RadioDiff-Flux：通过生成式去噪扩散模型轨迹中点复用实现高效无线电地图构建

Xiucheng Wang，*IEEE*研究生学生会员，Peilin Zheng，*IEEE*研究生学生会员，HonggangJia，*IEEE*研究生学生会员，Nan Cheng，*IEEE*高级会员，Ruijin Sun，*IEEE*会员，Conghao Zhou，*IEEE*会员，Xuemin (Sherman) Shen，*IEEE*会士

arXiv:2601.02790v1 [cs.LG] 6 Jan 2026

摘要—**准确构建无线电地图（RM）对于实现环境感知型自适应无线通信至关重要。然而，在以高速移动的网络实体和快速变化的环境为特征的未来6G场景中，满足实时要求极具挑战性。尽管生成式扩散模型（DM）能够以秒级延迟达到最先进水平的准确性，但其迭代特性会在对延迟敏感的场景中造成难以承受的推理延迟。本文揭示了扩散过程的一项关键结构特性：语义相似场景中的潜在中点高度一致。基于此，我们提出了RadioDiff-Flux，这是一种新颖的两阶段潜在扩散框架，将静态环境建模与动态细化解耦，从而能够复用预计算中点，避免冗余去噪。具体而言，第一阶段仅利用静态场景特征生成粗略的潜在表示，该表示可缓存并在相似场景间共享。第二阶段使用预训练模型，根据动态条件和发射机位置对该表示进行适配，从而避免重复执行早期阶段的计算。所提出的RadioDiff-Flux在保持保真度的同时，显著缩短了推理时间。实验结果表明，RadioDiff-Flux最高可实现 50× 倍加速，且准确率损失低于0.15%，证明了其在未来6G网络中实现快速、可扩展RM生成的实用价值。**

索引词—**无线电地图，生成式人工智能，扩散模型，中点复用。**

I. 引言

6G网络对高效、自适应信道估计方法的需求日益增长，研究重点已从传统的基于导频信号的测量转向计算方法 [1]–[3]。这主要是因为需要在大规模高维环境中估计信道特性，而这类环境在6G中十分常见；此外，还需要集成智能反射面等无源设备

本研究得到中国国家重点研发计划（2024YFB907500）的支持。

Xiucheng Wang、Peilin Zheng、Honggang Jia、Nan Cheng 和 Ruijin Sun 任职于综合业务网理论及关键技术国家重点实验室和西安电子科技大学通信工程学院，地址为中国西安 710071。（电子邮箱：{xcwang 1、plzheng、jiahg}@stu.xidian.edu.cn；dr.nan.cheng@ieee.org；sunruijin,@xidian.edu.cn；conghao.zhou@ieee.org）。（Peilin Zheng 和 Honggang Jia 贡献相同。）*Nan Cheng* 为通讯作者。Xuemin (Sherman) Shen 任职于滑铁卢大学电气与计算机工程系，地址为加拿大滑铁卢 N2L 3G1（电子邮箱：sshen@uwaterloo.ca）。

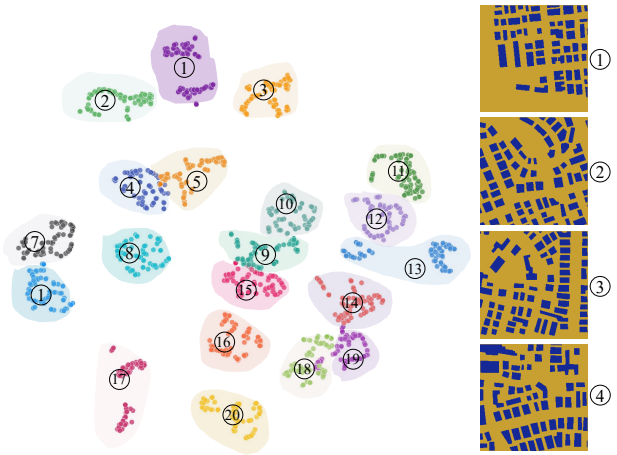

图 1：无线电地图潜变量相似性的示意图。

(智能反射面) [4]–[6]。此外，移动无线接入节点（如无人机和卫星）的移动路径预先规划，也使信道估计变得更加复杂，因为这些节点必须在抵达目标区域之前考虑其动态位置 [7], [8]。为应对这些挑战，无线电地图（RM） [9] 和信道知识地图（CKM） [10] 应运而生，成为通过预计算直观呈现无线信道特征空间分布的重要工具。尽管这些方法能够有效捕捉空间分布的准确性，但往往无法满足对高效构建和实时适应能力日益增长的需求，尤其是在环境因素或无线发射机参数动态变化时 [10], [11]。在 6G网络中，用户分布、环境条件和个性化服务需求的快速变化，会导致服务需求出现显著的时空变化 [12]。因此，网络管理者必须能够实时快速调整服务策略，以维持服务质量和效率 [13]。然而，传统的预计算无线电地图和信道知识地图难以提供及时更新或支持动态环境中的按需服务，因为它们往往受限于无法快速响应不断变化的条件 [10]。本研究指出，快速无线电地图推理至关重要，并提出一种创新方案：利用预先计算的无线电地图或其中间变量，在环境或

基站（BS）位置发生变化后，快速重建无线电地图。这一能力符合 6G网络的要求，能够提供必要的敏捷性和动态适应能力，以应对下一代无线系统的挑战。

现有技术可分为两种范式：物理驱动方法 [14], [14], [15]和数据驱动方法 [9]-[16], [17]。然而，两者在动态场景中都面临根本性局限。物理驱动方法（如射线追踪）通过求解麦克斯韦方程组来模拟电磁波的传播 [18]。虽然这类方法能够实现厘米级准确性的无线电地图建模，但其计算复杂度会随场景规模呈指数级增长。构建分辨率为100米的无线电地图，往往需要服务器级算力运行数十分钟；而任何细微的环境变化（如车辆移动）都可能导致电磁波路径发生全局变化，从而必须重新进行完整计算 [19]。这类方法僵化的计算架构显然无法满足6G场景下无线电地图按秒更新的需求。数据驱动方法试图通过神经网络学习环境特征映射，突破效率瓶颈。然而，传统判别模型虽然擅长根据局部特征回归信道参数，却难以生成空间连贯的全局无线电地图 [9], [20]。生成对抗网络（GAN）虽具备数据生成能力，但由于模式崩溃和训练不稳定性，其在实际部署中的可靠性不足 [16]。近年来，扩散模型凭借渐进式生成机制，在无线电地图构建任务中取得了显著进展。基于扩散模型的方法在准确性方面可媲美射线追踪 [17], [21]。然而，扩散模型的迭代去噪过程需要进行数千次神经网络推理，导致生成单张无线电地图需要数秒，这仍难以满足高动态场景的实时需求 [22]。此外，传统扩散模型的“零记忆”生成模式完全忽略了场景连续演化中的时空相关性。例如，当无人机沿轨迹移动时，扩散模型需要针对每个新位置从头执行完整的去噪过程，却未能有效利用相邻位置无线电地图之间隐含的传播规律相似性。这种冗余计算不仅效率低下，还可能因随机噪声初始化而引入帧间抖动，进而破坏时间一致性——对于需要连续无线电地图序列的应用而言，这尤其致命。

为解决现有无线电地图构建方法在动态环境中的局限性，如图 1 所示，我们的研究揭示了一项关键的实证发现：在具有相近环境特征的场景中，扩散过程中的中间潜变量表现出很强的相似性。例如，当在相同建筑布局内对基站位置进行轻微调整时，尽管最终无线电地图存在显著差异，扩散轨迹在去噪的中间阶段仍展现出高度一致的潜在表示。这一观察表明，中间状态主要编码了稳定的场景不变特征，例如建筑结构和材料属性，而后续阶段则负责细化天线辐射方向图和动态障碍物等场景特定细节。基于这一洞见，我们提出了 RadioDiff-Flux，这是一种两阶段隐式扩散框架，旨在复用生成过程中的中间状态，即中点。通过将静态环境特征的建模与动态元素或发射机特定元素的细化解耦，我们的方法在保持空间和时间一致性的同时，显著提升了推理效率。由此形成的框架能够实现可扩展且低时延的无线电地图生成，尤其适用于动态 6G场景。本文的主要贡献总结如下。

1）我们对潜在扩散过程进行了详细分析，发现，在同一静态环境中，由不同基站位置或动态变化生成的无线电地图具有高度相似的扩散中点。这些中点捕捉了稳定的环境语义，使其得以复用，从而显著减少动态场景中的冗余推理。2）为支持这一观察，我们基于 KL 散度进行了理论分析，表明结构相似的无线电地图具有高度一致的去噪轨迹。这为中点复用的可行性与有效性提供了严格的理论基础。3）基于上述洞见，我们提出了两种实现方案：原始中点复用，通过复用预训练模型中的缓存中点实现零成本适配；以及 RadioDiff-Flux，一种将静态与动态推理解耦、以提升准确性和效率的两阶段框架。这两种设计均可在保持生成保真度的同时，实现无线电地图的快速更新。4）大量实验结果证明了我们方法的有效性。在动态场景中，所提出的中间点复用策略使推理速度提升超过 50× 倍，同时无线电地图构建精度的下降低于 0.12%，显著提升了基于扩散的无线电地图生成在实时及移动性感知无线系统中的实用性。

II. 预备知识

扩散模型，尤其是去噪扩散概率模型（DDPM） [23], [24],，已成为适用于各种数据合成任务的强大生成模型，包括图像生成 [25],、去噪 [22], ，甚至无线信道估计领域 [17], [26]。这些模型通过前向过程逐步向数据添加噪声，然后学习在反向去噪过程中逆转噪声。扩散模型的主要优势在于，它们能够通过渐进式细化过程生成高质量数据，因此非常适合无线电地图构建[27], [28]等需要精确生成复杂数据分布的任务。

DDPM 的前向过程包含一个长度为 T 的马尔可夫链，在每一步中，都会逐渐向原始数据添加高斯噪声。从干净数据x_0 到含噪数据 x_T 的转换由一系列条件

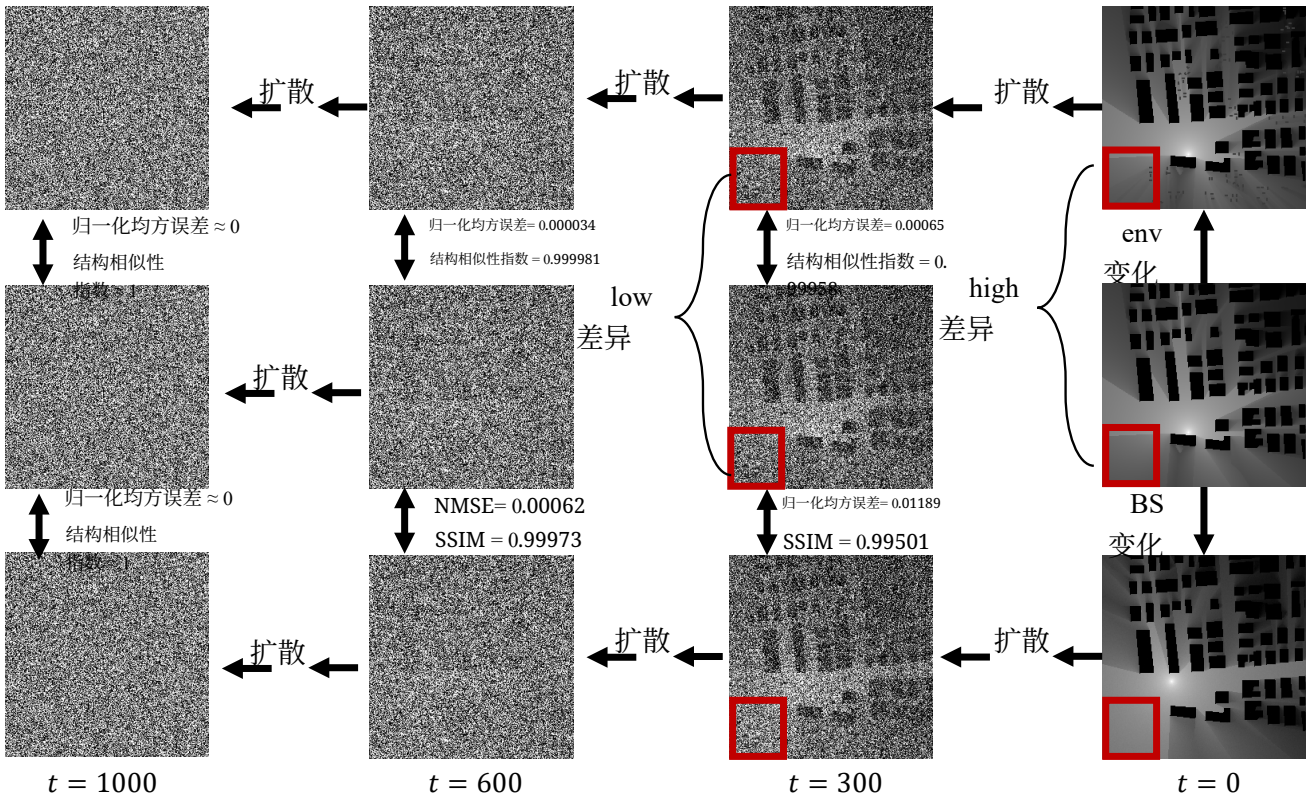

(a) 扩散中点变量的相似性。

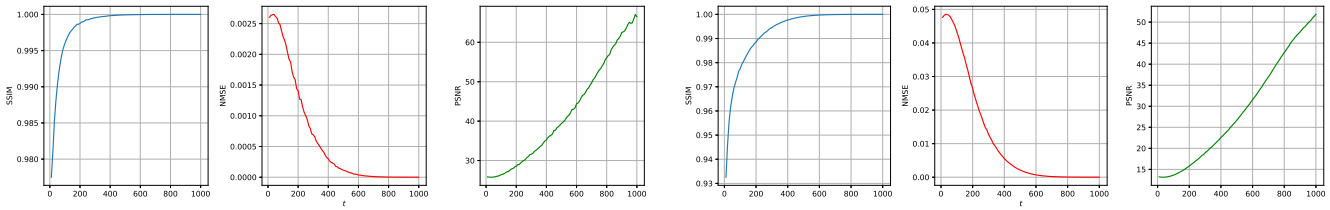

(b) 相似环境之间扩散中点变量的度量相似性。

(c) 不同位置之间扩散中点变量的度量相似性。

图 2：潜变量去噪复用的动机示意图。(a) 展示语义相似的无线电地图的扩散轨迹收敛情况。(b) 和 (c) 定量测量扩散过程中潜变量的相似性。x 轴表示扩散时间步 t，y 轴表示两个不同场景的潜变量之间的归一化均方误差。

分布定义；在每一步 t，数据都会受到扰动，方法是添加方差由一个时间表控制的噪声。形式上，前向过程建模如下 [23]。

$$q(x_t|x_{t-1}) = \mathcal{N}(x_t; \sqrt{1-\beta_t} \cdot x_{t-1}, \beta_t \cdot I), \quad (1)$$

其中，β_t 是方差调度，用于控制每一步添加的噪声量；$\mathcal{N}(\cdot)$表示高斯分布，I 是单位矩阵。变量 x_t表示时间步 t时数据的含噪版本，该过程持续进行，直到 $t = T$，此时数据 x_T 基本上是纯噪声。为简化起见，整个前向过程可表示如下。

$$q(x_T|x_0) = \mathcal{N}(x_T; \sqrt{\bar{\alpha}_T} \cdot x_0, (1-\bar{\alpha}_T) \cdot I), \quad (2)$$

其中 $\alpha_t = 1 - \beta_t$，以及 $\bar{\alpha}_T = \prod_{t=1}^{T} \alpha_t$。这一累积过程有效地将原始数据 x_0 映射为噪声样本 x_T.

数据被扩散为噪声后，便学习反向过程，旨在从噪声版本中恢复原始数据。反向过程本质上是去噪步骤，其中每个噪声图像 x_t 都会被映射回更清晰的版本 x_{t-1}。反向动力学由如下分布控制。

$$p_\theta(x_{t-1}|x_t) = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t), \sigma_t^2 I), \quad (3)$$

其中，$\mu_\theta(x_t, t)$是由神经网络预测的分布均值，σ_t^2 是步骤 t处的方差。模型通过以下目标函数学习去噪函数 $\mu_\theta(x_t, t)$。

$$\mathcal{L} = \mathbb{E}_q \left[\|\epsilon - \epsilon_\theta(x_t, t)\|^2 \right], \quad (4)$$

其中，ϵ 是前向过程中添加的噪声，而 $\epsilon_\theta(x_t, t)$

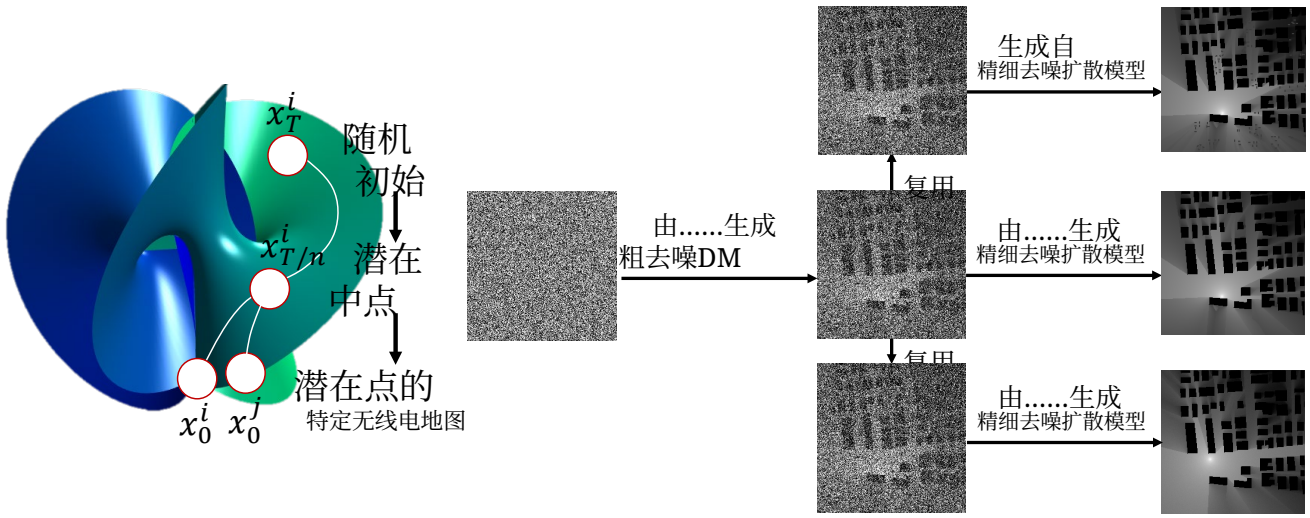

图 3：RM生成框架中潜在中点复用的示意图。

是模型预测的噪声。网络通过预测扩散每一步添加的噪声进行学习，并通过将预测噪声与真实噪声进行比较来最小化损失。通过从噪声 x_T开始迭代地反转这一过程，模型逐步恢复原始数据x_0。

根据 [29], 生成模型中潜变量的扩散过程可以等价地表示为如下随机微分方程（SDE） [30]。

$$\mathrm{d}\boldsymbol{z}_t = f_t \boldsymbol{z}_t \,\mathrm{d}t + g_t \,\mathrm{d}\boldsymbol{\epsilon}_t, \tag{5}$$

$$f_t = \frac{\mathrm{d}\log\gamma_t}{\mathrm{d}t}, \tag{6}$$

$$g_t^2 = \frac{\mathrm{d}\delta_t^2}{\mathrm{d}t} - 2f_t\delta_t^2, \tag{7}$$

其中， $\boldsymbol{z}_t$ 是时间 t的含噪潜在表示， $\boldsymbol{\epsilon}_t$ 是标准布朗噪声， f_t 和 g_t 分别表示漂移系数和扩散系数。逆向过程从 $\boldsymbol{z}_t$恢复 $\boldsymbol{z}_0$ ，其形式如下：

$$\mathrm{d}\boldsymbol{z}_t = \left[f_t\boldsymbol{z}_t - g_t^2\nabla_{\boldsymbol{x}}\log q(\boldsymbol{z}_t)\right]\mathrm{d}t + g_t\mathrm{d}\bar{\boldsymbol{\epsilon}}_t, \tag{8}$$

其中，$\bar{\boldsymbol{\epsilon}}_t$ 是来自时间反向扩散的高斯噪声项。

为增强可解释性和模块化程度，我们采用一种解耦的扩散表述，将去噪过程分解为加性结构：

$$\boldsymbol{z}_t = \boldsymbol{z}_0 + \int_0^t \boldsymbol{f}_t \,\mathrm{d}t + \int_0^t \mathrm{d}\boldsymbol{\epsilon}_t, \tag{9}$$

$$\boldsymbol{z}_0 + \int_0^t \boldsymbol{f}_t \,\mathrm{d}t = \boldsymbol{0}, \tag{10}$$

其中，第一个积分描述确定性信号衰减，第二个积分则表示累积噪声。假设扩散过程是各向同性的， $\boldsymbol{z}_0$ 给定时$\boldsymbol{z}_t$ 的条件分布可简化为：

$$q(\boldsymbol{z}_t|\boldsymbol{z}_0) = \mathcal{N}\left(\boldsymbol{z}_0 + \int_0^t \boldsymbol{f}_t \,\mathrm{d}t,\, t\boldsymbol{I}\right). \tag{11}$$

由此，我们推导出离散步长 Δt上的反向采样分布，这对于实际推理至关重要：

$$q\left(\boldsymbol{z}_{t-\Delta t} \mid \boldsymbol{z}_t, \boldsymbol{z}_0\right) = \mathcal{N}\left(\boldsymbol{z}_t + \int_t^{t-\Delta t} \boldsymbol{f}_t \,\mathrm{d}t - \frac{\Delta t}{\sqrt{t}}\boldsymbol{\epsilon}, \frac{\Delta t(t-\Delta t)}{t}\boldsymbol{I}\right). \tag{12}$$

[17]中的最先进神经网络无线电地图构建方法也采用了上述DDM架构。

III. 系统模型与问题表述

本文考虑在一个离散二维空间区域内构建无线电地图的场景，该区域表示为$N \times N$ 均匀网格。假设网格中的每个单元足够小，使得单元内的路径损耗近似不变。因此，无线电地图定义为矩阵 $\boldsymbol{P} \in \mathbb{R}^{N\times N}$，其中每个元素 $P(i,j)$表示位置(i,j)处的路径损耗。环境中部署了一个配备偶极天线的基站（BS），作为唯一的辐射源。其位置表示为 $r = \langle d_x, d_y, d_z\rangle$，其中$(d_x, d_y)$为水平位置， d_z 为基站高度。环境中包含静态和动态障碍物，分别由矩阵 $\boldsymbol{H}_s$ 和 $\boldsymbol{H}_d$ 描述。静态障碍物（例如建筑物）被建模为理想电磁（EM）屏蔽物，因此其内部的路径损耗为无穷大（$P(i,j) = \infty$）。相比之下，动态障碍物（例如车辆）会造成部分衰减和散射，但不会完全阻挡电磁传播。元素 $H_s(i,j) = 0$和 $H_d(i,j) = 0$分别表示位置(i,j)处不存在静态和动态障碍物。目标是学习一个由 $\boldsymbol{\theta}$ 参数化的神经网络$\boldsymbol{\mu}_\theta(\cdot)$，以预测路径损耗分布$\hat{}\boldsymbol{P} = \boldsymbol{\mu}_\theta(\boldsymbol{H}_s, \boldsymbol{H}_d, r)$，使其近似真实值 $\boldsymbol{P}$。$\hat{}$构建误差通过损失函数 $\mathcal{L}(\boldsymbol{P}, \boldsymbol{P})$衡量，通常采用均方误差（MSE）。

然而，在智能车联网或基于无人机的覆盖优化等时间敏感型应用中，构建延迟与准确性一样，成为一项关键的性能指标

。这一点在基于扩散的生成模型中尤为重要，因为凭借对高频纹理和多模态不确定性的卓越建模能力，这类模型在无采样RM构建方面已达到最先进水平。然而，扩散模型需要在T 个时间步上进行迭代去噪，每个时间步都需要进行一次完整的神经网络评估，从而导致显著的计算延迟。令 $\mathcal{C}_{\text{conv}}$ 和$\mathcal{C}_{\text{attn}}$ 分别表示卷积层和注意力层每次前向传播的计算复杂度。这些复杂度的增长如下所示。

$$\mathcal{C}_{\text{conv}} = \mathcal{O}(K^2 C_{\text{in}} C_{\text{out}} HW), \mathcal{C}_{\text{attn}} = \mathcal{O}(HWd^2 + H^2W^2d), \tag{13}$$

其中， K 为卷积核大小， C_{in}、 C_{out} 为输入/输出通道， $H \times W$ 为空间尺寸， d 为特征维度。这些操作主导了每次神经网络前向传播的运行时间。

对于去噪扩散模型，令 $\mathcal{C}_{\text{net}}$ 表示单次神经网络评估的复杂度。扩散过程的总计算复杂度如下。

$$\mathcal{C}_{\text{DM}} = T \cdot \mathcal{C}_{\text{net}}, \tag{14}$$

其中， T 为去噪步骤的数量，通常为500至1000。由于深度学习中的缩放定律，通过缩小模型规模来降低 $\mathcal{C}_{\text{net}}$ 通常会导致性能下降，因此需要通过减少 $\mathcal{C}_{\text{DM}}$ 或复用部分计算来最小化T 。

因此，我们将无线电地图构建任务重新表述为一个双目标优化问题，同时最小化构建误差和计算延迟。具体而言，令 $\mathcal{T}(\boldsymbol{\theta})$表示使用参数 $\boldsymbol{\theta}$构建无线电地图的预期时间，可近似表示为 $\mathcal{T}(\boldsymbol{\theta}) = T \cdot \tau(\boldsymbol{\theta})$，其中 $\tau(\boldsymbol{\theta})$为单次前向传播所需的时间。我们将无线电地图构建任务表述如下。

问题 1。

$$\min_{\boldsymbol{\theta}, T} \quad \mathcal{L}(\hat{\boldsymbol{P}}, \boldsymbol{P}) + \lambda \cdot \mathcal{T}(\boldsymbol{\theta}) \tag{15}$$

$$s.t. \quad \hat{\boldsymbol{P}} = \boldsymbol{\mu}_{\boldsymbol{\theta}}(\boldsymbol{H}_s, \boldsymbol{H}_d, r), \tag{15a}$$

其中， $\lambda > 0$ 是平衡准确性与推理速度的权重系数。约束条件 $T \leq T_{\max}$ 确保推理延迟可控。该表述强调了无线电地图构建兼顾准确性与效率的双重目标，凸显了优化扩散模型性能、扩散步数和架构效率的重要性。此外，它也为研究中间潜在状态的复用或去噪加速策略提供了理论动机，正如我们提出的方法所探讨的那样。需要指出的是，该表述主要为我们的工作提供高层次的动机，阐明构建准确性与推理延迟之间固有的权衡。系数 λ 代表速度相对于准确性的重要程度。我们提出的框架 RadioDiff-Flux 并未通过 λ直接优化这一目标函数，而是通过减少有效推理步数，从架构层面应对这一权衡。随后，我们的实验通过实证通过改变复用比率 R_{reuse} 来评估这种权衡。

为使表述和评估更加清晰，当前模型仅考虑单个基站。不过，该框架可以扩展到多基站环境。一种实用的方法是为每个基站分别生成无线电地图，再依据诸如在每个位置选取最强信号等信号叠加原理将其合并。在这种情况下，RadioDiff-Flux 的效率优势更加显著：通过复用预计算中点，它可以在同一静态环境中快速生成多个基站的无线电地图；与从头生成每张地图相比，这显著减少了总计算时间。更一体化的方法留待未来研究，即从架构上修改模型，使其能够将多个基站位置作为单个条件输入，直接生成复合RM。

IV. DM 中间点复用

A. 动机与理论分析

基于神经网络的 RM 生成近期取得了进展，尤其是采用潜在扩散模型（LDM）的方案，通过在压缩潜在空间中进行去噪，显著提升了构建保真度。尽管 LDM 的主要动机是降低推理复杂度，但语义通信领域的见解，特别是深度联合信源信道编码（Deep JSCC），揭示了更深层的意义：编码器的潜在特征图本身能够捕获环境特征的高层语义表征，例如障碍物布局和结构拓扑[31], [32]。在无线电地图构建中，这意味着在同一静态环境下、不同基站位置生成的无线电地图应当共享大量语义信息。图 1 和图 2(c)直观地印证了这一点：基站位置相近的无线电地图在潜在空间中的嵌入向量紧密聚集，表明它们共享相同的环境语义。

为通过实证验证这一观察，我们开展了一项受控研究，如图 2(c) 和图 2(b) 所示。我们考虑三种类型的场景：(1) 环境恒定但基站位置不同，(2) 基站位置固定但存在动态障碍物（例如移动车辆），以及 (3) 参考无线电地图。按照扩散前向过程，在这三种情况下引入相同的高斯噪声后，我们评估不同扩散步数下生成样本之间的归一化均方误差（NMSE）。结果表明，在仅存在动态变化的情况下，样本间的 NMSE 在约 $t = 600$ 后变得可忽略，其导数则在 $t = 400$ 附近急剧下降。这支持了以下假设：语义相似的无线电地图的去噪路径会在扩散后期显著收敛，这表明中间带噪表征（即 $\boldsymbol{z}_t$）可以在相关场景间有效复用，从而为我们提出的快速推理策略奠定基础。

为从理论上进一步支持这一观点，我们使用 Kullback-Leibler（KL）散度分析中间潜在状态之间的相似性。以下结果量化了在相同扩散噪声水平 t下，两个潜在向量之间的散度如何随其语义相似性的增加而减小：

定理 1. 设 z_i 和 z_j 是变分自编码器（*VAE*）从环境条件相似的无线电地图中提取的两个潜在向量。按照式 (11)所定义的前向扩散过程进行 t 步后，它们得到的分布分别为 $p(x) = \mathcal{N}((1-t)z_i, tI)$ 和 $q(x) = \mathcal{N}((1-t)z_j, tI)$。那么，它们之间的 *KL* 散度满足：

$$D_{\mathrm{KL}}(p\|q) = \frac{1}{2}\frac{(1-t)^2}{t}\|z_i - z_j\|^2.$$

证明。 设均值为 $\mu_i = (1-t)z_i$ 和 $\mu_j = (1-t)z_j$。 由于两个分布具有相同的协方差矩阵 tI，KL 散度为：

$$D_{\mathrm{KL}}(p\|q) = \frac{1}{2}(\mu_j - \mu_i)^T (tI)^{-1}(\mu_j - \mu_i).$$

代入 $\mu_j - \mu_i = (1-t)(z_j - z_i)$ 和 $(tI)^{-1} = \frac{1}{t}I$，可得：

$$D_{\mathrm{KL}}(p\|q) = \frac{1}{2}\frac{(1-t)^2}{t}\|z_j - z_i\|^2.$$

□

这一理论结果不仅为我们的实证发现提供了依据，还给出了散度的一个上界，该上界会随着 t 的增加而呈二次衰减。这意味着，在扩散步数足够高时，语义相似的潜在向量在分布上将变得 indistinguishable。因此，从实践和理论角度来看，当底层语义内容保持一致时，复用中间扩散状态是可行的。这构成了我们方法的核心创新，通过跳过冗余的去噪操作来加速无线电地图构建，同时不会影响估计质量。

在实践中，为了判断缓存中点是否可以跨环境复用，我们在预训练 RadioDiff 骨干网络的交叉注意力空间中衡量环境相似度。条件编码器生成令牌 H_s、 H_d 和 r。我们将它们拼接为 $\mathcal{C} = [H_s, H_d, r]$，然后使用来自 RadioDiff[17] 的冻结键矩阵和值矩阵 W_K 和 W_V，得到注意力前投影 $K = \mathcal{C}W_K$ 和 $V = \mathcal{C}W_V$。给定两个环境 A 和 B，它们使用相同的分词器和令牌布局，因此令牌彼此对齐，我们定义归一化的弗罗贝尼乌斯距离

$$D_{\mathrm{env}}(A,B) = \sqrt{\|K^A - K^B\|_F^2 + \|V^A - V^B\|_F^2}. \quad (16)$$

当 $D_{\mathrm{env}} \le \tau$ 时触发复用，并在小型验证集上根据准确率与复用率曲线的拐点选取 τ，以确保复用符合预设的误差预算。由于该判据基于令牌运行，因此与分辨率无关；注意力模块被冻结，因此无需重新训练；此外，该方法还利用了 RadioDiff 已学习到的几何与可见性感知嵌入向量。D_{env} 的实证示例以及 τ 的校准结果见实验部分。

B. 基于 *Dual-DM* 的无线电地图构建中点复用

为满足动态无线环境中对低时延、高保真无线电地图构建日益增长的需求，我们提出一种两阶段条件潜在扩散框架，明确将静态环境语义与动态变化及发射机特定属性解耦。该架构设计基于这一观察：语义相似场景的扩散轨迹在中间潜在空间中表现出强烈的收敛性，如第三节所示。所提出的方法旨在通过策略性地复用相似场景间共享的语义结构，尽量减少扩散早期步骤中的冗余计算。在框架的第一阶段，我们训练专用的潜在扩散模型来建模粗略的环境语义。该模型仅以静态环境上下文为条件，例如建筑物布局和大尺度地形，并生成一个称为扩散中点的中间潜在状态。该中点作为场景的高层语义表示，剔除了瞬态元素和发射机配置的影响。在第二阶段，另一个条件扩散模型进一步以动态环境（例如移动车辆）和基站位置为条件，执行剩余的去噪步骤，以重建最终无线电地图。值得注意的是，该第二阶段模型从预计算中点开始生成，从而跳过计算密集的去噪早期阶段。这种两阶段方案带来两项关键优势。首先，在移动性驱动应用中，例如涉及自主空中飞行器或移动基站的应用，静态环境特征保持不变，因此中点可以缓存，并在不同的基站部署位置之间复用。这使系统能够以极低开销快速适应新的基站坐标。其次，在基站部署位置固定、但动态条件不断变化的场景中，我们的框架通过利用预计算的静态条件潜在特征，将去噪工作仅限于动态扰动，从而实现高效的无线电地图更新。这些能力对于实现 6G 系统中的实时响应至关重要，因为这类系统具有密集的用户移动性和显著的环境变化。

在此背景下，“扩散中点”并非指固定的时间中点（即 $t = T/2$），而是指去噪轨迹上的任意中间潜在状态 z_t，由复用比率 R_{reuse} 决定。该点的选择具有灵活性，正如我们的实验所示，模型性能对这一选择十分敏感，因此推理速度与重建保真度之间存在直接的权衡。从计算角度来看，我们的设计还通过降低条件扩散模型中常用的条件嵌入模块的复杂度，显著提高了效率。这种两阶段方法能够确保降低计算复杂度。用于图像形式数据的特征提取网络通常以 CNN 层作为初始层。根据式 (13)，在这一关键的第一步中，将静态特征的输入通道深度从三降低到一，可显著且直接地减少所需的总浮点运算次数（FLOPs）。因此，总推理延迟和计算开销均大幅降低。总之，所提出的两阶段条件潜在扩散模型结合语义可复用性与架构解耦，实现了快速、自适应且可扩展的 RM 生成。通过使模型设计与语义相关场景间潜在相似性的理论洞见相契合，我们的方法在各类动态和移动性感知场景中均能保持稳健性能，从而

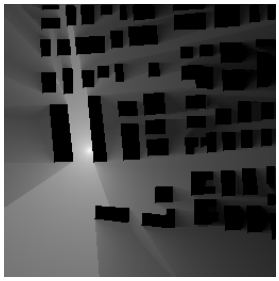

(a) 静态无线电地图的示意图。

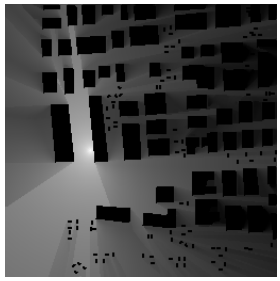

(b) 动态无线电地图的示意图。

图 4：无线电地图示意图。纯黑区域表示建筑物或车辆，意味着这些区域无线电信号无法通过。地图其余部分以灰度图像呈现，灰度级与路径损耗值呈正相关；较亮的区域表示路径损耗较高。

推动生成式无线电地图构建在下一代无线网络中的实用化。

V. 实验

A. 数据集和评估指标

我们的评估使用 RadioMapSeer 数据集 [33],，该数据集源自路径损耗无线电地图构建挑战。数据集包含 700 张独特的城市地图，每张地图均详细描绘了建筑物等地理特征（每张地图包含 50 至 150 栋建筑物）。我们选取 500 张地图用于训练，其余 200 张用于测试，确保两个子集之间没有空间重叠。每张地图均包含 80 个发射机位置及其对应的真实值无线电地图。地图数据来自 OpenStreetMap，覆盖安卡拉、柏林、格拉斯哥、卢布尔雅那、伦敦和特拉维夫等城市。整个数据集采用一致的标准物理参数：发射机和接收机的高度均为 1.5 米，建筑物高度为 25 米。每张地图均呈现为256 × 256像素的二值形态学图像，表示分辨率为 1 米的网格，其中“1”表示建筑物区域，“0”表示非建筑物区域。发射机位置以数值形式提供，并通过将形态学图像中的对应像素设为“1”来标记。发射功率为 23 dBm，载波频率为 5.9 GHz。训练所需的真实值无线电地图基于麦克斯韦方程组生成，对电磁射线反射和衍射造成的路径损耗进行建模。具体而言，静态无线电地图的真实值仅考虑固定建筑物的影响。对于动态无线电地图，真实值则同时纳入静态建筑物以及道路上随机分布的车辆所产生的影响，如图 4 所示。

为全面评估所构建无线电地图的质量，我们采用了几项关键指标。首先，我们使用以往研究中常用的误差度量，即归一化均方误差（NMSE）和均方根误差（RMSE） [9]。鉴于整体误差指标无法充分反映关键结构细节与完整性，我们进一步采用结构相似性指数（SSIM）和峰值信噪比（PSNR）进行评估。SSIM 用于量化结构保真度，而 PSNR 用于评估信号保真度，尤其是边缘精度。

1）均方误差（*MSE*）：均方误差（MSE）用于衡量真实值与预测无线电地图像素值之间差异的平方均值，可按以下公式计算：$MSE = \frac{1}{NM}\sum_{m=0}^{M-1}\sum_{n=0}^{N-1} e\ m\ n\ ^2$, $e\ m\ n$ (,)其中(,) 表示像素(m,n)处的误差， M,N表示图像尺寸。NMSE 将均方误差按信号功率进行缩放，而 RMSE 的误差度量单位与数据相同。其计算公式如下：$NMSE = \frac{\sum_{m=1}^{M}\sum_{n=1}^{N} I_b\ m\ n - I\ m\ n\ ^2}{\sum_{m=1}^{M}\sum_{n=1}^{N} I^2(m,n)}$，均方根误差为 $= \sqrt{MSE}$。

2）结构相似性指数：结构相似性指数通过考量亮度、对比度和结构信息来评估图像相似性，与评估无线电地图中高频细节的需求十分契合，其计算公式如下。

$$l(x,y) = \frac{2\mu_X(x,y)\mu_Y(x,y) + C_1}{\mu_X^2(x,y) + \mu_Y^2(x,y) + C_1} \tag{17}$$

$$c(x,y) = \frac{2\sigma_X(x,y)\sigma_Y(x,y) + C_2}{\sigma_X^2(x,y) + \sigma_Y^2(x,y) + C_2} \tag{18}$$

$$s(x,y) = \frac{\sigma_{XY}(x,y) + C_3}{\sigma_X(x,y)\sigma_Y(x,y) + C_3} \tag{19}$$

其中， x、 y 为图像， μ、 σ^2、和 σ_{xy} 分别为均值、方差和协方差。常数 $C_1 = (K_1L)^2$、 $C_2 = (K_2L)^2$, 和 $C_3 = C_2/2$ 用于防止除以零，其中 L 为数据动态范围。最终的结构相似性指数可按如下公式计算。

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + C_1)(\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \tag{20}$$

3）峰值信噪比：峰值信噪比以分贝表示，用于衡量最大信号功率与噪声功率之比，反映重建保真度。峰值信噪比越高，通常表示质量越好。对于无线电地图，峰值信噪比对于评估重建信号边缘的质量尤其重要，其计算公式如下。

$$PSNR = 10\log_{10}\left(\frac{r^2}{MSE}\right) \tag{21}$$

其中， r 是图像数据中可能的最大像素值。

为量化缓存占用，我们将中点存储在标准变分自编码器的潜在空间中。每个潜在表示的大小为64×64×4 个单精度浮点数，对应 65,536 字节，即每个缓存中点约占 64 KB。由于缓存维护在潜在空间中，其大小与输入分辨率无关。在我们的部署中，若基站布局固定，或移动接入点在固定的感兴趣区域内运行，则一个捕获静态建筑布局的缓存中点就足够了，总计约 64 KB。对于城市级服务，我们将缓存上限设为 100 个中点，使用单精度浮点数时约占 6.25 MB；采用半精度浮点存储可将其减半，同时保持模型行为不变。为了从条件 $\mathcal{C}$ 中提取特征，我们采用 Swin Transformer- B [34],架构，该架构以强大的层次化特征表示能力著称。我们提出的两阶段方法可直接降低该特征提取器的计算复杂度。节省的计算量来自变换器最初的图块嵌入层，该层由一个 3x3 卷积实现。通过使用单通道输入而非三通道输入来处理静态条件，我们大幅减少了

所需的运算量。具体而言，对于 256x256 的典型输入分辨率和 128 的嵌入维度，这一修改可将计算负载降低 300 百万浮点运算次数以上，从而使整个流水线在特征图传递至后续自注意力模块之前就更加高效。

B. 实验方法

RadioDiff-Flux 的训练流水线与 RadioDiff [17], 完全一致，以确保优化框架的一致性。具体而言，第二阶段模块负责在环境上下文和基站位置的共同条件下生成完整的无线电地图，它直接采用 RadioDiff 的预训练权重，无需额外微调或重新训练。只有第一阶段网络需要从头开始重新训练；该网络仅依据静态环境特征推断扩散中点。此重新训练过程采用与 RadioDiff 相同的训练策略和损失配置，确保两个阶段在架构和流程上保持一致。为评估所提出的 RadioDiff-Flux框架，尤其是中点复用策略的有效性，我们首先建立了基线扩散模型，随后针对多种环境变化场景开展了一系列实验。

1) 基线模型：为评估所提出方法的有效性，我们将其与四种具有代表性的基线模型进行比较。这些模型涵盖了用于无采样无线电地图构建的判别式和生成式范式，具体如下。

- **RadioUNet** [9] 是无线电地图重建中基于卷积神经网络的基础基准模型。它采用 U-Net 架构，以完全监督方式训练，直接根据环境特征回归无线电地图。其简单可靠的特点使其成为该领域的标准参考，尤其适用于评估判别式方法。

- **UVM-Net** [35] 沿用与 RadioUNet 相同的训练方案和输入格式，但以状态空间模型取代卷积骨干网络，从而增强了模型架构。状态空间模型旨在处理长程依赖，会将序列投影为隐状态动态，使 UVM-Net 能够更好地捕捉局部纹理和更广泛的结构模式。这一改进使其成为评估序列建模技术如何提升复杂环境中的空间推断能力的有力基准。

- **RME-GAN** [16] 提出了一种生成对抗框架，最初结合环境上下文与稀疏路径损耗测量进行条件生成。为在无需采样的设置下进行公平比较，我们禁用 SPM输入，仅使用环境数据。尽管 RME-GAN 展示了对抗学习在无线建模中的潜力，但其标准形式依赖采样测量，这限制了它的泛化能力。

- **RadioDiff** [17] 目前代表着RM生成领域的最先进水平，它将该任务建模为在潜在空间中使用扩散模型的条件生成过程。通过集成用于编码的变分自编码器和基于UNet的去噪器进行反向时间生成，RadioDiff能够捕捉精细的空间细节和宏观尺度的路径损耗结构。其在准确性和感知质量方面的表现，为先进的生成式方法奠定了坚实的基线。

- **原始中点复用（我们的方法）**通过直接复用扩散轨迹的缓存中点，实现了一种加速推理的直观策略。当基站位置或环境配置发生变化时，去噪过程将从这一先前计算的中点开始。随后，扩散模型的条件输入会更新，以反映新的场景，从而无需任何微调或额外训练即可实现复用。该方法充分利用了预训练的 RadioDiff 模型。

- **RadioDiff-Flux（我们的方法）**引入了一个结构更清晰的两阶段框架。第一阶段训练一个仅以静态环境为条件的扩散模型，从而高效生成具有语义意义的中点，并捕捉大尺度空间结构。第二阶段则使用预训练的 RadioDiff 模型完成去噪过程，其条件同时包括动态环境特征和基站位置。这种设计支持对静态信息进行模块化复用，同时在动态变化的条件下保持较高的重建保真度。

值得注意的是，由于 RadioDiff-Flux 在其核心条件生成阶段直接继承了 RadioDiff 的架构和预训练权重，因此 RadioDiff 在我们的评估中发挥着双重作用：它不仅是最先进水平的基准，也是我们这一不采用中点复用策略的框架的确定性消融基线。

2）环境变化下复用策略的评估：利用训练好的模型，我们设计了三个实验场景，以评估不同复用比率 R_{reuse} 对 RM 生成的影响。整个过程从一个高斯噪声样本开始，经过 $T = 100$ 个扩散步骤进行去噪。我们的复用策略是在此过程中途改变环境条件信息，改变时机由 R_{reuse} 决定。

场景1：改变基站位置。本场景研究在同一静态环境中仅改变基站位置时，复用初始去噪步骤的效果。首先，使用初始基站位置运行静态模型，执行总步骤数中的一部分（$R_{\text{reuse}} \cdot T$）。随后，在剩余步骤中，将条件切换为新的目标基站位置。最后，将生成的无线电地图与该新位置对应的真实值进行比较。与从头开始独立生成两张无线电地图相比，这种复用方法旨在节省计算资源。我们评估了 $[0.1, 0.4, 0.7, 0.9, 0.95, 0.98]$ 的 R_{reuse} 个取值。结果见图 5。

场景2：从静态环境过渡到动态环境。该场景模拟在先前的静态环境中引入车辆等动态元素。建筑布局和基站位置保持不变。首先运行静态模型，完成最初一部分步骤。随后切换到动态模型，执行剩余的

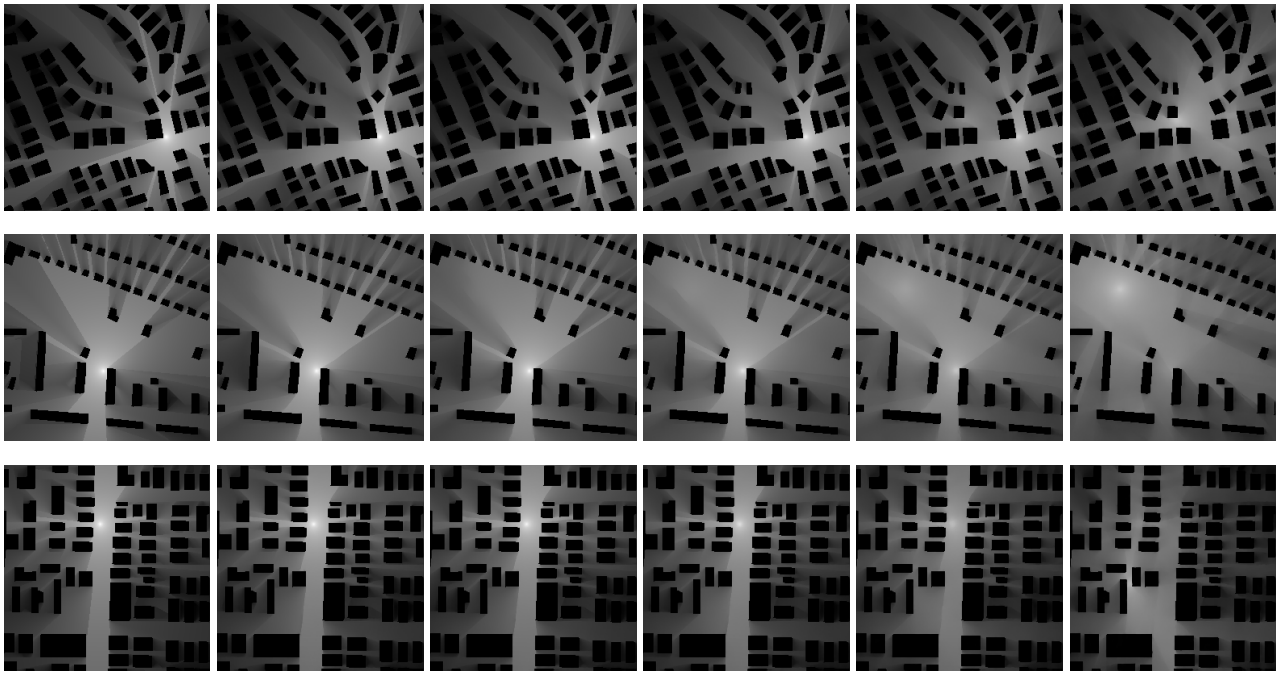

真实值　　$R_{\text{复用}} = 0.4$　　$R_{\text{复用}} = 0.7$　　$R_{\text{复用}} = 0.9$　　$R_{\text{复用}} = 0.95$　　$R_{\text{复用}} = 0.98$

图5：场景1（基站位置变化）下无线电地图生成的可视化对比。每一行展示一个不同的测试用例。第一列显示真实值RM。后续各列展示采用不同轨迹复用比例（R_{reuse}）生成的无线电地图。

步骤，并向其提供新的车辆信息。将最终无线电地图与包含这些车辆的真实值进行比较评估。不同复用比率下的结果如图6所示。

场景3：直接修改静态环境。此场景用于评估静态环境本身发生变化时的复用策略，其中建筑布局和基站位置均会改变。整个过程中均使用静态模型。在前一部分步骤中，模型以初始静态布局和基站位置为条件；在剩余步骤中，则以新的建筑布局和基站位置为条件。针对这一新环境，将最终无线电地图与真实值进行评估。结果详见图7。

C. 实现细节

为进行稳健的统计评估，每种配置均使用测试集进行了3000次独立试验。在每次试验中，设定初始条件和后续条件后，生成最终无线电地图，并根据第二阶段的真实值评估其性能。最终结果报告为这些试验的平均指标得分。所有实验均在配备 NVIDIA A40 GPU（48GB 显存）的服务器上进行，运行 PyTorch 2.2.0 和 CUDA 11.8，扩散采样过程使用 $T = 100$ 步。完整测试结果见表I、III和IV。

在训练成本方面，RadioDiff-Flux 通过策略性地复用预训练模型，展现出显著的计算效率。我们框架中负责最终无线电地图生成的整个第二阶段，实际上无需训练，因为它直接采用了原始 RadioDiff 模型完全相同的架构和预训练权重。同样，第一阶段中的变分自编码器组件也直接复用，未作任何修改。唯一需要进行的新训练是第一阶段的条件扩散模型。我们没有从头开始训练，而是使用 RadioDiff 的权重初始化该模型，并对其进行约 10 个 epoch 的微调。这一微调过程在我们的硬件上耗时约 12 小时，与从头训练标准 RadioDiff [17] 模型所需的约 480 小时相比，大幅缩短了训练时间。这种方法不仅有效，而且在计算资源方面也极具实用性。

D. 结果分析

本节详细分析实验结果，通过考察定量指标和定性视觉效果来评估框架的性能。分析重点关注复用比率 R_{reuse} 对三个既定场景下无线电地图构建准确性和推理速度的影响。

1) 场景*1*：当仅基站位置发生变化时，中点复用策略在低至中等复用比率下表现出显著效果。如表 I 所示，将 R_{reuse} 提高至 0.7 时，归一化均方误差仅略有增加，同时推理速度大幅提升（例如，在 $R_{\text{reuse}} = 0.7$ 时加速比达到 3.47× ）。图 5 证实，当 R_{reuse} 不超过 0.8 时，生成的无线电地图与真实值在视觉上保持高度相似。在非常高的复用比率（$R_{\text{reuse}} \geq 0.9$）下，准确性下降得更为明显，但加速效果显著。这表明，剩余的去噪步骤数量不足以让模型适应

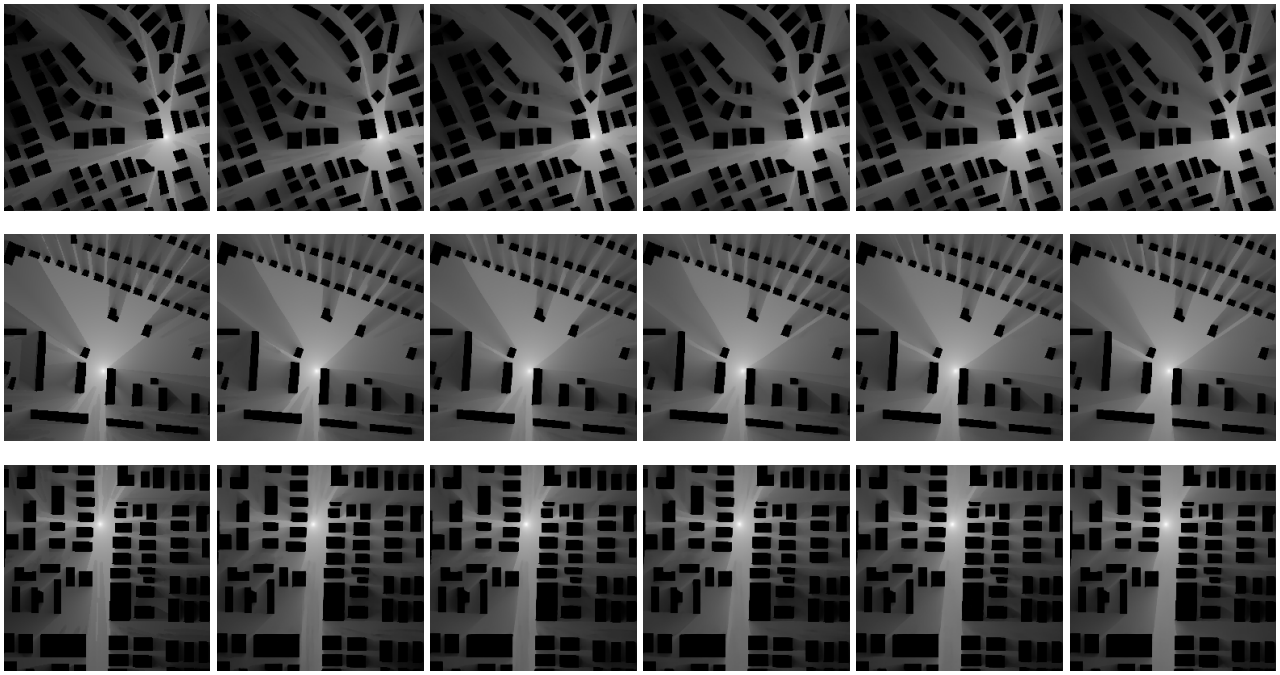

真实值 $R_{\text{复用}} = 0.4$ $R_{\text{复用}} = 0.7$ $R_{\text{复用}} = 0.9$ $R_{\text{复用}} = 0.95$ $R_{\text{复用}} = 0.98$

图6：场景2（从静态环境到动态环境的转换）下RM生成的视觉对比。每行展示一个不同的测试用例。第一列展示真实值无线电地图。后续各列展示采用不同轨迹复用比例生成的无线电地图（R_{reuse}）。

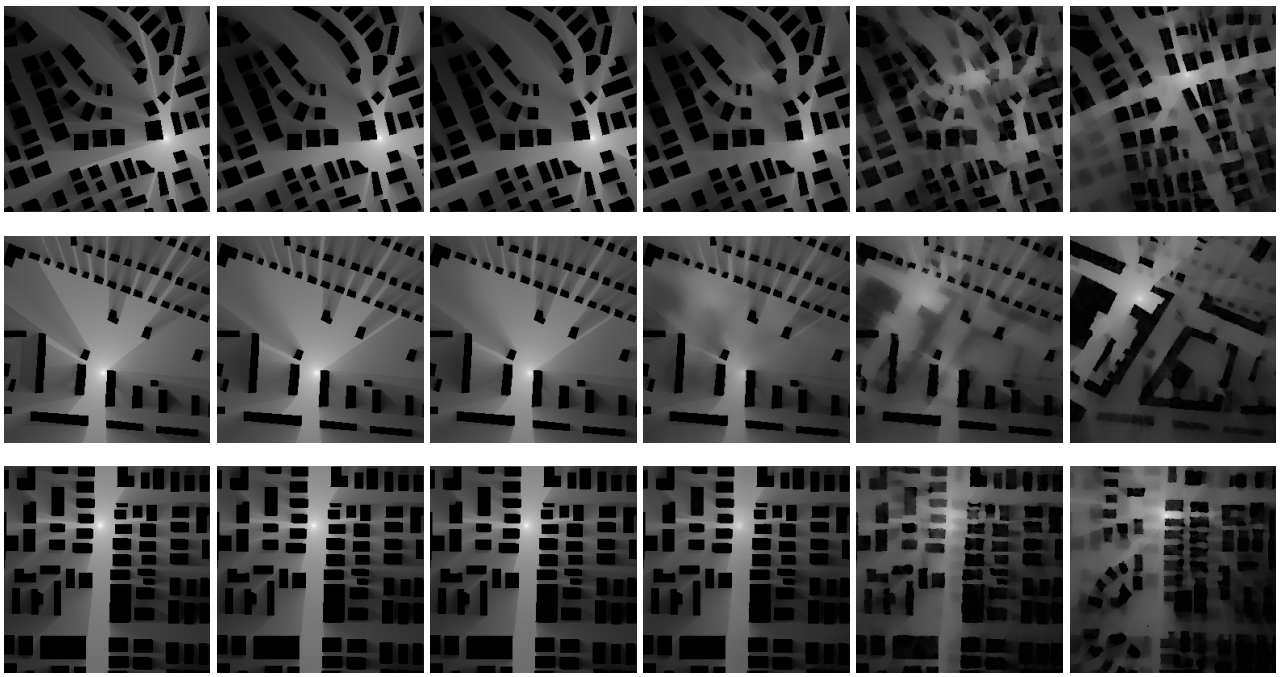

真实值 $R_{\text{复用}} = 0.4$ $R_{\text{复用}} = 0.7$ $R_{\text{复用}} = 0.9$ $R_{\text{复用}} = 0.95$ $R_{\text{复用}} = 0.98$

图7：无线电地图生成的视觉对比 在场景3（静态环境修改）下。每行展示一个不同的测试用例。
第一列显示真实值 无线电地图。后续各列展示采用不同轨迹复用比例（R_{reuse}）生成的无线电地图。

表 I：场景1（改变基站位置）的定量性能。RadioDiff 条目同时作为消融基线，表示未采用所提出的中点复用策略时我们架构的性能。

方法	R_{reuse}	NMSE	RMSE	SSIM	峰值信噪比（分贝）	时间（毫秒）
RME-GAN	-	0.01150	0.03030	0.93230	30.54000	42
UVM-Net	-	0.00850	0.03040	0.93200	30.34000	95
RadioUnet	-	0.00740	0.02440	0.95920	32.01000	60
RadioDiff	0.00	0.00580	0.01990	0.96474	34.67248	600
原始中点复用（我们的方法）	0.10	0.00581	0.01991	0.96474	34.66587	532
	0.20	0.00582	0.01995	0.96472	34.64317	477
	0.30	0.00586	0.02001	0.96467	34.61296	416
	0.40	0.00592	0.02013	0.96462	34.55543	356
	0.50	0.00603	0.02034	0.96448	34.45523	301
	0.60	0.00625	0.02075	0.96421	34.27014	236
	0.70	0.00671	0.02159	0.96368	33.92364	173
	0.80	0.00797	0.02369	0.96234	33.13318	120
	0.90	0.01542	0.03297	0.95571	30.47665	63
	0.95	0.04271	0.05474	0.93620	26.33720	31
	0.98	0.13098	0.09766	0.88361	21.20604	12

表 II：RadioDiff-Flux 在场景1中 R_{reuse} 值较高时的定量性能。

R_{reuse}	NMSE	RMSE	SSIM	峰值信噪比（分贝）
0.98	0.02957	0.04567	0.94584	27.52674
0.95	0.01292	0.02968	0.95849	31.28677
0.90	0.00832	0.02381	0.96261	33.18820
0.80	0.00655	0.02114	0.96439	34.23921
0.70	0.00607	0.02035	0.96487	34.59251

潜在表示到新的基站位置。对于此场景， R_{reuse} 在 0.7 到 0.8 之间时，能够在速度和准确性之间实现最佳平衡。

为缓解复用比率较高时出现的“模糊叠加”效应，我们采用了 RadioDiff-Flux 方法。如表II和图8所示，这种方法显著提升了性能。在 $R_{\text{reuse}} = 0.98$ 时，归一化均方误差从 0.13098 降至 0.02957。这表明，创建广义中点可以降低模型受单一初始条件影响的敏感度，为需要快速更新且要求更高保真度的场景提供了有价值的改进。

2）场景*2*：该场景展现出卓越的鲁棒性，即使复用比率极高也不例外。初始阶段采用静态模型，为后续工作奠定了坚实基础；随后，动态模型对其进行高效更新。定量来看，如表III所示，在所有复用比率下，准确性始终保持在极高水平。即使在 $R_{\text{reuse}} = 0.98$ 下，归一化均方误差也仅为 0.00776，加速比则高达 58.07×。

然而，车辆的引入带来了高频细节。如图6所示，这些动态细节会随着 R_{reuse} 的增加而减弱。虽然归一化均方误差和均方根误差体现了出色的整体准确性，但对结构信息敏感的结构相似性指数通过持续但幅度较小的下降，更好地反映了精细细节的损失。该场景凸显了该框架在引入动态元素时能够以极小的整体误差实现大幅加速，但极高的复用比率可能会牺牲精细的动态特征。

3）场景*3*：当静态环境本身发生变化时，复用的影响更为关键。对于 R_{reuse} 最高达 0.7 的情况，生成的无线电地图仍能在很大程度上反映目标条件，在保持合理

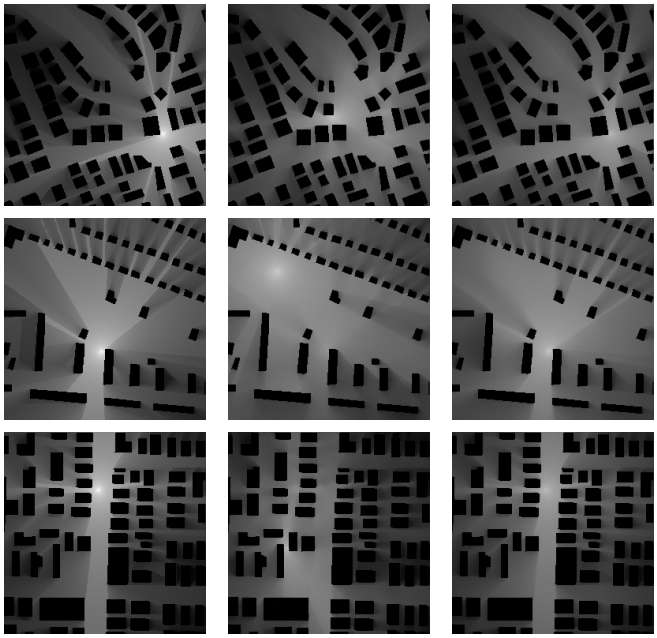

真实值　　原始中点复用　　RadioDiff-Flux

图8： $R_{\text{reuse}} = 0.98$时场景1的视觉对比：真实值（左）、原始中点复用（中）和 RadioDiff-Flux（右）。最右侧列中的图像为占位图。

准确性的同时实现了显著的加速比（3.{v4}）（表IV）。然而，由于底层静态特征变化更为显著，其性能不如其他场景稳定。

在较高的复用比率（$R_{\text{reuse}} \geq 0.8$）下，性能会急剧下降，如图6所示。生成的无线电地图往往会保留初始环境中显著且错误的特征。这凸显了中点复用策略的一项关键局限：当基础静态布局发生重大变化时，初始潜在表示会产生强烈的“惯性偏差”，使模型无法在剩余的少数去噪步骤中克服这种偏差。这明确了我们方法的有效边界，表明当环境发生剧烈变化时，必须降低复用比率，或从噪声完全重新生成，以确保准确性。

表III：场景2（从静态环境到动态环境）的定量性能。RadioDiff 条目也作为消融基线，代表不采用所提出的中点复用策略时我们架构的性能。

方法	R_{reuse}	NMSE	RMSE	SSIM	峰值信噪比（分贝）	时间（毫秒）
RME-GAN	-	0.01180	0.03070	0.92190	30.40000	42
UVM-Net	-	0.00880	0.03010	0.93260	30.42000	95
RadioUNet	-	0.00890	0.02580	0.94100	31.75000	60
RadioDiff	0.00	0.00643	0.02239	0.95325	33.22775	600
原始中点复用（我们的方法）	0.10	0.00643	0.02238	0.95317	33.23308	546
	0.20	0.00642	0.02236	0.95313	33.23967	461
	0.30	0.00640	0.02233	0.95312	33.24747	396
	0.40	0.00640	0.02233	0.95307	33.24915	348
	0.50	0.00639	0.02234	0.95299	33.23908	301
	0.60	0.00642	0.02238	0.95294	33.22383	224
	0.70	0.00646	0.02247	0.95293	33.18599	171
	0.80	0.00659	0.02271	0.95278	33.09520	125
	0.90	0.00688	0.02325	0.95247	32.88742	57
	0.95	0.00732	0.02401	0.95170	32.61643	28
	0.98	0.00776	0.02474	0.95094	32.37078	10

表IV：场景3（直接修改静态环境）下原始中点复用的定量性能。

R_{reuse}	NMSE	RMSE	SSIM	峰值信噪比（分贝）	时间（毫秒）
0	0.00680	0.02092	0.96152	34.22417	600
0.10	0.00681	0.02093	0.96152	34.21530	537
0.20	0.00685	0.02099	0.96145	34.17983	472
0.30	0.00692	0.02112	0.96135	34.11101	412
0.40	0.00705	0.02138	0.96114	33.98104	359
0.50	0.00729	0.02184	0.96076	33.75646	296
0.60	0.00778	0.02273	0.95995	33.36347	239
0.70	0.00889	0.02458	0.95795	32.64405	175
0.80	0.01267	0.02986	0.94886	30.96165	117
0.90	0.04694	0.05926	0.87976	25.09397	58
0.95	0.19226	0.12455	0.66350	18.40915	28
0.98	0.58418	0.22358	0.37236	13.11929	11

4）总体讨论与总结：实验结果始终表明，复用比率与RM准确度之间存在权衡，且对环境变化的敏感程度因变化性质而异。当初始条件与目标条件之间的语义相似性较高时，我们框架中的中点复用最为有效。场景2表现出最高的鲁棒性，在保持出色全局准确性的同时实现了大幅加速。场景1的表现也不错，尤其是在高复用比率下采用 RadioDiff-Flux 精炼时。场景3最具挑战性，只有适度复用才能实现良好平衡。这些发现证实，复用中间扩散状态是加速RM生成的一种极为有效的策略。这表明可以采用自适应 R_{reuse} 策略：面对微小扰动时采用高复用比率，面对重大重配置时则采取保守的复用策略。在许多实际场景中，我们的框架可将RM生成速度提升3.5$\times$ 倍以上，且保持高保真度，展现出其在动态无线环境中实现近实时RM更新的潜力。值得注意的是，尽管我们的实验是在高性能GPU上进行的，但所实现的显著相对加速比是部署到资源受限边缘设备的关键条件。将推理时间缩短一个数量级的能力，使得即使在性能较弱的硬件上也能实现近实时RM适配，这是迈向移动6G系统实际应用的关键一步。

这些发现表明，自适应 R_{reuse}策略具有应用潜力在实际部署中，可针对微小扰动采用较高的复用比率，例如小幅基站移动或动态障碍物变化；而对于大幅环境重构，则适合采用更保守的比率。开发一种轻量级机制，用于量化不同场景之间的变化幅度，并自动选择最优的 R_{reuse} ，仍是未来值得探索的方向。

VI. 结论

本文提出了 RadioDiff-Flux，这是一种新颖的高效无线电地图构建框架，通过在生成式去噪扩散模型中创新性地复用轨迹中点来实现这一目标。理论分析和实验结果证实，RadioDiff-Flux 能够大幅降低推理延迟，同时保持无线电地图的高保真度。因此，RadioDiff-Flux 有望成为实现实时、高准确性无线电地图生成的重要一步，解决 6G 自适应无线网络管理面临的一项关键瓶颈。未来，我们将探索基于环境变化的自适应中点复用策略，并提升序列RM生成的时间一致性。

参考文献

[1] Y. Han、S. Jin、C.-K. Wen 和 X. Ma，“超大规模大规模MIMO系统的信道估计”，*IEEEWireless Commun. Lett.*，第9卷，第5期，第633–637页，2020年。[2] T. Ma、B. Qian、X. Qin、X. Liu、H. Zhou 和 L. Zhao，“卫星与地面一体化6G：超密集低轨卫星网络管理架构”，*IEEE Wirel. Commun.*，第31卷，第1期，第62–69页，2022年。

[3] N. Cheng、F. Chen、W. Chen、Z. Cheng、Q. Yang、C. Li 和 X. Shen，“6G全场景按需服务提供：愿景、技术与展望（中文）”，《中国科学：信息科学》，第54卷，第1025–1054页，，2024年。[4] Z. Wang、L. Liu、S. Zhang 和 S. Cui，“智能反射面辅助的大规模MIMO通信”，IEEE Trans. Wireless Commun.，第22卷，第4期，第2566–2582页，2022年。[5] T. Jiang、H. V. Cheng 和 W. Yu，“利用隐式信道估计学习智能反射面的反射与波束成形”，IEEE Journal on Selected Areas in Communications，第39卷，第7期，第1931–1945页，2021年。[6] ¨O. ¨Ozdogan、E. Bj¨ornson 和 E. G. Larsson，“智能反射面：物理学、传播与路径损耗建模”，IEEE Wirel. Commun. Letters，第9卷，第5期，第581–585页，2019年。[7] N. Cheng、F. Lyu、W. Quan、C. Zhou、H. He、W. Shi 和 X. Shen，“面向物联网应用的空天辅助计算卸载：一种基于学习的方法”，IEEE J. Select. Areas Commun.，第37卷，第5期，第1117–1129页，2019年。[8] X. Wang、L. Fu、N. Cheng、R. Sun、T. Luan、W. Quan 和 K. Aldubaikhy，“面向6G无人机物联网网络的飞行中继位置与路由联合优化：一种基于图神经网络的方法”，Remote Sens.，第14卷，第17期，第4377页，2022年。[9] R. Levie、C.. Yapar、G. Kutyniok 和 G. Caire，“RadioUNet：基于卷积神经网络的快速无线电地图估计”，IEEE Trans. Wireless Commun.，第20卷，第6期，第4001–4015页，2021年。[10] Y. Zeng、J. Chen、J. Xu、D. Wu、X. Xu、S. Jin、X. Gao、D. Gesbert、S. Cui 和 R. Zhang，“面向6G的信道知识图谱环境感知通信教程”，IEEE Commun. Surveys Tuts.，第26卷，第3期，第1478–1519页，2024年。[11] S. Dang、O. Amin、B. Shihada 和 M.-S. Alouini，“6G应该是什么样的？”Nature Electron.，第3卷，第1期，第20–29页，2020年。[12] X. Shen、J. Gao、M. Li、C. Zhou、S. Hu、M. He 和 W. Zhuang，“迈向6G沉浸式通信”，Front. Comput. Sci-chi，第4卷，第1068478页，2023年。[13] Y. Zeng 和 X. Xu，“借助信道知识图谱迈向环境感知6G通信”，IEEE Wireless Commun.，第28卷，第3期，第84–91页，2021年。[14] G. A. Deschamps，“电磁学中的射线技术”，Proc. IEEE，第60卷，第9期，第1022–1035页，1972年。[15] T. Rautiainen、G. Wolfle 和 R. Hoppe，“验证城市环境中三维射线追踪传播模型对路径损耗和时延扩展的预测”，载于《IEEE第56届车辆技术会议（VTC）论文集》，第4卷，IEEE，2002年，第2470–2474页。[16] S. Zhang、A. Wijesinghe 和 Z. Ding，“RME-GAN：一种基于条件生成对抗网络的无线电地图估计学习框架”，IEEE Internet Things J.，第10卷，第20期，第18 016–18 027页，2023年。[17] X. Wang、K. Tao、N. Cheng、Z. Yin、Z. Li、Y. Zhang 和 X. Shen，“RadioDiff：一种用于无采样动态无线电地图构建的有效生成式扩散模型”，IEEE Trans. Cognit. Commun. Networking，第11卷，第2期，第738–750页，2025年。[18] M. Zhou、L. Ying、L. Lu、L. Shi、J. Zi 和 Z. Yu，“Weyl系统中的电磁散射定律”，Nature Commun.，第8卷，1388，2017 1，第。页。[19] S. Oh 和 N.-H. Myung，“使用射线追踪传播模型的MIMO信道估计方法”，Electron. Lett.，第40卷，1，2004 21，第。页。[20] H. Li、K. Gupta、C. Wang、N. Ghose 和 B. Wang，“RadioNet：基于深度学习的鲁棒无线电指纹识别”，载于《2022年IEEE通信与网络安全会议（CNS）论文集》，2022年，第190–198页。[21] X. Wang、Q. Zhang、N. Cheng、R. Sun、Z. Li、S. Cui 和 X. Shen，“Radiodiff-k^2：由亥姆霍兹方程提供信息的生成式扩散模型，用于多径感知无线电地图构建”，arXiv预印本 arXiv:2504.15623，2025年。[22] R. Rombach、A. Blattmann、D. Lorenz、P. Esser 和 B. Ommer，“利用潜在扩散模型进行高分辨率图像合成”，载于《IEEE/CVF计算机视觉与模式识别会议（CVPR）论文集》，2022年，第10 684–10 695页。[23] J. Ho、A. Jain 和 P. Abbeel，“去噪扩散概率模型”，《神经信息处理系统进展》（NeurIPS），第33卷，第6840–6851页，2020年。[24] J. Song、C. Meng 和 S. Ermon，“去噪扩散隐式模型”，载于《2020年国际学习表征会议（ICLR）论文集》，2020年，第1–12页。[25] O. Avrahami、D. Lischinski 和 O. Fried，“用于自然图像文本驱动编辑的混合扩散”，载于《IEEE/CVF会议论文集》计算机视觉与模式识别（*CVPR*），2022，第 18 208–18 218 页。[26] X. Wang, Q. Zhang, N. Cheng, J. Chen, Z. Zhang, Z. Li, S. Cui, and X. Shen, “Radiodiff-3d：一种用于6G环境感知通信的3D × 3D无线电地图数据集及基于生成式扩散的基准测试，” *IEEE*网络科学与工程汇刊，第 1–18 页，2025。[27] H. Jia, W. Chen, Z. Huang, H. Xiao, N. Jia, K. Wu, S. Lai, and Y. Yue, “RMDM：融入物理信息的无线电地图扩散模型，” *arXiv*预印本 *arXiv:2501.19160*，2025。[28] X. Wang, Z. Fang, N. Cheng, R. Sun, Z. Li 等，“Radiodiff-inverse：通过扩散增强的贝叶斯逆估计实现ISAC无线电地图构建，” *arXiv*预印本 *arXiv:2504.14298*，2025。[29] Y. Song, J. Sohl-Dickstein, D. P. Kingma, A. Kumar, S. Ermon, and B. Poole，“通过随机微分方程进行基于得分的生成建模”，载于国际学习表征会议（*ICLR*），2020。[30] Y. Huang, Z. Qin, X. Liu, and K. Xu，“解耦扩散模型：图像到零与零到噪声的同步转换”，2024。[31] E. Bourtsoulatze, D. B. Kurka, and D. G¨und¨uz，“面向无线图像传输的深度联合信源信道编码”，*IEEE*认知通信与网络汇刊，第5卷，第3期，第567–579页，2019。[32] H. Xie, Z. Qin, G. Y. Li, and B.-H. Juang，“深度学习赋能的语义通信系统”，*IEEE*信号处理汇刊，第69卷，第2663–2675页，2021。[33] C.. Yapar, F. Jaensch, R. Levie, G. Kutyniok, and G. Caire，“首届路径损耗无线电地图预测挑战赛”，载于*2023*年*IEEE*声学、语音与信号处理国际会议（*ICASSP*）论文集，2023，第1–2页。[34] Z. Liu, Y. Lin, Y. Cao, H. Hu, Y. Wei, Z. Zhang, S. Lin, and B. Guo，“Swin Transformer：采用移位窗口的层次化视觉Transformer”，载于*IEEE/CVF*国际计算机视觉会议论文集，2021，第10 012–10 022页。[35] Z. Zheng and C. Wu，“用于单幅图像去雾的U形视觉Mamba”，*arXiv*预印本 *arXiv:2402.04139*，2024。