通过引导流匹配构建信道知识地图

黄子宇，曾勇，*IEEE* 会士，傅申，徐晓丽，*IEEE* 会员，以及杜宏阳，*IEEE* 会员

arXiv:2601.06156v1 [cs.IT] 6 Jan 2026

摘要——**高效构建准确的信道知识地图（CKM），对于充分释放环境感知无线网络的潜力至关重要。然而，由于可用的特定位置的信道知识数据稀疏，这仍是一个难以解决的不适定问题。尽管去噪扩散概率模型（DDPM）等基于扩散的方法已被用于 CKM 构建，但它们依赖迭代随机采样，导致速度过慢，无法满足实时无线应用的需求。为弥合高保真度与高效 CKM 构建之间的差距，本文提出一种基于线性传输引导流匹配（LT-GFM）的新框架。与扩散模型的去噪范式不同，我们的方法将 CKM 生成过程建模为遵循线性最优传输路径的确定性常微分方程（ODE），从而大幅减少所需的推理步数。我们提出了一种统一架构，不仅适用于传统的信道增益地图（CGM）构建，也适用于更具挑战性的空间协方差矩阵（SCM）构建。为实现融入物理信息的 CKM 构建，我们引入环境语义（如建筑物掩码）以恢复边缘，并强制 SCM 满足厄米对称性。仿真结果证实，与去噪扩散概率模型相比，LT-GFM 具有更优的分布保真度，弗雷歇起始距离（FID）显著更低，推理速度提升 25 倍。**

索引词—**引导流匹配、信道知识地图构建、环境感知通信、扩散模型。**

I. 引言

获取特定位置的先验信道知识，是实现无线数字孪生最重要的方面之一 [1]。为避免实时信道估计或环境感知所需的高昂开销， [2], 人们提出了信道知识图谱（CKM）的概念，以实现环境感知无线网络这一新范式[3], ，该范式利用历史数据推断特定位置的先验信道知识。根据所包含的信道知识类型，CKM 可分为多种类别，例如信道增益、到达角（AOA）、路径时延分布等。本文关注一种综合性 CKM，它由两个基本组成部分构成：信道增益地图（CGM），用于表征信道路径损耗和阴影衰落，这些信息对于

通信作者：徐晓丽。黄子宇、傅申和徐晓丽就职于中国南京210096东南大学国家移动通信研究实验室（电子邮箱：213220760@seu.edu.cn；sfu@seu.edu.cn；xiaolixu@seu.edu.cn）。曾勇就职于中国南京210096东南大学国家移动通信研究实验室，同时就职于中国南京211111紫金山实验室泛在通信研究中心（电子邮箱：yong zeng@seu.edu.cn）。杜宏阳就职于中国香港特别行政区香港大学电气与电子工程系（电子邮箱：duhy@eee.hku.hk）。

功率分配和覆盖预测至关重要；空间协方差矩阵（SCM）则用于捕获多径角度分布，可用于多天线波束成形等下游任务 [4]。

利用空间稀疏数据构建 CKM 面临着独特的挑战。这项任务属于严重的病态逆问题。现有解决方案通常分为三类：数值插值、基于深度学习的回归和生成建模。克里金插值是插值的经典示例。尽管效率较高，克里金插值却无法捕捉复杂的非线性关系。随后，深度回归方法（例如 RadioUNet [5]）得到了广泛研究。然而，由于优化的是逐像素均方误差（MSE），这类方法会受到“回归到均值”现象的影响。例如，对于上述 SCM 构建任务，它们往往会产生过度平滑的结果，虽能将平均误差降至最低，却会损害精确空间波束成形所需的清晰特征结构。为恢复高频细节，人们引入了生成对抗网络[6] 等生成模型，但这类模型的训练不稳定问题仍广为人知。尽管去噪扩散概率模型（去噪扩散概率模型）近期已实现较高的生成质量 [7] [8],，但其在无线网络中的应用受到延迟过高的制约，因为它们需要在数百个迭代步骤中模拟随机微分方程。

为解决这些局限性，我们提出了一种基于**引导流匹配**（GFM）与线性输运（LT） [9]的高效且符合物理规律的 CKM 构建框架。不同于依赖随机噪声去除的扩散模型，GFM 学习一个确定性常微分方程（ODE），沿直线轨迹将简单的先验分布输运至复杂的数据分布。这种几何上的简洁性使得常微分方程求解器能够采用较大的步长，从而显著加快推理速度。更重要的是，我们的方法通过对概率流进行建模，而非执行逐点回归，保留了信道特征的统计分布，从而确保较低的弗歇雷起始距离（FID）。

本文的主要贡献总结如下。首先，我们提出了一种基于流匹配的全新 CKM 构建框架。与主要聚焦于 CGM 的现有生成式方法不同， [10],我们提出的框架建立了一种统一的方法，既适用于 CGM，也适用于更具挑战性的 SCM 构建。其次，我们设计了一种多模态条件机制，将环境语义纳入其中，以引导生成流，实现准确的 CGM 构建。此外，对于 SCM 构建，我们施加了厄米特对称约束，以确保物理有效性。最后，仿真结果表明，与作为基准的基于 DDPM 的方法相比，我们的方法在边缘保持和特征结构保真度方面表现更优，所有

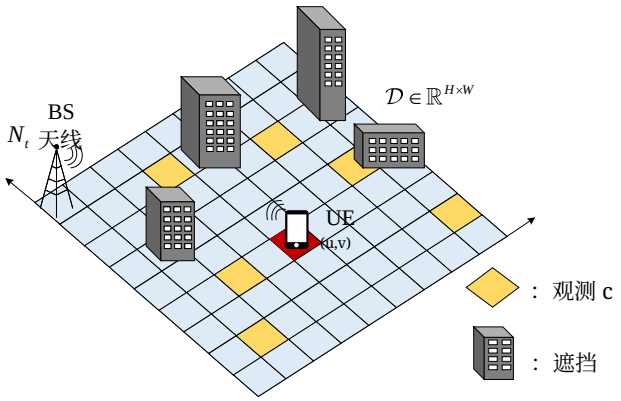

图 1. 使用环境语义进行 CKM 构建。

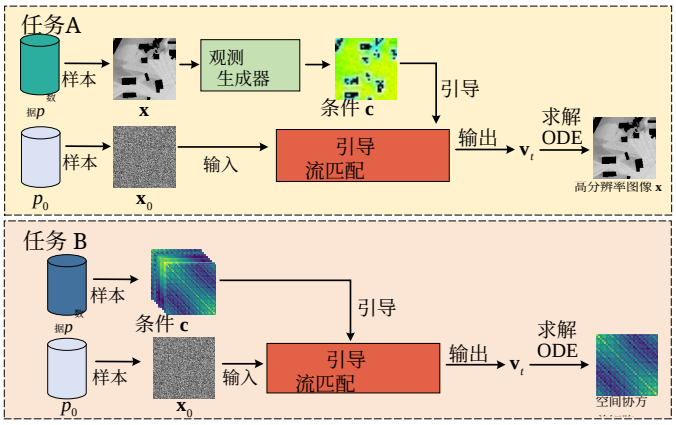

图 2. CKM 构建中不同任务的框架。

同时将推理速度提升 25 倍。

II. 系统模型与问题表述

如图 1所示，我们考虑一个在目标区域内运行的无线通信系统，该区域表示为 $\mathcal{D}$。该区域被离散为大小为 $H \times W$ 的均匀二维网格，其中每个像素 (u, v) 代表一个潜在的用户设备（UE）位置。配备 N_t 根天线的基站（BS）为分布在 $\mathcal{D}$ 中的单天线用户设备提供服务。我们将 CKM 构建问题表述为学习条件分布 $p(\mathbf{x}|\mathbf{c})$，其中 $\mathbf{x}$ 表示高保真度信道知识，其维度需根据具体应用确定；而 $\mathbf{c}$ 表示可用的降质观测。该一般性表述包含以下两个作为特殊情形的具体子问题：

A：CGM 构建：目标是从粗糙观测中恢复高分辨率 CGM。令$\mathbf{x} \in \mathbb{R}^{HW\times 1}$表示真实信道增益图的向量化形式（单位：dB）。观测到的含噪且不完整的信道知识可表示为：$\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{n}$，其中$\mathbf{y} \in \mathbb{R}^{hw\times 1}$ 表示观测到的信道增益数据，$\mathbf{A} \in \{0,1\}^{hw\times HW}(hw \ll HW)$表示下采样矩阵，$\mathbf{n}$ 为均值$\mathbf{0}$ 、协方差矩阵为 $\sigma^2\mathbf{I}$的加性高斯噪声。为融入环境语义，我们同时应用分割提取算法和 Canny检测算法，根据观测引入建筑物掩码$\mathbf{m}$ 和边缘图$\mathbf{e}$ ， 以观测$\mathbf{y}$为基础。我们定义$\mathbf{m}_{u,v} = \mathbb{I}((u,v) \notin \mathcal{B})$以标示有效的室外区域，并定义$\mathbf{e}_{u,v} = \mathbb{I}((u,v) \in \partial\mathcal{B})$以突出绕射边缘，其中 $\mathbb{I}(\cdot)$为指示函数， $\mathcal{B}$表示遮挡。这些输入拼接后构成条件张量$\mathbf{c} \in \mathbb{R}^{3\times hw\times 1}$:

$$\mathbf{c} = [\mathbf{y}, \mathbf{m}, \mathbf{e}]. \tag{1}$$

我们的框架旨在学习条件分布$p(\mathbf{x}|\mathbf{c})$，通过利用这些几何先验引导流，恢复$\mathbf{x}$ 的高分辨率纹理。

B：SCM 构建：该任务的目标是利用无线信道的空间一致性，恢复目标位置（u， v）处缺失的 SCM。为表述这一问题，我们首先建立正向物理模型。真实 SCM 场可以建模为由局部散射环境决定的空间连续函数。对于任意位置$\mathbf{p} = (u, v)$，SCM $\mathbf{R}(\mathbf{p})$ 定义为：

$$\mathbf{R}(\mathbf{p}) = \mathbb{E}\left[\mathbf{h}(\mathbf{p})\mathbf{h}^H(\mathbf{p})\right], \tag{2}$$

其中，$\mathbf{h}(\mathbf{p})$ 是信道向量。由于电磁传播的连续性，位置 $\mathbf{R}(\mathbf{p})$处的 SCM 在统计上依赖于其周围位置的 SCM。这种依赖关系可以表示为$\mathbf{R}(\mathbf{p}) \approx \Psi(\{\mathbf{R}(\mathbf{q}) \mid \mathbf{q} \in \mathcal{N}_\mathbf{p}\})$，其中 $\mathcal{N}_\mathbf{p}$ 表示$\mathbf{p}$周围的空间邻居集合，而 $\Psi(\cdot)$表示由物理环境诱导的复杂映射。

基于前向模型，我们将 SCM 构建定义为逼近 Ψ 的学习问题。我们将目标数据 $\mathbf{x} \in \mathbb{R}^{2\times N_t\times N_t}$ 定义为真实 SCM 的实值张量分解，即 $\mathbf{x} = [\Re\{\mathbf{R}(\mathbf{p})\}; \Im\{\mathbf{R}(\mathbf{p})\}]$。对于观测，我们假设处于稀疏采样场景中，此时目标 SCM 未知，但可以获得一组 K 相邻张量 $\mathbf{y} = \{\mathbf{x}_1, \cdots, \mathbf{x}_K\}$。条件张量$\mathbf{c}$ 通过沿通道维度堆叠这些相邻张量构建：

$$\mathbf{c} = [\mathbf{x}_1, \cdots, \mathbf{x}_K] \in \mathbb{R}^{2K\times N_t\times N_t}. \tag{3}$$

我们的目标是学习条件分布 $p(\mathbf{x}|\mathbf{c})$，以在给定空间上下文的情况下构建中心 SCM$\mathbf{x}$ ，其中空间上下文为$\mathbf{c}$。我们的任务框架如图2所示。

III. 用于 CKM 构建的引导流匹配框架

A. 通过最优传输生成 *CKM* 流

从稀疏观测中构建完整的 CKM 是一个严重的病态逆问题，这意味着无数潜在的 CKM $\mathbf{x}$ 都可能符合有限的观测$\mathbf{y}$。与其确定性地估计单一解（这往往会导致模糊平均），我们将构建过程表述为学习物理有效信道的条件概率分布。为了定义这一过程，我们引入三个关键分布。**目标分布** $p_{data}(\mathbf{x})$表示有效 CKM 的真实流形$\mathbf{x}$。**先验分布** p_0 是我们的起点，定义为一个不含任何信息的标准高斯分布 $p_0(\mathbf{x}) \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$。**生成分布** p_1 是模型的输出。我们的根本目标是将先验

分布 p_0 转换为 p_1，使得 p_1 能够很好地近似真实的物理分布 p_{data}。

为实现上述转换，我们采用流匹配范式。不同于依赖随机朗之万动力学的扩散模型 [11], 我们的框架将 CKM生成建模为由常微分方程控制的确定性流：

$$\begin{cases} \frac{d\mathbf{x}_t}{dt} = \mathbf{v}_\theta(\mathbf{x}_t, t, \mathbf{c}), \quad t \in [0,1], \\ \mathbf{x_0} \sim p_0(\mathbf{x}), \mathbf{x}_1 \sim p_1(\mathbf{x}) \end{cases} \tag{4}$$

其中，$\mathbf{x}_t$ 表示时间 t 时的中间 CKM状态，$\mathbf{v}_\theta$ 是用于参数化速度场的神经网络。从 $t = 0$ 时刻的纯噪声出发，我们对该常微分方程进行积分，逐步“去噪”该状态，使其演变为 $t = 1$ 时刻的有效 CKM。

尽管存在许多将 p_0 转化为 p_{data}的路径，我们出于计算效率考虑选择线性输运路径。从几何角度看，线性输运路径 **直接**通过一条直线轨迹连接噪声样本 $\mathbf{x}_0$ 和数据样本 $\mathbf{x}_1$，其定义为 $\mathbf{x}_t = (1-t)\mathbf{x}_0 + t\mathbf{x}_1$。这种线性插值意味着目标速度场$\mathbf{u}_t$ 是一个从噪声直接指向数据的恒定向量：$\mathbf{u}_t = \mathbf{x}_1 - \mathbf{x}_0$。因此，网络训练简化为一个回归问题，即最小化预测速度$\mathbf{v}_\theta$ 与线性方向之间的差异：

$$\mathcal{L}_{GFM}(\theta) = \mathbb{E}_{t,\mathbf{x}_0,\mathbf{x}_1,\mathbf{c}}\left[\|\mathbf{v}_\theta(\mathbf{x}_t, t, \mathbf{c}) - (\mathbf{x}_1 - \mathbf{x}_0)\|^2\right]. \tag{5}$$

最小化公式（5）自然能够使我们将 $\mathbf{x}_0$ 平滑地转换为 $\mathbf{x}_1$。

B. 训练与推理

如图 3所示，所提出的框架分为两个阶段：通过回归学习条件速度场，以及通过数值积分生成样本，这两个阶段也分别称为训练阶段和推理阶段。

1）训练阶段：训练目标是优化网络参数 θ，使其逼近 LT 路径。具体流程如算法 1 所示。我们的训练利用由真实样本导出的数据集对 $(\mathbf{c}, \mathbf{x}_1)$。具体而言，为了使任务A中的低分辨率观测适配U-Net架构，我们采用显式的条件对齐策略。首先使用双三次算子 $\mathcal{U}(\cdot)$ 将原始观测 y 预先上采样至目标域 $H \times W$，然后将其与建筑物掩码 m 和边缘图 e 拼接，得到条件张量 $\mathbf{c} = [\mathcal{U}(\mathbf{y})\ \mathcal{U}(\mathbf{m})\ \mathcal{U}(\mathbf{e})]$。对于任务 B，c 通过堆叠相邻的 SCM 构成。

模型学习回归一个恒定的速度场。通过采样时间步 $t \sim \mathbb{U}[0,1]$ 并构造中间状态 $\mathbf{x}_t = (1-t)\mathbf{x}_0 + t\mathbf{x}_1$,，我们强制概率质量沿直线移动。网络参数

通过最小化预测速度 $\mathbf{v}^{\text{pred}}$ 与目标方向 $\mathbf{u}^{\text{target}} = \mathbf{x}_1 - \mathbf{x}_0$，之间的均方误差（MSE）进行更新，确保学习到的流直接从噪声先验指向数据流形。

2）推理阶段：在推理过程中，模型通过求解已学习的常微分方程，从纯噪声$\mathbf{x}_0 \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ 构建高保真 CKM，详见算法2。我们采用欧拉离散化方法，使状态从 $t = 0$演化至 $t = 1$。在整个过程中，条件$\mathbf{c}$ 保持不变，充当流轨迹的导航指引。积分完成后，将进行特定于任务的后处理。对于任务 B，求解器输出 $\hat{\mathbf{x}}$ 表示矩阵的实部和虚部。为确保所构建信道协方差的结构一致性，我们执行对称化步骤：$\mathbf{R}_{final} = \frac{1}{2}(\mathbf{R}+\mathbf{R}^H)$。此操作严格施加厄米对称性，这是有效 SCM 的基本前提，-也是实现下游波束成形稳定性的关键。

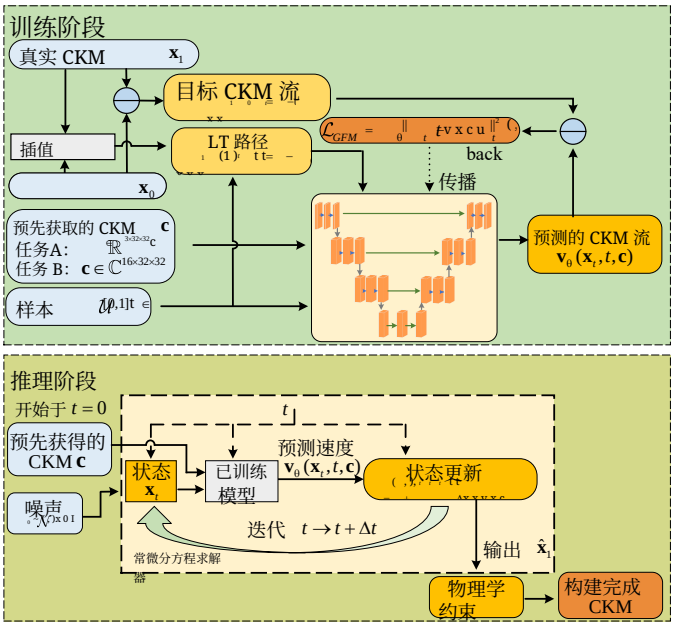

图 3. 所提出的 CKM 构建框架的训练和推理阶段框图。

算法 1 通过引导流匹配进行 CKM 构建的训练流程

1：输入：预归一化数据集 $\mathcal{S} = \{(\mathbf{c}, \mathbf{x}_1)\}$，包含条件张量和真实目标。 2：超参数：批量大小 B、学习率 η、训练轮次N。 3：初始化：神经网络参数 θ (DiffUNet)、优化器。 4：当 $i < N$ 时，执行 5：采样一小批量的配对样本$(\mathbf{c}, \mathbf{x}_1) \sim \mathcal{D}$、初始高斯噪声 $\mathbf{x}_0 \sim \mathcal{N}(0, \mathrm{I})$ 和随机时间步 $t \sim \mathcal{U}[0,1]$。 6：构建线性传输路径：$\mathbf{x}_t = (1-t)\mathbf{x}_0 + t\mathbf{x}_1$ 7：计算条件目标速度：$\mathbf{u}^{\text{target}} = \mathbf{x}_1 - \mathbf{x}_0$ 8：由神经网络预测：$\mathbf{v}^{\text{pred}} = \mathbf{v}_\theta(\mathbf{x}_t, t, \mathbf{c})$ 9：计算损失：$\mathcal{L}(\theta) = \frac{1}{B}\sum \|\mathbf{v}^{\text{pred}} - \mathbf{u}^{\text{target}}\|^2$ 10：更新网络参数：$\theta \leftarrow \theta - \eta\nabla_\theta\mathcal{L}(\theta)$ 11：结束循环 12：输出：优化后的模型参数 θ^*

IV. 仿真结果

A. 仿真设置

我们的实验使用通过 Wireless InSite 仿真软件生成的 *CKMImageNet* 数据集 [12],。对于**任务**

算法 2通过以下方式构建 CKM 的推理过程：ODE采样

输入： 条件张量 $\mathbf{c}$ ，预训练的 FlowUNet 参数 θ，积分步数 N，通道统计量（$\boldsymbol{\mu}, \boldsymbol{\sigma}$），由训练集预先计算得到。
初始化： 采样初始高斯噪声 $\mathbf{x}_0 \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$。
预处理： $\tilde{\mathbf{c}} \leftarrow (\mathbf{c} - \boldsymbol{\mu})/\boldsymbol{\sigma}$。
设置时间步长 $\Delta t = 1/N$。
当 $i < N$ **时**
  当前时间嵌入 $t \leftarrow i/N$。
  通过神经网络预测：$\mathbf{v}^{\text{pred}} = \mathbf{v}_\theta(\mathbf{x}_t, t, \tilde{\mathbf{c}})$
  状态演化：$\mathbf{x}_{t+\Delta t} = \mathbf{x}_t + \mathbf{v}_{\text{pred}} \cdot \Delta t$
结束循环
后处理： $\hat{\mathbf{x}} \leftarrow \mathbf{x}_1 \cdot \boldsymbol{\sigma} + \boldsymbol{\mu}$。
如果任务 B**则**
  根据$\mathbf{R}$由$\hat{\mathbf{x}}$的实部和虚部通道构造。
  设置物理约束）：$\mathbf{R}_{\text{final}} = \frac{1}{2}(\mathbf{R} + \mathbf{R}^H)$
  输出： $\mathbf{R}_{\text{final}}$
否则
  输出：超分辨率 CGM $\hat{\mathbf{x}}$
结束 if

A，原始信道增益地图（128×128）被归一化为灰度图像。为模拟真实的退化情况，将高分辨率图（其中每个像素的值介于 0 到 255 之间）按 4 倍因子下采样，并在像素级别添加高斯噪声（$\mathbf{n} \sim \mathcal{N}(\mathbf{0}, 30^2\mathbf{I})$）。对于**任务 B**，我们考虑一座配备 $N_t = 32$ 根天线的基站，并且 $K = 8$，表示给定周围 8 个位置的 SCM，以预测目标位置的 SCM。

B. 性能指标

我们采用了多种指标，汇总于表I。包括像素级均方误差、峰值信噪比（PSNR）和结构相似性指数（SSIM）在内的常规指标，用于像素级和感知评估。为评估分布保真度和物理一致性，我们特别采用：

1) ***Fr´echet*** 起始距离（***FID***）： FID 衡量真实数据与生成数据的特征分布之间的二阶瓦瑟斯坦距离。FID 越低，表明统计真实感越高：

$$\text{FID} = \|\boldsymbol{\mu}_r - \boldsymbol{\mu}_g\|_2^2 + \text{Tr}\left(\boldsymbol{\Sigma}_r + \boldsymbol{\Sigma}_g - 2(\boldsymbol{\Sigma}_r\boldsymbol{\Sigma}_g)^{1/2}\right), \quad (6)$$

其中，$(\boldsymbol{\mu}_r, \boldsymbol{\Sigma}_r)$ 和 $(\boldsymbol{\mu}_g, \boldsymbol{\Sigma}_g)$ 分别表示根据真实数据集（真实值）和生成数据集的深层特征表示计算得到的经验样本均值向量和协方差矩阵 [13]。

2) 矩阵相似性指数（***MSI***）： 对于任务 B，MSI 用于评估空间协方差矩阵特征空间结构的保留情况：

$$\text{MSI}(\mathbf{R}, \hat{\mathbf{R}}) = \frac{1}{N}\sum_{n=1}^{N} \frac{\left|\text{Tr}(\mathbf{R}_n \hat{\mathbf{R}}_n^H)\right|}{\|\mathbf{R}_n\|_F \|\hat{\mathbf{R}}_n\|_F}, \quad (7)$$

其中， N 表示评估样本总数。$\mathbf{R}^n^和\mathbf{R}_n$ 分别表示第 n个样本的真实空间协方差矩阵和构造的空间协方差矩阵。术语 $\|\cdot\|_F$ 表示弗罗贝尼乌斯范数，而$(\cdot)^H$ 表示共轭转置。

表 I 性能指标的适用性

类别	指标	任务 A	任务 B
像素级	均方误差、均方根误差、归一化均方误差	✓	✓
感知	峰值信噪比、结构相似性指数、弗雷歇起始距离	✓	FID
物理	MSI	–	✓

C. 数值结果

我们将提出的 LT-GFM框架与多种基线方法进行比较，包括插值方法（双三次、双线性、K近邻）、基于UNet的回归以及 DDPM。

1) 任务A： 如表II所示，我们的方法实现了最低的归一化均方误差（NMSE）和最高的结构相似性指数（SSIM）（0.8341），显著优于回归基线方法（0.6624）。图 4 展示了采用不同方法生成的一组可视化图像。在生成质量方面，与 DDPM 相比，弗雷歇起始距离（FID）降低了 43%，表明确定性流生成的纹理更加清晰逼真（例如建筑阴影）。重要的是，这一性能提升同时带来了更高的效率：与 DDPM 相比，我们的方法将推理时间缩短了约 $25\times$ （417 毫秒对 10428 毫秒）。这一加速验证了直线 LT 概率路径能够有效克服传统随机采样的计算瓶颈。

表 II 任务A（CGM 构建）的数值比较

方法	归一化均方误差↓	峰值信噪比↑	结构相似性指数↑	FID↓	时间(毫秒)
KNN	0.0735	16.55	0.2935	300.74	-
双线性	0.0612	17.44	0.3862	263.91	-
双三次	0.0641	17.15	0.3410	248.05	-
基线UNet	0.0558	17.93	0.6624	184.58	149
DDPM	0.0368	20.53	0.6392	107.69	10428
所提方法	**0.0021**	**32.49**	**0.8341**	**61.02**	**417**

2) 任务 B： 表III 展示了 SCM 的构建性能。虽然 U-Net 的均方误差较低，但其较高的弗雷歇起始距离（23.78）表明其丢失了分布特征。相比之下，我们的方法取得了近乎完美的 MSI（0.90），且弗雷歇起始距离显著更低，仅为 1.40。这证实了该框架能够保留特征结构，而这将显著影响波束成形等下游任务，并避免“过度平滑”效应。具体而言，回归型基线方法往往会模糊细粒度的空间相关特征，而我们的生成流能够准确合成与散射环境一致的高频细节。

D. 消融研究

我们研究了常微分方程采样步数 N 对构建质量和延迟的影响。如表IV所示，性能（结构相似性指数）在约 $N = 10$ 时趋于饱和。继续增加 N 虽能带来些许提升，却会使计算成本线性增加。因此， $N = 10$ 在两者之间取得了良好

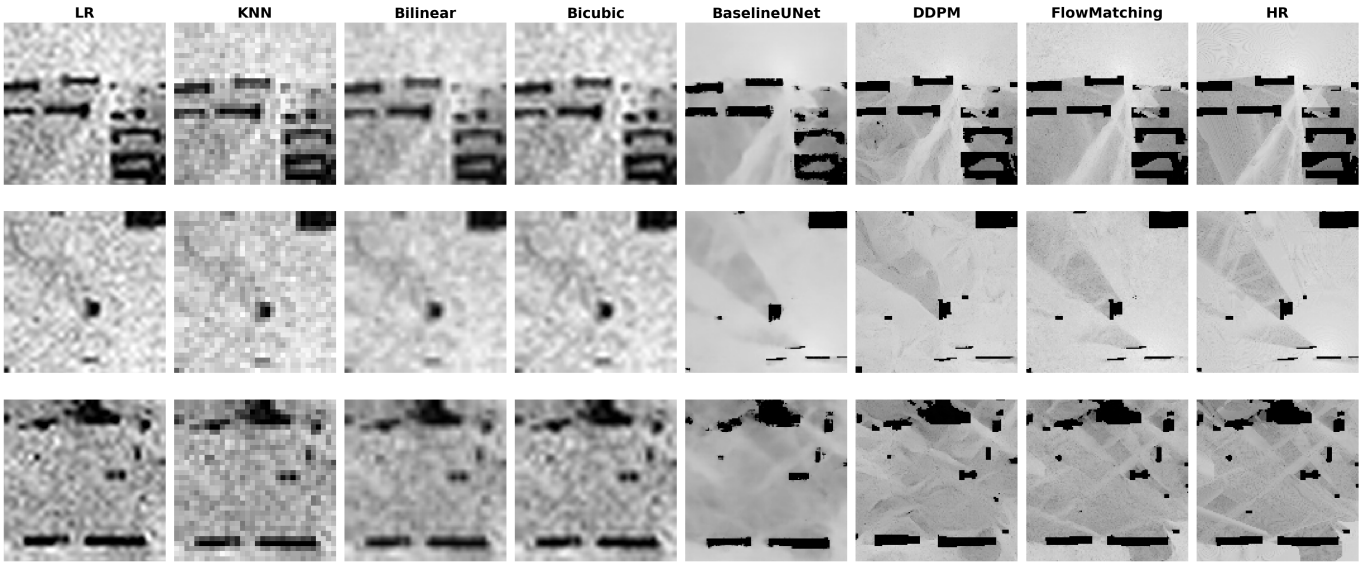

图 4. 不同方法构建的 CGM 对比

表 III 任务 B（SCM 构建）的数值比较

方法	均方根误差↓	归一化均方误差↓	MSI↑	FID↓
KNN	0.012	0.35	0.77	63.71
UNet	0.004	0.17	0.91	23.78
所提方法	**0.006**	**0.22**	**0.90**	**1.40**

平衡，以仅 417 毫秒的推理时间实现了高保真度。此外，条件分析表明，移除几何先验（掩码和边缘）会导致结构相似性指数从 0.858 降至 0.564，验证了环境语义的必要性。

表 IV 采样步数消融研究

步数（N）	SSIM	时间（毫秒）
1	0.3674	77.75
2	0.5345	150.53
4	0.7194	299.35
8	0.8168	598.08
10	0.8356	745.08
20	0.8562	1489.94
50	0.8569	3726.70

结论

本文提出了一种基于线性传输引导流匹配的全新 CKM 构建生成框架。通过将生成过程建模为具有直线轨迹的确定性常微分方程，我们的方法有效克服了传统扩散模型的计算瓶颈。我们将环境语义和物理约束融入流学习过程，从而能够准确恢复大尺度阴影效应和小尺度空间相关结构。数值结果证实，我们的方法在构建精度方面表现优异，保留了特征结构和逼真的纹理。最重要的是，与 DDPM 相比，该方法将推理速度提升了一个数量级（25×）。这种高保真度与低延迟的结合，证实了流匹配有望成为未来 6G 网络中实时 CKM 构建的实用解决方案。

参考文献

[1] Y. Wu、K. Zhang 和 Y. Zhang，《数字孪生网络：综述》，第 8 卷，第 18 期，第 13 789–13 804 页，2021年9月。[2] J. A. del Peral-Rosado、R. Raulefs、J. A. L´opez-Salcedo 和 G. Seco-Granados，《蜂窝移动无线电定位方法综述：从 1G 到 5G》，第 20 卷，第 2 期，第 1124–1148 页，2018年第 2 季度。[3] Y. Zeng 和 X. Xu，《通过信道知识图谱实现环境感知 6G通信》，第 28 卷，第 3 期，第 84–91 页，2021年6月。[4] A. Adhikary、J. Nam、J.-Y. Ahn 和 G. Caire，《联合空分复用——大规模阵列场景》，第 59 卷，第 10 期，第 6441–6463 页，2013年10月。[5] R. Levie、C. Yapar、G. Kutyniok 和 G. Caire，《RadioUNet：利用卷积神经网络快速进行无线电地图估计》，*IEEE*无线通信汇刊，第 20 卷，第 6 期，第 4001–4015 页，2021年。[6] 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*物联网期刊，第 10 卷，18 027，2023 20，18 016 期，第 – 页。[7] X. Luo、Z. Li、Z. Peng、M. Chen 和 Y. Liu，《用于生成式无线网络中无线电地图估计的去噪扩散概率模型》，*IEEE*认知通信与网络汇刊，第 11 卷，第 2 期，第 751–763 页，2025年。[8] S. Fu、Y. Zeng、Z. Wu、D. Wu、S. Jin、C.-X. Wang 和 X. Gao，《Ckmdiff：一种利用学习先验通过逆问题进行 CKM 构建的生成式扩散模型》，*arXiv*，2025年。[9] Y. Lipman、R. T. Q. Chen、H. Ben-Hamu、M. Nickel 和 M. Le，《用于生成建模的流匹配》，载于国际学习表征会议论文集（国际学习表征会议），2023年5月。[10] H. Sun、S. Liu、X. Yu 和 Y. Sun，《基于流匹配的低空无人机无线电地图构建主动学习》，*arXiv*，2025年。[11] F.-A. Croitoru、V. Hondru、R. T. Ionescu 和 M. Shah，《视觉中的扩散模型：综述》，第 45 卷，第 9 期，第 10 850–10 869 页，2021年9月。[12] Z. Wu、D. Wu、S. Fu、Y. Qiu 和 Y. Zeng，《CKMImageNet：面向环境感知通信与感知的基于人工智能的信道知识图谱数据集》，第 1–1 页，2025年。[13] G. Y. Lu 和 D. W. Wong，《一种自适应反距离加权空间插值技术》，《计算机与地球科学》，第 34 卷，第 9 期，第 1044–1055 页，2008年。