例如，屋顶或天花板上）。每个 BS 具有包括唯一标识符、场景中的 3D 位置、方向（例如，由航向角和倾斜角给出）以及 dBm 单位的发射功率在内的属性。

- **MT:** 类型的 MT 在整个环境中随机分布。每个 MT 由类似于 BS 的参数定义。重要的是，我们可以为每个 MT 分配一个速度向量来模拟运动，这在信道中引入了时间变化，允许生成随用户移动而变化的时间变化 CIR。
- **天线:** 两个 BS 和 MT 都配备了天线阵列，由它们的尺寸（垂直和水平维度中的元素数量）和元件间距定义。这些参数对于准确建模 MIMO 系统的空间特性和波束成形能力至关重要。
- **参考信息服务:** RIS 面板可选择性地包含在环境中以智能控制信号反射。我们考虑两种波束成形模式：

(i) 单光束聚焦：对于点对点高吞吐量回传链路，我们根据路径长度差异应用相位梯度聚焦策略来引导和聚焦波束。为了向期望方向 (θ_0, ϕ_0) 进行波束成形，RIS 的相位配置为

$$\Phi(x, y) = -\frac{2\pi}{\lambda} (x \sin \theta_0 \cos \phi_0 + y \sin \theta_0 \sin \phi_0), \quad (2)$$

假设 RIS 位于 xy 平面内。这种在 RIS 表面上的线性相位梯度将波束引导到方向 (θ_0, ϕ_0) 。(ii) 多波束优化：对于更复杂的多波束场景（例如，同时服务多个用户），我们采用迭代优化方法（例如，随机梯度下降 [16]）来设计相位码本，以逼近所需的多波束辐射模式。

- **系统带宽:** 系统带宽决定了 CIR 的时间分辨率和 CFR 的频率采样间隔。更宽的带宽会产生更高的时间分辨率（较短可区分的多径延迟）。

C. GPU 加速的光线追踪模拟

基于 NVIDIA 的 Sionna 无线仿真库，我们进行了一次 GPU 加速的光线追踪模拟以生成信道数据。该光线追踪器在详细的 3D 场景上运行，并使用配置的参数传播信号并捕捉多径效应。该过程可以分解为几个阶段：

- **初始化:** 我们从每个发射器发射大量的光线。为了高效地做到这一点，我们使用斐波那契球形采样方法在 3D 空间中几乎均匀地分布这些光线。如果从一个发射器发出 M 条光线，它们的方向 (θ_k, ϕ_k) 可以通过以下方式确定：

$$\theta_k = \arccos\left(1 - \frac{2(k + 0.5)}{M}\right), \quad \phi_k = \frac{2\pi k}{\Phi_G}, \quad (3)$$

对于 $k = 0, 1, \dots, M - 1$ ，其中 $\Phi_G = \frac{1+\sqrt{5}}{2}$ 是黄金比例。这种参数化方法在球面上产生了一个近似均匀的光线采样。我们还可以对分布进行偏置，使光线集中在关键区域（例如，在用户所在的接近地面的位置使用更密集的采样），这进一步提高了模拟效率。

- **加速：**光线追踪引擎使用 NVIDIA 的 OptiX 框架进行加速，从而在 GPU 硬件上实现高度并行计算。成千上万的光线被同时追踪，每个光线都在每一步检查与环境几何体的交点。这种加速对于在合理的时间内生成大量数据集至关重要，因为它允许我们捕获丰富的多路径信息而不会造成不切实际的延迟。
- **优化（早期终止）：**为了进一步提高效率，我们实现了两个标准来提前终止光线。首先，为每条光线设置一个最大交互深度 $N_{\max}$ ，计算反射或折射次数。如果超过这个限制，则停止该光线。其次，我们设定了一个功率阈值：在每次交互中，光线的功率会根据材料属性和行进距离而衰减。如果剩余功率低于预定义阈值 $P_{\min}$ ，则终止光线，因为进一步的交互将贡献微不足道的能量。形式上，如果光线的交互次数 N_{int} 达到 $N_{\max}$ 或其功率 P 低于 $P_{\min}$ ，则该光线终止：

$$N_{\text{int}} \geq N_{\max} \quad \text{or} \quad P \leq P_{\min}. \quad (4)$$

这种对低功率光线的剪枝显著提高了模拟速度而不影响精度。

- **物理建模：**我们的光线追踪器以确定性方式考虑了所有主要的电磁波现象。具体而言，我们使用几何光学（GO）原理和基于材料属性的菲涅耳方程来模拟反射和透射。例如，我们计算每次交互的菲涅耳反射系数。对于两个介质界面处的垂直极化，它由以下给出：

$$\Gamma_{\perp}(\theta_i) = \frac{n_1 \cos \theta_i - n_2 \cos \theta_t}{n_1 \cos \theta_i + n_2 \cos \theta_t}, \quad (5)$$

其中 θ_i 是入射角， θ_t 是根据斯涅尔定律 $n_1 \sin \theta_i = n_2 \sin \theta_t$ 确定的透射角，和 n_1, n_2 是两个介质的折射率。在每次交互中，光线的复振幅 α 会乘以相应的反射系数（ Γ ）或传输系数（ T ），并乘以该路径段的自由空间传播因子。特别地，在入射角度为 θ_i

和传播距离为 d 的反射后，光线的复振幅更新为：

$$\alpha_{\text{new}} = \alpha_{\text{old}} \Gamma(\theta_i) \frac{e^{-jkd}}{d}, \quad (6)$$

其中 $k = 2\pi/\lambda$ 。我们还应用均匀衍射理论（UTD）来建模信号如何绕过锐边（例如建筑物角落），使用标准衍射系数来捕捉这些非视距路径。为了高效实现这些效果，每一步我们都执行几何交点测试，并选择最近的交点（贪婪策略）作为下一次交互。然后在该点应用相应的物理反射、传输或衍射模型，并记录交互的确切坐标和相位。对于每条光线的物理参数（例如相位、振幅、极化）都会随着光线传播而更新并记录以供进一步处理。

D. 信道数据提取与后处理

运行光线追踪仿真后，我们处理并组织输出数据以形成最终的数据集格式。DeepTelecom 数据集的结构包括详细的传播路径数据和合成信道响应，以及用于可视化的辅助输出。数据集中的每个场景（环境）生成以下组件：

场景快照：每个场景都配备了一台可自由移动的虚拟相机，允许从不同的角度和时间步骤捕捉场景。模拟框架可以输出环境的渲染图像或视频，这些图像或视频被保存用于可视化和分析。

传播路径：每个场景的核心输出是所有发射器和接收器之间的多跳传播路径集。通过配置诸如发射光线的数量和最大反射/衍射次数等参数，框架记录详细的几何路径信息。这些数据以坐标点序列（加上交互标签）的形式存储，显示信号穿过环境的轨迹。此类路径数据为分析传播机制或优化网络（例如，放置新的中继器或 RIS）提供了基础。

覆盖热图：此组件为环境中的指定平面生成 2D/3D 信号覆盖图。通过配置地图的中心位置、大小、方向（例如，在给定高度处的水平面）和分辨率，该工具计算并可视化该平面上每个网格点接收到的功率或路径损耗。这有助于理解障碍物和距离对信号强度的影响，支持诸如网络规划和部署优化等任务。

信道响应：使用物理路径数据，该数据集提供了标准信道信息——最重要的是 CIR 和 CFR：

- **圆环：**对于一个具有 N_t 发射天线和 N_r 接收天线的 MIMO 系统，时域 CIR $\mathbf{H}(t)$ 是所有 L 传播路径贡献的叠加。每个路径 l 都由其复增益 α_l 、传播

延迟 τ_l 、入射角 $\Omega_{t,l}$ 和到达角 $\Omega_{r,l}$ 特征化。CIR 可以写成：

$$\mathbf{H}(t) = \sum_{l=1}^L \alpha_l \mathbf{a}_r(\Omega_{r,l}) \mathbf{a}_t^H(\Omega_{t,l}) \delta(t - \tau_l), \quad (7)$$

其中 $\mathbf{a}_r(\Omega_{r,l})$ 和 $\mathbf{a}_t(\Omega_{t,l})$ 分别是路径的 AoA 和 AoD 的接收和发射阵列响应向量， $\delta(\cdot)$ 是 Dirac delta。

- **成本加运费：**周期自相关函数是循环互相关函数的傅里叶变换，其由下式给出：

$$\mathbf{H}(f) = \sum_{l=1}^L \alpha_l \mathbf{a}_r(\Omega_{r,l}) \mathbf{a}_t^H(\Omega_{t,l}) e^{-j2\pi f \tau_l}. \quad (8)$$

通过这种严谨的方法，DeepTelecom 数据集明确地将环境几何形状和材料与通信信号联系起来，在时域和频域内建立了分析现实世界对 MIMO 信道行为影响的物理准确基础。室内和室外场景的可视化示例分别显示在图 4 和 5 中。




图 4. 室内场景可视化示例。




图 5. 户外场景可视化示例。

IV. 实验分析

我们应用该框架构建了 DeepTelecom 数据集，并评估了其规模和多样性。结果证明了该流程的灵活性及其输出的丰富性：

- 1) **场景生成的普遍性：**给定 GPS 坐标，系统重建带地形和建筑物的户外双胞胎；给定室内点云（例如 LiDAR 或 RGB-D），它生成 LoD3 内部模型。我们通过从各自的地理空间或点云输入中生成城市微小区和多房间办公室场景来验证这一点，然后为每个场景导出信道数据——展示了简单地扩展到新区域和布局的能力。
- 2) **综合场景包：**每个场景都是独立的，包括 3D 模型（带材质）和当需要时的 XML 场景描述、完整的仿真配置（BS/MT 布置、天线/RIS 设置），以及所有输出：场景快照、多径轨迹、功率-延迟分布图、覆盖热图和计算出的 CIR/CFR。例如，一个户外城市案例包括城市模型、BS/MTs 的配置文件，以及光线追踪路径、热图、信道矩阵及其伴随可视化的目录。

跨越数十种不同的配置，如市区、郊区和农村，每个场景都会产生数千个收发器对和数百万条原始射线路径。同样的流程允许用户按需生成新场景。由此产生的多模态数据支持广泛的大无线 AI 任务，包括定位 [17], [18] 和波束成形 [19], [20] 等。

V. 讨论与结论

在本文中，我们介绍了 DeepTelecom，这是一个利用 LLM 辅助管道构建 LoD3 精度的可分割和材质参数化表面的室外和室内环境的 3D 数字孪生信道数据集。通过使用 Sionna 的光线追踪引擎，DeepTelecom 准确模拟了全面的无线电波传播效应。借助 GPU 加速处理，该数据集动态生成光路轨迹和实时信号强度热图，并将其编译成高帧率视频，同时产生同步多视角图像、信道张量和多尺度衰落轨迹。通过实现高效的大规模、高保真度和多模态信道数据流传输，DeepTelecom 不仅为无线 AI 研究建立了标准化基准，还提供了丰富的领域特定训练基础，促进大型模型智能与下一代通信系统的无缝集成。

参考文献

- [1] A. Shahid, A. Kliks, A. Al-Tahmeesschi, A. Elbakary, and etc., “Large-scale AI in telecom: Charting the roadmap for innovation, scalability, and enhanced digital experiences,” [Online] available: <https://arXiv.org/abs/2503.04184>, Mar. 2025.
- [2] F. Zhu, X. Wang, X. Li, M. Zhang, Y. Chen, and etc., “Wireless large AI model: Shaping the AI-native future of 6G and beyond,” [Online] available: <https://arXiv.org/abs/2504.14653>, Apr. 2025.

- [3] T. Imai, "A survey of efficient ray-tracing techniques for mobile radio propagation analysis," *IEICE Trans. Commun.*, vol. 100, no. 5, pp. 666–679, May. 2017.
- [4] Y. Huangfu, J. Wang, S. Dai, R. Li, J. Wang, C. Huang, and Z. Zhang, "WAIR-D: Wireless AI research dataset," [Online] available: <https://arxiv.org/abs/2212.02159>, Dec. 2022.
- [5] L. Yu, J. Zhang, M. Fu, and Q. Wang, "BUPTCMCC-6G-dataAI+: A generative channel dataset for 6G AI air interface research," [Online] available: <https://arxiv.org/abs/2410.10839>, Sept. 2024.
- [6] Z. Shen, L. Yu, Y. Zhang, J. Zhang, Z. Zhang, X. Hu, S. Han, J. Jin, and G. Liu, "DataAI-6G: a system parameters configurable channel dataset for AI-6G research," in *Proc. IEEE Global Commun. Conf. (Globecom)*. IEEE, Dec. 2023.
- [7] C. Wang, Z. Lv, X. Gao, X. You, Y. Hao, and H. Haas, "Pervasive wireless channel modeling theory and applications to 6G GBSMs for all frequency bands and all scenarios," *IEEE Trans. Veh. Technol.*, vol. 71, no. 9, pp. 9159–9173, Sept. 2022.
- [8] C. Wang, Z. Lv, Y. Chen, and H. Haas, "A complete study of space-time-frequency statistical properties of the 6G pervasive channel model," *IEEE Trans. Commun.*, vol. 71, no. 12, pp. 7273–7287, Dec. 2023.
- [9] X. Cheng, Z. Huang, L. Bai, H. Zhang, M. Sun, B. Liu, S. Li, J. Zhang, and M. Lee, " M^3SC : A generic dataset for mixed multi-modal (MMM) sensing and communication integration," *China Commun.*, vol. 20, no. 11, pp. 13–29, Nov. 2023.
- [10] A. Alkhateeb, "DeepMIMO: A generic deep learning dataset for millimeter wave and massive MIMO applications," [Online] available: <https://arxiv.org/abs/1902.06435>, Feb. 2019.
- [11] M. Alrabeiah, A. Hredzak, Z. Liu, and A. Alkhateeb, "ViWi: A deep learning dataset framework for vision-aided wireless communications," in *Proc. IEEE Veh. Technol. Conf. (VTC)*, May. 2020.
- [12] H. Choi, J. Oh, J. Chung, G. C. Alexandropoulos, and J. Choi, "WiThRay: A versatile ray-tracing simulator for smart wireless environments," *IEEE Access*, vol. 11, pp. 56 822–56 845, Jun. 2023.
- [13] J. Hoydis, S. Cammerer, F. A. Aoudia, A. Vem, N. Binder, G. Marcus, and A. Keller, "Sionna: An open-source library for next-generation physical layer research," [Online] available: <https://arXiv.org/abs/2203.11854>, Mar. 2022.
- [14] C. Zhu, Z. Zhao, J. Bao, Z. Yang, C. Huang, and Z. Zhang, "Integrated optical sensing, communication, and computation system for quadruped robots," in *Proc. Int. Conf. Wireless Commun. Signal Process. (WCSP)*, Feb. 2024.
- [15] M. Keller, D. Lefloch, M. Lambers, S. Izadi, T. Weyrich, and A. Kolb, "Real-time 3D reconstruction in dynamic scenes using point-based fusion," in *Proc. Int. Conf. 3D Vis. (3DV)*, Sept. 2013.
- [16] G. Zhou, C. Pan, H. Ren, K. Wang, M. El Kashlan, and M. Di Renzo, "Stochastic learning-based robust beamforming design for RIS-aided millimeter-wave systems in the presence of random blockages," *IEEE Trans. Veh. Technol.*, vol. 70, no. 1, pp. 1057–1061, Jan. 2021.
- [17] B. Wang, F. Zhu, M. Liu, C. Huang, Q. Yang, A. Alhammedi, Z. Zhang, and M. Debbah, "Multi-sources information fusion learning for multi-points NLOS localization," in *Proc. IEEE Veh. Tech. Conf. (VTC)*, Jun. 2024.
- [18] B. Wang, Z. Shuai, C. Huang, Q. Yang, Z. Yang, R. Jin, A. Al Hammedi, Z. Zhang, C. Yuen, and M. Debbah, "Multi-sources fusion learning for multi-points NLOS localization in OFDM system," *IEEE J. Sel. Topics Signal Process.*, vol. 18, no. 7, pp. 1339 – 1350, Sept. 2024.
- [19] F. Zhu, B. Wang, Z. Yang, C. Huang, Z. Zhang, G. C. Alexandropoulos, C. Yuen, and M. Debbah, "Robust millimeter beamforming via self-supervised hybrid deep learning," in *Proc. Eur. Signal Process. Conf. (EUSIPCO)*, Sept. 2023, pp. 915–919.
- [20] F. Zhu, X. Wang, C. Zhu, T. Gong, Z. Yang, C. Huang, X. Chen, Z. Zhang, and M. Debbah, "Robust Deep Learning-Based Physical Layer Communications: Strategies and Approaches," *IEEE Netw.*, pp. 1–1, 2025.