NetSpatial：面向蜂窝网络规划与运营的空间条件交通生成

Shiyuan Zhang香港大学，中国香港
shiyuanzhang@connect.hku.hk

Jiale Du香港大学，中国香港
u3650171@connect.hku.hk

Yuanwei Liu香港大学，中国香港
yuanwei@hku.hk

Kaibin Huang香港大学，中国香港
huangkb@hku.hk

Hongyang Du*香港大学，中国香港
duhy@hku.hk

arXiv:2603.13839v1 [cs.CE] 14 Mar 2026

摘要

基站（BS）的部署与运行是网络性能的基础，但这需要准确理解需求，而这对运营商而言仍然十分困难。高密度城市区域的蜂窝网络流量测量数据丰富，但变化剧烈，这削弱了基于预测的管理效果；而新兴地区交通测量数据稀缺，限制了明智部署决策的制定。因此，现有方法要么依赖人工规划启发式方法，要么采用无法捕捉随机流量变化的自回归预测器。我们提出 NetSpatial，通过空间条件交通生成，为蜂窝网络规划与运行提供统一系统。NetSpatial 利用多模态城市环境信息，包括卫星影像和兴趣点（POI）分布，学习物理环境与功能语义如何影响基站需求。它采用多层流匹配架构，将周期性结构与残差动态分离，从而能够直接生成长时域流量序列。NetSpatial 支持两种互补的决策场景：一是用于部署规划的假设分析，根据生成的流量曲线对候选站点进行排序；二是用于网络运营的行动建议，利用生成的流量预测指导基站休眠调度和负载均衡。基于真实世界蜂窝网络流量数据的实验表明，与最强基线相比，NetSpatial 将詹森–香农散度（JSD）降低了 29.44%，在零样本实验中能够跨城市泛化，并在保持体验质量超过 80% 的同时实现最高 16.8% 的节能。

CCS 概念

• 网络 → 网络仿真；• 计算方法 → 建模与仿真；• 信息系统 → 时空系统。

*通讯作者。

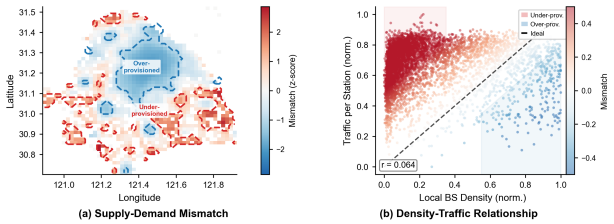


图1：上海的基站密度与流量。左：基站的空间分布显示，城市中心部署密集，而郊区和新开发区域缺乏覆盖。右：流量利用率分析表明，在部署密集的区域存在显著的容量浪费，许多基站的运行远低于其容量。

关键词

蜂窝网络流量、生成式人工智能、地球观测

1 引言

第五代（5G）蜂窝网络有望支持自动驾驶、工业自动化和智慧城市服务等新兴应用 [22, 27]。这些应用对高度城市化环境中的网络容量和覆盖可靠性提出了严格要求，而这些环境具有动态的流量需求和复杂的传播条件 [3, 10, 48]。要大规模满足这些要求，需要从城市级层面理解网络行为和城市动态，因为基站（BS）的部署和运行与空间结构、流量模式和环境因素相互作用 [56]。

尽管 5G 网络迅速部署，但由于空间部署与动态流量需求之间存在复杂的相互作用，城市规模蜂窝系统的管理仍然充满挑战。为以真实数据为讨论提供依据，我们分析了上海的 5,326 个基站—— [56],

上海是规模最大、人口最稠密的大都市区之一，如图1所示。图中揭示了两种相互关联的现象。首先，空间部署极不均衡。基站集中在成熟的城市中心，而郊区和新开发区域则面临覆盖缺口。实际上，新兴区域流量可见性有限，迫使运营商依赖启发式方法，优先覆盖成熟的商业区，使快速发展的区域得不到充分服务。其次，即便在基站密集部署的区域，仍存在大量容量浪费。相当一部分基站长期远低于设计容量运行，而其他基站则会周期性过载。这种空间和时间上的失衡源于缺乏实时流量预测；若能进行预测，便可实现动态负载均衡和节能休眠调度，避免运行方式僵化、能源浪费及资源利用低效等问题。

传统的蜂窝网络规划依赖专家驱动的站点选择和无线电传播仿真 [5,7, 12, 17, 53]。这些方法在局部覆盖优化方面效果显著，但难以扩展至全市范围的部署，而且往往无法捕捉细粒度的需求异质性。为提高规划效率，人们引入了数据驱动的需求建模，利用历史流量模式、人口统计数据、兴趣点（POI）和移动轨迹来估计或预测流量需求 [4, 52]。然而，现有方法严重依赖大量历史流量测量数据，因此不适用于缺乏先前数据的新开发区域 [44]。此外，即使对于现有网络，自回归预测模型的误差也会在长预测时域内不断累积，且难以捕捉随机非周期性波动，从而限制了其在长期规划和实时运行中的效用 [35, 43]。

一个切实可行的契机在于城市环境天然蕴含着丰富的空间上下文。卫星影像和兴趣点数据共同编码了城市语义，涵盖从物理基础设施到功能活动模式的各种信息，而这些信息与通信需求高度相关 [11, 21, 36, 42, 57]。受这一观察启发，我们旨在学习从多模态城市环境到流量需求的直接映射。这种映射能够在缺乏历史流量测量数据的区域实现需求感知部署，同时也支持对现有网络进行准确的流量预测。该统一建模系统在一致的需求建模范式下支持长期规划和实时运行，并为需求感知站点选择、动态休眠调度和负载均衡等决策提供支持。要实现这种城市级需求智能，还需应对若干技术挑战。

• **异构环境表征**。城市需求由多种信号共同塑造，这些信号在模态、分辨率和噪声方面各不相同。要有效利用此类数据，必须在地理空间中对齐异构信号，并对它们之间能够预测流量需求的跨模态交互进行建模。学习到的表征必须能够适应常见的模态缺失、稀疏或不完善情况，同时捕捉稳定且可迁移的模式，从而适用于不同的城市环境。

• **不确定性下的长期需求合成**。基站部署本质上是一项长期决策，取决于需求如何真实演变。这要求合成需求轨迹，既保留周期性结构和随机非周期变化，又避免自回归模型常见的误差累积问题 [46, 47]。合成的需求应能捕捉关键时空统计特征，并支持可靠的长期假设分析。

• **实时运营优化**。除了长期规划之外，运营商还需要面向现有网络的实时策略。推理引擎必须在毫秒级延迟内生成准确的流量预测，同时与规划所用的长期模型保持一致，从而确保运营决策与部署假设相符。

我们提出了 NetSpatial，这是一个统一系统，通过多模态空间上下文条件流量生成，同时解决网络规划与运行问题。NetSpatial 学习一个多模态编码器，以对齐异构空间信号，并捕捉城市语义与通信需求之间的复杂关联。借助多层流匹配架构，NetSpatial 直接生成完整的 672 小时流量序列，并分别建模周期性趋势和随机残差，从而减轻误差累积，同时保留真实变化性。同一生成式框架支持两种决策场景：假设分析根据部署感知效用对候选站点进行排序，以支持部署规划；而“做什么”决策则利用实时流量预测指导基站休眠调度与负载均衡，从而实现运营优化。我们的工作贡献总结如下。

• 我们设计了一种多模态空间上下文对齐模块，将物理环境和功能语义整合到统一的空间表示中。具体而言，卫星影像捕捉物理城市结构，而兴趣点分布则编码功能活动模式。通过将这些异构信号对齐到共享表示中，该模块建立了城市语义与蜂窝网络需求之间可迁移的关联。

• 我们提出了一种用于长期流量合成的多层流匹配生成架构，可有效减少误差累积。

• 我们展示了，同一个生成骨干网络既能支持面向部署效用的站点排名，也能支持部署

规划，以及用于睡眠调度和负载均衡的实时流量预测，且两种模式之间无需修改架构。

•我们在真实世界数据集上评估了 NetSpatial。与最强基线相比，所提出的系统将 JSD 降低了 29.44% 以上；在零样本实验中，该系统能够泛化到不同城市，并在下游运营仿真中实现最高 16.8% 的能耗降低，同时保持 80% 以上的体验质量（QoE）。该系统已部署为用于基站规划的在线平台。

2 预备知识

2.1 交通信号分解

蜂窝网络流量受人类活动驱动，呈现出显著的时间规律性；移动网络测量数据中广泛观察到清晰的日模式和周模式 [12]。令 $x(t)$ 表示基站在时间 t的流量。我们将信号分解为结构化的周期分量和残差分量：

$$x(t) = p(t) + r(t), \tag{1}$$

其中， $p(t)$刻画规则的时间模式， $r(t)$刻画非周期性波动。周期分量包含多个时间尺度上的规律性。如图3(b)和(c)所示，我们首先考虑一天内各小时的日模式。令 $\tau \in [0, 24)$表示一天中的小时。为体现工作日与周末之间的行为差异，我们引入两种日模式，即工作日模式 $d_w(\tau)$和周末模式 $d_e(\tau)$，这些模式通常呈现日间峰值和夜间低谷。

随后，我们将五个工作日模式与两个周末模式依次组合，构建一个覆盖168小时的完整每周模板，

$$w(t) = \begin{cases} d_w(t \bmod 24), & \text{if } \left\lfloor \frac{t}{24} \right\rfloor \bmod 7 < 5, \\ d_e(t \bmod 24), & \text{otherwise.} \end{cases} \tag{2}$$

通过重复每周模板，我们直接得到周期分量，

$$p(t) = w(t \bmod 168). \tag{3}$$

残差分量正是移除周期性成分后剩余的部分，

$$r(t) = x(t) - p(t), \tag{4}$$

它捕捉由随机事件、异常和短期变化引起的非周期性波动，这些变化无法通过常规时间结构加以解释。如图 2 所示，这种分解有效地区分了确定性的周期行为与残差动态，因此后续流量生成采用多层建模方法，分别处理周期性结构和残差不确定性。

2.2 蜂窝网络流量的空间与时间特征

蜂窝流量模式会受到周边城市环境 [12, 56]的显著影响。位于不同功能区域（如办公区、商业区、住宅区和娱乐区）的基站呈现出各自独特的时间使用模式，而处于相似环境中的基站则往往表现出相近的流量模式。

城市中的物理环境塑造了流量需求随时间的变化方式。为说明这种关系，我们考察了位于上海不同功能区域的代表性基站。如图3所示，这些区域在峰值时段和工作日与周末差异方面呈现出明显差异。这些观察结果表明，城市语义是流量需求空间异质性的关键驱动因素。

除了物理环境之外，区域的功能语义也会影响流量波动性。中心城区的人类活动往往遵循更规律的模式，因此流量需求相对稳定。外围城区的需求变化则更加剧烈，波动也更大。这些差异源于各区域发生的活动类型，并反映在附近兴趣点的分布中。

形式化地，令 $\mathbf{c}_i = [\mathbf{e}_i; \mathbf{z}_i]$ 表示位置 i处的空间上下文，其中 $\mathbf{e}_i$ 表示从卫星影像中提取的物理环境特征，而$\mathbf{z}_i$ 表示根据周围兴趣点分布得出的功能语义。我们将位置 i 处的站点流量表示为

$$\mathbf{x}_i^{1:T} = \mathbf{p}_i^{1:T} + \mathbf{r}_i^{1:T} = f_1(\mathbf{c}_i) + f_2(\mathbf{c}_i) \tag{5}$$

其中， $\mathbf{x}_i^{1:T} = \{x_i(t)\}_{t=1}^{T}$ 表示基站 i 在 T 个时间步内的完整时间序列， $\mathbf{p}_i^{1:T}$和 $\mathbf{r}_i^{1:T}$分别表示可预测分量和残差分量，而$f_1(\mathbf{c}_i)$ 和 $f_2(\mathbf{c}_i)$ 是以空间上下文 $\mathbf{c}_i$为条件的函数。

2.3 从实测基站到可行候选站点

我们的训练数据仅提供已部署基站的流量轨迹，但部署规划需要评估大量候选位置。我们通过将流量建模为以位置为条件的站点流量潜在函数，弥合这一差距。在训练期间，每个已部署的基站都提供一个带标签的样本，其中以周边空间上下文$\mathbf{c}$ 为输入，以测得的流量时间序列为对应标签。模型学习一个条件生成器 $G_\theta \colon \mathbf{c}_i \mapsto P(\mathbf{x}_i \mid \mathbf{c}_i)$，将空间上下文映射为流量序列的概率分布。在推理期间，令 $\mathsf{C} = \{1, \ldots, M\}$ 表示满足基本工程约束的 M可行网格单元集合。对于每个单元 $j \in \mathsf{C}$，我们提取其空间上下文$\mathbf{s}j$，并生成月度流量序列 $\hat{}\mathbf{x}_j = [\hat{}x_j(1)\ldots, \hat{}x_j(T)],$，将其解释为流量

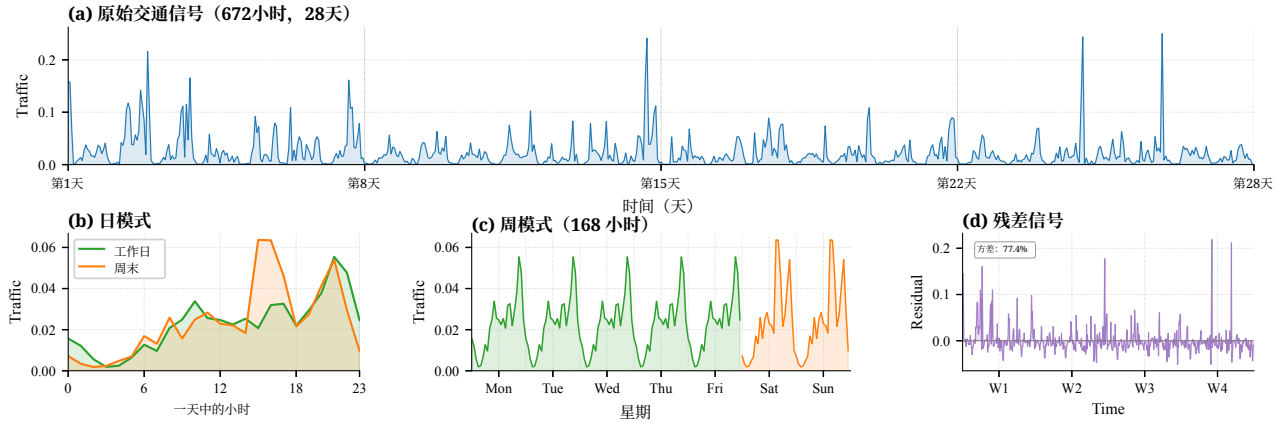


图2：将基站流量分解为周期性分量和非周期性分量。(a) 小时粒度下原始的 28 天流量信号。(b) 工作日和周末的日模式。(c) 覆盖 168 小时的每周模板。(d) 残差信号捕捉非周期性波动。

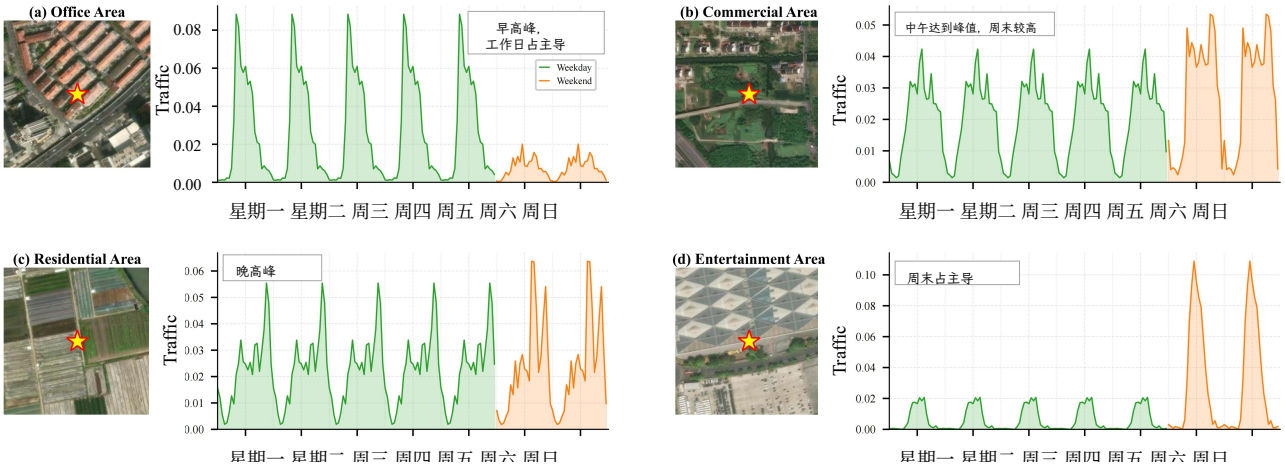


图3：空间因素对基站流量模式的影响。不同功能区域的基站呈现出不同的每周流量曲线。办公区域在工作日白天出现峰值，商业区在中午出现峰值且周末活动更活跃，住宅区域在傍晚出现峰值，而娱乐区的流量则以周末为主。

如果在单元 j部署，基站将承载的流量。由于生成器会为每个候选位置生成完整的流量序列，下游的站点排序目标可以灵活定义，以适应不同的规划目标。例如，运营商可能优先考虑需求量大、峰值负载高或潜在收入高的位置。作为一个示例，我们引入一个简单的负载稳定性指数(LSI)，优先选择随时间变化较为稳定的流量模式。在实际部署场景中，这种稳定性十分理想，因为运营商更倾向于选择流量持续较高的位置，而非需求高度波动、可能导致频繁过度配置或拥塞的位置。形式上，我们

将 LSI 定义为

$$\mathrm{LSI}_j = \frac{1}{\sigma(\hat{\mathbf{x}}_j) + \epsilon}, \tag{6}$$

其中，$\sigma(\hat{\mathbf{x}}_j)$ 是生成序列的时间标准差，且 $\epsilon = 10^{-6}$。给定 K 个新站点的预算，我们选择

$$\mathcal{S}^* = \underset{\mathcal{S}\subseteq C,\,|\mathcal{S}|=K}{\arg\max} \sum_{j\in\mathcal{S}} \mathrm{LSI}_j, \tag{7}$$

由于目标函数具有模性，这等价于按 LSI 排序并保留前 K个条目。

重要的是，流量生成器与排序目标相互解耦。由于模型会为每个候选位置生成完整的交通

序列，因此无需重新训练即可直接应用其他部署效用。

3 系统概述

本节介绍 NetSpatial，这是一个基于空间条件交通生成的统一蜂窝网络规划与运营系统。NetSpatial 的核心是一个多级条件生成模型，它融合卫星影像和兴趣点分布，将空间上下文映射为长期站点流量序列，从而支持基站部署规划的假设分析，以及实时网络运营中的行动决策。

3.1 问题设定与输出

对于具有流量测量数据的基站，每个站点构成一个带标签的训练样本。标签是一个长度为 672 的 28 天窗口小时流量序列。输入是站点周围的空间多模态上下文，由卫星影像和兴趣点分布得出。模型学习根据该空间上下文生成一个包含 672 小时的站点流量序列。

对候选位置进行推理。对于缺少流量数据的候选位置，即潜在部署站点，NetSpatial 会在应用可部署性约束后，根据网格单元筛选出一组可行候选位置，并对其进行评估。对于每个可行候选位置，NetSpatial 使用与训练时相同的流程提取空间多模态上下文，并生成长度为 672 小时的每小时流量序列。我们将该序列视为基站部署在该候选位置时所承载的流量负载。

对现有基站进行实时推理。对于已投入运行的基站，生成模型利用卫星影像和兴趣点数据捕捉空间上下文，并利用根据公式 (2) 和 (3) 得出的周期模式捕捉时间动态，从而进行实时流量预测。这些预测可支持动态运营决策，包括在低流量时段安排基站休眠以节省能源，以及在相邻基站之间进行负载均衡，从而优化网络资源利用率。

决策输出。NetSpatial 提供两类不同的决策输出，

- 对于网络规划，NetSpatial 根据每个候选站点生成的月度流量序列计算其 LSI，按该指标对所有站点进行排名，最终选出排名前 K 的最优位置。
- 对于网络运营，它能够提供准确的实时流量预测，为动态基站开关切换和高效的站间负载重新分配决策提供依据。

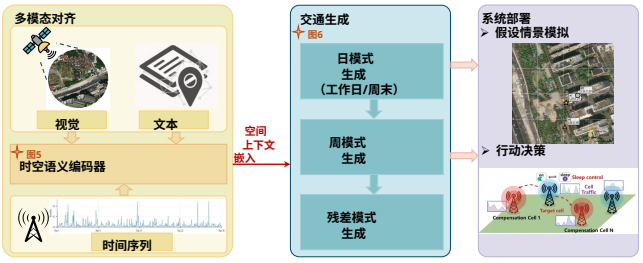


图4：NetSpatial 的系统概述。

3.2 设计概述

图 4 概述了 NetSpatial 的端到端工作流程，该流程由三个模块组成：多模态数据对齐、多层条件生成，以及用于规划和运行的决策支持。第一个模块接入异构空间数据源，包括卫星图像和兴趣点分布，并使用多模态编码器将这些数据对齐为统一的空间表示。第二个模块以对齐后的多模态上下文为输入，通过多层流匹配架构生成一个包含 672 小时的交通序列 $\hat{x}_j(t)$，用于$t \in \{1, \ldots, 672\}$，并分别对周期性趋势和随机残差进行建模。第三个模块支持两种决策场景。在网络规划的假设分析中，根据候选站点生成的流量曲线计算负载稳定性指数（公式（6）），并对候选站点进行排序，选取需求随时间最稳定的前 K 个位置进行部署。在网络运行的具体行动决策中，同一生成器可提供实时流量预测，为基站休眠调度和负载均衡提供依据。

4 方法论

4.1 多模态表征学习

如图 5 所示，我们提出了一种多模态框架，可为每个位置生成统一空间嵌入 $\mathbf{C} \in \mathbb{R}^d$ ℓ。输入由一个地理配准卫星图像块 $\mathbf{x}^I \in \mathbb{R}^{H\times W\times 3}$和一组附近的兴趣点 $\mathrm{P}(\ell) = \{p_i\}_{i=1}^{K}$ 组成，这些兴趣点位于固定半径范围内（K可能为零）。该框架从图像中提取密集的视觉线索，并从兴趣点中提取稀疏的符号语义，同时处理可变的兴趣点密度，包括兴趣点完全缺失的情况。

4.1.1 多模态感知 我们采用冻结的预训练编码器，以实现稳定且可迁移的特征提取。

视觉模态。 基于视觉Transformer的编码器 f_I 处理卫星图像块，并生成视觉嵌入 $\mathbf{v} \in \mathbb{R}^d$（随后进行 ℓ_2 归一化；下文所示的所有嵌入在使用前也都经过归一化）。

文本模态。 对于每个兴趣点 p_i，我们构建一个地址提示 T_i^A和一个周边上下文提示 T_i^S。A

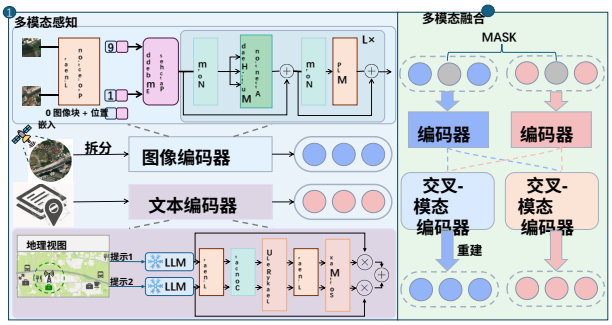


图 5：所提出的多模态感知与融合框架概览。该框架包含两个阶段。（1）多模态感知：专用的冻结编码器处理卫星影像和兴趣点数据，以提取模态特定特征。（2）多模态融合：基于掩码的生成机制将这些特征整合为统一表示，使其能够稳健应对缺失模态。

冻结的大语言模型 llama-3.1-8b [39] H提取嵌入 $\mathbf{e}_i^A, \mathbf{e}_i^S \in \mathbb{R}^D$，并由轻量级评分网络进行融合，

$$[\alpha_i^A, \alpha_i^S] = \mathrm{softmax}\big(s_\theta(\mathbf{e}_i^A \| \mathbf{e}_i^S)\big), \quad \mathbf{e}_i = \alpha_i^A\,\mathbf{e}_i^A + \alpha_i^S\,\mathbf{e}_i^S, \tag{8}$$

其中，$\|$ 表示拼接。每个融合嵌入都经过线性投影，映射到共享的 d维空间，以获得$\mathbf{p}_i$。

为处理可变的 K，我们直接通过注意力池化聚合$\{\mathbf{p}_i\}_{i=1}^K$，

$$\beta_i = \mathrm{softmax}_i\big(a_\varphi(\mathbf{p}_i)\big), \quad \mathbf{p} = \textstyle\sum_{i=1}^K \beta_i\,\mathbf{p}_i \in \mathbb{R}^d. \tag{9}$$

当 $K = 0$时，兴趣点模态被视为缺失。

4.1.2 多模态融合我们采用生成式掩码建模策略融合$\mathbf{v}$ 和 $\mathbf{p}$，以促进跨模态交互，并增强模型对缺失模态的鲁棒性。引入两个可学习的掩码标记$\mathbf{v}_{\text{mask}}$，$\mathbf{p}_{\text{mask}} \in \mathbb{R}^d$ 以及一个融合标记$\mathbf{t}_F \in \mathbb{R}^d$。

训练期间，我们采样一个二值掩码（m^I，m^P），其中 $m^I + m^P = 1$，并始终用相应的掩码标记替换被掩码的模态，

$$\tilde{\mathbf{v}} = (1-m^I)\,\mathbf{v} + m^I\,\mathbf{v}_{\text{mask}}, \quad \tilde{\mathbf{p}} = (1-m^P)\,\mathbf{p} + m^P\,\mathbf{p}_{\text{mask}}. \tag{10}$$

这一约束确保每个训练步骤中仅有一个模态可见，另一个模态被掩码，从而迫使模型根据可见模态重建被掩码的模态。

轻量级 Transformer T_θ处理由三个标记组成的序列 $[\mathbf{t}_F;\ \tilde{\mathbf{v}};\ \tilde{\mathbf{p}}]$，并返回隐藏状态 $[\mathbf{h}_F, \mathbf{h}_v, \mathbf{h}_p]$。统一空间嵌入从融合标记中读取，

$$\mathbf{z} = \mathrm{norm}(\mathbf{W}_z\,\mathbf{h}_F) \in \mathbb{R}^d. \tag{11}$$

通过线性头部从对应的隐藏状态重建被掩码的模态，以实现跨模态对齐。训练目标最大化重建结果与原始内容之间的余弦相似度，

$$\mathcal{L}_{\text{gen}} = \mathbb{E}_{m^I,m^P}\Big[m^I\,(1-\hat{\mathbf{v}}^\top\mathbf{v}) + m^P\,(1-\hat{\mathbf{p}}^\top\mathbf{p})\Big]. \tag{12}$$

在推理阶段，当缺少兴趣点（$K = 0$）时，我们设置 $m^P = 1$，使模型能够平稳地退化为纯视觉语义。仅训练融合模块的参数，编码器 f_l 和 H 保持冻结。

4.2 月度交通流生成的多层条件模型

多模态感知与融合模块生成共享空间表示 $C \in \mathbb{R}^d$。我们将 C 用作跨层级空间先验，并通过轻量级多尺度投影获得层级特定条件c_1，c_2，c_3。基于 C 构建的高峰时段分类器会生成一个覆盖24小时的分布，并确定高峰索引 $h^\star$。该模块对应于图6中的**位置编码器**，用于定位月度时间范围内主要交通高峰和低谷出现的时间。随后，将 $h^\star$ 作为显式条件注入残差层级，使生成的长期模式锚定在正确的高峰位置。生成器将长度为 $T = 672$ 、每天包含 $S = 24$ 小时的月度序列分解为日模板 d、周模式 w、周期分量 u和残差 r

$$\begin{aligned} d &= G_1(z_1, c_1), \quad w = G_2(z_2, d, c_2), \quad u = \mathrm{Rep}(w), \\ r &= G_3(z_3, u, d, w, c_3, h^\star), \quad \hat{x} = \mathrm{clippos}(u + r). \end{aligned} \tag{13}$$

此处，z_1，z_2，$z_3 \sim \mathrm{N}(0, I)$ 是各层级特定的噪声输入，G_1，G_2，G_3分别是日模板、周模式和残差的条件生成器，Rep 将 w 重复至长度T，$\mathrm{clippos}(x) = \max(x, 0)$ 用于确保交通流量非负。每个层级均通过流匹配进行训练，以回归目标速度场

$$\mathcal{L}_{fm}^{\ell} = \mathbb{E}\,\big\|v_\theta^{\ell}(x_t, t, c_\ell, \cdot) - v^\star\big\|_2^2. \tag{14}$$

我们采样 $x_0 \sim \mathrm{N}(0, I)$ 和 $t \sim \mathrm{U}(0,1)$，设置 $x_t = tx_1 + (1-t)x_0$ 和 $v^\star = x_1 - x_0$，其中 v_θ^{ℓ} 表示层级 ℓ 速度场。辅助损失用于约束非负性、时间平滑性、日周期和周周期一致性、均值偏差校正、高峰时段分类以及相关性对齐。目标函数为加权和

$$\mathcal{L} = \sum_{\ell=1}^{3} \lambda_\ell\,\mathcal{L}_{fm}^{\ell} + \sum_{p\in\mathcal{P}} \lambda_p\,\mathcal{L}_p \tag{15}$$

其中，$\mathrm{P} = \{\mathrm{bnd}, \mathrm{tmp}, \mathrm{per}, \mathrm{bias}, \mathrm{peak}, \mathrm{corr}\}$，$\mathrm{L}_p$ 表示相应的辅助损失 [18], ，且所有 λ_* 均为严格的非负权重。

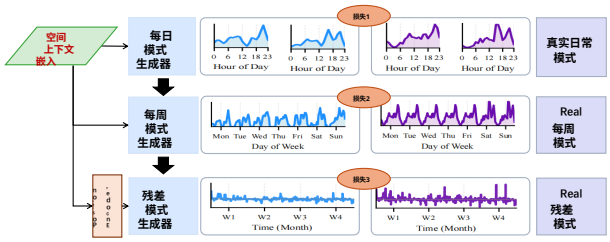


图6：用于月度交通流生成的多层条件模型架构。在上下文嵌入的引导下，该框架通过层次细化逐步生成完整的月度周期交通流。

4.3 生成器算法与推理效率

算法1和算法2详细说明了训练和推理过程。二者均基于共享的空间嵌入 $C \in \mathbb{R}^d$，并通过学习得到的投影导出特定层级的条件 c_1， c_2， c_3 。线性峰值分类器生成$q = \mathrm{softmax}(W_C C)$，并提取峰值小时索引 $h^\star = \mathrm{argmax}_h\, q_h$，以此将残差层级锚定到正确的日内峰值。

层次化目标分解。 给定一段跨越 W=4 周的真实流量序列 $x \in \mathbb{R}^T$（T=D×S、 D=28 天、S=24 小时），我们将其分解为三个时间分辨率依次递增的目标。

(1) 日目标 $d_{\mathrm{tar}} = [d_{\mathrm{wk}}\ d_{\mathrm{we}}] \in \mathbb{R}^{2S}$，分别表示工作日和周末的平均小时曲线。(2) 周目标 $w_{\mathrm{tar}} \in \mathbb{R}^{7S}$，表示一周中每天的平均小时曲线，基于 W 周的数据计算得出。(3) 残差目标 $r_{\mathrm{tar}} = x - u_{\mathrm{tar}} \in \mathbb{R}^T$，表示相对于周期分量 $u_{\mathrm{tar}} = \mathrm{Rep}(w_{\mathrm{tar}})$ 的偏差，其中 Rep(·) 会将周模式平铺至长度 T。

每个层级都学习生成一个目标，并以所有更粗粒度层级的输出作为条件，从而避免误差在不同尺度间累积。

生成与后处理。 三个级别均采用相同的欧拉积分方案，包含 N_ℓ 步，步长为$\Delta t_\ell = 1/N_\ell$。每一步之后，我们应用 clipsym(· b_ℓ)，将数值裁剪至 $[-b_\ell, b_\ell]$，以使中间状态保持在物理上合理的范围内。第3级从缩放噪声 $x \sim 0.1\,\mathrm{N}(0, I)$ 初始化，而非标准高斯分布，这反映了残差波动相较于周期分量幅度更小。最终输出按公式（13）组装。

算法 1 层次化流匹配训练

输入： 真实数据序列 $x \in \mathbb{R}^T$，空间嵌入 C
确保： 总损失 L
// 共享预处理
$q = \mathrm{softmax}(W_C C)$; $h^\star = \arg\max_h q_h$; $c_1, c_2, c_3 \leftarrow$ 投影(C)
计算目标 d_{tar}， w_{tar}， u_{tar}， r_{tar}，来自 x
采样 $t \sim \mathrm{U}(0,\ 1)$
// 第 1 层：日模式
$z_1 \sim \mathrm{N}(0, I)$; $x_t = t\, d_{\mathrm{tar}} + (1-t)\ z_1$; $v^\star = d_{\mathrm{tar}} - z_1$
$\mathrm{L}^1_{fm} \leftarrow \|G_1(x_t,\ t,\ c_1) - v^\star\|^2$ ▷ 公式 (14)
// 第2级：周模式
$z_2 \sim \mathrm{N}(0,\ I)$; $x_t = t\, w_{\mathrm{tar}} + (1-t)\ z_2$; $v^\star = w_{\mathrm{tar}} - z_2$
$\mathcal{L}^2_{fm} \leftarrow \|G_2(x_t,\ t,\ c_2,\ d_{\mathrm{tar}}) - v^\star\|^2$
// 第3级：残差
$z_3 \sim \mathrm{N}(0, I)$; $x_t = t\, r_{\mathrm{tar}} + (1-t)\ z_3$; $v^\star = r_{\mathrm{tar}} - z_3$
$\mathcal{L}^3_{fm} \leftarrow \|G_3(x_t, t, c_3, d_{\mathrm{tar}}, w_{\mathrm{tar}}, u_{\mathrm{tar}}, h^\star) - v^\star\|^2$
// 辅助损失
通过算法2生成 $\hat{x}$
计算 $\{\mathrm{L}_p\}_{p\in\mathcal{P}}$(边界、时间、周期性、偏差、峰值、相关系数)
返回 $\mathrm{L} = \sum_{\ell=1}^{3} \lambda_\ell \mathrm{L}^{\ell}_{fm} + \sum_{p\in\mathrm{P}} \lambda_p \mathrm{L}_p$ ▷ 公式（15）

5 实验

5.1 实验设置

我们在真实世界的蜂窝网络数据集上评估 NetSpatial，并将其与先进基线方法进行比较，展示其在假设情景和行动决策场景中的表现，同时开展消融研究。

5.1.1 数据集。 我们收集了一个大规模蜂窝网络流量数据集，来自上海，涵盖 5,326 个基站，采集时间为 2021 年的一个月，并包含每个基站的小时流量信息。

5.1.2 基线方法。 我们将提出的模型与以下六种基线方法进行比较。值得注意的是，我们使用两种不同类型的输入评估每个模型：1）仅噪声向量；2）噪声向量和多模态融合表示 C。

时间序列生成对抗网络 [51]。时间序列生成对抗网络在生成器和判别器中均结合了长短期记忆网络，以生成时间序列数据。

Trans-GAN [15]。TransGAN 是一种基于 Transformer 的生成对抗网络（GAN），它结合多尺度判别器来捕捉低级纹理和语义上下文，并使用采用 Transformer 模块的生成器。在本研究中，我们调整了 Transformer 模块的大小，以生成网络流量数据。

TCN-GAN [24]。TCN-GAN 是一种生成对抗网络，由生成器和判别器组成，二者均使用时间

算法2 分层流匹配推理

要求： 空间嵌入 C，步数 N_1，N_2，N_3
确保： 生成序列 $\hat{x} \in \mathbb{R}^{T}$

$q = \mathrm{SoftMax}(W_C C)$; $h^\star = \arg\max_h q_h$; $c_1, c_2, c_3 \leftarrow$ 投影(C)
// 第 1 层：日模式 $(\mathbb{R}^{2S})$
$x \sim \mathrm{N}(0, I)$
对 $k = 1, \ldots, N_1$ **执行**
  $x \leftarrow$对称裁剪$\left(x + \frac{1}{N_1} G_1(x, \frac{k}{N_1}, c_1) \quad b_1\right)$
结束循环
$d \leftarrow x$
// 级别 2：周模式 $(\mathbb{R}^{7S})$
$x \sim \mathrm{N}(0, I)$
对于 $k = 1, \ldots, N_2$ **执行**
  $x \leftarrow$对称裁剪$\left(x + \frac{1}{N_2} G_2(x, \frac{k}{N_2} c_2, d) \quad b_2\right)$
结束循环
$w \leftarrow x$; $u \leftarrow \mathrm{Rep}(w)$
// 第3级：残差 $(\mathbb{R}^{T})$
$x \sim 0.1\,\mathrm{N}(0, I)$ ▷ 缩放噪声
对于 $k = 1, \ldots, N_3$ **执行**
  $x \leftarrow$对称裁剪$\left(x + \frac{1}{N_3} G_3(x, \frac{k}{N_3} c_3, d, w, u, h^\star) \quad b_3\right)$
结束循环
$r \leftarrow x$
返回r ▷ 公式 (13)

卷积网络（时间卷积网络）来生成网络流量数据。

keGAN [56]。一种分层生成对抗网络，利用自行构建的城市知识图谱（UKG），在预测过程中显式融入城市特征。

CSDI [37]。一种结合二维注意力的条件扩散模型，可捕捉结构化输入中的复杂依赖关系，以实现精准的条件生成。

DiT [26]。一种新颖的扩散模型采用 Transformer骨干网络处理潜在图像块，而非传统的 U-Net架构。

5.1.3 评估指标我们使用以下指标集评估模型。

均方根误差（RMSE）。RMSE 是 MSE 的平方根，提供了一种易于解读的误差指标，其单位与目标变量相同。

$$\mathrm{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}. \tag{16}$$

平均绝对误差 (MAE)。 MAE 衡量误差的平均幅度，而不考虑误差方向。数值越小，表示性能越好。

$$\mathrm{MAE} = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i|. \tag{17}$$

詹森–香农散度 (JSD)。 JSD [9] 是常用的衡量两个分布相似度的指标，其定义如下：

$$JSD(\hat{\mathbf{X}}, \mathbf{X}) = \sqrt{\frac{KL(\mathbf{X} \parallel \hat{\mathbf{X}}) + KL(\hat{\mathbf{X}} \parallel \mathbf{X})}{2}}, \tag{18}$$

其中，$\mathbf{X}$表示真实数据，$\hat{}\mathbf{X}$ 表示生成值，KL(·) 表示库尔贝克–莱布勒散度。较低的 JSD 意味着生成模型效果更好，因为生成数据的分布与真实数据更加相似。

一阶差分。为评估生成流量数据中每两个相邻点之间的变化，我们计算时间序列的一阶差分，记为$\hat{}\mathbf{X}_d = \hat{} x_{t+1} - \hat{} x_t$。随后，我们计算生成数据集的一阶差分与其对应真实数据集的一阶差分之间的 JSD。

5.2 交通生成性能

表 1 展示了所提出的模型与基线模型在蜂窝网络流量生成任务上的实验结果。未包含"+ C"的模型仅以噪声作为输入，而"+ C"表示模型还以多模态空间表示作为条件。所有"+C"条件模型均采用相同的训练轮数（即 100 轮），以确保公平比较。可以看到，NetSpatial 在 JSD 、均方根误差和平均绝对误差方面均取得了最低值，这表明生成的流量序列更接近真实数据的分布，且流量绝对值更加准确。尽管一些基于扩散的模型（如 DiT 和 CSDI ）在 JSD_DIFF 上的结果略好，但该指标反映的是相邻时间步之间的短期波动，而非长期时间结构。相比之下，NetSpatial 显式地对每日和每周周期模式进行建模，并通过分层生成过程将其与随机残差动态分离，因此更能体现蜂窝网络流量的时间特征。

表 1 的另一个观察结果是，空间条件对不同基线架构的影响各不相同。多模态空间表示包含有关城市环境与流量需求之间关系的有用信息，但其效用取决于生成框架。对于最初并非为纳入分层语义条件而设计的基线方法，仅将空间嵌入与输入噪声进行拼接，并不一定能带来一致的改进。在我们实验中采用的固定 100 个训练轮次预算下，添加条件可能会提升分布层面的相似性，但不一定总能降低 RMSE 或 MAE 等逐点误差；RNN-GAN 以及其他几个基线方法中都可以观察到这一模式。相比之下，其架构已经整合城市语义信息的模型往往

表 1：总体比较。 Δ：我们的方法相对于各方法的相对提升； Δ_c：添加条件（+C）带来的提升。所有指标均为越低越好。单元格颜色编码 Δ 幅度： = 表示我们的方法更优； =表示我们的方法更差

方法	JSD			JSD_DIFF			RMSE			MAE		
	Val	Δ	Δ_c	Val	Δ	Δ_c	Val	Δ	Δ_c	Val	Δ	Δ_c
RNN-GAN	0.8326	**93.33%**	17.75%	0.3040	**88.86%**	-0.61%	0.3875	**94.23%**	-95.73%	0.3866	**95.86%**	-69.45%
+ *C*	0.6848	**91.89%**	–	0.3058	**88.93%**	–	0.7585	**97.05%**	–	0.6552	**97.56%**	–
TCN-GAN	0.6931	**91.99%**	0.00%	0.3040	**88.86%**	5.02%	0.4601	**95.14%**	-1.79%	0.4500	**96.45%**	-2.97%
+ *C*	0.6931	**91.99%**	–	0.2887	**88.28%**	–	0.4683	**95.23%**	–	0.4634	**96.55%**	–
Trans.-GAN	0.2978	**81.36%**	49.53%	0.0493	31.29%	37.58%	0.0300	25.36%	-6.74%	0.0255	37.27%	8.13%
+ *C*	0.1503	63.06%	–	0.0308	-10.07%	–	0.0320	30.08%	–	0.0234	31.72%	–
DiT	0.1268	56.22%	37.95%	0.0198	-70.86%	-241.63%	0.0291	23.30%	-13.28%	0.0233	31.37%	-13.72%
+ *C*	0.0787	29.44%	–	0.0677	49.99%	–	0.0330	32.29%	–	0.0265	39.65%	–
CSDI	0.1119	50.36%	2.15%	0.2198	**84.60%**	-1.85%	0.0755	70.39%	-2.12%	0.0531	69.90%	-3.06%
+ *C*	0.1094	49.27%	–	0.2238	**84.88%**	–	0.0771	71.01%	–	0.0548	70.79%	–
keGAN	0.6895	**91.95%**	41.18%	0.0660	48.69%	-76.21%	0.3281	**93.19%**	**91.88%**	0.3217	**95.03%**	**93.15%**
+ *C*	0.4056	**86.31%**	–	0.1162	70.88%	–	0.0266	16.08%	–	0.0220	27.36%	–
Ours	**0.0555**	–	–	**0.0338**	–	–	**0.0224**	–	–	**0.0160**	–	–

从额外空间条件中获益更多。例如，keGAN 融入了城市知识图谱来建模层次化的城市特征，使其设计更能兼容外部空间表示；引入条件信息后，RMSE 和 MAE 的改善幅度也因此更大。

我们还在相应的空间功能区内开展了一项案例研究，选取了六个功能区域，即中央商务区（CBD）、居住区、商业区、大学区、工业区和混合区，并比较不同功能区域中生成的流量与真实流量。如图7和图8所示，我们观察到生成的交通数据呈现出明显的日、月时间模式。这证实，多模态空间语义已成功合成为异质城市区域中的高保真交通模式，展现了多模态感知与融合架构以及多模态条件生成机制的有效性。

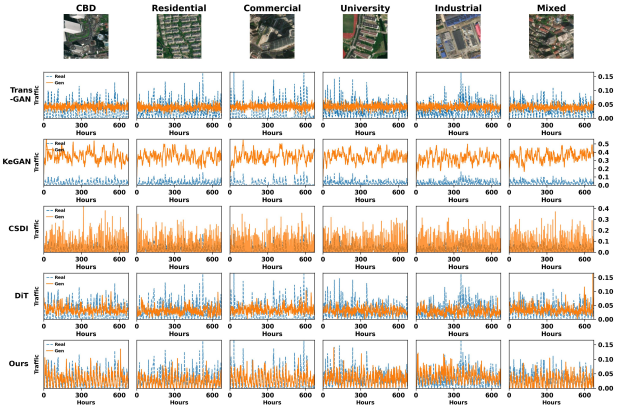


图 7：按月粒度可视化生成的基站流量。

5.3 蜂窝网络规划与运营可视化平台

我们为 NetSpatial 开发了一个基于 Mapbox 构建的可视化平台，并将部分功能集成到基于网络的应用程序中进行演示。演示视频可在 https://anonymous.4open.science/r/Traffic- 获取。

Flow-Predictor-Demo。该系统具备基站分析功能，可实现流量可视化和站点选择。

5.3.1 空间动态下的假设规划。我们的平台从空间上下文的视角提供基站选址能力，并带来交互式体验。如图9所示，用户可以探索一个 3 km × 3km 的城市空间；如果在某个可行网格部署基站，我们的条件生成模型便会估算与该网格关联的流量序列

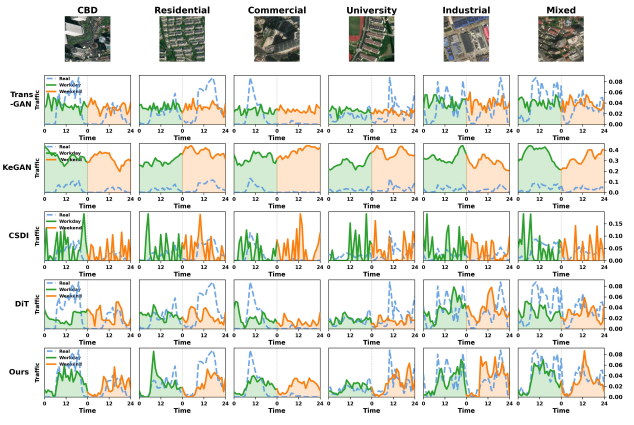


图8：按日粒度可视化生成的基站流量。



图9：我们的基站分析模块用户界面。

。该平台旨在支持不同的部署目标，并根据所选效用对候选网格进行评分和排序。在当前演示中，我们以 LSI 为例，突出显示流量需求相对较高且时间上较为稳定的位置。为使决策过程更加透明，系统还利用大语言模型生成结合具体情境的解释理由。除选址外，平台还支持在二维和三维视图之间切换，以从多个角度可视化基站流量分布。

5.3.2 波动情况下的运营操作。我们评估系统在基站进行能量控制时作出应采取何种操作决策的能力。在每个基站，系统识别高波动时间段，并仅在这些时间窗口内启用生成的目标，同时在其他时间保留观测到的流量。如图 10 所示，第一行展示了观测负载、控制目标以及在波动时段使用的生成信号。第二行展示了相应的功率调整信号，并突出显示能耗降低和增加的片段。

令 ρ_t^{obs} 和 ρ_t^{ctrl} 分别表示在时间槽 t 无控制和有控制时的归一化流量。根据 EARTH线性功率模型 [1],，在相对比较中空闲功率相互抵消，从而得到节能率

$$\eta = 1 - \sum_{t=1}^{T} \rho_t^{\text{ctrl}} \Big/ \sum_{t=1}^{T} \rho_t^{\text{obs}} . \tag{19}$$

服务质量通过需求加权满足率来衡量 [25], ，该指标仅对供给不足进行惩罚，

$$\text{QoE} = 1 - \sum_{t=1}^{T} [\rho_t^{\text{obs}} - \rho_t^{\text{ctrl}}]^{+} \Big/ \sum_{t=1}^{T} \rho_t^{\text{obs}} , \tag{20}$$

其中 $[\cdot]^{+} = \max(\cdot,\ 0)$。

结果表明，该平台能够持续做出可解释的控制决策，仅在波动较大时启用生成式控制，在其他情况下则保持稳定运行。采用这种选择性激活策略，模型最多可节省16.8%的能源，同时维持80%以上的体验质量，体现了能源效率与服务质量之间的有效权衡。

5.4 交叉城市鲁棒性测试

为评估鲁棒性和泛化能力，我们开展了跨城市零样本迁移实验：将在上海训练的模型不经微调，直接应用于北京和南京。在北京选取覆盖不同城市区域的50个基站进行评估；在南京选取覆盖城市核心区和混合区域的50个基站进行评估。图11展示了随机选取的4个基站作为可视化示例。对于北京的基站，模型取得了0.5738的最高相关系数，平均绝对误差为0.1071，成功捕捉到与真实值相符的每周周期性、每日波动和峰值特征。对于南京的基站，模型在50个基站上保持稳定的零样本生成效果，平均绝对误差为0.0210，展现出准确的流量估计能力，并能适应不同的城市特征。值得注意的是，遵循先前跨城市流量预测研究的评估框架 [56],，我们提出的零样本方法仅依靠卫星影像和地理信息，无需历史流量数据，即可直接部署到新城市。这表明NetSpatial学到的是可泛化的时空表征，而非城市特定模式。

5.5 消融研究

我们接下来通过消融研究，评估位置编码器在多级条件生成模型中的作用，以及多模态表征学习对蜂窝流量生成的效果。

位置编码器的作用。我们的模型采用三层条件生成结构，显式地对具有不同特征的时间序列进行建模，包括

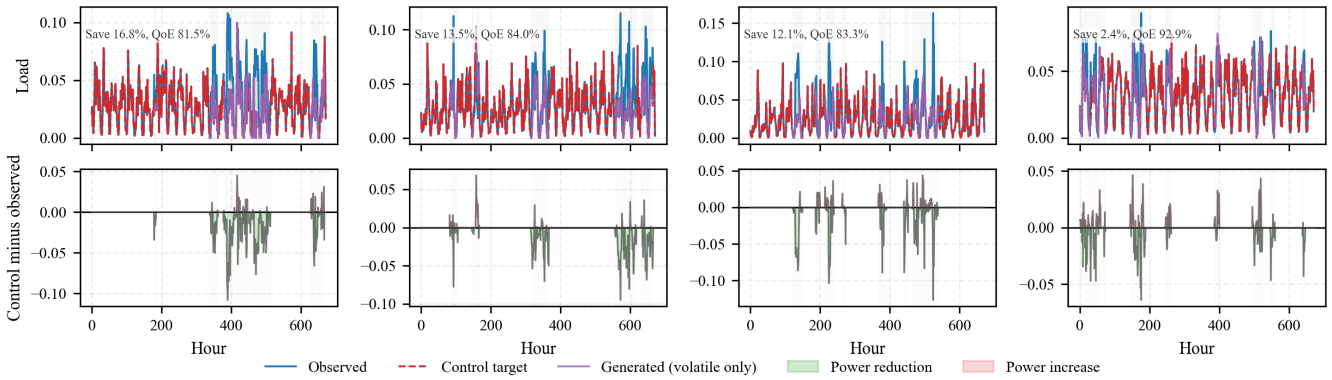


图10：四个基站的决策中心控制可视化。上排：观测负载、控制目标，以及仅在高波动时段使用的生成信号。下排：功率调整信号，显示能耗降低和能耗增加的区域。

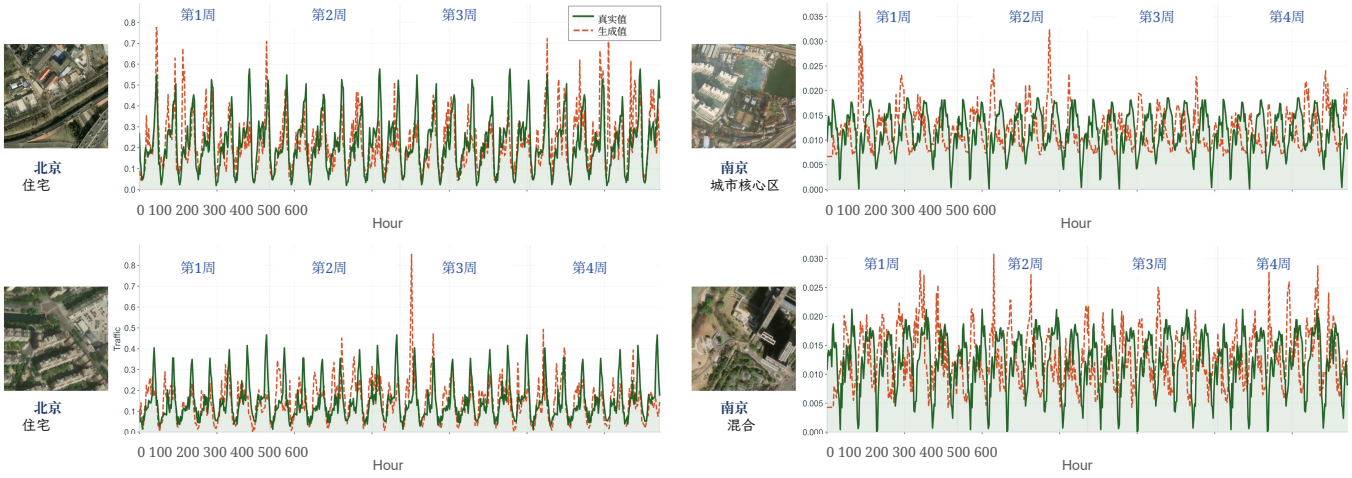


图11：跨城市零样本迁移结果。

周期性分量和非周期性分量，并利用多模态空间表示来引导蜂窝网络流量生成。为了检验引入位置编码器是否有助于从多模态空间表示中捕捉非周期性波动（即波动发生的时间及其对应的幅度），我们通过移除位置编码器开展消融研究，使最低层模块在不包含这些非周期性信息的情况下生成蜂窝网络流量。实验结果如表2所示。我们发现，移除位置编码器会使模型在所有指标上的表现均明显下降，其中一些指标降幅超过50%。

多模态表征学习的效果。我们采用生成式掩码建模策略进行多模态表征学习。为了评估其对空间嵌入的贡献，我们进行了两项消融研究，即移除条件信息，并将其替换为通过基于 CLIP 的方法获得的嵌入。实验结果如表2所示。我们观察到，两种消融变体都会导致模型在大多数指标上的表现下降，其中部分指标降幅超过 65%。

训练数据规模的敏感性。我们通过改变基站所占比例，测试 NetSpatial 的性能如何随训练数据规模变化。如图12所示，随着可用数据增多，性能持续提升。值得注意的是，从 20% 增至 40% 时提升最为显著，之后进入平台期，而超过 80% 后性能再次提升。这些结果表明，我们的无监督时间聚类具有良好的泛化能力，且不会过拟合。实际应用中，如果无法收集 >80% 的数据，那么以 ~40% 为目标最具成本效益。

表2：消融研究。 Δ：我们的方法相对于各个变体的改进幅度。越低越好。单元格颜色： = 我们的方法更优； =我 法较差。

方法	JSD		JSD_D		RMSE		MAE		T/ms	
	Val	Δ	Val	Δ	Val	Δ	Val	Δ	Val	Δ
无位置	0.1801		.0718		459		026		0 -1.5	
无条件	0.0799	3	.0058		.0516		0404		.80 1.9	
裁剪条件	0.1626		0.0239		0.0274		0.0194	1	3.60 5	
Ours	**0.0555**	–	**0.0338**	–	**0.0224**	–	**0.0160**	–	**88.06**	–

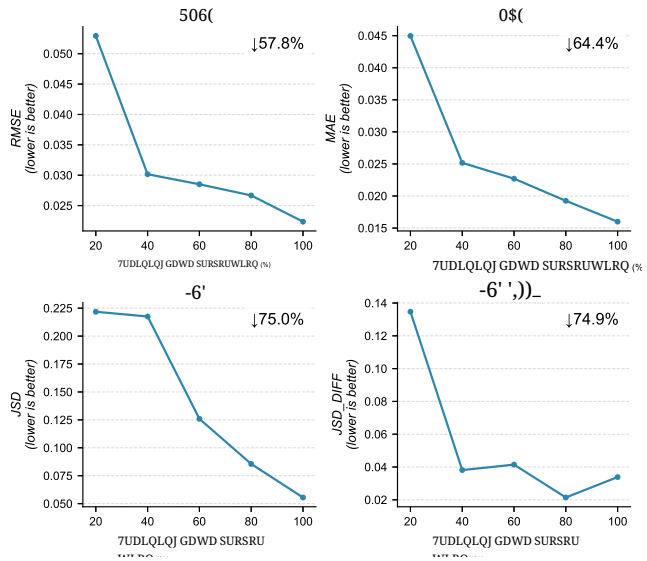


图12：训练数据规模的性能敏感性。

6 相关工作

网络流量生成。早期的流量生成依赖泊松过程和马尔可夫链等数学模型 [38, 40, 54],，之后引入了自回归模型 [2, 45] 来捕捉时间依赖关系。生成对抗网络已广泛用于这项任务。PcapGAN [6]生成数据包级轨迹，而 DoppelGANger [19, 50]联合建模属性与时间序列，以提高保真度。近年来，扩散概率模型成为一种替代性的生成范式 [49]。NetDiffusion [14] 和 NetDiffus [32] 将扩散模型应用于受协议约束的数据包轨迹合成。对于时空流量建模，DiffSTG [41] 将去噪扩散扩展到时空图，DiffUFlow [58] 则结合时空特征与语义特征，用于城市流量推断。然而，这些方法在城市级蜂窝流量生成方面存在明显局限。数据包级方法 [6, 14, 30, 55] 无法扩展到单个基站以外的范围。预测与超分辨率方法 [41, 58] 需要已有观测数据，无法从头生成流量。此外，这些方法均未纳入多模态空间条件，因此限制了它们在面向网络规划和假设分析的空间感知合成中的适用性。

蜂窝网络规划与运营。传统蜂窝网络规划依赖经验传播模型 [28, 29] 和基于优化的基站 [11, 16, 33, 34]部署方法。近期研究采用机器学习，根据建筑几何结构和航拍图像预测无线电地图 [8, 13]。数字孪生框架 [20, 23, 31] 将仿真与真实数据相结合，用于网络规划和假设分析。然而，现有工具无法生成以空间上下文为条件的逼真城市尺度流量分布，这限制了它们在缺乏真实观测数据的新建部署中的效用。

7 讨论

NetSpatial 提供了一个统一系统，通过空间条件流量生成连接网络规划与运行。借助多模态空间上下文，该系统能够对蜂窝网络进行基于场景的分析，并估算不同部署和运营条件下的流量需求。这种生成能力既支持部署规划（利用空间上下文评估候选位置），也支持网络运营（生成流量预测，为休眠调度和负载均衡等策略提供指导）。

尽管具有这些优势，仍存在若干局限。首先，当前系统依赖卫星影像和兴趣点分布等静态空间特征，而移动模式和特殊事件等动态因素也可能影响流量需求。其次，该模型根据空间上下文生成流量，但未对相邻基站之间的交互进行显式建模，而这可能会影响密集部署中的负载重新分配。未来的工作可以纳入移动数据和网络拓扑信息，以进一步改进需求建模和运营决策支持。

8 结论

我们介绍了**NetSpatial**，这是一种空间条件化的蜂窝流量生成系统，可支持蜂窝网络规划与运行。借助多模态空间上下文，NetSpatial 能够在多种空间场景下生成逼真的流量模式，使运营商能够评估候选部署方案，并支持流量预测和负载管理等运营决策。在真实世界的蜂窝网络数据集上进行的实验表明，所提出的系统能够有效捕捉时空特征

，并为数据驱动的规划与优化提供了实用工具。未来的工作将从三个方向扩展 NetSpatial。首先，纳入更丰富的空间信号和城市结构信息，有望提升空间语义和流量表征。其次，在更广泛的多城市数据集上评估模型，将有助于研究其泛化能力和区域差异。第三，整合更多网络测量数据并开发在线建模能力，可进一步支持动态且面向服务的网络管理。

参考文献

[1] Gunther Auer, Vito Giannini, Claude Desset, Istvan Godor, Per Skiller- mark, Magnus Olsson, Muhammad Ali Imran, Dario Sabella, Manuel J Gonzalez, Oliver Blume 等。2011。运行无线网络需要多少能源？*IEEE Wireless Communications* 18, 5 (2011), 40–49。[2] Alisson Assis Cardoso 和 Flávio Henrique Teles Vieira。2019。使用基于变换自回归模型的自适应算法生成合成网络流量序列。*IEEE*拉丁美洲汇刊 17, 08 (2019), 1268–1275。[3] Stefano Carrese、Ernesto Cipriani、Livia Mannini 和 Marialisa Nigro。2017。采用新数据源对城市交通网络进行动态需求估计与预测。《交通研究*C*辑：新兴技术》81 (2017), 83–98。[4] Haoye Chai、Shiyuan Zhang、Xiaoqian Qi、Baohua Qiu 和 Yong Li。2025。Uomo：面向无线网络优化的移动流量预测通用模型。载于第*31*届 *ACM SIGKDD* 知识发现与数据挖掘大会论文集第*2*卷。4308–4319。[5] Guoxuan Chi、Zheng Yang、Chenshu Wu、Jingao Xu、Yuchong Gao、Yunhao Liu 和 Tony Xiao Han。2024。RF-diffusion：通过时频扩散生成无线电信号。载于第*30*届移动计算与网络年度国际会议论文集。77–92。[6] Baik Dowoo、Yujin Jung 和 Changhee Choi。2019。PcapGAN：基于风格生成对抗网络的数据包捕获文件生成器。载于*2019*年第*18*届 *IEEE*机器学习与应用国际会议（*ICMLA*）。IEEE，1149–1154。[7] Simon Erni、Martin Kotuliak、Patrick Leu、Marc Roeschlin 和 Srdjan Capkun。2022。Adaptover：蜂窝网络中的自适应遮蔽攻击。载于第*28*届移动计算与网络年度国际会议论文集。743–755。[8] Bin Feng、Meng Zheng、Wei Liang 和 Lei Zhang。2025。无线网络无线电地图估计方法最新综述。*Electronics* 14, 8 (2025), 1564。[9] Bent Fuglede 和 Flemming Topsoe。2004。詹森–香农散度与希尔伯特空间嵌入。载于*2004*年信息论国际研讨会（*ISIT 2004*）论文集。IEEE，31。[10] Ushasi Ghosh、Azuka Chiejina、Nathan Stephenson、Vijay K Shah、Srinivas Shakkottai 和 Dinesh Bharadia。2024。SPARC：面向下一代蜂窝网络多站点频谱管理的时空自适应资源控制。《*ACM*网络学报》2, CoNEXT4 (2024), 1–18。[11] Sheikh Salman Hassan、Yu Min Park、Yan Kyaw Tun、Walid Saad、Zhu Han 和 Choong Seon Hong。2024。SpaceRIS：利用MAPPO深度强化学习和鲸鱼优化实现6G亚太赫兹网络中的低地球轨道卫星覆盖最大化。《*IEEE*通信领域精选期刊》42, 5 (2024), 1262–1278。[12] Shuodi Hui、Huandong Wang、Tong Li、Xinghao Yang、Xing Wang、Junlan Feng、Lin Zhu、Chao Deng、Pan Hui、Depeng Jin 等。2023。通过具有多周期模式的知识增强生成对抗网络生成大规模城市蜂窝流量。载于第*29*届 *ACM SIGKDD*知识发现与数据挖掘大会论文集。4195–4206。[13] Xinyue Jiang、Tong Li、Zhu Xiao、Ke Chen、Shuai Ma、Zhaocheng Wang 和 Keqin Li。2025。UniRM：用于多频段三维无线电地图构建的通用大模型。《*IEEE*通信领域精选期刊》(2025)。[14] Xi Jiang、Shinan Liu、Aaron Gember-Jacobson、Arjun Nitin Bhagoji、Paul Schmitt、Francesco Bronzino 和 Nick Feamster。2024。Netdiffusion：通过协议约束流量生成实现网络数据增强。《ACM测量与分析论文集》

计算系统 8, 1 (2024), 1–32。 [15] Yifan Jiang、Shiyu Chang 和 Zhangyang Wang。2021。Transgan：两个纯 Transformer 即可组成一个强大的生成对抗网络，并可实现规模扩展。神经信息处理系统进展 34 (2021), 14745–14758。[16] Elham Kalantari、Sergey Loyka 和 Halim Yanikomeroglu。2024。通过凸优化确定蜂窝基站的最佳位置：分析框架与数值算法。*IEEE Access* 12 (2024), 75180–75198。[17] Dongheon Lee、Sheng Zhou、Xiaofeng Zhong、Zhisheng Niu、Xuan Zhou 和 Honggang Zhang。2014。蜂窝网络中的流量密度空间建模。*IEEE Wireless Communications* 21, 1 (2014), 80–88。[18] Tong Li、Shuodi Hui、Shiyuan Zhang、Huandong Wang、Yuheng Zhang、Pan Hui、Depeng Jin 和 Yong Li。2024。通过多尺度分层生成对抗网络生成移动用户流量。*ACM* 数据知识发现汇刊 18, 8 (2024), 1–19。 [19] Zinan Lin、Alankar Jain、Chen Wang、Giulia Fanti 和 Vyas Sekar。2020。使用生成对抗网络共享网络化时间序列数据：挑战、初步前景与开放问题。*ACM* 互联网测量会议论文集，464–483。[20] Haoqiang Liu、Weikang Su、Tong Li、Wenzhen Huang 和 Yong Li。2024。数字孪生增强的多智能体强化学习，用于大规模移动网络覆盖优化。*ACM* 数据知识发现汇刊 19, 1 (2024), 1–23。[21] Yilai Liu、Shiyuan Zhang 和 Hongyang Du。2025。海报：通过时空相关性成像增强移动流量数据生成。载于第*31*届移动计算与网络年度国际会议论文集。1377–1379。[22] Evangelos Lykakis、Ioannis O Vardiambasis 和 Evangelos Kokkinos。2025。5G及超越网络的数据流量预测：新兴趋势、挑战与未来方向——范围综述。*Electronics* 14, 23 2025 4611( ), 。[23] Yuyin Ma 、 Fei Song 、 Giovanni Pau 、 Ilsun You 和 Hongke Zhang。2023。网络数字孪生中面向动态资源分配的自适应服务供给。*IEEE Network* 38, 1 (2023), 61–68。 [24] Olof Mogren。2016。采用对抗训练的连续循环神经网络。*arXiv*预印本 *arXiv:1611.09904* (2016)。[25] Eunsung Oh、Kyuho Son 和 Bhaskar Krishnamachari。2013。绿色蜂窝网络的动态基站开关策略。*IEEE* 无线通信汇刊 12, 5 (2013), 2126–2136。[26] William Peebles 和 Saining Xie。2023。基于Transformer的可扩展扩散模型。载于*IEEE/CVF* 国际计算机视觉会议论文集。4195–4205。[27] Wajid Rafique、Joyeeta Rani Barai、Abraham O Fapojuwo 和 Diwakar Krishnamurthy。2024。面向智慧城市应用的超越5G网络切片综述。*IEEE* 通信综述与教程 27, 1 2024 595 628 ( ), – 。[28] Theodore S Rappaport。2010。无线通信：原理与实践，第*2*版。培生印度教育。[29] Theodore S Rappaport、Yunchou Xing、George R MacCartney、Andreas F Molisch、Evangelos Mellios 和 Jianhua Zhang。2017。第五代（5G）无线网络毫米波通信概述——聚焦传播模型。*IEEE* 天线与传播汇刊 65, 12 (2017), 6213–6230。[30] Markus Ring、Daniel Schlör、Dieter Landes 和 Andreas Hotho。2019。使用生成对抗网络进行基于流的网络流量生成。*Computers & Security* 82 (2019), 156–172。[31] Mario Sanz Rodrigo、Diego Rivera、José Ignacio Moreno、Manuel Alvarez-Campana 和 Diego R López。2023。5G网络的数字孪生：建模与部署方法。*IEEE Access* 11 (2023)

, 38112–38126.

[32] Nirhoshan Sivaroopan、Dumindu Bandara、Chamara Madarasingha、Guillaume Jourjon、Anura P Jayasumana 和 Kanchana Thilakarathna。2024。Netdiffus：通过时间序列成像和扩散模型生成网络流量。《计算机网络》251（2024），110616。[33] Weikang Su、Tong Li、Wenzhen Huang、Zihan Huang 和 Yong Li。2025。GenNet：一种由生成式人工智能驱动的移动网络模拟器，用于结合强化学习进行多目标网络优化。《*IEEE*移动计算汇刊》（2025）。[34] Weikang Su、Haoqiang Liu、Tong Li、Xingzai Lv、Hua Rui、Wenzhen Huang、Zhaocheng Wang 和 Yong Li。2025。使用分层强化学习联合优化基站部署和天线。*ACM* 数据知识发现汇刊20，1（2025），1–25。[35] Chuanhao Sun、Kai Xu、Gianni Antichi 和 Mahesh K Marina。2024。NetGSR：利用生成式超分辨率实现高效、可靠的网络监测。《*ACM*网络学报》2, CoNEXT4（2024），1–27。[36] Chuanhao Sun、Yu Zhang、Bill Tao、Deepak Vasisht 和 Mahesh Ma-rina。2025。DeepSpace：利用超分辨率实现高效、可靠的卫星图像数据采集。载于*ACM SIGCOMM 2025*会议论文集。311–328。[37] Yusuke Tashiro、Jiaming Song、Yang Song 和 Stefano Ermon。2021。CSDI：用于概率时间序列插补的条件分数扩散模型。神经信息处理系统进展34（2021），24804–24816。[38] Kashi Venkatesh Vishwanath 和 Amin Vahdat。2009。Swing：逼真且响应迅速的网络流量生成。《*IEEE/ACM*网络汇刊》17，3（2009），712–725。[39]Sajana Weerawardhena、Paul Kassianik、Blaine Nelson、Baturay Saglam、Anu Vellore、Aman Priyanshu、Supriti Vijay、Massimo Aufiero、Arthur Goldblatt、Fraser Burch 等。2025。Llama-3.1-foundationai-securityllm-8b-instruct技术报告。*arXiv*预印本 *arXiv:2508.01059*（2025）。[40] Michele C Weigle、Prashanth Adurthi、Félix Hernández-Campos、Kevin Jeffay 和 F Donelson Smith。2006。Tmix：一种用于在 ns-2 中生成真实 TCP 应用工作负载的工具。《*ACM SIGCOMM*计算机通信评论》36, 3（2006），65–76。[41] Haomin Wen、Youfang Lin、Yutong Xia、Huaiyu Wan、Qingsong Wen、Roger Zimmermann 和 Yuxuan Liang。2023。DiffSTG：利用去噪扩散模型进行概率时空图预测。载于第*31*届 *ACM*地理信息系统进展国际会议论文集。1–12。[42] Zhu Xiao、Rui Wang、Jing Bai、Tong Li、Shiyuan Zhang、Keqin Li 和 Zhu Han。2025。一种用于移动流量预测的大语言模型增强条件扩散模型。《*IEEE*通信杂志》63，9（2025），60–67。[43] Chengcheng Xu、Zhibin Li 和 Wei Wang。2016。一种基于自回归积分滑动平均和遗传编程的方法，用于短期交通流量预测。《交通运输》31，3（2016），343–358。[44] Kai Xu、Rajkarn Singh、Marco Fiore、Mahesh K Marina、Hakan Bilen、Muhammad Usama、Howard Benn 和 Cezary Ziemlicki。2021。Spectragan：基于频谱生成城市尺度时空移动网络流量数据。载于第*17*届新兴网络实验与技术国际会议论文集。243–258。[45] Shengzhe Xu、Manish Marwah 和 Naren Ramakrishnan。2020。STAN：使用自回归神经模型生成合成网络流量。*arXiv*预印本 *arXiv:2009.12740*（2020）。[46] Shuona Xu 和 Biqing Zeng。2014。基于自回归滑动平均的网络流量预测模型。《网络期刊》9, 3（2014），653。

[47] Xuecai Xu、Xiaofei Jin、Daiquan Xiao、Changxi Ma 和 Sze Chun Wong。2023。一种结合混合自回归分数阶积分滑动平均与非线性自回归神经网络的短期交通流量预测模型。智能交通系统期刊 27，1，2023，1–18。[48] Xiaowen Xu、Xiaosi Liu、Zhidan Liu、Zhenjiang Li 和 Kaishun Wu。2025。海报：扩散驱动的时空建模，用于蜂窝流量生成。载于第*31*届移动计算与网络年度国际会议论文集。1326–1328。[49] Yiyuan Yang、Ming Jin、Haomin Wen、Chaoli Zhang、Yuxuan Liang、Lintao Ma、Yi Wang、Chenghao Liu、Bin Yang、Zenglin Xu、Jiang Bian、Shirui Pan 和 Qingsong Wen。2024。时间序列与时空数据扩散模型综述。*arXiv*预印本 *arXiv:2404.01928*（2024）。[50] Yucheng Yin、Zinan Lin、Minhao Jin、Giulia Fanti 和 Vyas Sekar。2022。使用 NetShare 实用地生成基于生成对抗网络的合成 IP 头部轨迹。载于 *ACM SIGCOMM 2022*会议论文集。458–472。[51] Jinsung Yoon、Daniel Jarrett 和 Mihaela Van der Schaar。2019。时间序列生成对抗网络。神经信息处理系统进展32（2019）。[52] Yuan Yuan、Jingtao Ding、Jie Feng、Depeng Jin 和 Yong Li。2024。UniST：一种由提示赋能的城市时空通用模型。载于第*30*届 *ACM SIGKDD*知识发现与数据挖掘会议论文集。4095–4106。

[53] Chaoyun Zhang、Marco Fiore、Cezary Ziemlicki 和 Paul Patras。2020。Microscope：面向网络切片即服务的移动服务流量分解。载于 第*26*届移动计算与网络年度国际会议论文集。1–14。[54] Junhui Zhang、Jiqiang Tang、Xu Zhang、Wen Ouyang 和 Dongbin Wang。2015。网络流量生成综述。（2015）。[55] Shiyuan Zhang、Haoye Chai、Yong Li、Baohua Qiu、Lei Yue 和 Raoyuan Pan。2025。PacketDiff：用于网络数据包轨迹生成的流引导扩散模型。*IEEE* 物联网期刊（2025）。[56] Shiyuan Zhang、Tong Li、Shuodi Hui、Guangyu Li、Yanping Liang、Li Yu、Depeng Jin 和 Yong Li。2023。通过城市知识图谱进行城市级蜂窝流量生成的深度迁移学习。载于第*29*届 *ACM SIGKDD* 知识发现与数据挖掘大会论文集。4842–4851。[57] Shiyuan Zhang、Tong Li、Zhu Xiao、Hongyang Du 和 Kaibin Huang。2025。LSDM：大语言模型增强的时空扩散模型，用于服务级移动流量预测。*arXiv* 预印本 *arXiv:2507.17795*（2025）。[58] Yuhao Zheng、Lian Zhong、Senzhang Wang、Yu Yang、Weixi Gu、Junbo Zhang 和 Jianxin Wang。2023。Diffuflow：利用去噪扩散模型进行鲁棒的细粒度城市流量推断。载于 第*32*届 *ACM* 信息与知识管理国际会议论文集。3505–3513。