波束头脑风暴：一种生成式场景特定波束成形方法

Zihao Zhou、Zhaolin Wang，*IEEE*会员，以及 Yuanwei Liu，*IEEE*会士

arXiv:2601.02219v1 [eess.SP] 5 Jan 2026

摘要—**准确理解传播环境是场景特定波束成形（SSBF）面临的一项基础挑战。本文提出一种新颖的生成式场景特定波束成形（GenSSBF）方案，实现了从传统非结构化预测向联合结构建模的范式转变。首先，考虑到波束生成与传统图像合成之间的根本差异，本文提出统一的 GenSSBF 框架，其中包括站点配置文件、无线提示模块和生成器。其次，本文提出作为该 GenSSBF 框架具体实现的波束头脑风暴（BBS）方案。具体而言，通过离散傅里叶变换（DFT）将信道数据从空间域转换至可逆潜在空间，从而配置站点配置文件。为便于实际部署，无线提示由使用少量 DFT波束测得的参考信号接收功率（RSRP）构建。最后，采用定制的条件扩散模型开发生成器。BBS 不依赖精心设计的全局码本，而是在无线提示的引导下直接生成多样且高保真的用户专属波束。在精准的射线追踪数据集上进行的仿真结果表明，即使在低信噪比（SNR）环境下，BBS 也能实现接近最优的波束成形增益，同时大幅降低波束扫描开销。**

索引词—**波束成形、生成式扩散模型、生成式人工智能、6G。**

I. 引言

DECADES 方面的进步已使多天线技术成为现代无线通信系统的基石 [1]。波束成形是推动这一演进的重要技术，它通过空间分集和复用带来显著的性能提升 [2]。对于工作在毫米波（mmWave）或太赫兹（THz）频段的网络而言，这一点尤为关键，因为高度定向的波束成形对于补偿显著的传播损耗和穿透损耗不可或缺 [3]–[5]。从理论上讲，实现最优波束成形需要准确、及时且完备的信道状态信息（CSI）。然而在实践中，鉴于无线环境的复杂性、大规模阵列维度的不断增长以及用户移动性，实时获取完备的CSI并不可行。

第五代新空口（5G NR）中的波束成形方法主要遵循两种范式 [6]：基于特征的方法和基于波束扫描的方法。对于前者，系统通常采用“估计并优化”流程。具体而言，应首先基于上下行互易性，通过发送导频信号来估计CSI；随后，基站（BS）采用复杂的优化算法计算波束成形器，基于获得的信道状态信息 [7]–[9]。然而，信道状态信息估计需要大量导频资源和密集的基带处理[10]。当天线数量极其庞大时，这种开销尤为突出。相比之下，基于波束扫描的方法更为常用，它涉及依次进行探测、测量和报告 [11]。这种范式依赖预定义码本，其波束能够覆盖所有可能的量化方向（例如，离散傅里叶变换（DFT）或过采样DFT（O-DFT）码本 [12]）。具体而言，在下行链路中，基站使用同步信号块（SSB）对码本中的探测波束进行穷举扫描。用户设备（UE）监测接收信号功率，然后将测量结果报告给基站。基站根据来自用户设备的反馈确定最佳波束。然而，当码本中的窄波束数量激增时，这种穷举搜索会导致极高的波束扫描开销。因此，人们提出了分层搜索方法 [13]–[15] ：基站先使用SSB扫描较宽的波束，再通过更灵活的信道状态信息参考信号（CSI-RS）逐步扫描更窄的子波束。

值得注意的是，前述基于波束扫描的方法采用的码本是与站点无关的，也就是说，同一码本会普遍应用于不同站点。然而，无线传播环境本质上具有特定站点属性，因为它受局部几何特征、用户分布和所采用硬件的影响，而这些因素在不同部署站点之间各不相同。因此，传统的与站点无关的码本存在以下固有局限：

- **环境感知不足**：码本中的波束力求覆盖所有可能的角度方向，但对于某些特定站点（例如走廊、热点），某些方向可能永远不会被使用 [16]。这会导致波束扫描时间延长，并产生不必要的开销。
- **性能瓶颈**：离散傅里叶变换码本或 O-离散傅里叶变换码本中的波束通常为单波瓣，这限制了波束成形增益，尤其是在非视距（NLoS）场景中。此外，这些基于栅格的方法存在“栅格失配”问题 [12]，，即预定义波束可能无法与实际信道完全对齐，从而导致性能不佳。
- **可扩展性有限**：随着天线阵列规模增大（例如，拥有数百甚至数千根天线的超大规模 MIMO（XL-MIMO）[17]），这些与站点无关的码本规模也将大幅增长。传统的波束搜索优化只能

作者任职于香港大学电机电子工程系，香港（电子邮箱：eezihaozhou@connect.hku.hk,zhaolin.wang@hku.hk,yuanwei@hku.hk）

带来微小的增益。

因此，面向 6G 的波束成形技术必须不断发展，将空间智能融入其中；这一范式称为场景特定波束成形 (SSBF) [18]。近年来，深度学习（DL）辅助的 SSBF 日益受到关注。在 [16], 中，复杂值神经网络（NN）以信道向量为输入，在离线阶段学习场景特定探测码本。模拟移相器的波束成形权重直接由神经元权重表示。沿用通过复值 NN 直接表征码本的思路， [19] 的作者增加了一个预测层，根据扫描已学习探测码本所获得的功率测量值，预测离散傅里叶变换码本中的最优窄波束索引。在 [20], 的框架中， [19]被改用于分层波束对准，其中每一层的探测码本和下一层选择器都经过联合训练。不同于通过射线追踪使用信道数据， [21] 的作者提出采用接收信号的功率测量值作为数据集，训练端到端码本学习和窄波束索引预测框架。在[22],中，有研究提出了一种基于计算机视觉（CV）的场景特定码本设计方法：针对视距用户，利用基站（BS）拍摄的图像学习码本；针对非视距用户，则利用从三维点云中提取的特征进行学习。 [23] 的作者提出使用场景特定数字孪生生成合成信道数据，并将其用于码本学习。

尽管上述方法 [16], [19]–[23]学习到了能够捕获特定场景信息的更具“意义”的码本，但通信波束仍然位于栅格上。由于码本规模有限，无论波束是从学习得到的码本中选择，还是从传统的与站点无关的码本中选择，系统的总体波束成形增益仍受到限制。此外，上文提到的“栅格失配”问题依然存在。在 [24], 中，提出了一种无栅格场景特定波束对齐框架，其中探测码本与基于多层感知机（MLP）的波束合成器进行了联合训练。类似地， [12]将 MLP 应用于混合波束成形， [25] 则将其应用于全双工系统中的联合发射与接收波束成形。然而，由于多径传播环境的复杂性，不同用户可能具有相似的粗略信道状态信息测量值（即这些判别模型的输入），而其对应的最优波束成形向量却可能完全不同。这种现象在场景特定波束成形（SSBF）中被称为多模态性。在这种情况下，基于均方误差（MSE）损失的传统判别式回归倾向于对多个合理波束进行平均，从而导致显著的性能下降。此外，这些方法本质上属于“非结构化预测” [26]，其假设是在给定输入的情况下，波束成形向量的所有元素彼此条件独立。然而，这一假设未能考虑到这些元素之间具有高度相关性，并共同决定信号在接收机处进行相长叠加还是相消叠加 [27]。

与判别模型相比，生成式人工智能（GenAI）模型属于“结构化预测”类别，能够学习多模态分布，展现出超越传统判别模型边界的变革性潜力[28], [29]。近期研究还展示了生成式人工智能（例如扩散模型 [30], [31]）在无线通信中的重要作用。在 [32],中，给定少量真实信道矩阵后，研究采用条件去噪扩散隐式模型（cDDIM）生成更多增强信道样本。类似地，研究人员探索了扩散模型辅助的多输入多输出系统信道估计、外推和反馈 [33]。 [34]的作者将扩散模型视为端到端（E2E）无线通信系统中的可微信道生成器，从而能够在高保真信道分布下设计/训练其他模块（例如编码器/解码器）。在 [35], 中，研究人员在深度强化学习（DRL）框架中采用扩散模型作为演员网络，以解决基于速率分割多址（RSMA）的低空移动边缘计算（MEG）场景中的资源分配问题。同样，遵循“扩散模型作为深度强化学习中的演员”这一范式， [36] 的作者研究了智能反射面（RIS）辅助物联网（IoT）通信中的安全波束成形。然而，做出下一步决策需要信道矩阵、传输/窃听速率以及历史动作，这会导致显著的信令开销和时延。

对于实际的场景特定波束成形（SSBF）任务而言，其要求低开销和高波束成形增益。从理论上讲，学习联合结构和多模态分布能够使模型更好地理解复杂站点内的信号传播过程，从而实现更准确的波束成形。然而，现有文献对生成式人工智能在这一问题上的应用仍鲜有探索，这引出了以下重要问题：(1) 生成式人工智能适用于 *SSBF* 场景吗？以及 (2)生成式人工智能能在多大程度上提升波束成形增益？因此，本文提出了一种生成式场景特定波束成形（GenSSBF）统一设计框架，并建立了一个与当前 5G 标准中的波束成形流程完全兼容的 GenSSBF 基线。主要贡献总结如下：

- 我们提出了一种统一的 GenSSBF 框架，同时考虑波束生成任务与图像合成之间的根本差异。所提出的 GenSSBF 框架由站点配置文件、结构化无线提示模块和生成器组成。该工作流程经过精心设计，使各模块协同工作，生成能够准确捕捉特定站点信息且满足物理约束的波束。与传统的基于非结构化判别式回归的 SS BF 相比，GenSSBF 联合学习波束成形向量的内部关联及其与外部传播环境的交互，从而显著增强对特定站点的感知能力。

- 我们提出了 Beam_BrainStorm_（BBS）解决方案，作为 GenSSBF 框架的一种具体实现。具体而言，通过离散傅里叶变换将空间域中的信道数据转换到可逆潜在空间，从而配置站点配置文件，

进而降低学习难度。对于提示模块，原始无线提示定义为使用少量均匀选取的离散傅里叶变换波束进行探测所获得的参考信号接收功率（RSRP）。随后，我们开发了一种条件扩散模型，在无线提示的引导下生成用户专属波束。“波束头脑风暴”一词体现了该模型按需为不同用户设备生成一组高保真波束的能力，这些波束可用于后续的波束扫描过程。

- 大量仿真结果验证了所提出的 BBS 方案的有效性。具体而言，在各种环境下（例如涵盖视距（LoS）/非视距链路条件的室内和室外场景），BBS 的性能优于穷举搜索和基于判别式回归的波束预测，能够以显著更低的波束扫描开销实现更高的波束成形增益。值得注意的是，即使在低信噪比（SNR）环境中，无线提示有限时，头脑风暴也能显著提升可实现的波束成形增益。

本文其余部分安排如下。第II节介绍系统模型和问题表述。第III节介绍所提出的 GenSSBF 统一设计框架和 BBS 方案。第IV节给出所使用的数据集和仿真结果，随后在第V节总结全文。

符号说明：标量、向量和矩阵分别用常规字体、小写粗体和大写粗体字母表示（例如 $\mathbf{x}$、$\mathbf{x}$ 和$\mathbf{X}$）。复数集和实数集分别记为 $\mathbb{C}$ 和 $\mathbb{R}$。转置和共轭转置分别记为 $(\cdot)^T$ 和 $(\cdot)^H$。绝对值和欧几里得范数分别记为 $|\cdot|$ 和 $\|\cdot\|$。$\mathcal{N}(a, b^2)$ 表示均值为 a 、方差为 b^2 的高斯分布。期望算子记为 $\mathbb{E}[\cdot]$。

II. 系统模型与问题表述

考虑一个下行通信系统，其中，配备有包含 N 个阵元的天线阵列的基站为 K 个单天线用户设备提供服务。采用包含 L 条路径的一般基于射线的信道模型，其表达式为

$$\mathbf{h} = \sum_{l=1}^{L} \alpha_l \mathbf{a}(\phi_l^D, \theta_l^D), \tag{1}$$

其中，α_l 是第 l 条路径的复增益，出发方位角和俯仰角分别表示为 ϕ_l^D 和 θ_l^D，而 $\mathbf{a}(\phi_l^D, \theta_l^D)$ 表示阵列导向向量。为简单起见，本文考虑均匀线性阵列（ULA），其波束转向受限于方位角域 [1]。因此，ϕ_l 处的导向向量可写为

$$\mathbf{a}(\phi_l) = \frac{1}{\sqrt{N}} \left[1, \mathrm{e}^{j\frac{2\pi d}{\lambda}\sin(\phi_l)}, \cdots, \mathrm{e}^{j(N_t-1)\frac{2\pi d}{\lambda}\sin(\phi_l)}\right]^{\mathrm{T}}, \tag{2}$$

其中，λ 和 d 分别为载波波长和天线间距。

[1]我们提出的框架适用于任意几何形状的阵列。

鉴于全数字波束成形的成本和复杂性，尤其是在高频频段，基站通常采用纯模拟或混合波束成形 [19]。因此，本文假设基站采用单条射频（RF）链，并利用移相器网络进行发射波束成形。在这种架构下，用户设备的发射波束成形向量可表示为

$$\mathbf{w} = \frac{1}{\sqrt{N}}[\mathrm{e}^{j\theta_1}, \mathrm{e}^{j\theta_2}, \cdots, \mathrm{e}^{j\theta_N}]^{\mathrm{T}}, \tag{3}$$

其中，$\mathbf{w} \in \mathbb{C}^{N\times 1}$ 满足功率约束，且 $\mathbf{w}$ 的每个元素均满足恒模约束。记 s 为该用户设备的发送符号，其平均功率约束为 $\mathbb{E}[|s|^2] = 1$。因此，该用户设备的接收信号可表示为

$$y(\mathbf{w}) = \sqrt{P_T}\mathbf{h}^{\mathrm{H}}\mathbf{w}s + n, \tag{4}$$

其中，P_T是基站的发射功率，$n \sim \mathcal{CN}(0, \sigma^2)$是噪声功率为$\sigma^2$的复加性噪声。用户设备处的信噪比（SNR）可表示为

$$\mathrm{SNR} = \frac{P_T|\mathbf{h}^{\mathrm{H}}\mathbf{w}|^2}{\sigma^2}. \tag{5}$$

最终目标是设计一个能够最大化信噪比的波束成形向量。然而，由于获取瞬时信道状态信息的复杂度高、时延长，当前第五代移动通信技术采用基于波束扫描、测量和报告的波束成形框架，从预定义码本中选择波束。因此，对于这类基于码本的方法，目标可转化为在包含 N_W 个波束（例如，离散傅里叶变换码本或某些学习得到的码本）的预定义码本$\mathbf{W} \in \mathbb{C}^{N\times N_W}$ 中找到最优窄波束索引 N_W，其可表示为

$$i^*_{\mathbf{W}} = \underset{i=1,2,\cdots,N_W}{\mathrm{argmax}} \left(\frac{P_T|\mathbf{h}^{\mathrm{H}}\mathbf{w}_i|^2}{\sigma^2}\right) = \underset{i=1,2,\cdots,N_W}{\mathrm{argmax}} \ (|\mathbf{h}^{\mathrm{H}}\mathbf{w}_i|^2). \tag{6}$$

然而，无论是与站点无关还是特定站点，码本在站点内对所有用户设备都是通用的。因此，可实现的整体波束成形增益从根本上受限于所设计的码本。本文回归问题本源，旨在部署阶段无需获取完整信道状态信息，直接为每个用户设备单独设计波束成形向量。具体而言，给定有限的观测值$\mathbf{c}_k$[2]，通过优化“波束生成器” $f(\cdot)$来构建信噪比最大化问题

$$\max_{f} \quad |\mathbf{h}_k^H f(\mathbf{c}_k)|^2 \tag{7a}$$

$$\text{s.t.} \quad \|f(\mathbf{c}_k)\|^2 = 1, \tag{7b}$$

$$f(\mathbf{c}_k) \in \mathcal{S}, \tag{7c}$$

其中$\mathbf{h}_k \in \mathbb{C}^{N\times 1}$ 是 k-用户设备的信道向量，约束（7b）表示波束成形向量的归一化功率限制，而 $\mathcal{S}$ 在（7c）中表示受硬件约束的可行集，例如（3）中波束成形向量每个元素的单位模约束。

[2]观测可以采用不同模式，具体将在第III-A节中介绍。

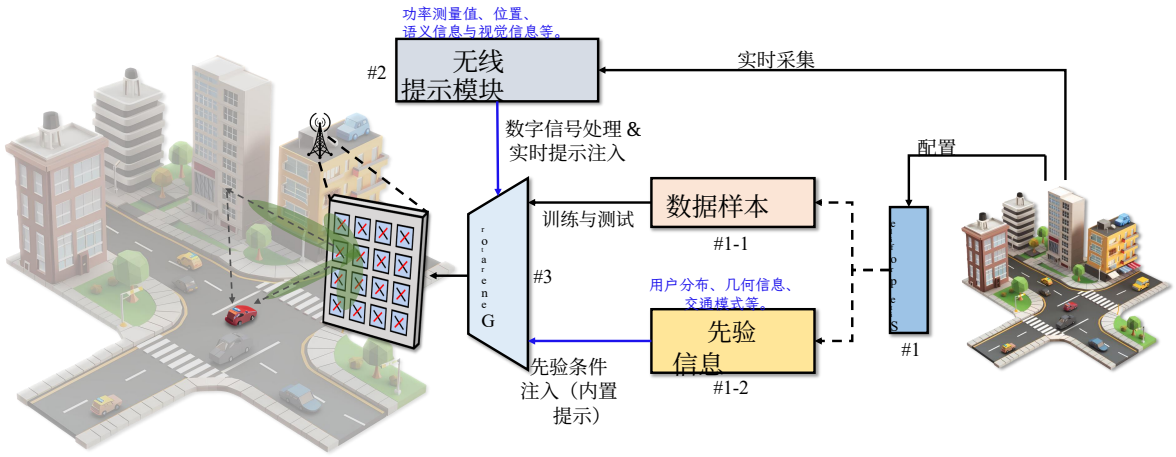


图 1. GenSSBF 的统一框架。

III. 所提出的生成式场景特定波束成形设计

本节详细介绍所提出的 GenSSBF 方法。首先，我们将在第III-A节介绍所提出的统一 GenSSBF 框架。作为该框架的一种实例化方案，随后将在第III-B节介绍所提出的 BBS 方案。

A. 所提出的统一框架设计

现有的场景特定波束成形方法要么依赖经过学习的量化码本，要么采用判别式人工智能模型进行非结构化波束预测。前者会受到网格失配问题的影响，而后者由于对环境的理解不足，其波束表达能力可能受到限制。这些关键局限性促使我们从传统的非结构化预测 [26] 转向结构化生成。因此，我们提出了 GenSSBF 及其统一框架，如图1所示。该框架可作为基础性且通用的设计流程。通常，GenSSBF 框架由三个组件组成：1）站点配置文件；2）无线提示模块；以及 3）生成器。

具体而言，对于所提出的 GenSSBF 框架中的站点配置文件（图1中的“#1”框），可以通过历史数据或数字孪生进行配置。站点配置文件包含数据样本和先验信息（例如，用户分布、几何知识）。数据样本用于训练和测试模型（图1中的“#1-1”框），而先验信息则可作为内置提示注入生成模型（图1中的“#1-2”框）。

然而，仅凭先验信息不足以生成用户专属的波束成形向量。因此，另一个关键组成部分是无线提示模块（图1中的“#2”框），它作为实时用户专属条件提供器。然而，传统生成任务中常用的文本提示无法传达与传播环境相关的精确信息，而结构化文本提示则需要大量专业知识 [37]。因此，GenSSBF 需要可量化的结构化无线提示，以准确捕捉场地信息。为此，我们的框架引入了“无线提示”这一概念。无线提示可以采用不同模态，以提供可量化的特定站点信息，例如来自小型探测码本的功率测量值、来自全球导航卫星系统（GNSS）的位置信息，以及视觉和语义信息（例如RGB-D图像和三维点云）。此外，这些多模态提示可以整合为异构条件，从而有望提升生成性能。

获得数据样本和提示后，可以离线训练生成模型，再将其部署用于在线推理，如图1中标注为“#3”的方框所示。不过，GenSSBF 在生成模型的设计上需要考虑一些独特因素。首先，与传统图像生成中像素值的波动通常在感知上可以容忍不同，波束生成中，波束成形向量中每个元素的相位值都至关重要。它直接决定信号在目标接收机处是相长叠加还是相消叠加。其次，生成的波束应能在真实系统中发挥作用，这意味着模型设计时需要考虑一些实际约束（例如移相器约束和基站的功率限制）。下一小节将详细介绍一种具体方案，作为我们所提出的 GenSSBF 框架的实例。

B. 用于场景特定波束成形的 *BBS*

基于上述框架，本小节介绍我们为 GenSSBF 提出的波束头脑风暴（BBS）方案。BBS 能够隐式学习无线传播环境对波束成形的影响，代表着从传统的基于非结构化预测的方法向生成式方法的范式转变。对于每个 UE，一个特定站点且容量无界的波束数据库可以由训练充分的生成模型[3]表示。“头脑风暴”一词指的是模型能够自主、按需地生成一组紧凑的高保真波束，这些波束随后将用于波束扫描过程。

[3]“容量无界”是指，该模型通过其权重为任意用户设备参数化一个无限的波束成形向量空间，而非显式存储这些向量。

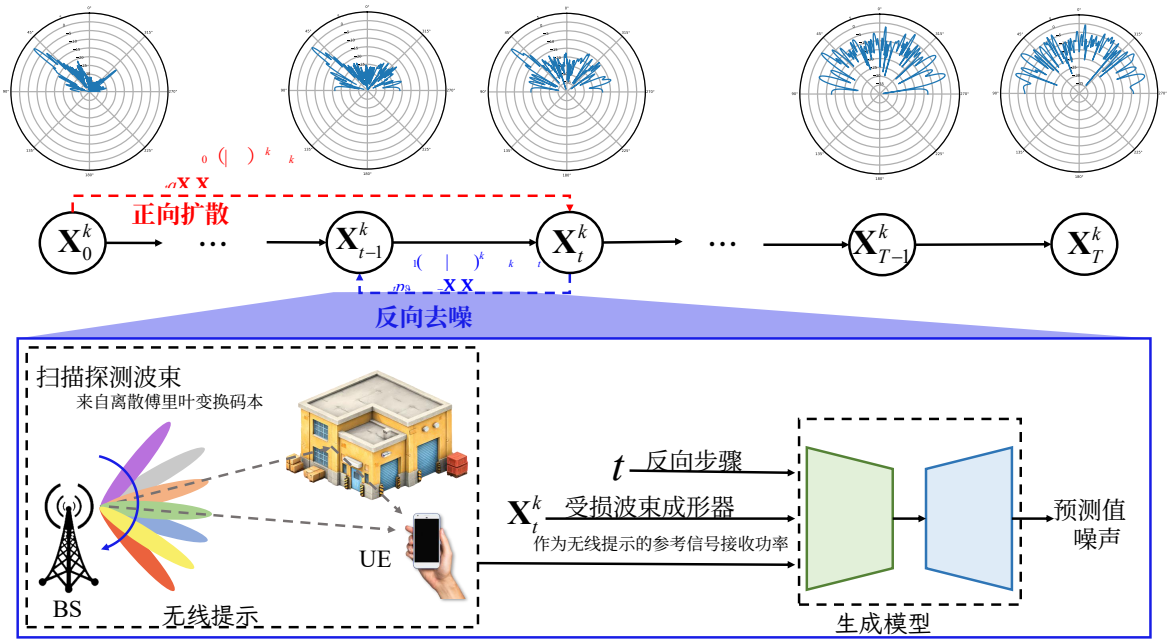


图2. 所提出的BBS方案的总体结构。

由于生成的波束实际上已捕获特定站点的信息（例如传播环境），因此只需极小的候选集即可满足需求，从而显著降低波束扫描开销。所提出的 BBS 整体框架如图所示2。下文将从三个方面详细介绍我们的 BBS 方案：1）基于条件扩散的波束生成的公式化；2）定制的模型架构；以及3）训练与部署算法。

1）基于条件扩散的波束生成：首先，考虑前向扩散过程，即在一系列时间步中通过逐步添加噪声来破坏数据样本的过程。在本工作中，采用最大比传输（MRT）波束成形器作为数据样本的来源。具体而言，对于信道为 $\mathbf{h}_k \in \mathbb{C}^{N_t \times 1}$ 的用户 k，MRT波束成形器可表示为

$$\mathbf{w}_0^k = \frac{1}{\sqrt{N}} \left[e^{j\angle \mathbf{h}_k[1]}, e^{j\angle \mathbf{h}_k[2]}, \cdots, e^{j\angle \mathbf{h}_k[N]} \right]^{\mathrm{T}}, \quad (8)$$

其中，$\angle$表示复数的相位。我们不直接在空间域中向信道信息 $[\angle \mathbf{h}_k[1], \angle \mathbf{h}_k[2], \cdots, \angle \mathbf{h}_k[N]]^{\mathrm{T}}$ 添加噪声，而是利用远场信道在角域中的稀疏特性，对空间信道的离散傅里叶变换（DFT）表示 $\mathbf{h}_k^{\mathcal{A}} = \mathcal{F}(\mathbf{h}_k)$ 执行前向扩散过程，其中 $\mathcal{F}(\cdot)$ 为离散傅里叶变换算子。因此，本工作中的数据样本可表示为

$$\mathbf{X}_0^k = \begin{bmatrix} \angle \mathbf{h}_k^{\mathcal{A}}[1] & \angle \mathbf{h}_k^{\mathcal{A}}[2] & \cdots & \angle \mathbf{h}_k^{\mathcal{A}}[N] \\ |\mathbf{h}_k^{\mathcal{A}}[1]| & |\mathbf{h}_k^{\mathcal{A}}[2]| & \cdots & |\mathbf{h}_k^{\mathcal{A}}[N]| \end{bmatrix} \quad (9)$$

其中，$|\cdot|$ 表示复数 [4]的幅度。将$\mathbf{X}_t^k$ 记为时间步 t时第 k个用户设备受损或含噪的数据。因此，在一个前向扩散过程中，经过总计 T 个时间步，我们将得到一系列受扰动的矩阵 $\{\mathbf{X}_1^k、\mathbf{X}_2^k、\cdots、\mathbf{X}_T^k\}$。具体而言，在每个时间步 t，$\mathbf{X}_t^k$都从分布 $q(\mathbf{X}_t^k|\mathbf{X}_{t-1}^k)$ 中采样，该分布可以表示为

$$q(\mathbf{X}_t^k|\mathbf{X}_{t-1}^k) = \prod_{i=1}^{2} \prod_{j=1}^{N} \mathcal{N}(\mathbf{X}_t^k[i,j]; \sqrt{1-\beta_t}\mathbf{X}_{t-1}^k[i,j], \beta_t), \quad (10)$$

其中，$\beta_t \in (0, 1)$ $t = 1, 2, \cdots, T$表示预定义噪声调度，用于控制噪声随时间添加或移除的速率。根据马尔可夫性质，从$\mathbf{X}_0^k$ 到$\mathbf{X}_T^k$ 的整个前向扩散过程表示为

$$q(\mathbf{X}_T^k|\mathbf{X}_0^k) = \prod_{t=1}^{T} q(\mathbf{X}_t^k|\mathbf{X}_{t-1}^k). \quad (11)$$

式（11）使我们能够建立递推关系，从而得出$\mathbf{X}_0^k$ 到$\mathbf{X}_T^k$ 的闭式关系：

$$\mathbf{X}_T^k = \sqrt{\prod_{t=1}^{T}(1-\beta_t)}\mathbf{X}_0^k + \sqrt{1-\prod_{t=1}^{T}(1-\beta_t)}\mathbf{Z}_{0\to T}, \quad (12)$$

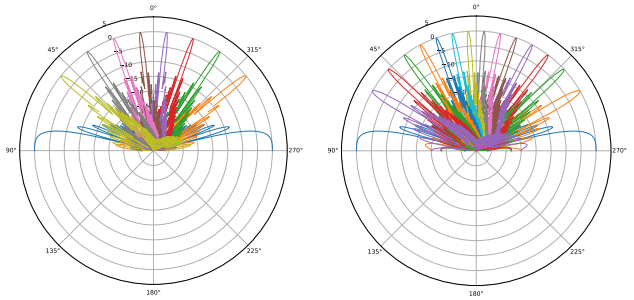
其中，$\mathbf{Z}_{0\to T}$ 是与$\mathbf{X}_0^k$形状相同的噪声矩阵。$\mathbf{Z}_{0\to T}$ 中的每个元素都是一个均值为零、方差为单位值的高斯随机变量。

接下来，考虑反向去噪过程，即通过迭代去噪$\mathbf{X}_t^k$ 来恢复原始数据样本$\mathbf{X}_0^k$的过程。根据贝叶斯定理，我们有

$$q(\mathbf{X}_{t-1}^k|\mathbf{X}_t^k, \mathbf{X}_0^k) = \frac{q(\mathbf{X}_t^k|\mathbf{X}_{t-1}^k, \mathbf{X}_0^k)q(\mathbf{X}_{t-1}^k|\mathbf{X}_0^k)}{q(\mathbf{X}_t^k|\mathbf{X}_0^k)}. \quad (13)$$

术语 $q(\mathbf{X}_t^k|\mathbf{X}_{t-1}^k, \mathbf{X}_0^k)$、$q(\mathbf{X}_{t-1}^k|\mathbf{X}_0^k)$以及 $q(\mathbf{X}_t^k|\mathbf{X}_0^k)$ 在（13）中可以由（10）和（11）得到。因此，通过重新排列，可得

[4]$\mathbf{h}_k^{\mathcal{A}}$ 的幅度可以进行缩放，以提高训练的稳定性和效率。



(a) (b)

图3。 用于实时条件控制的探测波束，(a) Q=9 和 (b) Q=15。

$$q(\mathbf{X}_{t-1}^k|\mathbf{X}_t^k,\mathbf{X}_0^k)=\prod_{i=1}^{2}\prod_{j=1}^{N}\mathcal{N}\left(\mathbf{X}_{t-1}^k[i,j];\mathbf{U}_t[i,j],\sigma_t^2\right), \tag{14}$$

其中，$\mathbf{U}_t[i,j]$ 可表示为

$$\mathbf{U}_t[i,j]=\frac{\sqrt{1-\beta_t}\left(1-\prod_{i=1}^{t-1}(1-\beta_i)\right)}{1-\prod_{i=1}^{t}(1-\beta_t)}\mathbf{X}_t^k[i,j] +\frac{\beta_t\sqrt{\prod_{i=1}^{t-1}(1-\beta_i)}}{1-\prod_{i=1}^{t}(1-\beta_i)}\mathbf{X}_0^k[i,j], \tag{15}$$

和 σ_t^2 可表示为

$$\sigma_t^2=\frac{\beta_t\left(1-\prod_{i=1}^{t-1}(1-\beta_i)\right)}{1-\prod_{i=1}^{t}(1-\beta_i)}. \tag{16}$$

回顾一下，在 (12) 中，$\mathbf{X}_t^k$ 与 $\mathbf{X}_0^k$ 之间的关系为

$$\mathbf{X}_0^k=\frac{\mathbf{X}_t^k-\sqrt{1-\prod_{i=1}^{t}(1-\beta_i)}\mathbf{Z}_{0\to t}}{\sqrt{\prod_{i=1}^{t}(1-\beta_i)}}. \tag{17}$$

然而，需要注意的是，$\mathbf{Z}_{0\to t}$ 仅在前向扩散过程中已知，因此使用深度神经网络 ϵ_ϑ （由 ϑ 参数化）来预测反向去噪过程中的噪声矩阵。此外，为了使模型能够为每个用户设备生成有意义的波束，用户设备报告的接收功率测量值被用作实时无线提示，以引导生成过程。具体而言，基站使用从具有 k个窄波束的离散傅里叶变换码本中均匀选取的 Q 探测波束向第[5] 个用户设备发送 N 参考信号，如图3所示。因此，根据 (4)，功率测量向量$\mathbf{c}_k\in\mathbb{R}^{Q\times 1}$ 是为第 $\mathbf{X}_0^k$ 个用户设备生成 k的条件，可表示为

$$\mathbf{c}_k=\left[|y_k(\mathbf{w}_1^{\mathrm{DFT}})|^2,|y_k(\mathbf{w}_2^{\mathrm{DFT}})|^2,\cdots,|y_k(\mathbf{w}_Q^{\mathrm{DFT}})|^2\right]^{\mathrm{T}}, \tag{18}$$

其中，$\mathbf{w}_q^{\mathrm{DFT}}$表示从离散傅里叶变换码本中选取的第 q个窄波束的波束成形向量。因此，时间步 t的预测噪声矩阵可表示为

$$\epsilon_\vartheta(\mathbf{X}_t^k,\mathbf{c}_k,t)\approx\mathbf{Z}_{0\to t}. \tag{19}$$

[5]探测波束的选择策略可以通过优化，甚至由其他模态条件控制机制替代，这将留待我们未来的工作。

将（19）和（17）代入（15）可得

$$\mathbf{U}_t'=\frac{1}{\sqrt{1-\beta_t}}\left(\mathbf{X}_t^k-\frac{\beta_t}{\sqrt{1-\prod_{i=1}^{t}(1-\beta_i)}}\epsilon_\vartheta(\mathbf{X}_t^k,\mathbf{c}_k,t)\right). \tag{20}$$

因此，式（ $q(\mathbf{X}_{t-1}^k|\mathbf{X}_t^k,\mathbf{X}_0)$ 14）中的条件分布14）可使用参数化模型$p_\vartheta(\mathbf{X}_{t-1}^k|\mathbf{X}_t^k)$近似表示为

$$p_\vartheta(\mathbf{X}_{t-1}^k|\mathbf{X}_t^k)=\prod_{i=1}^{2}\prod_{j=1}^{N}\mathcal{N}\left(\mathbf{X}_{t-1}^k;\mathbf{U}_t'[i,j],\sigma_t^2\right). \tag{21}$$

第 k个用户设备的生成分布 $p_\vartheta(\mathbf{X}_0^k)$通过从$\mathbf{X}_T^k$ 到$\mathbf{X}_0^k$的反向马尔可夫链定义：

$$p_\vartheta(\mathbf{X}_0^k)=q(\mathbf{X}_T^k)\prod_{t=1}^{T}p_\vartheta(\mathbf{X}_{t-1}^k|\mathbf{X}_t^k), \tag{22}$$

其中，在每个时间步 $t=1,2,\cdots,T$，均使用确定性近似执行去噪更新$\mathbf{X}_{t-1}^k=\mathbf{U}_t'$。这是因为，与对像素级波动不太敏感的传统图像生成任务相比，波束成形要求更精确地生成复数的相位和幅度。尽管如此，在BBS中，波束生成的多样性仍可得到保留，即$\mathbf{X}_T^k$ 的不同样本将对应于第 k个用户设备的不同波束图样。

因此，在从$t=T$到 $t=1$的范围内重复执行（21）中的去噪步骤后，$\mathbf{X}_0^k$ 可以被重构，而用户 k 的波束成形向量的第 n个元素可表示为

$$\mathbf{w}_0^k[n]=\frac{1}{\sqrt{N}}\mathrm{e}^{j\angle\mathcal{F}^{-1}\left(\mathbf{X}_0^k[2,n]\mathrm{e}^{j\mathbf{X}_0^k[1,n]}\right)}, \tag{23}$$

其中 $\mathcal{F}^{-1}(\cdot)$为IDFT算子。

2）模型架构：BBS采用改进的 U-Net模型对波束成形器进行去噪。具体而言，如图4所示，该模型由三个主要构建模块组成：“双卷积块”、“下采样块”和“上采样块”，它们共同构成模型的收缩路径、桥接层和扩展路径。

在“双卷积块”（如图中蓝色框所示）4）中，两个一维卷积层（卷积核大小 = 1，填充 = 1）级联排列，每个卷积层前均设有一个高斯误差线性单元（GELU）激活层 [38]。第二个一维卷积层的输出通过残差连接与经过投影的融合嵌入及该“双卷积块”的原始输入相加。随后，将该结果输入多头自注意力块，以生成波束特征图。在收缩路径中，每个“下采样块”均采用一维最大池化，将波束特征图的长度减半。相反，在扩展路径中，每个“上采样块”均采用一维线性插值来增加长度。如图中绿色箭头所示，“上采样块”输出的上采样波束特征图会与同一阶段来自收缩路径的对应特征图进行拼接。4。随后，将合并后的特征图作为扩展路径中下一个“双卷积块”的输入。去噪过程由时间步 t 和功率测量向量 $\mathbf{c}_k$引导。采用正弦位置编码来获取时间步嵌入，

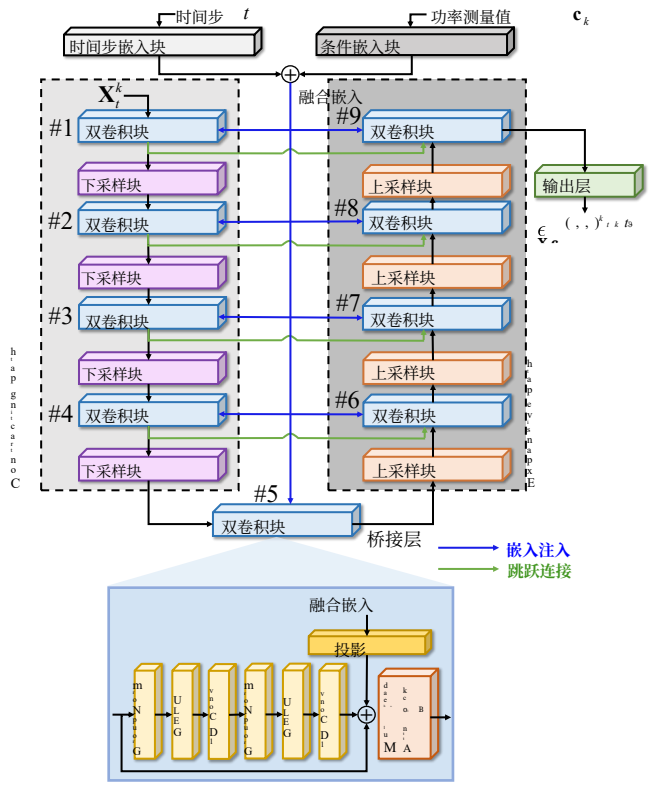


图 4. 模型架构。

条件嵌入则通过一个带有GELU激活函数的两层多层感知机获得。最后，输出层（以一维卷积层实现）根据（19）中的定义预测噪声。

3）训练与部署：在离线训练阶段，数据集为 $\mathcal{D} = (\mathbf{h}_d, \mathbf{X}_0^d, \mathbf{c}_d)_{d=1}^D$，其中 D 是通过射线追踪仿真器获取信道向量的场景中激活点的总数。需要注意的是，由于离线训练阶段没有关于噪声的先验信息，向量 $\mathbf{c}_d$ 由无噪声功率测量值构成，其元素为$|\mathbf{h}_d^{\mathrm{H}}\mathbf{w}_q^{\mathrm{DFT}}|^2$。每个训练轮次中，整个数据集被划分为小批量，批量大小为 $B(1 \le B \le D)$。对于批次中的每个数据样本 $\mathbf{X}_0^b$，我们从 $(0, T]$ 中随机生成一个整数时间步 t_b，并按照 (12) 应用 t_b 步前向扩散过程来破坏原始数据样本 $\mathbf{X}_0^b$，从而得到 $\mathbf{X}_{t_b}^b$。将这个受损批次记为 $\mathbf{X}_t^b \in \mathbb{R}^{B\times 2\times N}$，然后将 $\mathbf{X}_t^b$、一批时间步 $\mathbf{t}_B \in \mathbb{Z}_+^{B\times 1}$和一批条件 $\mathbf{c}_B \in \mathbb{R}^{B\times Q}$ 输入模型，以获得注入噪声的预测值 $\epsilon_\vartheta(\mathbf{X}_t^b, \mathbf{t}_B, \mathbf{c}_B)$。采用噪声预测的均方误差（MSE）损失来更新模型参数，其表达式为

$$\mathcal{L} = \mathbb{E}\left[\|\mathbf{Z}_B - \epsilon_\vartheta(\mathbf{X}_t^b, \mathbf{t}_B, \mathbf{c}_B)\|^2\right], \tag{24}$$

其中$\mathbf{Z}_B \in \mathbb{R}^{B\times 2\times N}$ 是前向扩散过程中的注入噪声矩阵。因此，去噪神经网络的参数 ϑ 可通过梯度下降更新为 $\vartheta \leftarrow \vartheta - l_r\nabla_\vartheta\mathcal{L}$，其中 l_r 是学习率。

算法1BBS中的离线训练

初始化：训练轮数“MAX EPOCHS”，
探测波束 Q、学习率 l_r、噪声调度 $\{\beta_t\}_{t=1}^T$，
批量大小 B、扩散步数 T、改进的 U-Net 的参数 ϑ
改进的 U-Net。
/* 站点配置文件*/:
对于数据集中的每个已激活用户设备 d **执行**
获取空间域中的信道信息$\mathbf{h}_d$
以及潜在空间中的信道信息$\mathbf{h}_d^A = \mathcal{F}(\mathbf{h}_d)$
根据$\mathbf{X}_0^d$ 基于 （9）
获取无噪声 RSRP 向量$\mathbf{c}_d$
结束循环
构建训练集 $\mathcal{D} = (\mathbf{h}_d, \mathbf{X}_0^d, \mathbf{c}_d)_{d=1}^D$
/* 离线训练 */:
轮次=1 至最大轮次 **执行**
对每个批次 $(\mathbf{h}_b, \mathbf{X}_0^b, \mathbf{c}_b)_{b=1}^B \sim \mathcal{D}$ **执行**
从 **(0时间步**$_B \in \mathbb{Z}_+^{B\times 1}, T]$
使用**时间步**$_B$ 对批次数据进行加噪，依据 (12)
根据 (19) 进行噪声预测
根据 (24) 计算损失
通过梯度下降更新 ϑ
结束循环
结束循环

算法 2 针对第 k 个用户设备的在线推理

初始化：头脑风暴次数 M**/* 无线提示 */:** 从离散傅里叶变换码本中均匀选择 Q 个窄波束。执行波束扫描并获取 RSRP 向量 $\mathbf{c}_k$ 初始化 M 高斯噪声矩阵 $\{\mathbf{X}^{k,}{}_T{}^m\}_{m=1}^M$，基于（25）**/* 头脑风暴*/: for** $m = 1$ 到 M **dofor** $t = T$ 到 **1 do**基于（20）通过反向去噪获得 $\mathbf{X}^{k,}{}_{t-1}^m$ **end forend for**使用 $\{\mathbf{X}^{k,}{}_0{}^m\}_{m=1}^M$ 执行波束扫描并获取 RSRP。获得最优波束成形向量 $\mathbf{X}^{k,}{}_0{}^*$

训练后，对于某个用户设备 k，我们初始化 M 个高斯噪声矩阵 $\{\mathbf{X}^{k,}{}_T{}^m\}_{m=1}^M$ 其中

$$q(\mathbf{X}_T^{k,m}) = \prod_{i=1}^{2}\prod_{j=1}^{N}\mathcal{N}(\mathbf{X}_T^{k,m}[i,j]; 0, 1). \tag{25}$$

对于每个 $\mathbf{X}^{k,}{}_T{}^m$，基于（20）执行迭代反向去噪过程，以获得 $\mathbf{X}^{k,}{}_0{}^m$。随后，应用基于逆离散傅里叶变换（IDFT）的无损逆映射，将 $\mathbf{X}^{k,}{}_0{}^m$ 重构为波束成形向量 $\mathbf{w}^{k,}{}_0{}^m$，如式（23）所示。依次对不同的高斯噪声矩阵应用 T 个去噪步骤后，M 将生成针对第 M 个用户设备定制的波束成形向量。随后，基站扫描这些 k波束，并根据用户设备的反馈，选择接收功率最高的波束。

我们提出的框架无需预先设计全局码本。通过利用条件扩散模型的生成能力，

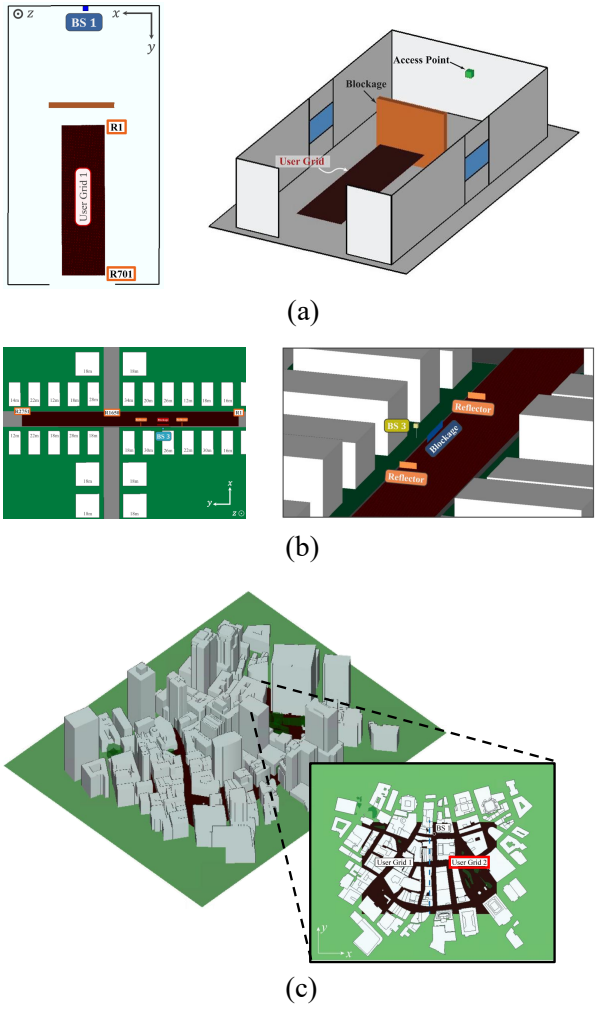


图5. 射线追踪环境示意图：(a) I2 28B、(b) O1B 28 和 (c) Boston5G 28。

它能够隐式地为每个用户设备构想数量无限的特定位置波束。在部署过程中，模型只需“头脑风暴” M 波束，其中 M 通常可以非常小，从而将波束扫描开销 O 控制 $Q+M$ 在（当 $M>1$）[6]以内。所提出的 BBS 的离线训练和在线推理分别总结于 **算法**1 和**算法** 2中。在第 V节中，我们将展示，所提出的方法在大幅降低开销的同时，显著提高了波束成形增益。

备注 1。所提出的 BBS 方案基本遵循当前 5G 标准采用的“扫描-测量-报告”波束管理流程。由于用于获取无线提示的探测波束是从离散傅里叶变换码本中均匀选取的，因此可以通过“始终开启”的 SSB 进行传输。生成的用户专属波束则可以通过 CSI-RS 进行传输。因此，所提出的 BBS 方案可以无缝集成到当前 5G 系统中，无需更改标准化协议。

[6]当 $M=1$ 时，波束扫描开销为 Q。

表I 仿真参数

场景名称	I2 28B，O1B 28 和 Boston5G 28
基站天线	64×1 均匀线性阵列
天线间距	半波长间距
用户设备天线	单个
天线单元	各向同性
载波频率	28 GHz
路径数	5
数据样本总数	100k
训练集比例	80%
学习率	10^{-4}
批量大小 B	32
扩散步数 T	1000
训练轮数	300
EMA衰减系数	0.995

IV. 数据集与仿真结果

A. 数据集

准确的数据集有助于分析所提出算法在实际环境中的表现。我们采用公开 DeepMIMO 数据集 [39] 中的三个不同场景，以全面考量各种传播环境，例如室内和室外、视距和非视距链路等。DeepMIMO 数据集中的信道数据是通过采用先进商用软件进行射线追踪生成的。具体而言，在仿真中，我们使用 DeepMIMO I2 28B、O1B 28 和 Boston5G 28 来评估 BBS 方案的性能，以下将对这些数据集进行介绍。

*1) DeepMIMO I2 28B*场景： DeepMIMO I2 28B数据集[7] 对一个室内场景进行建模，其中所有用户均未与基站建立视距连接，如图5(a)所示。基站位于房间内侧墙壁上，共有 140901 个用户分布在遮挡后方的棕色区域。载波频率为 28 GHz。

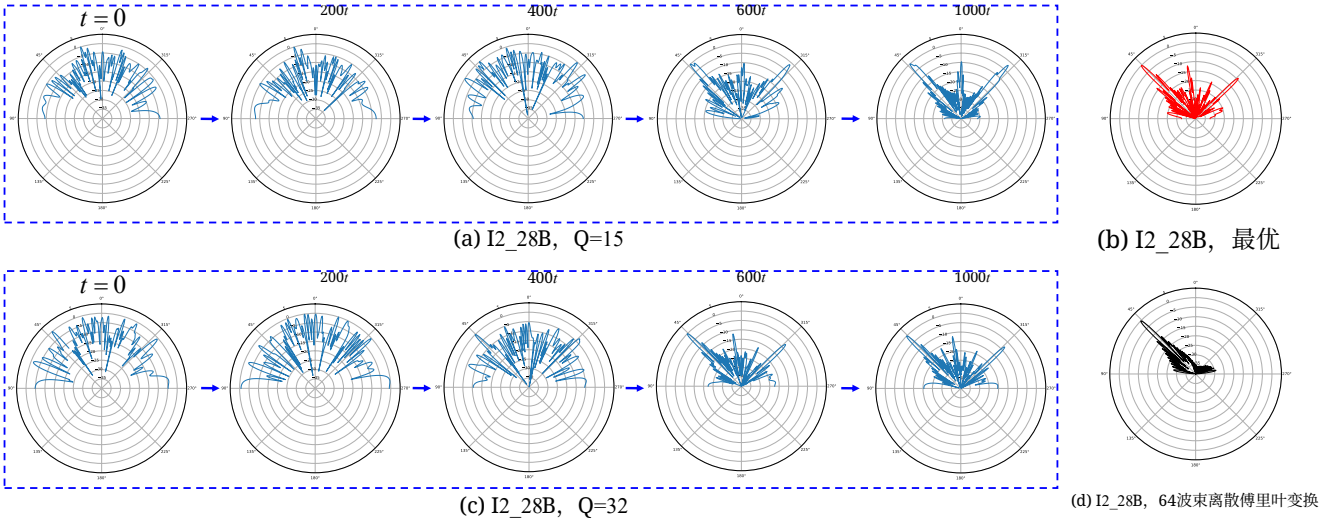
*2) DeepMIMO O1B 28*场景： DeepMIMO O1B 28 数据集[8] 对一个存在遮挡和反射的室外街道环境进行建模，如图5(b)所示。具体而言，选取了 O1 28 数据集中对应于基站 #3 和用户网格 #1 的部分。因此，484264 名用户总计包括与基站具有视距链路的用户，以及具有非视距链路的用户。载波频率为 28 GHz。

3）DeepMIMO Boston5G 28 场景：DeepMIMO Boston5G 28 数据集[9] 包含美国波士顿市中心的高层建筑、街道和开阔空间。具体而言，基站位于 15 米高处，并选用图 5(c) 所示的用户网格 #2，其中有 102762 个激活用户。5（c）。载波频率为 28 GHz。

B. 仿真结果

在本节中，我们评估所提出的 BBS方案在第IV-A节所述场景下的性能。对于每种场景，100k 个数据样本中的 80% 用于训练，其余 20% 用于测试。扩散时间步总数 T 设为 1000。条件

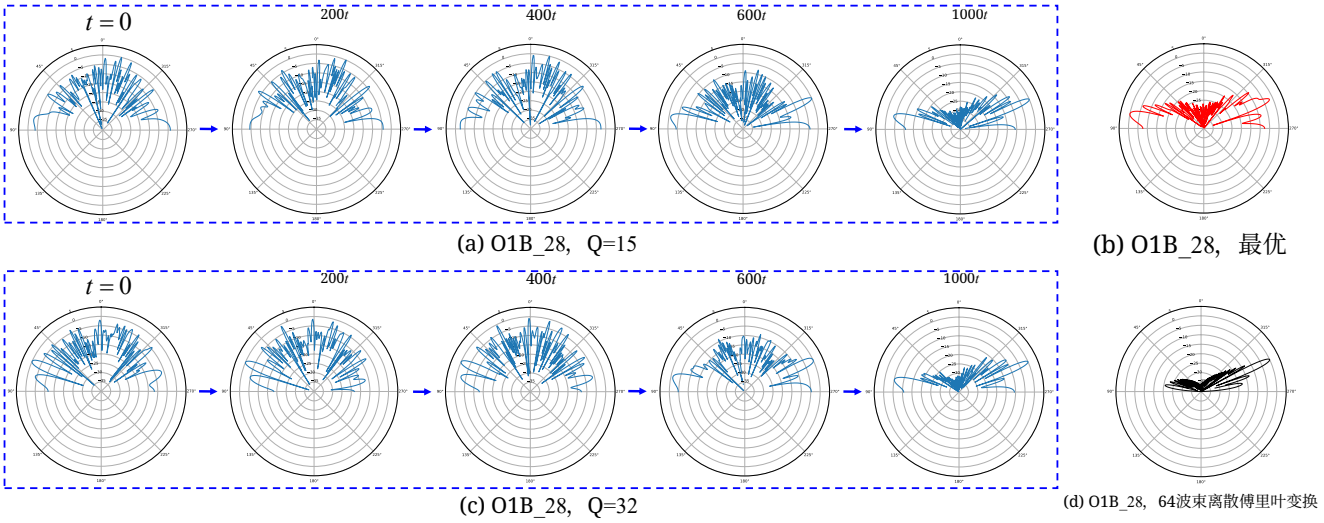
[7]https://www.deepmimo.net/scenarios/v4/i228b [8] https://www.deepmimo.net/scenarios/v4 28 9 1/o b [9] https://www.deepmimo.net/scenarios/v4/boston5g 28



(a) I2_28B，Q=15　(b) I2_28B，最优

(c) I2_28B，Q=32　(d) I2_28B，64波束离散傅里叶变换

图 6。 I2 28B场景中的波束图对比，分别由(a) 使用 $Q = 15$ 的 BSS、(b) 最大比传输、(c) 使用 $Q = 32$ 的 BBS，以及 (d) 穷举搜索 64波束DFT码本获得



(a) O1B_28，Q=15　(b) O1B_28，最优

(c) O1B_28，Q=32　(d) O1B_28，64波束离散傅里叶变换

图 7。O1B 28场景中的波束图对比，分别由 (a) 使用 $Q = 15$ 的 BSS、(b) 最大比传输、(c) 使用 $Q = 32$ 的 BBS，以及 (d) 穷举搜索 64波束DFT码本获得

嵌入模块是一个两层多层感知机，隐藏层和输出层均包含 256 个神经元，两层之间使用 GELU 激活函数。时间步 t 也通过正弦位置编码投影到 256 维嵌入空间。对于去噪神经网络，在收缩路径和桥接层中，每个双卷积块（图4中的双卷积块 #1–#5）处理输入信道维度为 $[1, 64, 128, 256, 512]$ 的输入，并分别输出信道维度为 $[64, 128, 256, 512, 1024]$, 的特征。相应地，在扩张路径中（双卷积块 #6–#9），输出信道维度为 $[512, 256, 128, 64]$。多头注意力块的头数为 4。模型使用 Adam优化器训练 300 轮次，学习率和批量大小分别为 10^{-4} 和 32。此外，采用指数移动平均（EMA），以 0.995 的衰减系数更新模型参数。详细参数汇总于表 I。

C. 生成的波束图分析

在进行定量分析之前，我们首先直观地考察生成的波束图，以提取潜在的设计见解。图6、7 和8 分别展示了 I2 28B、O1B 28 和 Boston5G 28 场景下的生成过程、最优波束图样及离散傅里叶变换波束图样。如图6、7和8中蓝色虚线框所示，波束生成过程展示了各个去噪步骤[10]。可以观察到，随着去噪步骤的推进，波束成形向量从最初的随机模式逐渐演变为具有明确方向特征的模式。值得注意的是，尽管其初始化时使用的是从相同分布中采样的随机矩阵

[10]需要注意的是，此处的索引 t 表示反向去噪步骤的数量，其中 $t = 400$对应去噪过程中的 400 个步骤

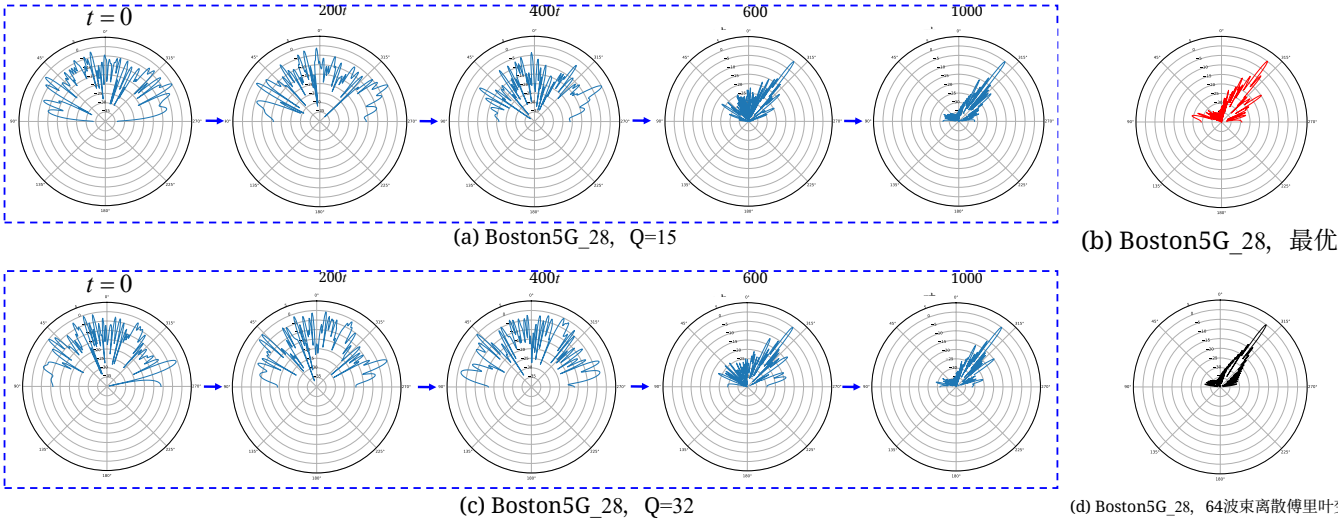


图8。波束图的比较in Boston5G_28 场景中，通过 (a) 具有 $Q = 15$ 的 BSS、(b) 最大比传输、(c) 具有 $Q = 32$ 的 BBS，以及 (d) 穷举获得搜索64波束DFT码本

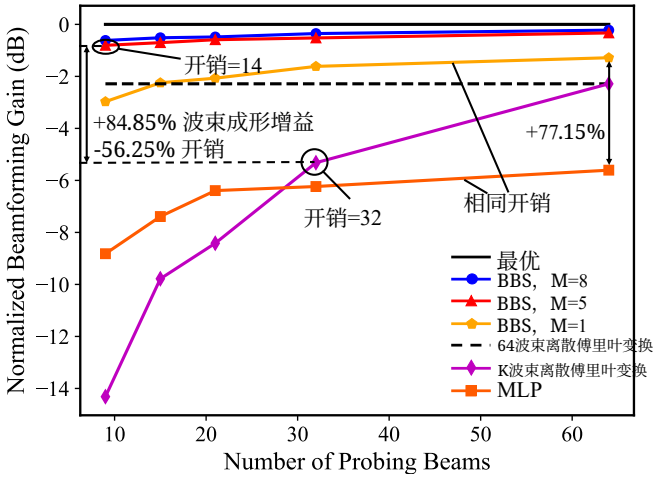


图9. I2 28B场景中的归一化波束成形增益与 Q的关系。

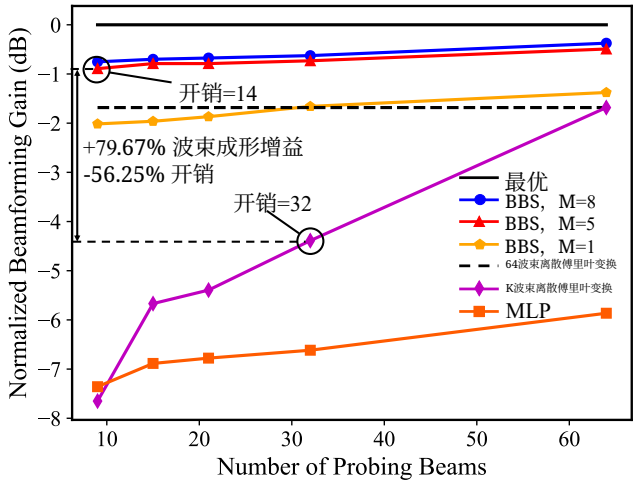


图10. O1B 28场景中的归一化波束成形增益与 Q 的关系。

高斯分布下，所提出的 BBS 会根据不同的无线提示，在三个场景中生成明显不同的波束图样。这一结果表明，该模型具有很强的场地特定信息捕捉能力，并且对部署环境具有良好的上下文感知能力。

我们进一步将生成的波束图样与最优波束图样，以及通过对64波束DFT码本进行穷举搜索得到的波束图样进行比较。与通常呈现单个主瓣的传统离散傅里叶变换波束相比，生成的波束通常具有多个主瓣。这类波束图样可能能够捕获更多关于传播环境的信息，从而增强波束成形增益。以O1B 28场景为例，如图7所示，由于基站前方存在遮挡，且其两侧放置了反射器，如图中的几何信息所示5(b)所示，生成的波束也相应地将大部分能量集中到这些方向，呈现出与最优波束相似的特性。

此外，我们还研究了无线提示长度对生成质量的影响。对于图6中的 I2 28B，随着 RSRP向量长度从 15 增加到 32，约在 $\pm 45°$处的两个主瓣变得更加尖锐，位于0°处的波瓣向左调整了约10°。总体而言，这些变化使波束图更加接近最优波束图。对于图7中的 O1B 28，增加 RSRP向量长度带来的主要益处在于抑制旁瓣。如图7 (a)和(c)所示，尽管它们在 $t = 1000$处的主瓣形状几乎相同，但 $Q = 32$ 的情况能够更有效地抑制0°附近的旁瓣（在下一小节中，我们将看到提示长度与可实现的波束成形增益之间存在权衡）。对于图8中的 Boston5G 28，主要差异在于约 $-55°$处出现了一个主瓣。

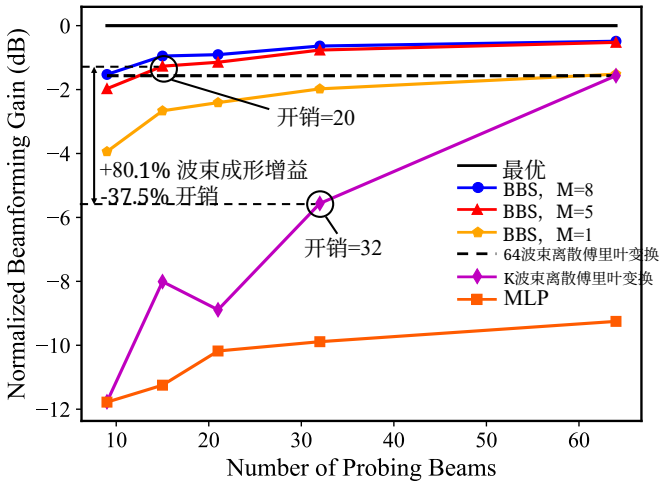


图 11. Boston5G 28 场景中归一化波束成形增益与 Q 的关系。

D. 波束成形增益与开销性能

虽然定性分析能够直观评估 BBS 是否可以生成“有意义的”波束，但定量分析则提供了对其带来具体增益的明确测量。归一化波束成形增益被视为关键指标，因为它与信噪比呈正相关。归一化波束成形增益可通过以下方式计算：

$$\bar{g} = 10\log_{10}\left(\frac{|\mathbf{h}^{\mathrm{H}}\mathbf{w}|^2}{|\mathbf{h}^{\mathrm{H}}\mathbf{w}_{\mathrm{MRT}}|^2}\right), \tag{26}$$

其中 $\mathbf{w}_{\mathrm{MRT}}$ 为采用 MRT 的波束成形向量，是最优解。图 9 - 11 分别展示了 I2 28B 、 O1B 28 和 Boston5G 28 场景下，归一化波束成形增益随无线提示长度的变化。首先可以观察到，在这 3 个环境中，所提出的 BBS 的归一化波束成形增益均随探测波束数量的增加而提升。这是因为更多的功率测量值能够为用户设备提供更丰富的特定站点信息，即无线提示包含的信息更加充分。此外，与“仅思考一次（YOTO）”方案（$M = 1$）相比，头脑风暴（$M > 1$）带来了显著的性能提升。这是因为对于经过训练的生成模型而言，其参数构成了一个潜在波束空间，能够按需为任意用户设备生成（无需显式存储）几乎无限数量的高质量特定站点波束。因此，利用一组此类定制波束通常能够带来更优的性能。例如，在 I2 28B 场景中，与 32 波束离散傅里叶变换方案相比，我们的 BBS方案（含 $Q = 9$ 和 $M = 5$）在波束成形增益方面提升了 84.85%，同时将波束扫描开销降低了 56.25%。与穷举 64波束离散傅里叶变换搜索相比，所提出的方案在波束成形增益方面提升了 64.74%，同时将开销显著降低了 78.1%。所提出的 BBS 与穷举搜索在波束扫描开销和相应波束成形增益方面的完整百分比变化汇总如下

表II 波束扫描开销和波束成形增益的变化百分比

S1	ΔO (BBS-M1)	-85.9%	-76.5%	-67.2%	-50%	0%
	$\Delta\bar{g}$ (BBS-M1)	-0.3%	+0.02%	+0.1%	+29.3%	+43.8%
	ΔO (BBS-M5)	-78.1%	-68.7%	-59.3%	-42.1%	+0.07%
	$\Delta\bar{g}$ (BBS-M5)	+64.7%	+69.2%	+74.2%	+77.2%	+85.6%
	ΔO (BBS-M8)	-73.4%	-64.1%	-54.7%	-37.5%	+12.5%
	$\Delta\bar{g}$ (BBS-M8)	+72.9%	+77.5%	+78.8%	+84.5%	+90.3%
S2	ΔO (BBS-M1)	-85.9%	-76.5%	-67.2%	-50%	0%
	$\Delta\bar{g}$ (BBS-M1)	-19.7%	-16.5%	-10.9%	+0.01%	+18.2%
	ΔO (BBS-M5)	-78.1%	-68.7%	-59.3%	-42.1%	+0.07%
	$\Delta\bar{g}$ (BBS-M5)	+47%	+53.1%	+53.1%	+56.5%	+70.7%
	ΔO (BBS-M8)	-73.4%	-64.1%	-54.7%	-37.5%	+12.5%
	$\Delta\bar{g}$ (BBS-M8)	+55.2%	+58.3%	+59.8%	+62.8%	+77.8%
S3	ΔO (BBS-M1)	-85.9%	-76.5%	-67.2%	-50%	0%
	$\Delta\bar{g}$ (BBS-M1)	-151.6%	-70.1%	-53.7%	-26.3%	+0.03%
	ΔO (BBS-M5)	-78.1%	-68.7%	-59.3%	-42.1%	+0.07%
	$\Delta\bar{g}$ (BBS-M5)	-0.25%	+19%	+26.8%	+51.3%	+66.6%
	ΔO (BBS-M8)	-73.4%	-64.1%	-54.7%	-37.5%	+12.5%
	$\Delta\bar{g}$ (BBS-M8)	+0.02%	+39.3%	+42%	+59.2%	+68.8%

表 II中，其中 S1、S2 和 S3 分别表示 I2 28B、O1B 28 和 Boston5G 28。此外，还对采用判别式回归的基于波束预测的方法进行了比较。然而可以观察到，该方案在三个场景中的平均波束成形增益性能最低。这种性能不佳可能源于模型对环境的理解不足，从而使其适应过程适得其反。具体而言，在相同开销（$Q = 32$，$M = 1$）下，BBS 在三个场景中的平均波束成形增益可提升 76.3%。

此外，值得注意的是，将 M 从 1 增加到 5 会显著提升波束成形增益，而进一步增加到 8 带来的额外增益有限，却会增加波束扫描开销。这意味着头脑风暴的强度存在权衡。同样，对于无线提示的长度 Q，也观察到了阈值效应。超过这一阈值后，性能仅略有提升，开销却会增加。如何优化这些权衡是一个值得探讨的问题，将留待未来工作。

E. 含噪无线提示的影响

为了评估其可行性，测试其在噪声环境下的性能至关重要。本小节评估含噪无线提示对 GenSSBF 性能的影响。具体而言，噪声功率根据探测 DFT波束的接收功率中位数和信噪比计算得出。图中展示了三个不同场景下的含噪 RSRP向量。12，信噪比从 10 dB 变化至 30 dB。可以观察到，噪声水平越高，RSRP向量的波动越大，尤其是功率测量值较低的向量。在 I2 28B、O1B 28 和 Boston5G 28 中，不同信噪比下的归一化波束成形增益分别如图13–图15所示。显然，随着信噪比降低，BBS 的波束成形增益也会下降，因为环境“越脏”，提供的指导就越不准确。然而，得益于对环境更深入的理解，所提出的 BBS 在低信噪比环境下仍能实现更优的波束成形增益性能。例如，如图所示，在 I2 28B场景中

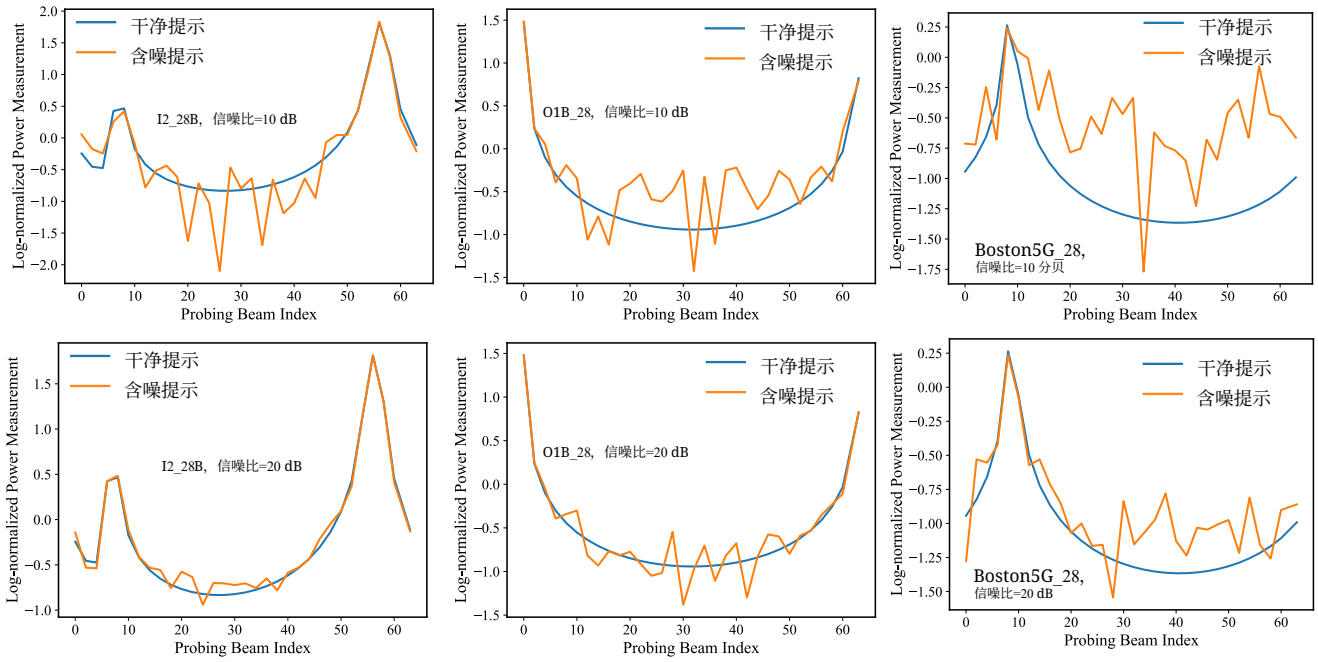


图12. 不同场景和信噪比下的含噪无线提示。

图中13所示，在相同的波束扫描开销下，BBS 的表现优于穷举搜索：在 10 dB 信噪比下，波束成形增益提高 66.99%；在 30 dB 信噪比下，提高 93.38%。然而，另一个重要发现是：由于 BBS 使用的无线提示是通过 DFT波束探测获得的，因此 BBS 的鲁棒性从根本上受限于离散傅里叶变换码本。此外，RSRP向量包含高功率和低功率测量值。在低信噪比情况下，尤其是噪声功率超过接收功率时，向量中的有用信息会被噪声淹没，从而导致性能下降。因此，未来一项非常重要的研究方向是设计更鲁棒的无线提示结构。

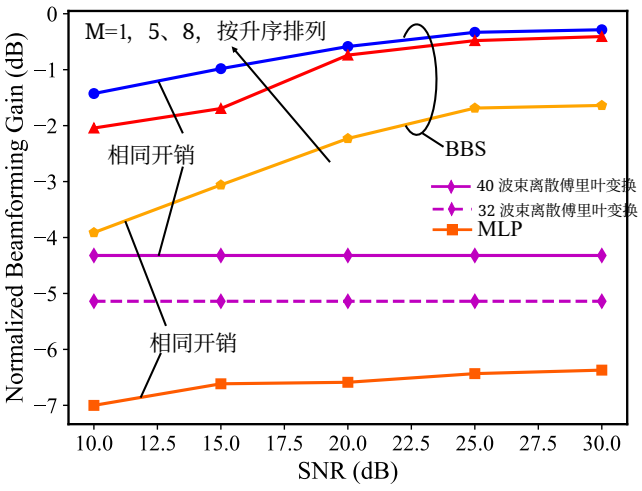


图13. I2 28B场景下归一化波束成形增益与信噪比的关系。

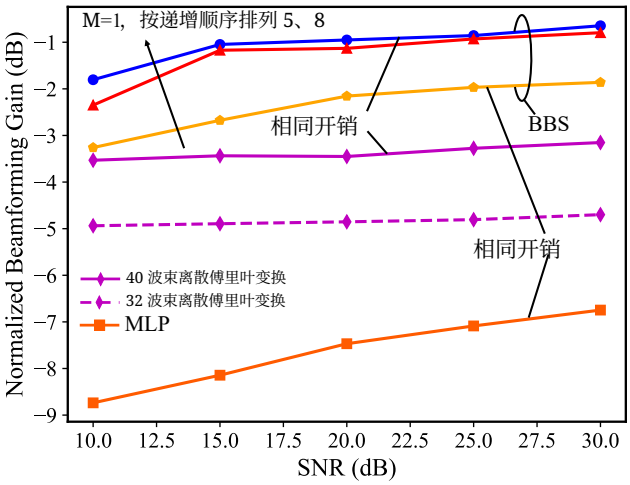


图14. O1B 28场景下归一化波束成形增益与信噪比的关系。

V. 结论

本文提出了一种用于 GenSSBF 的统一设计框架，由站点配置文件、无线提示模块和生成器组成。作为该 GenSSBF 框架的一种具体实现，我们进一步提出了一种基于条件扩散模型和 RSRP 提示的 BBS 方案，该方案可无缝集成到现有 5G系统中，而无需更改标准化协议。我们使用 DeepMIMO数据集对所提出的 BBS 方案进行了广泛评估，涵盖具有视距链路和非视距链路的室内及室外场景。仿真结果表明：1）适度的头脑风暴可以显著提升波束成形性能；2）与基准方法相比，BBS 在有效提升波束成形增益的同时，显著降低了波束扫描开销。

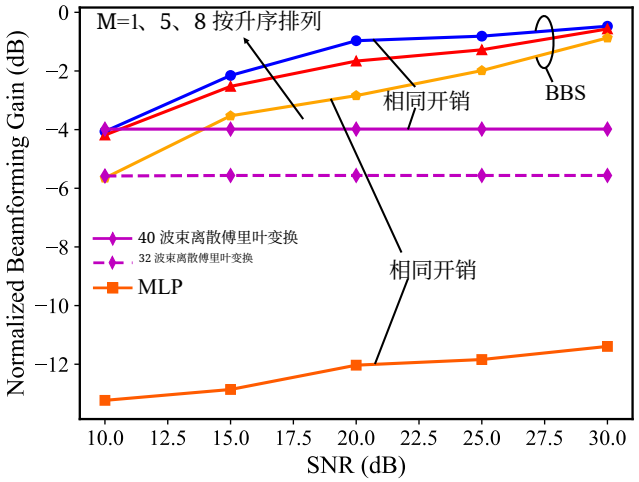


图 15. Boston5G 28 场景中归一化波束成形增益与信噪比的关系。

3）即使在噪声环境中，所提出的 BSS 仍能实现更高的波束成形增益，表明其能够在真实世界的无线传播场景中运行。未来的工作将探索设计鲁棒性更强的其他无线提示类型，并研究 GenSSBF 框架在多用户和多小区场景中的应用。

参考文献

[1] J. Mietzner、R. Schober、L. Lampe、W. H. Gerstacker 和 P. A. Hoeher，“无线通信中的多天线技术——综合文献综述”，*IEEE Commun. Surv. Tut.*，第 11 卷，第 2 期，第 87-105 页，2009 年 6 月。[2] K. -K. Wong、A. Shojaeifard、K. -F. Tong 和 Y. Zhang，“流体天线系统”，*IEEE Trans. Wireless Commun.*，第 20 卷，第 3 期，第 1950-1962 页，2021 年 3 月。[3] M. Xiao，等，“面向未来移动网络的毫米波通信”，*IEEE J. Sel. Areas Commun.*，第 35 卷，第 9 期，第 1909-1935 页，2017 年 6 月。[4] S. Kutty 和 D. Sen，“毫米波通信中的波束成形：综合综述”，*IEEE Commun. Surv. Tut.*，第 18 卷，第 2 期，第 949-973 页，2016 年 12 月。[5] S. Kim、J. Park、J. Moon 和 B. Shim，“通过依赖频率的波束成形实现快速且准确的太赫兹波束管理”，*IEEE Trans. Wireless Commun.*，第 23 卷，第 3 期，第 1699-1712 页，2024 年 7 月。[6] E. Dahlman、S. Parkvall 和 J. Skold，*5G NR*：下一代无线接入技术。美国纽约州纽约：Academic，2018 年 9 月。[7] H. Q. Ngo、A. Ashikhmin、H. Yang、E. G. Larsson 和 T. L. Marzetta，“无蜂窝大规模MIMO与小区网络的比较”，*IEEE Trans. Wireless Commun.*，第 16 卷，第 3 期，第 1834-1850 页，2017 年 3 月。[8] J. Guo、C. -K. Wen 和 S. Jin，“基于深度学习的CSI反馈：用于单小区和多小区大规模MIMO系统的波束成形”，*IEEE J. Sel. Areas Commun.*，第 39 卷，第 7 期，第 1872-1884 页，2021 年 7 月。[9] J. Li、Q. Lv、P. Zhu、D. Wang、J. Wang 和 X. You，“采用波束成形训练进行CSI估计的网络辅助全双工分布式大规模MIMO系统”，*IEEE Trans. Wireless Commun.*，第 20 卷，第 4 期，第 2190-2204 页，2021 年 4 月。[10] J. -C. Shen、J. Zhang、K. -C. Chen 和 K. B. Letaief，“大规模MIMO中的高维CSI获取：稀疏性启发方法”，*IEEE Syst. J.*，第 11 卷，第 1 期，第 32-40 页，2017 年 3 月。[11] Y. Heng，等，“5.5G和6G系统中波束管理的六项关键挑战”，*IEEE Commun. Mag.*，第 59 卷，第 7 期，第 74–79 页，2021 年 7 月。[12] A. Abdallah、A. Celik、A. Alkhateeb 和 A. M. Eltawil，“面向基于RSSI的多用户波束探测与混合预编码的可解释自编码器设计”，*arXiv preprint arXiv:2503.08267*，2025 年。[13] T. He 和 Z. Xiao，“毫米波通信的次优波束搜索算法与码本设计”，*Mobile Netw Appl.*，第 20 卷，第 1 期，第 86-97 页，2015 年 2 月。[14] Z. Xiao、T. He、P. Xia 和 X. Xia，“毫米波通信中用于波束成形训练的分层码本设计”，IEEE Trans. Wireless Commun.，第 15 卷，第 5 期，第 3380–3392 页，2016 年 5 月。[15] C. Qi、K. Chen、O. A. Dobre 和 G. Y. Li，“基于分层码本的毫米波大规模MIMO多用户波束训练”，IEEE Trans. Wireless Commun.，第 19 卷，第 12 期，第 8142–8152 页，2020 年 12 月。[16] M. Alrabeiah、Y. Zhang 和 A. Alkhateeb，“基于神经网络的波束码本：学习适应部署环境和硬件的毫米波大规模MIMO波束”，IEEE Trans. Commun.，第 70 卷，第 6 期，第 3818-3833 页，2022 年 6 月。[17] Y. Liu、Z. Wang、J. Xu、C. Ouyang、X. Mu 和 R. Schober，“近场通信：教程式综述”，IEEE Open J. Commun. Soc.，第 4 卷，第 1999-2049 页，2023 年 8 月。[18] Y. Heng、Y. Zhang、A. Alkhateeb 和 J. G. Andrews，“通过深度学习实现6G中的特定场景波束对齐”，IEEE Commun. Mag.，第 62 卷，第 8 期，第 162-168 页，2024 年 8 月。[19] Y. Heng、J. Mo 和 J. G. Andrews，“学习用于快速毫米波波束对齐的特定场景探测波束”，IEEE Trans. Wireless Commun.，第 21 卷，第 8 期，第 5785-5800 页，2022 年 1 月。[20] J. Yang 、 W. Zhu 、 M. Tao 和 S. Sun，“ 毫米波通信系统的分层波束对准：一种深度学习方法”，IEEE Trans. Wireless Commun.，第 23 卷，第 4 期，第 3541-3556 页，2024 年 9 月。[21] J. W. Kwak、H. Yoo、I. P. Roberts 和 C. B. Chae，“无需显式信道知识的特定场景波束对齐：一种深度学习方法”，载于 Proc. Asilomar Conf. Signals, Syst., Comput.，2024 年 10 月，第 1139-1143 页。[22] J. Chen、F. Gao、X. Tao、G. Liu、C. Pan 和 A. Alkhateeb，“ 计算机视觉辅助的 MIMO 通信系统码本设计 ”，IEEE Trans. Wireless Commun.，第 22 卷，第 5 期，第 3341-3354 页，2023 年 11 月。[23] H. Luo 和 A. Alkhateeb，“ 数字孪生辅助的毫米波 MIMO：特定场景波束码本学习”，arXiv preprint arXiv:2512 01902，2025 年。。[24] Y. Heng 和 J. G. Andrews，“通过特定场景深度学习实现无网格MIMO波束对齐”，IEEE Trans. Wireless Commun.，第 23 卷，第 2 期，第 908-921 页，2024 年 2 月。[25] S. Li 和 I. P. Roberts，“全双工大规模MIMO无线系统的特定场景波束学习”，arXiv preprint arXiv:2510 00342，2025 年。。[26] A. Torralba、P. Isola 和 W. T. Freeman，“计算机视觉基础”，第 1 版。麻省理工学院出版社，2024 年 4 月。[27] C. Masouros 和 G. Zheng，“将已知干扰作为绿色信号功率用于下行波束成形优化”，IEEE Trans. Signal Process.，第 63 卷，第 14 期，第 3628-3640 页，2015 年 5 月。[28] H. Du，等，“增强深度强化学习：网络优化中生成式扩散模型教程”，IEEE Commun. Surv. Tut.，第 26 卷，第 4 期，第 2611-2646 页，2024 年 5 月。[29] X. Xu、R. Zhong、X. Mu、Y. Liu 和 K. Huang，“移动边缘生成赋能的数字孪生：架构设计与研究机遇”，IEEE Commun. Mag.，第 63 卷，第 4 期，第 32-39 页，2025 年 4 月。[30] J. Ho、A. Jain 和 P. Abbeel，“去噪扩散概率模型”，载于 Proc. Adv. Neural Inf. Process. Syst. (NeurIPS)，第 33 卷，第 6840-6851 页，2020 年 12 月。[31] J. Song、C. Meng 和 S. Ermon，“去噪扩散隐式模型”，arXiv preprint arXiv:2010.02502，2020 年。[32] T. Lee、J. Park、H. Kim 和 J. G. Andrews，“使用扩散模型生成高维用户特定无线信道”，IEEE Trans. Wireless Commun.，提前访问，2025 年 8 月，doi: 10.1109/TWC.2025.3600286。[33] X. Xu、X. Mu、Y. Liu、H. Xing、Y. Liu 和 A. Nallanathan，“面向移动通信的生成式人工智能：扩散模型视角”，IEEE Commun. Mag.，第 63 卷，第 7 期，第 98-105 页，2025 年 7 月。[34] M. Kim、R. Fritschek 和 D. F. Schaefer，“用于准确信道分布生成的扩散模型”，arXiv preprint arXiv:2309.10505，2023 年。[35] X. Wang、H. Du、L. Feng 和 K. Huang，“通过生成式人工智能增强的深度强化学习实现RSMA赋能的低空移动边缘计算优化”，arXiv preprint arXiv:2507.12910，2025 年。[36] J. Zhang、Z. Liu、X. Feng、H. Yang 和 S. Liang，“采用生成式扩散模型赋能的优化方法增强IRS辅助物联网通信中的安全波束成形”，IEEE Internet Things J.，第 12 卷，第 10 期，第 13398-13414 页，2025 年 5 月。[37] H. Zhou，等，“面向无线网络的大语言模型：从提示工程视角进行的综述”，IEEE Wireless Commun.，第 32 卷，第 4 期，第 98-106 页，2025 年 8 月。[38] D. Hendrycks，“高斯误差线性单元（GELU）”，arXiv preprint arXiv:1606.08415，2016 年。[39] A. Alkhateeb，“DeepMIMO：面向毫米波和大规模MIMO应用的通用深度学习数据集”，arXiv preprint arXiv:1902.06435，2019 年。