用于不规则地形快速无线电传播预测的混合解析-神经残差代理模型

Yongyua n Hu，Jiahao Li，Keqi Ni，Yuqi Ouyang*IEEE*会员，以及Hao Qin *IEEE*会员

arXiv:2611.32698v1 [eess.SP] 24 Nov 2026

摘要—**快速预测不规则地形上的无线电波传播，对于山区环境中的覆盖分析至关重要，因为必须反复评估许多地形和天线配置。高保真的分步抛物方程（SSPE）求解器能够捕捉地形引起的阴影效应和干扰，但其计算成本较高，不适合重复性的规划研究。基于学习的代理模型可以降低这一成本，但直接进行场回归要求网络同时学习解析上可处理的传播趋势和依赖地形的残差结构。本文提出了一种混合解析-神经残差代理模型，将这两部分分离开来。确定性解析基线表示自由空间扩散、天线方向性、修正刀刃绕射和地形感知的镜面反射，而紧凑的由粗到细神经网络则预测残差场。该网络采用基于基线导出的引导通道、各向异性卷积和逐特征天线条件化，以匹配地形传播场的方向性结构。在**1.0 **吉赫兹的合成SSPE数据上，所提出的模型取得了**2.1061 **dB的平均绝对误差，相比之下，标准U-Net和复现的物理引导卷积神经网络的平均绝对误差分别为**3.3955 **dB和**3.2560**dB，同时将平均推理时间降低至每个样本**11.30 **毫秒。在**1.8**吉赫兹下进行的零样本测试，在无需重新训练的情况下取得**2.8692 **dB的平均绝对误差；此外，对实测Hjorringvej地形剖面的案例研究表明，该预测结果与SSPE 参考结果保持一致，并遵循实测的路径损耗趋势。**

索引词—**计算电磁学、地形传播、分析-神经混合模型、残差学习、代理模型、抛物方程法。**

I. 引言

在不规则地形上准确、高效地预测无线电波传播，是山区无线覆盖分析和频谱规划中的常见需求。在高保真传播求解器中，双向分步抛物方程（SSPE）方法在物理保真度和计算成本之间实现了有益的折中 [1]–[4]。然而，在规划流程中，如果需要多次改变地形剖面、天线高度、下倾角、波束宽度或工作频率，其计算成本仍然很高。

因此，研究人员开始探索机器学习（ML）代理模型，以加速电磁与无线电传播仿真 [5]–[11]。在室内、交通运输及其他特定场景中，物理引导卷积模型以远低于数值仿真的推理成本恢复了密集传播场 [5], [7], [12]。针对不规则地形，Brennan 和 McGuinness [13] 考虑了路径损耗预测，而 Huang 等人 [14] 则利用参数嵌入、位置编码和嵌套式 U 形骨干网络，将问题扩展至二维场图预测。

大多数现有的基于学习的地形代理模型仍采用直接全场回归 [13], [14]，，这也是相关传播模型中常见的做法 [15]–[17]。在这种建模方式下，网络必须根据地形和天线输入重现整个场。这会使自由空间扩散、天线方向性、绕射和反射等可通过解析方法预测的效应，与地形耦合的残余效应一并纳入同一学习映射。对于代理模型可能运行在资源受限计算节点上的部署场景 [18]，，这会低效地占用模型容量。此外，这也削弱了大尺度传播趋势与更难通过解析方法近似的残差结构之间的物理区分；这种区分已被证明有助于其他逆问题和复原问题中的残差学习方法 [19], [20]。

直接回归也往往会将载波频率依赖性隐式地吸收到学习权重中 [14], [21], [22]。当工作频率发生变化时，直接代理模型通常必须重新训练，或者至少使用新生成的数据。在覆盖分析中，这一点很不便，因为可能需要在同一设计过程中筛选邻近的工作频段。将主要的频率依赖性保留在解析分量中的一种公式化方法，可以减轻这一负担，前提是所学习的残差在训练频率之外仍具有信息性。

另一个问题是通用图像骨干网络与地形传播场之间的不匹配。不规则地形上的 SSPE 场具有与主传播距离方向和地形边界相关的方向性、多尺度结构 [23]，[24]。沿距离和高度方向的变化不可互换，而天线高度、下倾角和波束宽度充当全局控制量，而不是普通的局部图像信道。标准卷积架构最初是为视觉上均衡的图像模式开发的，并未显式编码这些特征 [25], [26]。特征级调制为将全局条件变量注入中间特征图提供了一种自然方式 [27]。

本文将地形传播预测重新表述为一个

Yongyuan Hu 任职于美国宾夕法尼亚州匹兹堡市匹兹堡大学 Swanson 工程学院，邮编 15261（derrick.hu@pitt.edu）。Jiahao Li、Keqi Ni 和 Hao Qin 任职于中国成都市四川大学电子与信息工程学院，邮编 610065（2023141520010@stu.scu.edu.cn，2023141520023@stu.scu.edu.cn，hao.qin@scu.edu.cn）。Yuqi Ouyang 任职于中国成都市四川大学计算机科学学院，邮编 610065（yuqi.ouyang@scu.edu.cn）。

混合解析-神经残差学习问题。首先，根据自由空间扩散、天线方向性、修正刀刃绕射和地形感知镜面反射构建确定性解析基线。随后，神经网络仅预测相对于该基线的残差校正，而不是直接回归整个 SSPE 场。在这一表述中，解析分量捕捉主要的传播趋势，而神经分量则专注于地形相关失配；这种失配难以用紧凑的闭式模型加以描述。这不同于物理引导的直接回归模型，后者主要将物理量用作辅助输入；在本文方法中，解析场估计是预测参考，而学习模型则经过训练以对其进行校正。

所提出的架构围绕这种解析—神经分解构建。由粗到细残差网络采用各向异性卷积来追踪主要传播方向，利用基线导出的引导通道呈现局部物理背景，并通过特征级调制将天线参数作为全局条件变量注入。由于载波频率显式包含在解析分量中，只需重新计算基线，即可在未见频率下评估同一个已训练残差模型。我们在不重新训练的情况下，测试了该模型从1.0吉赫兹迁移至1.8吉赫兹的能力。

因此，本研究的贡献有三点。首先，提出了一种用于不规则地形场预测的混合解析—神经残差公式，其中解析基线可在神经网络校正前去除主要传播结构。其次，开发了一种轻量级由粗到细架构，专为地形传播场的各向异性结构设计。第三，使用合成SSPE数据、复现的基于学习的基线方法、未见频率测试案例以及实测Hjorringvej地形剖面对所得代理模型进行了评估。

本文其余部分安排如下。第二节介绍问题表述、确定性基线以及所提出的由粗到细模型。第三节报告数值结果，包括消融研究、与复现基线方法的比较，以及零样本频率迁移实验。第四节给出在实测Hjorringvej地形上的验证结果。第五节总结全文并讨论未来工作。

II. 基于机器学习的地形传播模型

本节介绍所提出的混合解析-神经网络地形传播代理模型。该模型围绕基线-残差分解进行组织：确定性解析基线负责刻画主要的传播趋势，而紧凑型神经网络则预测剩余的场修正项。图1概述了该设置和所提出的公式。顶部面板展示了天线在不规则地形剖面上进行辐射的情形，其中目标是由地形几何和天线配置定义的二维场图。中间面板说明了传统的全场回归设置。底部面板展示了所提出的替代方案，其中神经网络模型学习相对于解析基线的残差。第二节A—节概述了用于生成参考场的SSPE模型。第二节B定义了残差公式和解析基线。第二节C介绍了由基线推导的输入。第二节D介绍了由粗到细的神经网络架构，第二节E给出了训练目标。

A. 双向*SSPE*模型

本文使用的参考数据通过双向SSPE方法生成。该方法是一种由亥姆霍兹波动方程 [2], [23], [24]推导出的抛物方程方法。该双向公式考虑了存在地形障碍物时的前向传播分量和后向传播分量。对于前向推进步骤，下一个距离平面中的约化场由下式得到：

$$u(x, z+\Delta z) = \mathcal{F}^{-1}\{C(k_x)\,\mathcal{F}\{u(x,z)\}\}\,, \tag{1}$$

其中， $\mathcal{F}$ 和 $\mathcal{F}^{-1}$ 表示傅里叶变换对， k_x 为谱变量， u为约化场，而

$$C(k_x) = \exp\!\left(\frac{-jk_x^2\,\Delta z}{2k_0}\right), \tag{2}$$

其中， $k_0 = 2\pi f/c$ 是载波频率为 f时的自由空间波数。反向推进步骤可写为

$$u(x, z-\Delta z) = \mathcal{F}^{-1}\{C(k_x)\,\mathcal{F}\{u(x,z)\}\}\,. \tag{3}$$

每次SSPE仿真都会在地形域上生成一张二维复场图。场强幅度被转换为分贝尺度，并用作监督学习目标。随后，训练代理模型以较低的推理成本近似这一SSPE映射。

B. 问题公式化与解析基线

令 $Y \in \mathbb{R}^{H\times W}$ 表示分贝尺度下的SSPE场图。我们不直接根据地形剖面和天线参数预测 Y，而是将目标分解为

$$Y(x,z) = B(x,z) + R(x,z), \tag{4}$$

其中， B 是确定性解析基线， R 是由网络学习得到的残差校正。这种分解的目的并不是使解析基线本身达到完全准确，而是在学习之前去除主要的低复杂度场趋势。因此，应将该基线理解为用于残差学习的紧凑参考场，而不是SSPE求解器的独立替代方案。

基线以复场形式构建如下

$$E_{\mathrm{base}}(x,z) = E_{\mathrm{fspl}}(x,z)\,G_{\mathrm{ant}}(x,z)\,A_{\mathrm{ke}}(x,z) + E_{\mathrm{refl}}(x,z), \tag{5}$$

其中， E_{fspl} 表示自由空间扩散， G_{ant} 为天线方向性因子， A_{ke} 为修正刀刃绕射项， E_{refl} 为地形感知镜面反射分量。这四个项如图 2 所示。

直接自由空间项写作

$$E_{\mathrm{fspl}}(x,z) = d^{-1/2}e^{-jk_0 d}, \qquad d = \sqrt{x^2 + (z-z_{\mathrm{tx}})^2}, \tag{6}$$

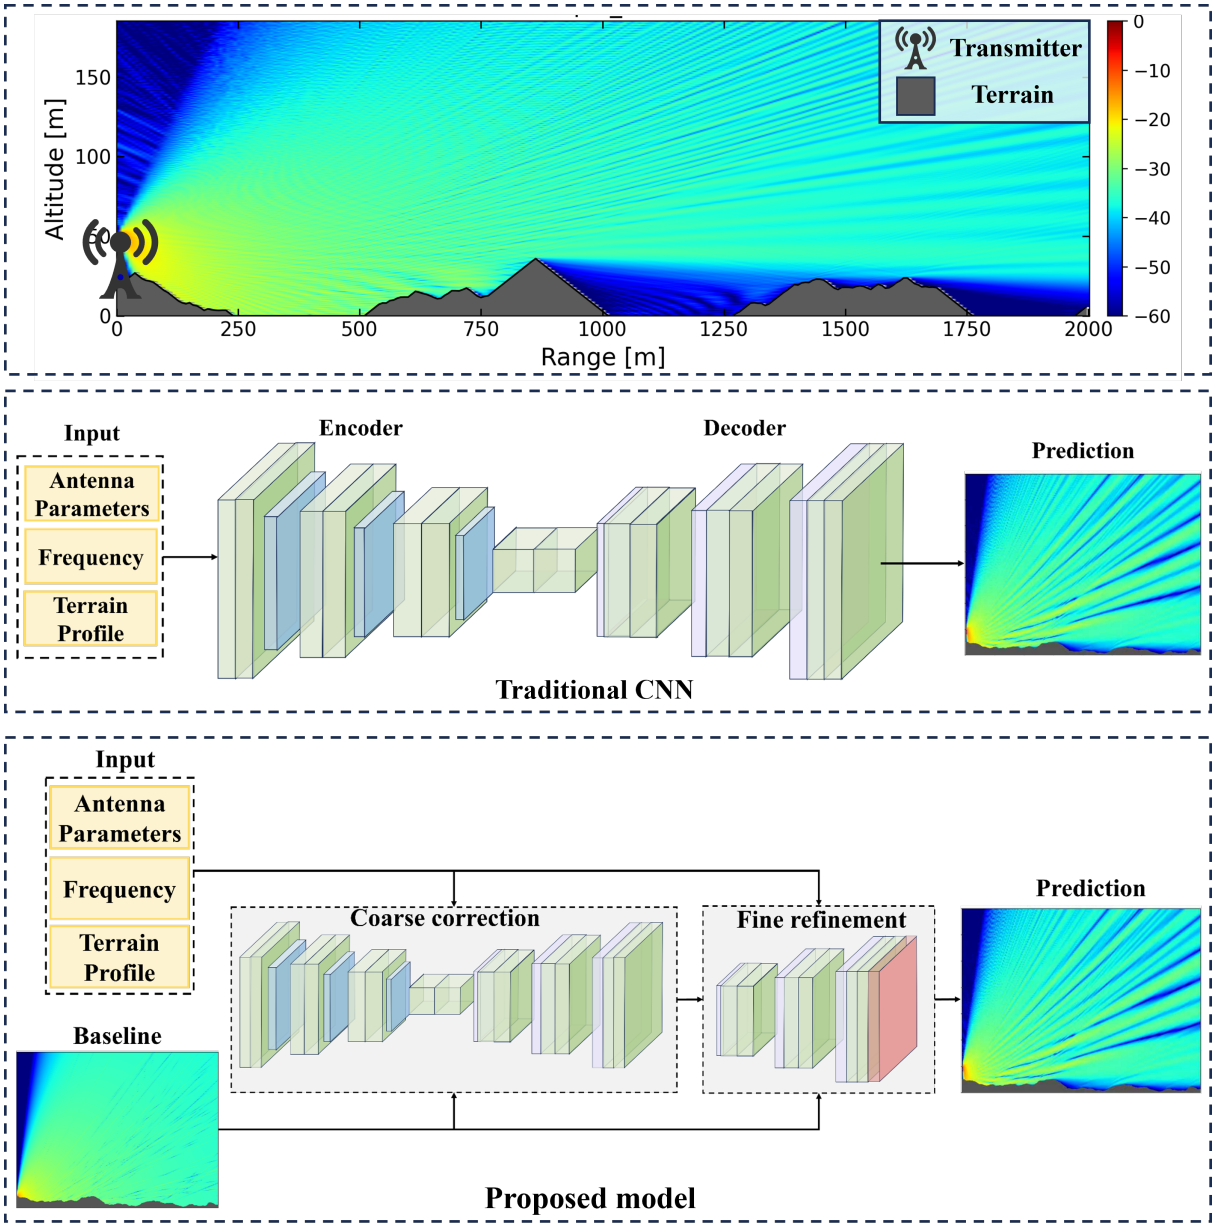

图1：传播场景及所提出的混合解析-神经基线-残差框架概览，并与传统全场回归进行对比。

其中， z_{tx} 是发射机高度， $k_0 = 2\pi f/c$ 是自由空间波数。天线方向图近似为高斯仰角波束，

$$G_{\mathrm{ant}}(x,z) = \exp\left[-\frac{(\theta_{\mathrm{dir}} + \theta_{\mathrm{tilt}})^2}{4\sigma_\theta^2}\right], \qquad \sigma_\theta = \frac{\theta_{3\mathrm{dB}}}{2\sqrt{2\ln 2}}, \tag{7}$$

其中， $\theta_{\mathrm{dir}} = \arctan((z - z_{\mathrm{tx}})/x)$， θ_{tilt} 为天线下倾角， $\theta_{3\mathrm{dB}}$ 为 3 dB 波束宽度。

绕射采用修正单刀刃近似表示。对于每个观测点，沿发射机-接收机路径使菲涅耳绕射参数最大化的点被选为主导地形障碍物。参考损耗遵循 ITU-R P.526 建议书，随后进行调整，以避免在阴影区域之外出现不合理的衰减：1）损耗乘以固定缩放因子 $\alpha = 0.7$ 以减弱；2）在超过有效盖帽高度后移除绕射惩罚，从而避免对非阴影区域的点过度衰减；3）将峰值后的阴影边界限制为单调下降，最大坡度为 $s_{\max} = -0.01$ m/m。由此得到的衰减因子为

$$A_{\mathrm{ke}}(x,z) = 10^{-L_{\mathrm{ke}}(x,z)/20}. \tag{8}$$

反射分量通过相对于镜面点处局部地形切线的镜像构造计算得到。其幅度由有损介电地面的菲涅耳反射系数加权。该项仅保留主要的镜面贡献，并不试图替代 SSPE 解。

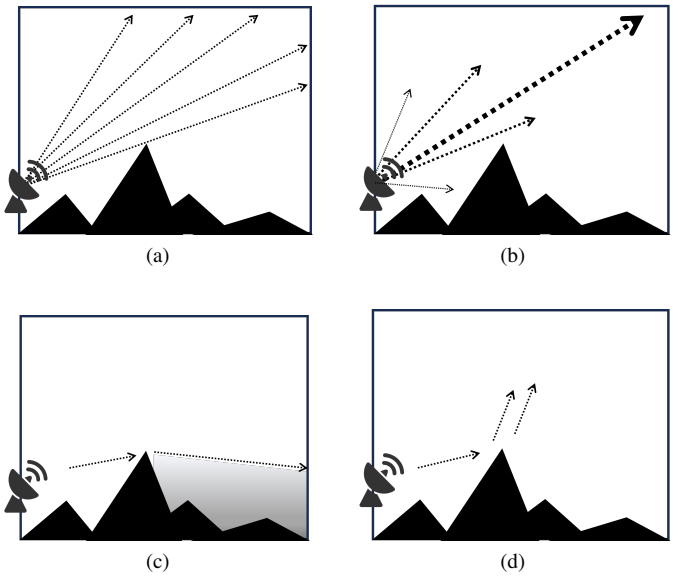

图 2：确定性解析基线中考虑的四种机制示意图。(a) 自由空间扩散。(b)高斯天线方向性。(c) 修正刀刃绕射。(d) 地形感知镜面反射。

最终得到分贝尺度下的确定性基线:

$$B(x,z) = \mathrm{clip}_{[-200,0]}\left(20\log_{10}|E_{\mathrm{base}}(x,z)|\right). \tag{9}$$

与数据集表示方式一致，地形以下的像素被赋予地板值。由于载波频率通过解析项进入 B ，在另一频率下测试训练好的代理模型只需重新计算基线；在第 III-C 节报告的零样本实验中，学习权重保持不变。

C. 基于基线的输入构造

网络输入由确定性基线和地形几何构建，而非仅由原始地形样本构建。我们首先构造一个带符号的边界距离图

$$D_b(x,z) = \frac{z - h(x)}{\max_{x,z}|z - h(x)|}, \tag{10}$$

其符号表示某点位于地形边界上方还是下方。阶段 1 在粗化表示上运行，该表示仅沿高度维度按 8 倍因子下采样得到,

$$X_c = [\tilde{B}^c, D_b^c]. \tag{11}$$

这两个通道的输入以紧凑形式向网络提供主导场趋势和地形边界。

为了进行全分辨率细化，我们进一步构建了一个七通道引导张量

$$G = [\tilde{B}, M, G_z, G_x, C, X, Z], \tag{12}$$

其中， M 是有效性掩膜， G_z 和 G_x 是基线的归一化垂直梯度和水平梯度， C 是高于地形表面的归一化净空高度， X 和Z 是归一化距离和高度坐标。天线高度、下倾角和波束宽度由低维条件向量表示，并通过特征级线性调制（FiLM） [27]注入。这些信道在学习非线性残差映射之前，显式呈现基线趋势、地形边界、局部基线梯度和空间位置。

D. 两阶段由粗到细网络

残差场分两个阶段进行预测。阶段 1 是一个紧凑的类 U-Net 预测器，在 $H/8 \times W$ 网格上运行。它采用沿距离轴对齐的各向异性卷积，并使用空洞瓶颈层，以便在降低高度分辨率的情况下捕获远距离传播结构。该阶段输出粗略残差 $\hat{r}_c$ 以及紧凑的潜在特征表示。

阶段 2 利用粗略预测、潜在粗粒度特征以及从 G中提取的多尺度引导信息，重建全分辨率残差。其解码器仅沿高度维度进行上采样,

$$H/8 \to H/4 \to H/2 \to H, \tag{13}$$

这遵循 SSPE 网格的非对称采样方式，并将大部分计算集中在较低分辨率下。由于天线参数会对场分布产生全局影响，而不是形成局部空间纹理，因此两个阶段均通过 FiLM 应用天线条件化。整体架构如图3所示。

令 $\hat{r}_f$ 表示细化后的全分辨率残差。最终场预测通过以下方式获得:

$$\hat{Y}(x,z) = B(x,z) + \sigma_f \hat{r}_f(x,z) + \mu_f, \tag{14}$$

其中， μ_f 和 σ_f 是细残差的训练集统计量。因此，粗阶段处理占主导地位的残差包络，而全分辨率阶段则细化局部阴影过渡和干扰细节。

E. 训练目标与优化

令 r_c 和 r_f 表示归一化的粗残差目标和细残差目标，令 $\hat{r}_c$ 和 $\hat{r}_f$ 表示相应的网络输出。训练采用加权掩膜 Huber 损失，仅在地形上方的有效像素处进行评估:

$$\mathcal{L} = \lambda_c \mathcal{L}_{\mathrm{Huber}}(\hat{r}_c, r_c; M_c) + \lambda_f \mathcal{L}_{\mathrm{Huber}}(\hat{r}_f, r_f; M_f), \tag{15}$$

其中 $\lambda_c = 1$ 和 $\lambda_f = 2$。粗残差和细残差仅在有效像素范围内分别进行归一化。

该网络采用 AdamW 进行优化，初始学习率为 5×10^{-4} ，权重衰减为 10^{-4}。训练过程中采用余弦退火调度，并结合混合精度训练、梯度裁剪和早停。

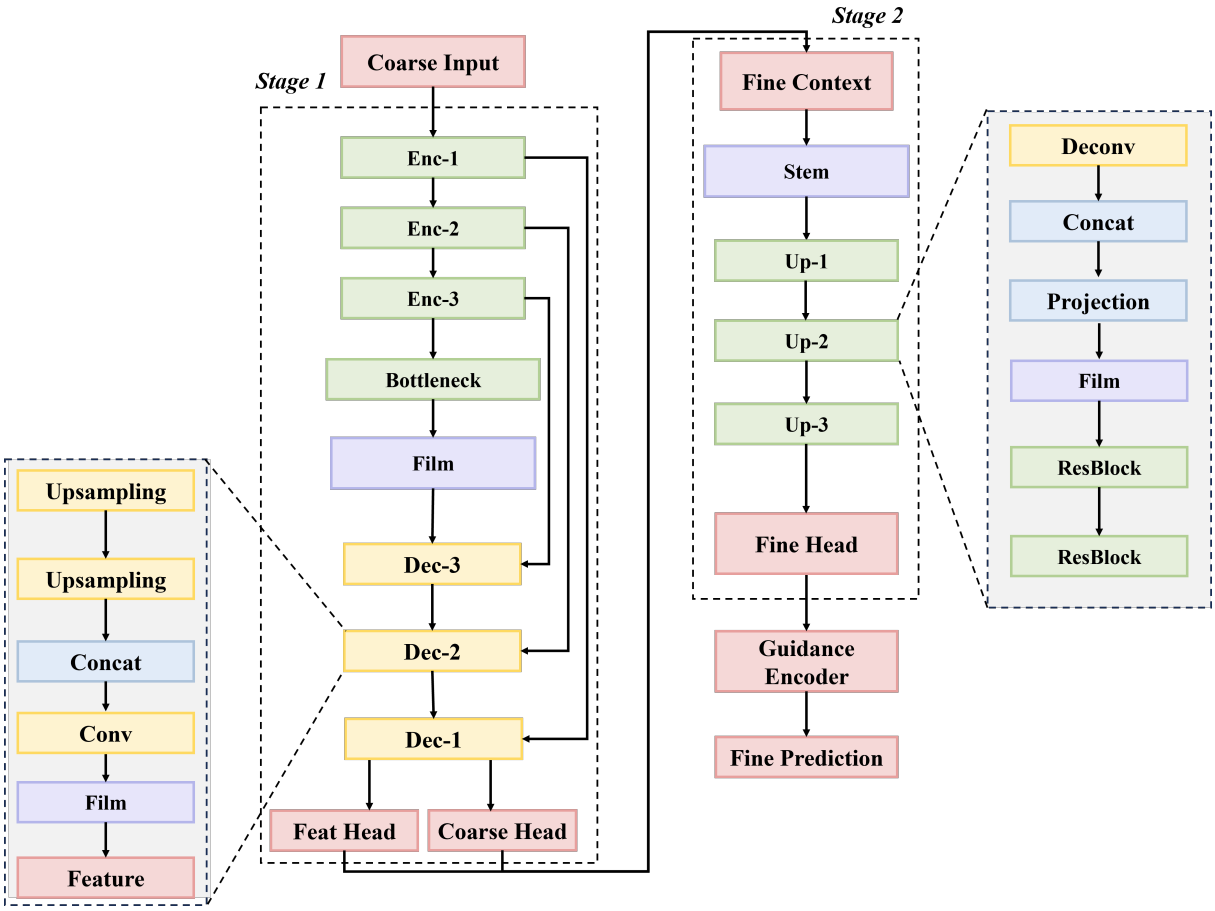

图3：所提出的两阶段由粗到细网络的详细结构。

表I：SSPE仿真的输入参数设置。

参数	最小值	最大值	增量
波束宽度 [度]	15	30	1
下倾角 [度]	0	15	1
天线高度 [米]	7	35	1
地形趋势 [度]	−0.3	0.3	0.06

III. 数值结果

本节在 SSPE 生成的合成数据上评估所提框架。评估内容包括组件消融、与标准 U-Net 以及复现的 Huang等 [14],物理引导卷积神经网络的比较，以及零样本跨频率测试。合成仿真域的距离范围为 2 km，高度为 150 m。主要训练和测试数据在 1.0 吉赫兹下生成，距离间隔为 $\Delta x = 25\lambda$ =7.5 m，高度为 $\Delta z = 0.5\lambda = 0.15$ m，遵循 [1] 中的指南。天线波束宽度、下倾角和高度分别从表I中的离散网格独立采样，地形趋势角则从所列区间中抽取。

合成地形剖面通过叠加 K =50 个具有对数间隔空间频率和幂律振幅的随机正弦分量生成。第 k 个分量的频率定义为

$$f_k = f_{\min} \cdot \left(\frac{f_{\max}}{f_{\min}}\right)^{\frac{k-1}{K-1}}, \quad k = 1, \ldots, K, \tag{16}$$

其中 $f_{\min} = 0.001\ \mathrm{m}^{-1}$，且 $f_{\max} = 1/(2\Delta x)$ 是由距离网格施加的奈奎斯特极限。相应的振幅遵循 $1/f$ 幂律谱，

$$a_k = a_{\max} \cdot f_k^{-\beta}, \tag{17}$$

其中 $a_{\max} = 10$ 和 $\beta = 1$，从而突出大尺度起伏，同时抑制不切实际的高频振荡。随后将原始地形扰动合成为

$$PN(x) = \sum_{k=1}^{K} a_k \sin(2\pi f_k x + \phi_k), \tag{18}$$

其中，相位 $\phi_k \sim \mathcal{U}[0, 2\pi)$ 针对每个剖面独立抽取。

为独立控制地形粗糙度而不影响其频谱形状，将 $PN(x)$ 归一化为零均值、单位方差，再乘以随机粗糙度因子 $\eta \sim \mathcal{U}[0.05, 0.50]$。随后叠加坡角为 θ 的线性趋势，得到最终的高程剖面

$$y(x) = h_0 + 30\eta\,\widetilde{PN}(x) + \tan(\theta)\,x, \tag{19}$$

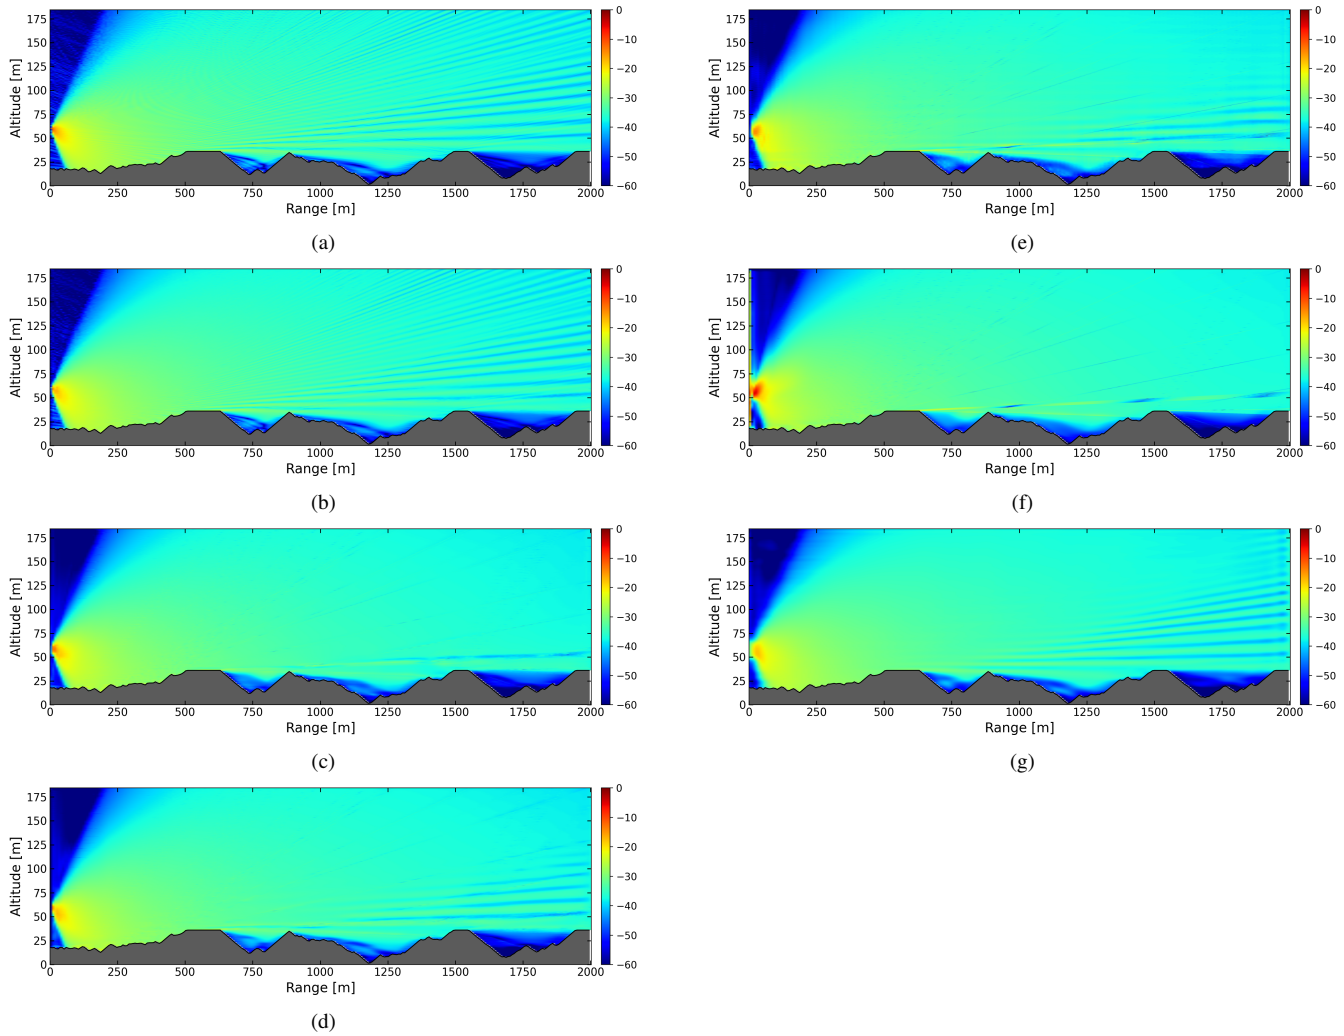

图 4：消融研究中的代表性场图预测。(a) SSPE 参考结果。(b) 完整模型。(c) 不使用各向异性卷积。(d) 不使用天线条件化。(e) 不使用第二阶段细化。(f) 不使用基于基线的引导堆栈。(g) 不使用解析基线。测试案例采用天线高度 25 m、3 dB 波束宽度 30° 和下倾角 10°。

其中，$h_0 = 18$ m 为发射机侧地面高程 $\widetilde{\ }$，$PN(x)$ 表示归一化地形扰动。所得剖面被裁剪至 $[0.1, 36]$ m，并将相邻距离采样点之间的高程变化限制为 1.8 m，以避免出现不切实际的陡峭坡度。

对于每个有效的地形–天线配置，SSPE求解器会生成一个二维场图，将其转换为分贝幅度，并将其下限设为 -200dB。共保留 9,836 个样本，并按 8:2 的比例划分为训练集和测试集。每个合成样本在单个 CPU核心上平均需要 289.77 秒的 SSPE仿真时间。神经网络推理时间在配备 Intel Xeon Gold 6458Q CPU 和 NVIDIA GeForce RTX 4090 D GPU 的工作站上测量。

A. 所提框架的消融实验

我们首先通过消融研究，分别分析各个设计组件的贡献。将完整模型与五种变体进行比较，这些变体分别移除了各向异性卷积、天线条件化、第二阶段细化、基线派生的引导堆叠或解析基线。在该组件隔离实验中，所有变体均采用相同的训练方案，因此消融结果应解读为表 II 中的相对比较。图 4 展示了一个测试案例的代表性场分布图，其中天线高度为 25 m、3 dB 波束宽度为 30°、下倾角为 10°；图 5 展示了高度为 50 m 处对应的路径损耗剖面。

在这次消融实验中，完整配置的平均绝对误差最低，为 2.2835 dB。移除基于基线的引导堆栈后，性能下降最明显，平均绝对误差升至 6.9426 dB。图 4(f) 中相应的场分布图显示，地形引起的阴影区域恢复效果较弱，障碍物后的场恢复也较差，这表明基于基线的引导信道为残差校正提供了重要先验。移除各向异性卷积后，平均绝对误差升至 4.1828 dB。图 4(c) 中的预测结果沿传播方向更加平滑，且部分斜向条纹连续性有所丢失，这支持了在 SSP E 网格上使用距离对齐卷积核。移除天线条件化后，平均绝对误差升至 3.7282 dB；图 4(d) 中的预测仍

表 II：所提框架在合成测试集上的消融研究。平均绝对误差越低越好。符号“–”表示相应组件在该消融设置下未定义。

各向异性卷积	天线条件化	第二阶段细化	基于基线的引导堆叠	分析基线	MAE (dB)
✓	✓	✓	✓	✓	2.2835
×	✓	✓	✓	✓	4.1828
✓	×	✓	✓	✓	3.7282
✓	✓	×	–	✓	3.4892
✓	✓	✓	×	✓	6.9426
✓	✓	✓	–	×	2.9837

能捕捉场的粗略结构，但对大尺度衰减趋势的预测不够准确。不进行第二阶段细化时，平均绝对误差升至 3.4892 dB，图 4(e) 显示精细振荡细节减少，局部阴影过渡也较弱。不使用解析基线的变体与其他消融变体有所不同，因为此时网络执行的是全场回归，且无法获得基于基线的引导堆栈。其平均绝对误差升至 2.9837 dB，与完整模型相比，条纹恢复较弱，阴影过渡的预测也不够准确。

图 5 中的一维比较呈现出相同的趋势。完整模型最接近地跟踪了 SSPE 路径损耗曲线，而每个消融变体都呈现出明显不同的偏差模式。移除基于基线的引导堆栈或各向异性卷积会产生最大的误差，而其他三个消融案例造成的退化较小，但仍然可见。这些结果支持基于基线的引导、各向异性特征提取、天线条件化和两阶段细化所作出的贡献。

B. 与基于学习的方法比较

接下来，我们在相同的留出合成测试集上，将所提框架与两种基于学习的代理模型进行比较。第一种是标准 U-Net，它经过训练，可根据地形和天线输入回归完整的

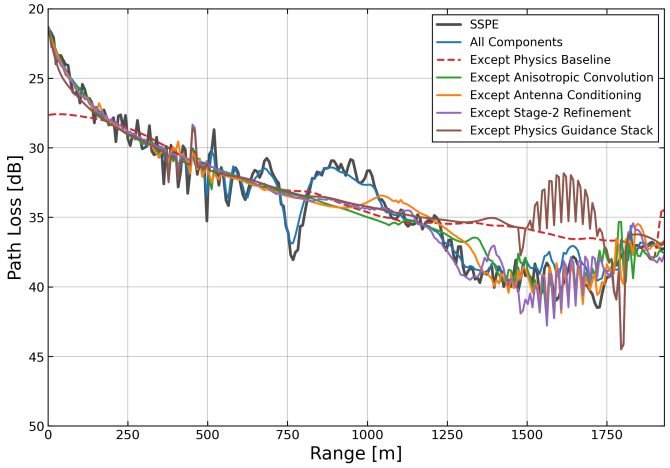

图 5：图 4 所示代表性消融案例在 50米高度处的路径损耗剖面。

表III：在相同的留出的合成测试集上与基于学习的方法进行比较。平均绝对误差越低、推理时间越短越好。

方法	平均绝对误差（dB）	平均推理时间（毫秒/样本）	# 参数
标准 U-Net	3.3955	45.75	17,325,697
Huang 等 [14]	3.2560	27.30	44,603,399
所提出的模型	2.1061	11.30	8,207,266

SSPE场，且不使用物理先验。第二种是复现的 Huang等人 [14]提出的物理引导卷积神经网络。这两种对照方法分别用于区分加入物理相关输入的价值与所提解析基线残差形式的价值。三种方法均采用相同的测试方案进行评估。表III报告了定量结果，图 6 和图 7 展示了一个具有代表性的场分布图和路径损耗剖面。

表III显示，所提出的模型在该测试集上同时提升了准确性和效率。标准 U-Net 的平均绝对误差为 3.3955 dB，而 Huang 等复现模型的平均绝对误差为 3.2560 dB。所提出的模型将平均绝对误差降至 2.1061 dB，相较于这两个基线分别降低了37.9%和35.3%。此外，该模型仅使用 8.2M 个参数，单样本平均推理时间为 11.3 ms；相比之下，标准 U-Net 使用 17.3M 个参数，推理时间为 45.75 ms，而 Huang 的模型使用 44.6M 个参数，推理时间为 27.30 ms。这些结果与混合解析-神经公式的预期作用一致：确定性基线吸收了部分大尺度传播趋势，使神经网络能够对地形相关校正进行建模。

图 6 中的定性比较与定量结果一致。标准 U-Net 能够捕捉整体衰减模式，但会平滑掉许多地形耦合条纹结构，并遗漏一些局部阴影过渡。Huang 的模型改善了大尺度包络，但在精细干扰模式中仍显得较为平滑。在这个具有代表性的案例中，所提出的模型能够更好地保留衰减包络和振荡条纹结构。

图 7 中的一维路径损耗比较呈现出相同的情况。在 2 千米范围内，所提出的预测结果与 SSPE 参考结果更为接近，而标准 U-Net 和 Huang 的模型在衰减趋势和局部振荡细节方面偏差更大。这些比较表明，对于这项任务，解析基线残差形式比单纯为直接回归模型添加物理条件输入更为有效。

C. 跨频率泛化

传播代理模型的一项重要实际要求，是在载波频率变化时仍能发挥作用。在传统的固定频率代理模型中，频率依赖性是从训练数据中隐式学习得到的，因此，将模型扩展到其他频段通常需要新的训练数据并重新训练。在所提框架中，主要的频率依赖性通过确定性基线 B显式表示，而神经网络则学习

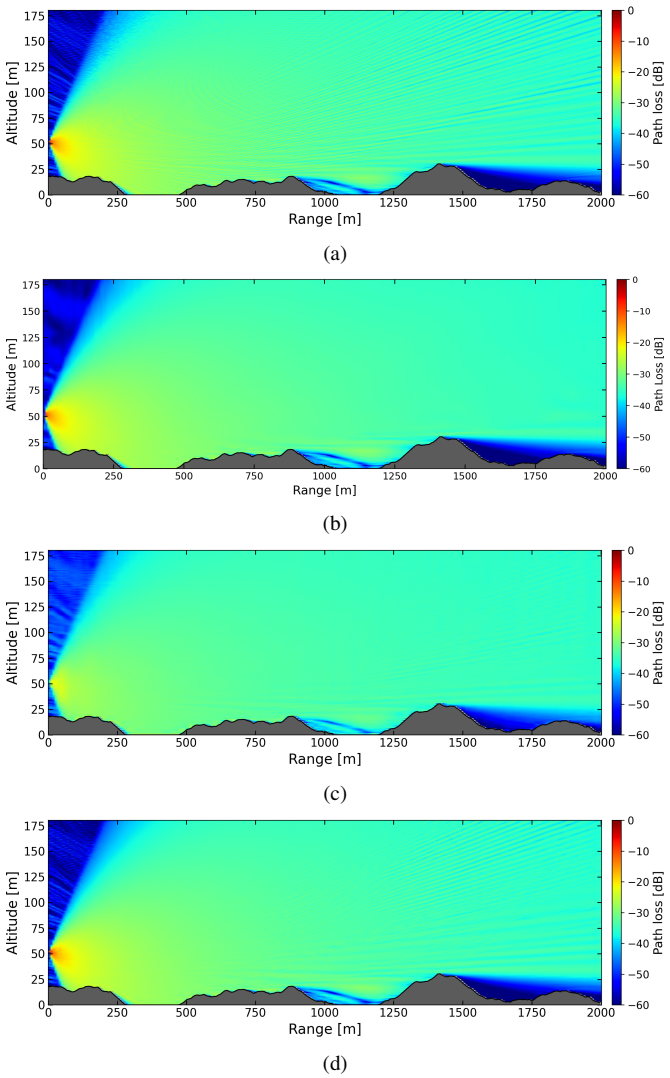

图 6：基于学习的方法之间的代表性场图比较。(a) SSPE 参考结果。(b) 标准 U-Net。(c) Huang 模型 [14]。(d) 所提出的模型。测试案例采用高度为 16 米的天线、3 dB 波束宽度 28°和下倾角 6°。

与地形和天线配置相关的残差校正。这种结构使训练完成的残差模型能够在未见频率下进行测试，且只需重新计算解析基线。

为评估这一行为，模型仅在合成的 1.0 吉赫兹数据集上进行训练，然后直接在包含 150 个样本的留出 1.8 吉赫兹测试集上进行评估。在训练或微调过程中均不使用 1.8 吉赫兹样本。在测试时，将解析基线重新计算为 1.8 吉赫兹，同时保持所有学习得到的参数不变。本实验旨在检验残差模型在重新计算基线后，是否仍对一个未见过的邻近频率有用；并不旨在证明其具备宽带泛化能力。

图 8 中的定性场图比较表明，在未见过的载波频率下，零样本预测保留了主要衰减模式和主要的地形耦合阴影过渡。图 9 中的路径损耗曲线与 SSPE 参考结果在大部分距离范围内吻合，但仍可看到局部偏差。1.8 吉赫兹测试集上的平均绝对误差为 2.8692 dB，而 1.0 GHz 频率内测试的误差为 2.1061 dB。频率大幅偏移时出现这种增幅是预期之中的，但结果表明，即使在新频率下重新计算解析基线，残差模型仍然保留了有用的信息。

IV. 实测地形剖面验证

所提出的模型还在丹麦北部实测的 Hjorringvej 不规则地形剖面上进行了测试 [28]。该案例采用的外部剖面并非来自用于训练的合成地形生成器。该剖面全长 11 km，在 970 MHz 下，针对相对介电常数为 $\varepsilon_r = 4.5$ 、损耗角正切为 $\tan\delta = 0.07$的有损介电地面进行了评估。图10和图11比较了所提出的预测结果、SSPE 参考结果以及现有的场测量数据。

图10中的场图比较表明，所提出的预测结果捕捉到了沿路线的主要衰减趋势和地形引起的阴影模式。图11中的路径损耗比较进一步表明，在剖面的大部分范围内，所提出的曲线与 SSPE 参考结果较为接近，并总体上跟随实测趋势。该结果应视为一个基于实测剖面的案例研究，而非完整的测量活动。它为真实地形剖面提供了一项外部一致性检查，但仍需开展更广泛的基于测量的验证。对于该剖面，SSPE 模拟完整场需要 9,343 s，而所提出的模型仅需 0.018 s。

V. 结论

本文提出了一种混合解析-神经残差代理模型，用于在不规则地形上进行快速无线电传播预测。该方法将 SSPE 场分解为确定性的解析基线和学习得到的残差校正。该基线表示自由空间扩散、天线方向性、修正刀刃绕射以及地形感知镜面反射

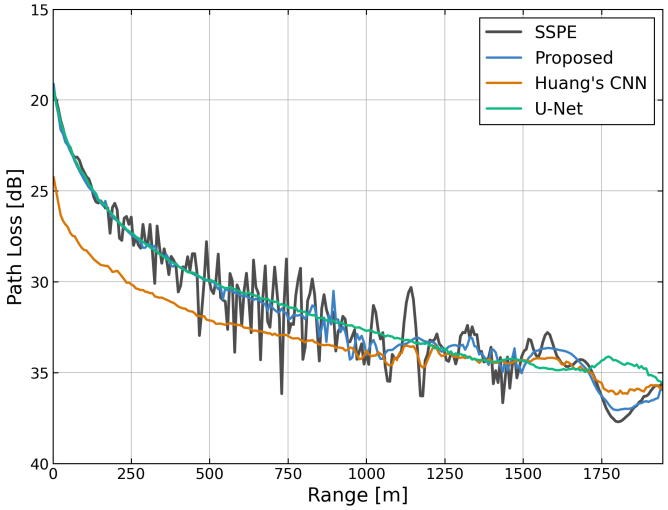

图 7：图 6 所示代表性对比案例在 50米高度处的路径损耗剖面。

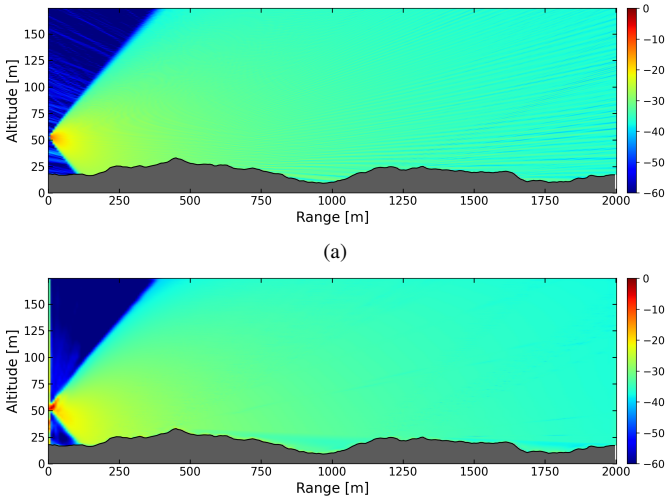

图 8：用于零样本迁移至 1.8 吉赫兹的代表性场图预测。(a) SSPE 参考结果。(b) 所提出的零样本预测。测试案例采用天线高度 26 m、3 dB 波束宽度 25° 和下倾角 4°。

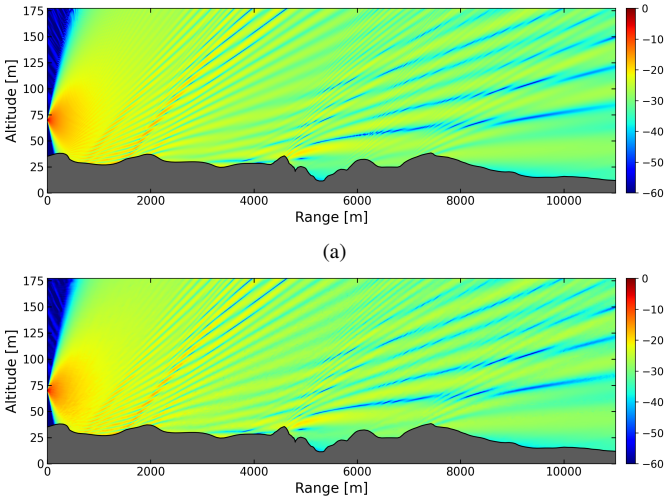

图10：970 MHz下实测*Hjorringvej*地形剖面的场图比较。(a) SSPE 参考结果。(b) 所提模型的预测结果。

，而神经网络则通过轻量级的由粗到细架构对剩余的地形相关失配进行建模。

在 SSPE生成的合成数据上进行的实验表明，相较于直接回归学习基线，这种解析基线残差形式改善了精度—效率权衡。在主要合成测试集上，所提出的模型将平均绝对误差从标准 U- Net 的 3.3955 dB 和复现的物理引导卷积神经网络的 3.2560 dB 降至 2.1061 dB，同时使用更少的参数并具有更低的推理时间。组件消融实验进一步表明，基于基线的引导堆栈、各向异性卷积、天线条件化、第二阶段细化以及解析基线均对最终预测质量有所贡献。

当前结果还表明，在解析基线中保留频率依赖性具有实际价值。在 1.0 吉赫兹下训练的模型，在无需重新训练、仅重新计算基线的情况下，于 1.8 吉赫兹下进行评估时，平均绝对误差为 2.8692 dB。此外，Hjorringvej 案例研究表明，所提出的代理模型仍然接近 SSPE 参考结果，并且在外部地形剖面上总体遵循实测路径损耗趋势。目前的验证仍局限于一个未见频率和一个实测剖面。未来的工作将把评估扩展到更广泛的频率范围、更多样的地形类别以及更大规模的基于测量的测试集。

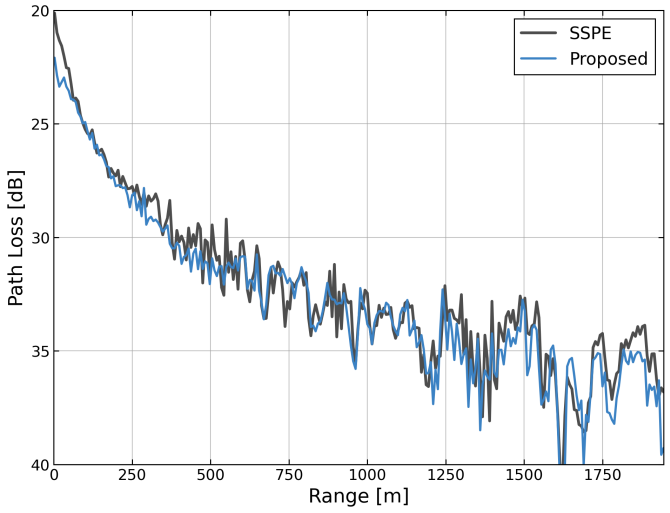

图9：图8所示代表性零样本迁移案例在50米高度处的路径损耗剖面。

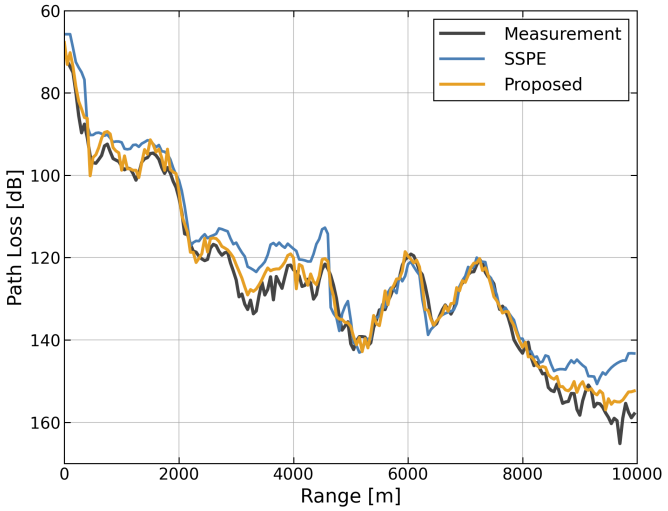

图11：970 MHz下实测*Hjorringvej*地形剖面的路径损耗比较。曲线分别对应场测量、SSPE 参考结果和所提模型。

参考文献

[1] Q. Guo 和 Y. Long，《用于不规则地形上传播建模的 Pade 二阶抛物方程》，IEEE天线与无线传播快报，第 16 卷，第 2852–2855 页，2017 年。[2] O. Ozgun，《用于对流层传播中地形效应建模的递归双向抛物方程方法》，IEEE《天线与传播汇刊》，第 57 卷，第 9 期，第 2706–2714 页，2009 年。[3] P. Zhang、L. Bai、Z. Wu 和 L. Guo，《将抛物方程应用于对流层地波传播：近期成果与重要里程碑综述》，IEEE天线与传播杂志，第 58 卷，第 3 期，第 31–44 页，2016 年。[4] H. Qin 和 X. Zhang，《用于隧道传播建模的有限差分与分步傅里叶抛物方程方法比较分析》，IET微波、天线与传播，第 18 卷，第 2 期，第 59–72 页，2024 年。[5] A. Seretis 和 C. D. Sarris，《面向室内传播的基于物理的可泛化卷积神经网络模型》，IEEE《天线与传播汇刊》，第 70 卷，第 6 期，第 4112–4126 页，2022 年。[6] A. Seretis、V. Jevremovic、A. Jemmali 和 C. D. Sarris，《体育场无线电波传播的可泛化基于机器学习的建模》，IEEE天线与传播开放期刊，第 4 卷，第 1116–1128 页，2023 年。[7] S. Bakirtzis、J. Chen、K. Qiu、J. Zhang 和 I. Wassell，《Em deepray：一种高效、可泛化且逼真的数据驱动室内传播模型》，IEEE《天线与传播汇刊》，第 70 卷，第 6 期，第 4140–4154 页，2022 年。[8] Z. Ma 、 K. Xu 、 R. Song 、 C.-F. Wang 和 X. Chen，《通过生成对抗网络实现基于学习的快速电磁散射求解器》，IEEE《天线与传播汇刊》，第 69 卷，第 4 期，第 2194–2208 页，2021 年。[9] V. V. Ratnam、H. Chen、S. Pawar、B. Zhang、C. J. Zhang、Y.-J. Kim、S. Lee、M. Cho 和 S.-R. Yoon，《Fadenet：基于深度学习的毫米波大尺度信道衰落预测及其应用》，IEEE Access，第 9 卷，第 3278–3290 页，2021 年。[10] T. Shan、J. Zeng、X. Song、R. Guo、M. Li、F. Yang 和 S. Xu，《用于电磁建模的物理信息监督式残差学习》，IEEE《天线与传播汇刊》，第 71 卷，第 4 期，第 3393–3407 页，2023 年。[11] H. Qin 和 X. Zhang，《用于隧道中毫米波传播建模的双向抛物方程法》，载于《2022 IEEE第八届计算机与通信国际会议》（ICCC），第 1573–1577 页，2022 年。[12] S. Huang、S. Wang 和 X. Zhang，《用于隧道中无线电波传播的可泛化卷积神经网络模型》，IET微波、天线与传播，第 18 卷，第 7 期，第 467–479 页，2024 年。[13] C. Brennan 和 K. McGuinness，《基于矩量法的特定场景深度学习路径损耗模型》，载于《2023年第17届欧洲天线与传播会议》（EuCAP），第 1–5 页，IEEE，2023 年。[14] S. Huang、H. Qin、W. Hou、X. Zhang 和 X. Zhang，《用于不规则地形传播的可泛化物理引导卷积神经网络》，IEEE《天线与传播汇刊》，第 73 卷，第 6 期，第 3975–3985 页，2025 年。[15] X. Zhang 、 J. Ren 、 X. Shu 、 L. Zhou、B. Zhang 和 X. Chen，《利用深度卷积神经网络进行蜂窝网络无线电传播建模》，载于《第26届ACM SIGKDD国际知识发现与数据挖掘会议论文集》，第 2378–2386 页，2020 年。[16] L. Liu、Y. Yao、Z. Cao 和 M. Zhang，《DeepLoRa：为低功耗广域网中的远距离链路学习精确的路径损耗模型》，载于《IEEE INFOCOM 2021——IEEE计算机通信会议》，第 1–10 页，2021 年。[17] R. Levie、C. Yapar、G. Kutyniok 和 G. Caire，《RadioUNet：利用卷积神经网络进行快速无线电地图估计》，IEEE无线通信汇刊，第 20 卷，第 6 期，第 4001–4015 页，2021 年。[18] M. Chen、D. G¨und¨uz、K. Huang、W. Saad、M. Bennis、A. V. Feljan 和 H. V. Poor，《无线网络中的分布式学习：近期进展与未来挑战》，IEEE J. Sel. Areas Commun.，第 39 卷，第 12 期，第 3579–3605 页，2021 年。[19] J. Kim、J. K. Lee 和 K. M. Lee，《利用超深卷积网络实现准确的图像超分辨率》，载于《IEEE计算机视觉与模式识别会议论文集》（CVPR），第 1646–1654 页，2016 年。[20] K. Zhang、W. Zuo、Y. Chen、D. Meng 和 L. Zhang，《超越高斯去噪器：用于图像去噪的深度 CNN 残差学习》，*IEEE*图像处理汇刊，第26卷，第3155页，2017年，第7期，第3142页。[21] M. Alrabeiah和A. Alkhateeb，“用于时分双工和频分双工大规模MIMO的深度学习：在空间和频率中映射信道”，载于*2019*年阿西洛马会议：信号、系统与计算机，第1465–1470页，2019年。[22] C.-J. Sung、F.-H. Lin、T.-H. Huang、C.-H. Huang、H. Chen、C.-K. Wen和H. Wymeersch，“CommUNext：基于深度学习的跨频段与多方向信号预测”，2025年。[23] M. Levy，《电磁波传播的抛物方程方法》。英国伦敦：电气工程师学会，2000年。[24] G. Apaydin和L. Sevgi，《无线电波传播与抛物方程建模》。美国新泽西州霍博肯：Wiley-IEEE出版社，2017年。[25] D. Boscaini、J. Masci、E. Rodol`a和M. Bronstein，“利用各向异性卷积神经网络学习形状对应”，载于神经信息处理系统进展（*NeurIPS*），第3189–3197页，2016年。[26] F. Yu、V. Koltun和T. Funkhouser，“空洞残差网络”，载于*IEEE*计算机视觉与模式识别会议论文集（*CVPR*），第636–644页，2017年。[27] E. Perez、F. Strub、H. de Vries、V. Dumoulin和A. C. Courville，“FiLM：基于通用条件层的视觉推理”，载于第三十二届*AAAI*人工智能会议论文集（*AAAI*），第3942–3951页，2018年。[28] J. T. Hviid、J. B. Andersen、J. Toftg˚ard和J. Bojer，“农村地区的基于地形的传播模型——一种积分方程方法”，*IEEE*《天线与传播汇刊》，第43卷，第46页，1995年，第1期，第41页。