

基于去噪扩散模型增强的换电需求数据生成算法

刘德华, 喻赛萱, 乔金兰, 黄河清, 程文辉

引用本文

刘德华, 喻赛萱, 乔金兰, 黄河清, 程文辉. 基于去噪扩散模型增强的换电需求数据生成算法[J]. 计算机科学, 2026, 53(4): 163-172.

LIU Dehua, YU Saixuan, QIAO Jinlan, HUANG Heqing, CHENG Wenhui. [Denoising Diffusion Model-enhanced Algorithm for Battery Swap Demand Data Generation](#) [J]. Computer Science, 2026, 53(4): 163-172.

相似文献推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[面向群车协同感知的车载视频压缩算法](#)

Vehicle-mounted Video Compression Algorithm for Collaborative Vehicle Crowdsensing
计算机科学, 2026, 53(4): 308-317. <https://doi.org/10.11896/jsjcx.250400103>

[语义引导的红外与可见光图像混合交叉特征融合方法](#)

Semantic-guided Hybrid Cross-feature Fusion Method for Infrared and Visible Light Images
计算机科学, 2026, 53(2): 253-263. <https://doi.org/10.11896/jsjcx.250100123>

[基于跨语言术语注意力机制的译文质量估计方法](#)

Translation Quality Estimation Based on Cross-lingual Term Attention Mechanism
计算机科学, 2025, 52(11A): 250200007-9. <https://doi.org/10.11896/jsjcx.250200007>

[基于声纹特征的无人机个体识别技术研究](#)

Research on Individual Unmanned Aerial Vehicles Identification Technology Based on Voiceprint Characteristics
计算机科学, 2025, 52(11): 444-451. <https://doi.org/10.11896/jsjcx.250300079>

[FDiff-Fusion:基于模糊逻辑驱动的医学图像扩散融合网络分割模型](#)

FDiff-Fusion:Medical Image Diffusion Fusion Network Segmentation Model Driven Based onFuzzy Logic
计算机科学, 2025, 52(6): 274-285. <https://doi.org/10.11896/jsjcx.240600006>

基于去噪扩散模型增强的换电需求数据生成算法

刘德华¹ 喻赛萱² 乔金兰³ 黄河清⁴ 程文辉¹

1 重庆大学计算机学院 重庆 400044

2 四川财经职业学院信息学院 成都 610101

3 联勤保障部队工程大学勤务指挥系 重庆 401331

4 重庆开放大学重庆工商职业学院 重庆 400053

(ldhtwx@163.com)

摘要 近年来,电动车换电服务凭借其快速便捷的补能优势得到迅速推广。精确的用户换电需求预测是提高换电平台运营效率的关键。然而,在换电站新部署城市中,由于历史数据的缺乏,传统预测模型往往训练不足,导致预测精度下降。为解决该难题,提出一种基于去噪扩散模型增强的换电需求数据生成算法。通过生成与真实换电需求数据分布一致的合成样本,对训练数据进行有效扩充,从而显著提升模型的预测精度。具体地,首先使用模拟位编码在连续空间中表示混合类型换电需求数据,使其能被扩散模型处理。进一步地,设计一个基于交叉注意力机制的条件去噪网络,并使用站点信息引导生成高质量换电需求数据。最后,基于成都市40个换电站一个月的真实换电数据集对所提算法进行性能评估。实验结果表明,与直接使用原训练数据训练相比,使用所提算法的生成数据与原训练数据结合后的换电需求预测在MAE, RMSE和MAPE误差指标上分别降低了9.29%, 8.56%和8.23%。

关键词 电动车换电服务;换电需求预测;换电需求数据生成;去噪扩散模型;交叉注意力机制

中图分类号 TP393

Denosing Diffusion Model-enhanced Algorithm for Battery Swap Demand Data Generation

LIU Dehua¹, YU Saixuan², QIAO Jinlan³, HUANG Heqing⁴ and CHENG Wenhui¹

1 College of Computer Science, Chongqing University, Chongqing 400044, China

2 College of Information, Sichuan Vocational College of Finance and Economics, Chengdu 610101, China

3 Department of Logistics Command, Engineering University of the Joint Logistics Support Force, Chongqing 401331, China

4 College of Chongqing Technology and Business, Chongqing Open University, Chongqing 400053, China

Abstract In recent years, electric vehicle battery swap services have rapidly gained popularity due to their fast and convenient energy replenishment capabilities. Accurate prediction of user battery swap demand is crucial for optimizing the operational efficiency of battery swap platforms. However, in cities with newly deployed battery swap stations, conventional prediction models often suffer from insufficient training due to the lack of historical data, resulting in degraded prediction accuracy. To address this challenge, this paper proposes a denosing diffusion model-enhanced algorithm for generating battery swap demand data. By synthesizing samples that preserve the statistical distribution of real-world battery swap demand data, the proposed approach effectively augments the training dataset, thereby significantly improving the model's prediction accuracy. Specifically, it firstly employs analog bit encoding to represent mixed-type battery swap demand data in continuous space, enabling it to be processed by the diffusion model. Furthermore, it designs a conditional denosing network incorporating the cross-attention mechanism, utilizing station information to guide the generation of high-quality battery swap demand data. Finally, the proposed algorithm is evaluated on a real-world battery swap dataset collected from 40 battery swap stations in Chengdu over a one-month period. Experimental results demonstrate that combining the generated data from the proposed algorithm with the original training data reduces the MAE, RMSE, and MAPE of battery swap demand prediction by 9.29%, 8.56%, and 8.23%, respectively, compared to using the original training data alone.

Keywords Electric vehicle battery swap service, Battery swap demand prediction, Battery swap demand data generation, Denosing diffusion model, Cross-attention mechanism

到稿日期:2025-06-26 返修日期:2025-10-09

基金项目:重庆市教委重点科技项目(KJZD-K202404002);合川区科技项目(HCKJ-2024-112)

This work was supported by the Key Science and Technology Project of the Chongqing Education Commission(KJZD-K202404002) and Science and Technology Project of Hechuan District(HCKJ-2024-112).

通信作者:乔金兰(qiaojinlan@163.com)

1 引言

近年来,电动车换电服务逐渐兴起^[1-3]。与传统的充电模式相比,换电模式通过“以换代充”的方式有效解决了用户的里程焦虑和充电难题,实现了更快速、更便捷、更安全的补能^[4-5]。因此,在政府和企业的大力推动下,换电行业进入了快速发展期。以电动两轮车换电市场为例,中国铁塔已在全国 320 多个城市部署了超过 7 万个换电站,为超过 120 万名外卖员和居民用户累计提供超过 11 亿次换电服务^[6]。为提高换电平台运营效率,换电公司常采用机器学习算法,利用历史换电数据对站点未来一段时间的换电需求进行精确预测。换电需求精确预测对换电平台具有重要意义,例如,运营商可根据预测的换电需求,在不同站点中调度电池以满足站点用户需求,同时提高站点电池利用率^[7]。

然而,随着换电市场的日益普及与快速发展,换电平台常需要在新城市部署换电站网络^[8]。与已经在其他城市部署运营数年的站点相比,换电站新部署城市的站点规模及运营时间有限,导致产生的换电需求数据较少。换电需求预测属于监督学习问题,基于机器学习的预测模型往往需要大量的带标签数据进行训练,训练数据的稀缺会影响模型训练效果,从而降低模型的预测准确性^[9-10]。

近年来,扩散模型在各个领域(包括计算机视觉^[11-12]、自然语言处理^[13]、音频^[14-15])展现出优异的数据生成效果。扩散模型通过前向过程对样本逐渐加噪,直至变成高斯噪声,并在反向过程中采样随机噪声对其去噪,从而生成符合原数据分布的新数据。由于扩散模型具有高质量的数据生成能力,本文提出利用扩散模型生成用于换电需求预测的换电需求数据(即训练样本数据),将生成数据与原训练数据相结合以扩充训练数据并丰富数据表示,从而提升换电需求预测模型的预测效果。然而,基于扩散模型进行换电需求数据生成面临以下两个方面的挑战。

1)传统扩散模型无法处理混合类型换电需求数据。换电需求数据中的特征数据类型混合多样,既包括时间特征、空间特征等类别特征,又包括历史换电需求等数值特征。而传统扩散模型仅作用于连续空间,无法直接进行包含混合数据类型的换电需求数据生成。

2)传统扩散模型难以生成高质量换电需求数据。换电需求数据包含的属性多样,如空间特征、历史使用特征、用户换电需求等属性数据;同时,不同属性之间可能存在复杂依赖关系。传统扩散模型捕捉复杂依赖的能力受限,从而难以生成高质量换电需求数据。

为应对上述挑战,本文提出一种基于去噪扩散模型增强的换电需求数据生成算法,通过将混合类型数据映射到同一向量空间并使用站点信息引导生成高质量换电需求数据。具体地,针对挑战 1,引入模拟位编码方法将换电需求数据中类别特征编码成连续数据,从而将混合类型换电需求数据映射到同一连续向量空间,使其能被扩散模型处理。针对挑战 2,使用站点信息(包括站点 ID 和站点空间特征)引导生成高质量换电需求数据,并在去噪网络中基于交叉注意力机制将站点信息与去噪数据进行融合,以实现站点信息对换电需求数据的控制生成。

综上所述,本文主要有以下 3 方面贡献:

1)设计了一种提升换电需求预测模型预测精度的方案。利用扩散模型生成换电需求数据,生成的数据可对换电需求预测模型的训练数据进行有效扩充,从而提升了模型预测精度,为提高换电站新部署城市换电平台运营效率提供了可行性方案。

2)提出了一种面向高质量换电需求数据生成的扩散模型。特别地,使用模拟位编码将混合类型换电需求数据映射到同一连续向量空间以便扩散模型进行处理,并设计基于交叉注意力机制的条件去噪网络,使用站点信息引导数据去噪,从而生成高质量换电需求数据。

3)利用成都市 40 个换电站一个月的真实换电数据集对所提算法进行深入全面的实验评估。实验结果表明,使用所提算法生成数据与训练数据相结合比直接使用原训练数据训练的换电需求预测在 MAE, RMSE 和 MAPE 误差指标上分别降低了 9.29%, 8.56% 和 8.23%。

本文第 2 章介绍并总结国内外相关研究工作;第 3 章介绍基础知识并进行问题定义;第 4 章详细介绍基于去噪扩散模型增强的换电需求数据生成算法;第 5 章进行算法实验评估;最后总结全文并展望未来。

2 相关工作

本章总结扩散模型、数据合成及共享资源需求预测增强的相关工作。

1)扩散模型。在计算机视觉任务上,扩散模型得到大量研究^[16-19]。Sohl-Dickstein 等^[16]首次提出扩散模型并应用于图像生成任务。Ho 等^[17]提出去噪扩散概率模型(DDPM),显著提升了扩散模型性能。Dhariwal 等^[19]在扩散模型中使用分类器引导生成图像。除了计算机视觉领域,条件扩散模型也被用于生成其他数据类型,如时间序列数据^[20]。Kong 等^[15]提出了用于音频生成的扩散模型 Diffwave,通过在去噪网络中使用双向扩张卷积捕捉不同时间步之间的依赖关系。大多数扩散模型用于生成图像、音频等领域的的数据,而本文则基于扩散模型生成用于提升换电需求预测精度的换电需求数据。

2)数据合成。本文研究的换电需求数据为表格数据,因此主要总结表格数据生成领域的相关工作。近几年,基于生成模型的表格数据生成方法被大量研究^[21]。其中, Yang 等^[22]采用自回归模型^[23],通过将表格数据生成任务建模成序列生成问题,以逐个属性的方式生成表格数据。Xu 等^[24]提出了用于表格数据生成任务的变分自编码器模型 TVAE,并介绍了基于生成对抗网络^[25]的表格数据生成模型 CT-GAN,该模型允许给定特定用户上下文内容生成表格数据。Kotelnikov 等^[26]设计了基于扩散模型的表格数据生成算法 TabDDPM,该算法分别用高斯扩散模型学习数值属性及多项扩散模型学习类别属性,从而解决混合类型表格数据的生成问题。以上工作主要研究通用表格数据生成技术,而本文则研究用于增强换电需求预测的换电需求数据生成算法。

3)共享资源需求预测增强。近几年,有相关学者研究过关于共享电动车及共享自行车等共享资源的需求预测增强方法^[9-10]。Chatterjee 等^[9]针对共享电动车需求预测训练数据

不足的问题,使用 WGAN 模型进行共享电动车需求数据生成,进一步丰富训练数据以增强共享电动车需求预测模型的预测效果。Zhang 等^[10]提出了基于 GAN 的共享自行车需求预测集成学习模型,首先使用 GAN 模型生成共享自行车需求数据,与原训练数据相结合后,再使用集成学习模型进行共享自行车需求预测以增强预测鲁棒性。以上方法均使用 GAN 模型进行需求数据生成,然而 GAN 本身存在模式崩溃的问题^[27],因此本文使用扩散模型进行换电需求数据生成,以增强换电需求预测效果。

3 基础知识和问题定义

3.1 扩散模型基础知识

去噪扩散概率模型(DDPM)^[17]是一种深度生成模型,通过对高斯噪声逐渐去噪以学习数据变量 x 的数据分布。DDPM 由前向加噪过程和反向去噪过程组成。

前向过程通过马尔可夫链将数据 $x_0 \sim q(x_0)$ 转换成潜在变量 x_1, \dots, x_T , 直至变成高斯噪声 $x_T \sim \mathcal{N}(0, I)$ 。马尔可夫链的变换表达式如下:

$$q(x_{1:T} | x_0) = \prod_{t=1}^T q(x_t | x_{t-1}) \quad (1)$$

$$q(x_t | x_{t-1}) = \mathcal{N}(x_t; \sqrt{1-\beta_t}x_{t-1}, \beta_t I) \quad (2)$$

其中, $q(x_{1:T} | x_0)$ 表示前向过程; $q(x_t | x_{t-1})$ 表示从 x_{t-1} 到 x_t 的加噪过程; $\mathcal{N}(x_t; \sqrt{1-\beta_t}x_{t-1}, \beta_t I)$ 是均值 $\sqrt{1-\beta_t}x_{t-1}$ 、方差 $\beta_t I$ 的正态分布; $\beta_t \in (0, 1)$ 表示噪声强度的超参数。给定数据 x_0 , $\alpha_t = 1 - \beta_t$, $\bar{\alpha}_t = \prod_{i=1}^t \alpha_i$, 可通过以下表达式直接采样任意时间步 t 的 x_t :

$$q(x_t | x_0) = \mathcal{N}(x_t; \sqrt{\alpha_t}x_0, (1-\bar{\alpha}_t)I) \quad (3)$$

也可重参数化表示为:

$$x_t = \sqrt{\alpha_t}x_0 + \sqrt{1-\bar{\alpha}_t}\epsilon \quad (4)$$

其中, ϵ 从标准高斯噪声 $\mathcal{N}(0, I)$ 中采样。

在反向过程中,模型逐步对高斯噪声 $x_T \sim \mathcal{N}(0, I)$ 去噪,直至恢复为原始数据 x_0 。由于反向过程无法直接推断出 $q(x_{t-1} | x_t)$, 因此使用深度学习模型 p_θ 拟合分布 $q(x_{t-1} | x_t)$ 。反向过程建模为:

$$p_\theta(x_{0:T}) = p(x_T) \prod_{t=1}^T p_\theta(x_{t-1} | x_t) \quad (5)$$

$$p_\theta(x_{t-1} | x_t) = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t), \sigma_\theta(x_t, t)I) \quad (6)$$

其中, $p_\theta(x_{0:T})$ 表示从纯噪声数据 x_T 逐步去噪成原始数据 x_0 的联合概率分布; $p_\theta(x_{t-1} | x_t)$ 表示去噪过程,即给定 x_t 的条件下,前一时间步 x_{t-1} 的概率分布。为从 x_t 获得 x_{t-1} , 可训练一个去噪网络 ϵ_θ 预测前向过程中注入 x_t 的噪声。因此,根据式(4)可得到 x_0 :

$$x_0 = \frac{1}{\sqrt{\alpha_t}}(x_t - \sqrt{1-\bar{\alpha}_t}\epsilon_\theta(x_t, t)) \quad (7)$$

在已知 x_0 的情况下,依据贝叶斯公式可得到:

$$q(x_{t-1} | x_t, x_0) = \mathcal{N}(x_{t-1}; \tilde{\mu}(x_t, x_0), \tilde{\beta}_t I) \quad (8)$$

在式(8)的推导中,通过贝叶斯公式可将反向过程转换为前向过程,将得到的概率密度函数与高斯概率密度函数的指数部分相对应,即有:

$$\tilde{\mu}(x_t, x_0) = \frac{\sqrt{\bar{\alpha}_{t-1}}\beta_t}{1-\bar{\alpha}_t}x_0 + \frac{\sqrt{\alpha_t}(1-\bar{\alpha}_{t-1})}{1-\bar{\alpha}_t}x_t \quad (9)$$

$$\tilde{\beta}_t = \frac{1-\bar{\alpha}_{t-1}}{1-\bar{\alpha}_t}\beta_t \quad (10)$$

将式(7)代入式(9),并依据式(10)可得到 $p_\theta(x_{t-1} | x_t)$ 的参数化实现:

$$\mu_\theta(x_t, t) = \frac{1}{\sqrt{\alpha_t}} \left(x_t - \frac{\beta_t}{\sqrt{1-\bar{\alpha}_t}} \epsilon_\theta(x_t, t) \right) \quad (11)$$

$$\sigma_\theta(x_t, t) = \frac{1-\bar{\alpha}_{t-1}}{1-\bar{\alpha}_t}\beta_t \quad (12)$$

去噪网络 ϵ_θ 可通过优化以下损失函数进行训练:

$$\mathcal{L}(\theta) = E_{x_0, \epsilon, t} \| \epsilon - \epsilon_\theta(x_t, t) \|^2 \quad (13)$$

3.2 问题定义

3.2.1 换电系统模型

换电系统能为电动车车主在换电站网络中任一站点提供换电服务,该换电服务可保证车主在短时间内将电量用尽的电池更换为充满电的电池。换电系统模型主要由以下3部分组成:

1)换电站网络:换电站网络包括在城市中部署的 I 个换电站。假设 z_i 和 m_i 分别表示站点 s_i 的站点 ID 和地理位置,则换电站网络表示为 $\mathcal{I} = \{s_1, s_2, \dots, s_i, \dots, s_I\}$, 其中 $s_i = (z_i, m_i)$ 。

2)用户换电需求:换电站网络 \mathcal{I} 中站点 s_i 在时段 t 内的用户换电需求表示为 $d_{i,t}$, $d_{i,t}$ 可通过统计站点 s_i 在时段 t 内的用户换电次数得到。时段 t 的粒度可自定义(本文默认为1天)。

3)站点换电需求记录:一个站点换电需求记录 $r_{i,t}$ 为记录站点 s_i 在时段 t 内的用户换电情况,包括一个用于描述影响用户换电需求的特征向量 $\mathbf{v}_{i,t}$, 以及用户换电需求 $d_{i,t}$, 具体表示为 $r_{i,t} = (\mathbf{v}_{i,t}, d_{i,t})$ 。其中特征向量 $\mathbf{v}_{i,t}$ 包括影响用户换电需求的时间特征、空间特征、历史使用特征和气象特征,具体特征设计见 5.1.4 节。表 1 列出了本文主要数学符号说明。

表 1 主要数学符号说明

Table 1 Explanation of main mathematical symbols

Symbols	Meaning of symbols
$s_i, \mathcal{I}, \mathcal{J}$	换电站 s_i , 站点总数量, 换电站网络
z_i, m_i	换电站 s_i 的唯一标识 ID 及地理位置
$d_{i,t}$	换电站 s_i 在时段 t 的用户换电需求
$r_{i,t}, \mathbf{v}_{i,t}$	换电站 s_i 在时段 t 的用户换电需求记录及对应的特征向量
R	历史站点换电需求记录集合
R^h, \mathbf{x}	编码后的站点换电需求记录集合及站点换电需求记录向量
$f(\cdot)$	站点换电需求记录生成模型
C	站点信息(包括站点 ID 和站点空间特征)

3.2.2 站点换电需求记录生成问题

考虑在新城市中换电站网络已经得到初步部署,因此需要通过换电需求预测模型优化换电站网络。站点换电需求记录生成即为生成新的训练样本数据,生成数据进一步与原训练数据相结合,从而增强换电需求预测模型效果。

具体地,给定历史站点换电需求记录集合 R , 需要训练一个模型 $f(\cdot)$, 该模型能够生成和真实站点换电需求记录分布相似的换电需求数据。具体形式如下:

$$\underset{f}{\text{Minimize error}}(D(R), D(\tilde{R})) \quad (14)$$

其中, $D(R)$ 和 $D(\tilde{R})$ 分别表示真实站点换电需求记录分布和生成的站点换电需求记录分布, error 指标可以为 Kolmogorov-Smirnov 统计量^[28] 等数据分布评价指标。

4 基于去噪扩散模型增强的换电需求数据生成算法

4.1 算法框架

为高效进行站点换电需求记录生成,本文提出了基于去




图1 换电需求数据生成算法架构

Fig. 1 Architecture of battery swap demand data generation algorithm

此外,本文对真实换电数据进行了数据分析,发现站点换电需求记录中的历史换电需求及用户换电需求对站点信息(包括站点 ID 和站点空间特征)存在复杂依赖关系。图 2 展示了 4 个站点连续 8 天(前 7 天表示历史换电需求,最后 1 天表示用户换电需求)的用户换电需求情况,可以观察到,同一站点下的每日用户需求数总体趋于稳定,但不同站点的每日用户需求数及随时间变化趋势差距较大,故站点 ID 对历史换电需求及用户换电需求有着重要影响。图 3 展示了两个处于不同功能区的站点一周每天不同小时段的用户换电需求变化情况。从图中可以观察到,由于商业区周末人流流量增多,故站点周末换电需求相比于工作日也会增多,而办公区周末由于工作人员减少,换电需求相比于工作日也会减少,因此站点空间特征对于历史换电需求和用户换电需求有着一定的影响。

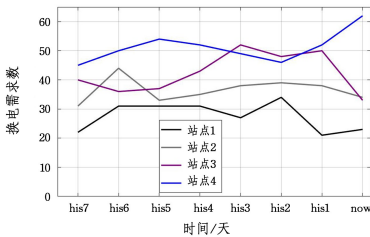




图2 不同站点用户换电需求情况

Fig. 2 User battery swapping demand at different stations



(a)商业区站点换电需求



(b)办公区站点换电需求

图3 站点一周用户换电需求情况

Fig. 3 Weekly user battery swap demand of stations

噪扩散模型增强的换电需求数据生成算法,算法框架如图 1 所示。前向过程和反向过程遵循标准扩散模型。特别地,通过设计站点换电需求记录编码模块,采用模拟位编码^[29]将类别特征转变为连续向量,从而将包含混合数据类型的原始分布转换成为能够被扩散模型学习的连续分布。

由于站点信息(包括站点 ID 和站点空间特征)对于站点换电需求记录生成有着重要影响,同时每个站点的站点信息都是固定不变的,因此提供了以站点信息为条件引导生成高质量站点换电需求记录的机会。为充分捕捉站点信息对站点换电需求记录生成的影响,本文设计了一个基于交叉注意力机制^[30]的条件去噪网络。以站点信息作为条件,并在去噪网络中结合交叉注意力机制进行站点信息与去噪数据的融合,以实现高质量站点换电需求记录生成。

接下来将分别介绍站点换电需求记录编码、基于交叉注意力机制的条件去噪网络、模型训练及采样过程。

4.2 站点换电需求记录编码

传统扩散模型仅作用于连续空间,其中前向和反向过程分别建模成高斯分布,因此针对于包含类别特征和数值特征的站点换电需求记录 R ,无法直接使用扩散模型捕捉其真实数据分布。为应对该挑战,本文使用一种非直接方法捕捉站点换电需求记录原始数据分布,即将每条站点需求记录 $r \in R$ 转变为连续向量 $x \in R^h$,其中 h 表示编码后的数据维度。具体地,本文采用一种称为模拟位编码的可逆编码方法将 r 中的类别特征转换为连续变量,从而将包含混合数据类型的原始数据分布转换成为能够被扩散模型学习的连续分布。在站点换电需求记录生成过程中,首先采样合成数据 x ,之后再逆编码成对应的站点换电需求记录 r 。

模拟位编码^[29]最初用于编码离散图像数据,在本文扩散模型框架中用于预处理站点换电需求记录中的类别特征。给定需求记录数据中的类别特征 A ,首先将 A 中每一类别编码为顺序整数(例如,数值范围从 $0 \sim |A| - 1$),从而将 A 转变为离散数值属性。之后,将属性离散值表示为二进制位,故 A 中的每个变量将会转化为一个二进制变量,即 $\{0, 1\}^h$,其中 $h = \lceil \log_2^{|A|} \rceil$ 。接着,将二进制变量 $\{0, 1\}^h$ 表示为能被连续扩散模型处理的实数,这些实数也称为模拟位,其形式与二进制位相同但表示为实数。在站点换电需求记录生成时,可通过阈值操作将生成的模拟位反转为二进制位,再进一步转换为原始离散数值并解码为相应的类别值。

在数据预处理阶段,站点换电需求记录 R 中类别特征使用模拟位编码进行编码,同时数值属性使用高斯分位数变换^[31]进行标准化处理,数据转换后的站点换电需求记录 R^h 可被连续扩散模型处理。

4.3 基于交叉注意力机制的条件去噪网络

DDPM的关键在于去噪网络 ϵ_θ 的设计,即从噪声数据 x_t 预测噪声。为使去噪网络能高效捕捉站点信息对站点换电需求记录的影响关系,本文提出了一种基于交叉注意力机制的条件去噪网络,具体设计如图4所示。去噪网络输入为时间步 t 、去噪数据 x_t 及站点信息 C ,其中站点信息 C 由编码后的站点ID及站点空间特征拼接而成,即 $C=(\mathcal{F}_{sta}^h, \mathcal{F}_{area}^h)$,去噪网络输出为预测噪声 $\hat{\epsilon}$ 。在去噪网络中,站点信息 C 进行一层全连接层处理输出 C_m ,时间步 t 采用正弦时间嵌入^[32]进行编码,编码后的时间步 t 与去噪数据 x_t 分别进行一层全连接层处理并进行拼接获得数据表示 P ,之后使用交叉注意力机制^[30]实现 C_m 与 P 的融合。具体地,令查询向量 $Q=C_m W_Q$,键向量 $K=PW_K$,值向量 $V=PW_V$,计算交叉注意力输出 A ,具体公式如下:

$$A = \text{Softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V \quad (15)$$

其中, W_Q, W_K, W_V 为线性变换矩阵权重,需要在训练过程中进行学习; d 为矩阵的隐藏维度。交叉注意力输出 A 经过由三层全连接层组成的预测网络处理,最终输出预测噪声 $\hat{\epsilon}$ 。

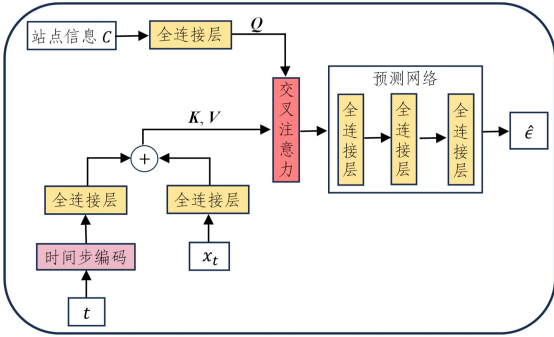


图4 去噪网络设计

Fig. 4 Denoising network design

4.4 模型训练及采样

模型训练阶段如算法1所示。首先站点换电需求记录集合 R 中每条需求记录需进行数据变换,其中类别特征采用模拟位编码进行编码,数值属性则进行标准化处理(第1行)。对数据变换后的需求记录集合 R^h 采样站点换电需求记录向量 x_0 ,随机采样时间步 t 及正态分布噪声 ϵ ,对 x_0 加噪变成时间步 t 的数据 x_t ,加噪过程与式(4)保持一致(第2-6行)。将加噪数据 x_t 、时间步 t 、需求记录向量 x_0 对应的站点信息 C 一同作为去噪网络的输入。去噪网络输出 $\epsilon_\theta(x_t, t, C)$,与噪声计算损失并进行梯度下降训练,直至模型收敛(第7-9行)。

算法1 换电需求数据生成算法训练阶段

输入:站点换电需求记录集合 R ,站点信息 C

输出:训练好的去噪网络 ϵ_θ

1. $R^h = \text{data_transformation}(R)$;
2. Repeat
3. 采样 $x_0 \in R^h$;
4. $t \sim \text{Uniform}(1, 2, \dots, T)$;
5. $\epsilon \sim \mathcal{N}(0, I)$;

6. $x_t = \sqrt{\alpha_t} x_0 + \sqrt{1 - \alpha_t} \epsilon$; /* 加噪过程 */

7. 进行梯度下降;

8. $\Delta_\theta \parallel \epsilon - \epsilon_\theta(x_t, t, C) \parallel^2$;

9. Until 收敛.

如算法2所示,在采样阶段中,将需要生成目标站点换电需求记录的站点信息 C 、待去噪数据 x_t 、时间步 t 一同作为去噪网络的输入,得到去噪网络输出 $\hat{\epsilon}$,同时采样标准高斯分布数据 z ,对 x_t 进行去噪得到 x_{t-1} ,去噪过程与式(6)一致,即从表示 $p_\theta(x_{t-1} | x_t)$ 的正态分布中进行采样,迭代时间步去噪得到生成数据 x_0 (第1-4行)。对生成数据 x_0 中的类别特征进行模拟位逆编码,对数值属性进行去标准化,可获得最终生成的站点换电需求记录 r (第5行)。

算法2 换电需求数据生成算法采样阶段

输入:噪声 $x_T \sim \mathcal{N}(0, I)$,站点信息 C

输出:站点换电需求记录 r

1. for $t = T, \dots, 1$ do

2. $\hat{\epsilon} = \epsilon_\theta(x_t, t, C)$;

3. $z \sim \mathcal{N}(0, I)$;

4. $x_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left(x_t - \frac{\beta_t}{\sqrt{1 - \alpha_t}} \hat{\epsilon} \right) + \sqrt{\frac{1 - \alpha_{t-1}}{1 - \alpha_t}} \beta_t z$; /* 去噪过程 */

5. $r = \text{data_transformation}(x_0)$;

6. return r .

5 实验评估

5.1 实验设置

5.1.1 实验数据集

通过与成都市一家换电企业进行合作,收集了换电平台在成都市2024年9月一个月的真实换电数据集。该数据集包括换电站基本信息(即站点ID和GPS位置)和用户换电记录(即用户ID、电池ID、站点ID和换电时间)。原始数据集共包含由5668个电池、3543名用户和40个换电站组成的50938次用户换电记录。通过统计站点每日换电需求数及提取与换电需求预测相关的特征(特征选择具体见5.1.4节),最终形成包含1200条站点换电需求记录的数据集。每条站点换电需求记录由7个类别特征、7个数值特征和每日用户换电需求组成。

5.1.2 对比算法

为评估本文提出的站点换电需求记录生成模型的数据生成效果,与4类其他生成模型进行对比。1) TVAE^[24]:用于混合类型表格数据生成的变分自编码器模型。2) CTGAN^[24]:基于GAN的合成表格数据生成模型,在表格数据生成中展现出良好的性能。3) TabDDPM^[26]:用于生成通用表格数据的扩散模型,与本文模型不同,其通过采用多项扩散模型处理类别特征。4) CTABGAN⁺^[33]:基于改进GAN的表格数据生成模型,通过在模型中引入Was+GP损失以提升模型训练效果。

5.1.3 评价指标

本节分别在合成数据保真度和换电需求预测误差上评估生成模型的数据生成效果。

1) 数据保真度: 数据保真度描述了合成数据与真实数据之间的分布相似程度。本文数据保真度评估遵循 Sattarov 等^[34]的评估方法, 在列层次和行层次上对生成数据进行评估。在列层次上, 数值属性使用 Kolmogorov-Smirnov 统计量 (KS)^[28] 进行评估, 类别属性使用总变分距离 (TVD)^[35] 进行评估。列保真度分数定义如下:

$$O_{\text{col}}^l = \begin{cases} 1 - \text{KS}(X^l, S^l), & \text{if } l \text{ 为数值型} \\ 1 - \frac{1}{2} \text{TVD}(X^l, S^l), & \text{if } l \text{ 为分类型} \end{cases} \quad (16)$$

其中, X 表示原始数据, S 表示合成数据, l 表示列索引。列保真度为 O_{col}^l 在所有属性的均值。行保真度评估了列属性之间的相关性, 对于数值属性, 使用皮尔森相关系数 (PC)^[36] 进行处理; 对于类别属性, 使用总变分距离 (TVD) 进行处理。行保真度分数定义如下:

$$O_{\text{row}}^{a,b} = \begin{cases} 1 - \frac{1}{2} \text{PC}(X^{a,b}, S^{a,b}), & \text{if } a, b \text{ 为数值型} \\ 1 - \frac{1}{2} \text{TVD}(X^{a,b}, S^{a,b}), & \text{if } a, b \text{ 为分类型} \end{cases} \quad (17)$$

其中, X 表示原始数据, S 表示合成数据, a 和 b 表示列索引。行保真度为 $O_{\text{row}}^{a,b}$ 在所有属性对的均值。生成数据的数据保真度分数表示为 O^* , 为列保真度和行保真度的均值。

2) 换电需求预测误差: 为评估合成数据对换电需求预测的增强效果, 分别使用 4 种回归预测模型对原始训练数据和基于合成数据增强的训练数据进行训练, 即 XGBoost、随机森林、KNN、决策树, 并在同一测试数据上测试回归模型的换电需求预测误差。换电需求预测评价指标选用平均绝对误差 (MAE)、均方根误差 (RMSE) 和平均绝对百分比误差 (MAPE), 具体计算过程如下:

$$\text{MAE} = \frac{1}{n} \sum_{k=1}^n |y^{(k)} - \hat{y}^{(k)}| \quad (18)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n |y^{(k)} - \hat{y}^{(k)}|^2} \quad (19)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{k=1}^n \left| \frac{y^{(k)} - \hat{y}^{(k)}}{y^{(k)}} \right| \quad (20)$$

其中, n 为样本数量, $y^{(k)}$ 为真实值, $\hat{y}^{(k)}$ 为预测值。总体换电需求预测误差表示为 4 种回归模型的平均 MAE 值、RMSE 值和 MAPE 值。

5.1.4 特征选择

基于对换电平台数据的深入分析, 本文共提取以下与换电需求预测相关的 4 类特征。

1) 时间特征 \mathcal{F}_T 。用户换电需求与时间因素密切相关, 图 3 展示了两个站点在一周每天不同小时段的用户换电需求情况, 从图中可以观察到, 站点每周不同天的需求变化的高峰有所差异, 故用户需求时间模式不同。此外, 周末的用户换电需求与工作日也有着较大区别。因此针对时间特征, 共提取两类特征: 一周的天数 \mathcal{F}_{dow} 及节假日 \mathcal{F}_{hol} 。

2) 空间特征 \mathcal{F}_S 。如图 3 所示, 用户需求呈现空间模式。商业区周末人流量增多, 为服务更多顾客, 站点骑手用户的换电需求也会增多, 而办公区周末由于工作人员减少, 站点用户换电需求也会减少。本文遵循 Yuan 等的方法^[37], 将城市划

分为七大功能区 (即住宅区、娱乐区、商业区、办公区、教育区、风景区和郊区), 从而捕捉站点换电需求的空间模式。特征表示为站点所处的功能区类别 $\mathcal{F}_{\text{area}}$ 。

3) 历史使用特征 \mathcal{F}_H 。由于站点用户需求在邻近天数中呈现相似的变化趋势 (见图 3), 因此可通过站点运营数据捕捉历史换电需求模式。具体特征包括过去 7 天的换电需求 (即 $\mathcal{F}_{\text{his1}}, \mathcal{F}_{\text{his2}}, \mathcal{F}_{\text{his3}}, \mathcal{F}_{\text{his4}}, \mathcal{F}_{\text{his5}}, \mathcal{F}_{\text{his6}}, \mathcal{F}_{\text{his7}}$) 和站点 ID \mathcal{F}_{sta} 。

4) 气象特征 \mathcal{F}_M 。环境特征 (如天气) 对人们的出行有着重要影响, 同样也会影响用户换电行为。通过收集气象数据并从中抽取可用于换电需求预测的特征, 具体分别抽取了 3 类特征: 天气 \mathcal{F}_{wea} 、温度 \mathcal{F}_{tem} 和风速 $\mathcal{F}_{\text{wind}}$ 。其中, 天气分为 3 类, 分别是晴朗、下雨、下雪; 温度有 3 类取值, 分别是寒冷 (< 15 度)、温和 ($15 - 30$ 度)、炎热 (≥ 30 度); 风速分为两类, 分别是轻 (≤ 3 级) 和重 (> 3 级)。

换电需求预测特征共有 14 个, 其中 7 个历史换电需求特征为数值特征, 其余特征为类别特征。

5.1.5 训练过程

实验数据集按照 8:2 的比例分为训练集和测试集。扩散模型在训练集上进行训练, 训练好的模型生成与训练集规模相同的换电需求数据, 并与原训练集相结合用于需求预测模型训练, 最终在测试集进行换电需求预测性能评估。扩散模型的训练轮数设为 500 轮, batch size 设为 512, 扩散步数设为 500 步。

5.2 实验结果

5.2.1 数据保真度评估

首先对比本文换电需求数据生成算法与其他对比算法在数据保真度上的性能差异。实验结果如图 5 所示, 本文算法相比于其他 3 种对比算法的数据生成质量最佳, 其数据保真度分数为 0.9471。CTABGAN+, TVAE, CTGAN 和 TabDDPM 相比于本文算法的数据保真度分数分别降低 7.48%, 9.07%, 13.13% 和 19.11%。实验结果表明, 本文算法能够准确捕捉真实站点换电需求记录的数据分布。

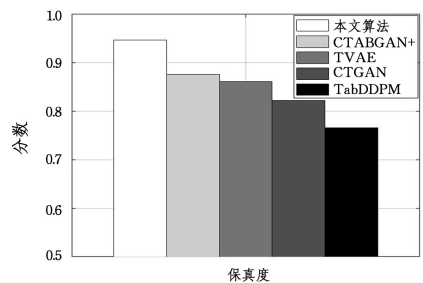


图 5 数据保真度对比结果

Fig. 5 Comparison results of data fidelity

为进一步理解本文算法及对比算法生成的换电需求数据与真实数据的分布差异, 通过 t-SNE 降维方法^[38]对生成数据及真实数据分布进行了可视化。如图 6 所示, TabDDPM, CTGAN 和 TVAE 没有很好地学习到真实数据分布, 而 CTABGAN+ 的生成数据与真实数据分布有一定差距, 本文算法的生成数据则符合真实数据分布。

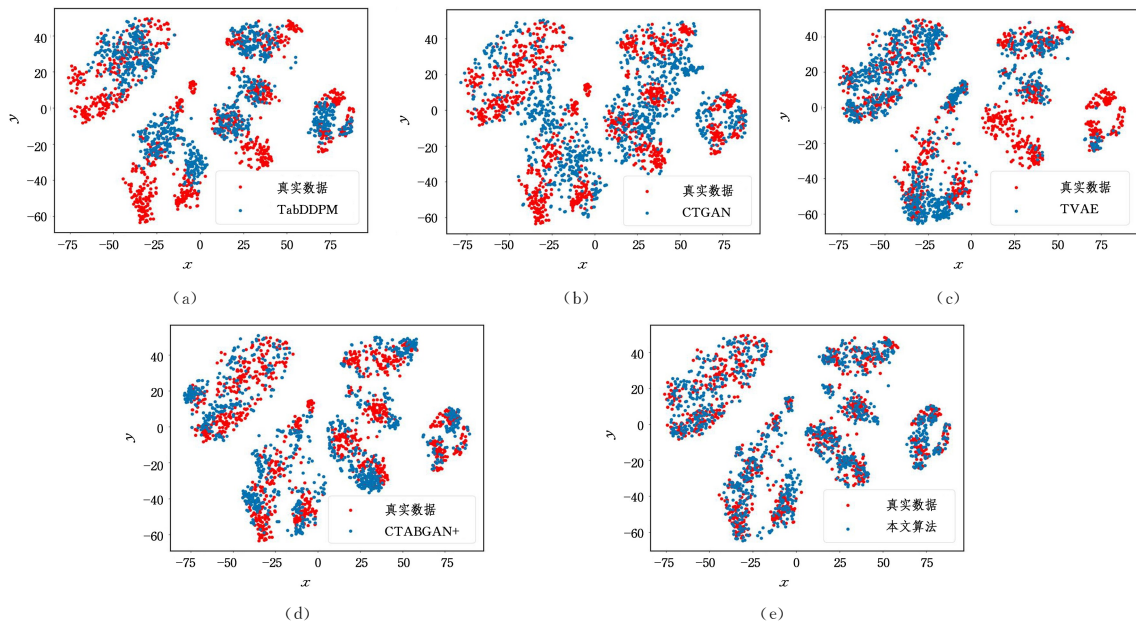


图6 真实数据及生成数据的 t-SNE 可视化

Fig.6 t-SNE visualization of the real-world data and generated data

5.2.2 换电需求预测精度评估

在本实验中,将本文算法与其他生成算法及直接使用原训练数据训练的换电需求预测模型进行了换电需求预测误差结果对比。如图7所示,相比于所有对比算法,基于本文算法进行训练数据增强后的需求预测误差最低,MAE, RMSE, MAPE 误差分别为 5.797,7.313,14.21%,比直接使用原训练数据进行训练的换电需求预测模型预测误差在 MAE, RMSE, MAPE 指标上分别降低了 9.29%,8.56%,8.23%。同时,基于训练数据增强后的换电需求预测误差相对于直接使用原训练数据训练的换电需求预测模型都有不同程度的降低,本文算法的3种换电需求预测误差指标相比次优算法分别降低了 3.11%,2.64%,1.93%。实验结果表明,本文算法能够有效保留换电需求数据的关键特征信息,从而降低换电需求预测误差。

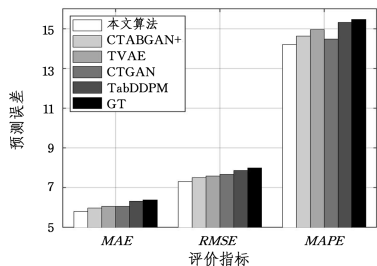


图7 换电需求预测误差对比结果

Fig.7 Comparison results of battery swap demand prediction errors

此外,为直观展现使用本文算法进行训练数据增强的换电需求预测情况,对两个站点2024年9月1日—2024年9月21日的换电需求预测结果进行了可视化,同时对比了直接使用原训练数据训练的换电需求预测情况。具体如图8和图9所示,横坐标表示预测的日期,纵坐标表示用户换电需求。从图中可以明显观察到,训练数据增强后的换电需求预测比直

接使用原训练数据训练的预测结果更接近于真实换电需求。结果表明,通过将本文算法生成数据与原训练数据相结合用于换电需求预测模型的训练,可有效提升模型的换电需求预测精度。




图8 站点1换电需求预测情况

Fig.8 Battery swap demand prediction at station 1




图9 站点2换电需求预测情况

Fig.9 Battery swap demand prediction at station 2

5.2.3 消融实验

首先为探究不同类别特征编码方法对换电需求数据生成效果的影响,分别对本文使用的模拟位编码、embedding 编码^[34]及 one-hot 编码^[26]进行性能评估,只改变类别特征编码方法,算法其余模块保持不变。具体实验结果如图10所示,模拟位编码数据保真度分数最高,而 one-hot 编码效果最差。实验结果表明,不同编码方法对生成数据效果有一定影响,模

拟位编码由于简洁高效的编码方式,能够有效处理类别特征。




图 10 不同类别数据编码方法保真度评估

Fig. 10 Fidelity assessment of different categorical data encoding methods

之后探究了条件信息模块对生成算法的性能影响。具体地,通过保持算法其余模块不变,分别采用条件信息模块与去除条件信息模块(Ours w/o C)进行数据生成,对比生成数据的数据保真度及换电需求预测误差。数据保真度实验结果如图 11 所示,去除条件信息模块后,数据生成质量下降 4.73%。需求预测误差实验结果如图 12 所示,在去除条件信息模块后,需求预测误差 MAE, RMSE 和 MAPE 分别增加 4.12%, 3.53% 和 3.31%。实验结果验证了使用站点信息引导的条件信息模块能够有效提升算法的数据生成质量及换电需求预测效果,表明站点信息引导模块在换电需求数据生成中起着重要作用。




图 11 去除条件信息模块数据保真度对比结果

Fig. 11 Comparison results of data fidelity without conditional information module

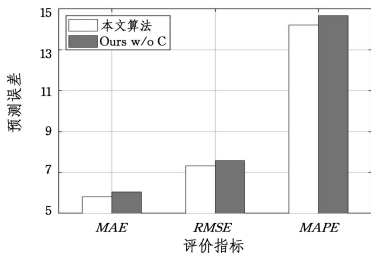




图 12 去除条件信息模块换电需求预测误差对比结果

Fig. 12 Comparison results of battery swap demand prediction errors without conditional information module

为进一步理解有无站点信息引导的站点换电需求记录生成情况,对只保留历史使用特征、空间特征及用户换电需求的站点换电需求记录进行了 t-SNE 可视化,如图 13 所示。从图中可以观察到,使用站点信息引导生成的站点换电需求记录相比于去除条件信息模块更加符合真实数据分布,表明使用站点信息引导能够生成更符合站点本身特点的站点换电需求记录。



(a) 去除站点点信息



(b) 使用站点点信息

图 13 去除条件信息模块生成数据 t-SNE 可视化

Fig. 13 t-SNE visualization of generated data without conditional information module

5.2.4 超参数分析

本节探究了扩散模型中扩散步数对算法性能的影响。如图 14 所示,随着扩散步数逐渐从 20 增加到 500,基于生成数据增强的换电需求预测误差也逐渐降低。其中,当扩散步数从 20 增加到 500 时,换电需求预测误差 MAE, RMSE 和 MAPE 分别降低了 6.68%, 6.27% 和 8.38%。这是因为扩散模型中扩散步数的增加能延长去噪过程,有效消除去噪数据的不确定性,提升站点换电需求记录生成质量,最终降低换电需求预测误差。




图 14 不同扩散步数对换电需求预测误差的影响

Fig. 14 Impact of different diffusion steps on the battery swap demand prediction errors

6 总结与展望

6.1 研究总结

本文设计了一种基于去噪扩散模型增强的换电需求数据生成算法。通过生成与换电需求预测模型训练数据分布相似的换电需求数据并与原训练数据相结合,可提升换电站新部署城市换电需求预测模型预测精度。具体地,为使扩散模型能够处理换电需求数据,使用模拟位编码将混合类型换电需求数据映射到能被扩散模型处理的同一连续向量空间。此外,设计了一种基于交叉注意力机制的条件去噪网络,并使用

站点信息引导生成高质量换电需求数据。最后在成都市真实换电数据集上进行实验评估,实验结果表明,所提算法生成的换电需求数据与原训练数据相结合能有效提升换电需求预测模型的预测精度。

6.2 未来展望

未来研究主要包括以下3个方面。1)本文研究的是对换电站新部署城市换电需求预测模型的训练数据进行增强,但对预测模型并没有深入研究。下一步会继续研究预测模型,如采用集成学习^[39]的方式,进一步提升换电需求预测精度。2)本文仅验证了在一个城市数据集的换电需求预测增强效果,未来会进一步在换电需求数据生成算法中融入更多城市信息(如POD),并在多个城市数据集中验证算法的有效性。3)本文尚未对算法实际应用进行实验探究。因此,探讨算法实际应用,如优化换电站电池调度任务,将是下一步研究工作。

参 考 文 献

- [1] WU H. A survey of battery swapping stations for electric vehicles: Operation modes and decision scenarios[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 23(8): 10163-10185.
- [2] KO H, PACK S, LEUNG V C M. An optimal battery charging algorithm in electric vehicle-assisted battery swapping environments[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 23(5): 3985-3994.
- [3] ZHOU E, LI Z, LIU D, et al. Balancing Electric Scooter Battery Swapping Network by Spatio-Temporal Recommendation[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(12): 21315-21326.
- [4] SARKER M R, PANDZIC H, ORTEGA-VAZQUEZ M A. Optimal operation and services scheduling for an electric vehicle battery swapping station[J]. *IEEE Transactions on Power Systems*, 2014, 30(2): 901-910.
- [5] CUI D, WANG Z, LIU P, et al. Operation optimization approaches of electric vehicle battery swapping and charging station: A literature review[J]. *Energy*, 2023, 263: 126095.
- [6] Xinhuanet. Writing the Digital Epic, Sharing the New Quality Future | China Tower Featured at the 2024 China International Fair for Trade in Services. [EB/OL]. (2024-09-13) [2025-05-18] <http://www.xinhuanet.com/info/20240913/f9e2190e701345969cb0fad08254c5b9/c.html>.
- [7] WANG S, CHEN A, WANG P, et al. Short-term electric vehicle battery swapping demand prediction: Deep learning methods[J]. *Transportation Research Part D: Transport and Environment*, 2023, 119: 103746.
- [8] CHENG W, LU H, XIANG C, et al. Breaking ‘Chicken-Egg’: Cross-city Battery Swap Demand Prediction via Knowledge-guided Diffusion[C]// *IEEE INFOCOM 2025 - IEEE Conference on Computer Communications*. IEEE, 2025: 1-10.
- [9] CHATTERJEE S, HAZRA D, BYUN Y C. GAN-based synthetic time-series data generation for improving prediction of demand for electric vehicles[J]. *Expert Systems with Applications*, 2025, 264: 125838.
- [10] ZHANG Z, WANG L, LIU Y, et al. A GAN-Based Ensemble Model for Predicting the Demand of Shared Bikes in 5G Networks[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 25(3): 2869-2879.
- [11] CROITORU F A, HONDRU V, IONESCU R T, et al. Diffusion models in vision: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(9): 10850-10869.
- [12] KANDWAL S, NEHRA V. A survey of text-to-image diffusion models in generative AI[C]// *2024 14th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*. IEEE, 2024: 73-78.
- [13] LOVELACE J, KISHORE V, WAN C, et al. Latent diffusion for language generation[J]. *Advances in Neural Information Processing Systems*, 2023, 36: 56998-57025.
- [14] CHEN N, ZHANG Y, ZEN H, et al. Wavegrad: Estimating gradients for waveform generation[J]. arXiv:2009.00713, 2020.
- [15] KONG Z, PING W, HUANG J, et al. Diffwave: A versatile diffusion model for audio synthesis[J]. arXiv:2009.09761, 2020.
- [16] SOHL-DICKSTEIN J, WEISS E, MAHESWARANATHAN N, et al. Deep unsupervised learning using nonequilibrium thermodynamics[C]// *International Conference on Machine Learning*. PMLR, 2015: 2256-2265.
- [17] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 6840-6851.
- [18] SONG J, MENG C, ERMON S. Denoising diffusion implicit models[J]. arXiv:2010.02502, 2020.
- [19] DHARIWAL P, NICHOL A. Diffusion models beat gans on image synthesis[J]. *Advances in Neural Information Processing Systems*, 2021, 34: 8780-8794.
- [20] LIN L, LI Z, LI R, et al. Diffusion models for time-series applications: a survey[J]. *Frontiers of Information Technology & Electronic Engineering*, 2024, 25(1): 19-41.
- [21] FONSECA J, BACAO F. Tabular and latent space synthetic data generation: a literature review[J]. *Journal of Big Data*, 2023, 10(1): 115.
- [22] YANG J, WU P, CONG G, et al. SAM: Database generation from query workloads with supervised autoregressive models[C]// *Proceedings of the 2022 International Conference on Management of Data*. 2022: 1542-1555.
- [23] GERMAIN M, GREGOR K, MURRAY I, et al. Made: Masked autoencoder for distribution estimation[C]// *International Conference on Machine Learning*. PMLR, 2015: 881-889.
- [24] XU L, SKOULARIDOU M, CUESTA-INFANTE A, et al. Modeling tabular data using conditional GAN[C]// *Advances in Neural Information Processing Systems*. 2019.
- [25] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]// *Advances in Neural Information Processing Systems*. 2014.
- [26] KOTELNIKOV A, BARANCHUK D, RUBACHEV I, et al. Tabddpm: Modelling tabular data with diffusion models[C]// *International Conference on Machine Learning*. PMLR, 2023: 17564-17579.

- [27] THANH-TUNG H, TRAN T. Catastrophic forgetting and mode collapse in GANs[C] // 2020 International Joint Conference on Neural Networks(IJCNN). IEEE, 2020; 1-10.
- [28] MASSEY JR F J. The Kolmogorov-Smirnov test for goodness of fit[J]. Journal of the American Statistical Association, 1951, 46(253): 68-78.
- [29] CHEN T, ZHANG R, HINTON G. Analog bits; Generating discrete data using diffusion models with self-conditioning[J]. arXiv:2208.04202, 2022.
- [30] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017; 6000-6010.
- [31] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, et al. Scikit-learn; Machine learning in Python[J]. The Journal of Machine Learning Research, 2011, 12: 2825-2830.
- [32] NICHOL A Q, DHARIWAL P. Improved denoising diffusion probabilistic models[C] // International Conference on Machine Learning. PMLR, 2021; 8162-8171.
- [33] ZHAO Z, KUNAR A, BIRKE R, et al. CTAB-GAN+: Enhancing tabular data synthesis[J]. Frontiers in Big Data, 2024, 6: 1296508.
- [34] SATTAROV T, SCHREYER M, BORTH D. Findiff; Diffusion models for financial tabular data generation[C] // Proceedings of the Fourth ACM International Conference on AI in Finance. 2023; 64-72.
- [35] VERDÚ S. Total variation distance and the distribution of relative information[C] // 2014 Information Theory and Applications Workshop(ITA). IEEE, 2014; 1-3.
- [36] BENESTY J, CHEN J, HUANG Y, et al. Pearson correlation coefficient[M] // Noise reduction in speech processing. Berlin: Springer, 2009; 1-4.
- [37] YUAN J, ZHENG Y, XIE X. Discovering regions of different functions in a city using human mobility and POIs[C] // Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2012; 186-194.
- [38] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9(11): 2579-2605.
- [39] DONG X, YU Z, CAO W, et al. A survey on ensemble learning [J]. Frontiers of Computer Science, 2020, 14: 241-258.



LIU Dehua, born in 2000, master. His main research interests include urban computing and generative model.



QIAO Jinlan, born in 1990, master, lecturer. Her main research interests include operational research, big data intelligence and AI.

(责任编辑:喻黎)