

人工智能教学研究：以生成模型下的射频指纹数据增强为例

李广博^{1*} 李慢¹ 简蕊¹ 刘雯秀¹ 关曼玉²

(1. 淮北理工学院电子与信息工程学院, 安徽 淮北 235000, 2. 淮北理工学院经济与管理学院, 安徽 淮北 235000)

摘要：AI生成内容(AIGC)技术的迅猛发展为突破数据瓶颈提供了新范式。其中，去噪扩散概率模型(DDPM)因其通过渐进式加噪与去噪的马尔可夫过程学习数据分布，具备训练稳定、生成质量高的优势，在复杂数据建模中展现出巨大潜力。本文将DDPM应用于射频指纹识别(RFF)领域，针对小样本场景下深度模型因数据稀缺导致的过拟合与性能下降问题，提出基于DDPM的数据增强框架，旨在合成高保真射频指纹信号以扩充训练集。与生成对抗网络(GAN)、变分自编码器(VAE)等主流生成模型相比，DDPM能更精准地捕捉和重建无线设备硬件损伤的细微特征。实验结果表明：在每类仅10个原始样本的条件下，DDPM生成的信号在关键评价指标上均显著优于WGAN、VAEGAN和DCGAN——均方根误差(RMSE)低至0.197(较次优降低64.4%)，峰值信噪比(PSNR)达14.003(提升160%)，频谱相干性(FSCS)达0.983(提升58.3%)，Fréchet距离(FD)仅39.4(降低93.6%)。IQ图、频谱图和星座图的可视化对比进一步证实了DDPM生成信号在时域、频域的高保真度。本研究表明，基于DDPM的AIGC方法能有效生成高鉴别性射频指纹信号，为小样本RFF识别提供了高效的数据增强解决方案。

关键词：去噪扩散概率模型(DDPM)；数据增强；射频指纹；生成对抗网络；变分自编码器

基金项目：安徽省教育厅自然科学研究项目(重大)(2024AH040217)；省级质量工程-教学研究项目(2023jyxm1009；2023xjzlt117；2023sdx145)；基于人工智能下的家禽康养与疾病预警技术研究(S202413620055)；基于自监督学习与对抗增强的小样本信号的智能感知研究(2025SK019)；基于深度学习的生猪识别与康养研究(S202513620083)；安徽省智慧农业技术与装备重点实验室开放基金(AEC2026016；AEC2025009)

DOI: doi.org/10.65436/hssj.v1i6.40

在当今信息技术迅猛发展的时代，人工智能(AI)已成为推动科技创新与社会变革的核心驱动力。作为其重要分支，生成式人工智能(Generative AI)在图像合成、自然语言处理、跨模态内容生成等领域展现出巨大潜力，正深刻改变着内容创作、媒体传播、教育科研乃至工业设计的范式。尤其在以数据为驱动力的智能时代，生成模型不断拓展着机器理解与创造能力的边界。

近年来，扩散模型(Diffusion Models)凭借强大的生成质量与训练稳定性，迅速崛起为生成式人工智能的主流架构^[1]。相较于生成对抗网络(GAN)的训练不稳定性 and 变分自编码器(VAE)的生成质量局限，扩散模型通过模拟物理扩散过程，以渐进式去噪的方式实现数据生成，在多个任务中展现出卓越性能，成为推动AIGC(人工智能生成内容)技术落地的关键引擎。其中，去噪扩散概率模型(Denoising Diffusion Probabilistic Models, DDPM)作为扩散模型的重要理论实现，通过严谨的数学框架(前向加噪与反向去噪马尔可夫链)和变分推断优化，实现了高效稳定的训练和高保真、多样化的样本生成，为Stable Diffusion等有影响力的系统提供了理论基础。

¹ **作者简介：**李广博(1997—)，男，安徽淮北人，讲师，博士。研究方向：人工智能、智能信号感知、模式识别、计算机视觉等；
李慢(2005—)，女，安徽池州人，本科生。研究方向：人工智能；
简蕊(2004—)，女，安徽蚌埠人，本科生。研究方向：人工智能与信号识别；
刘雯秀(2005—)，女，安徽滁州人，本科生。研究方向：人工智能；
关曼玉(1998—)，女，安徽淮北，硕士，助教。研究方向：人工智能与大数据。

通讯作者：李广博

而本文聚焦的射频指纹识别（Radio Frequency Fingerprinting, RFF）或称辐射源个体识别（Specific Emitter Identification, SEI）领域，正面临严峻的数据挑战。RFF 旨在利用无线设备硬件固有损伤造成的信号细微差异实现唯一设备识别，其难以复制的特性在军事侦察、物联网安全和频谱管理等非合作场景中至关重要。尽管深度学习方法凭借强大的特征学习能力，显著提升了 RFF 的准确性、鲁棒性和适应性，克服了传统方法依赖人工特征设计的局限，但其优异性能高度依赖于大量标注完备的训练数据。

然而，在实际应用中，特别是在非合作场景下，获取特定目标辐射源的大量高质量样本极其困难且成本高昂。数据的严重稀缺构成了深度学习 RFF 方法的主要瓶颈，导致模型在小样本条件下极易过拟合，识别性能急剧恶化。因此，亟需高效的数据增强解决方案来克服这一数据瓶颈。

生成模型作为学习数据潜在分布以合成新样本的代表性方法，为缓解数据稀缺问题提供了新思路。当前主流深度生成模型如 GAN、VAE 应用于射频信号生成时各有局限^[2-4]：GAN 存在模式崩溃和训练不稳定问题；VAE 生成的信号则往往模糊，难以捕捉硬件损伤的细微特征。

基于上述背景与挑战，并鉴于扩散模型（特别是 DDPM）在训练稳定性、生成质量（克服模糊缺陷）和严格概率建模方面的突出优势，本文提出采用扩散模型构建射频指纹生成框架^[5-7]。该框架旨在高效合成具有高鉴别性的辐射源信号，从而为下游深度 RFF 模型在小样本条件下克服数据瓶颈提供关键支持。

本文通过以下两方面进行展开：

1. 理论讲解和实际应用：针对小样本辐射源识别中数据匮乏的难题，本文提出采用去噪扩散概率模型（DDPM）进行数据增强。DDPM 通过前向扩散过程（FDP）逐步向原始 IQ 信号添加高斯噪声直至其变为随机噪声，再通过反向扩散过程（RDP）训练一个改进的 U-Net 网络（加入时间条件嵌入模块以感知扩散步长）来逐步预测并去除噪声，从而重建或生成高保真信号。该模型能有效学习辐射源 IQ 信号独特的调制模式（如相位噪声、频谱特征）和非平稳特性，为下游识别任务提供高质量的合成数据，缓解小样本问题。

2. 实验验证：实验在极低样本量（每类仅 10 个原始样本）下进行，对比了 DDPM 与主流生成模型（WGAN, DCGAN, VAEGAN）。结果表明，DDPM 在所有评价指标上均显著最优：其生成信号的时域保真度（RMSE=0.197）、信噪比（PSNR=14.003）、频谱一致性（FSCS=0.983）和时空结构相似性（FD=39.4）均大幅领先次优模型（提升幅度达 58.3%-160%）。IQ 图、频谱图、星座图等多维度可视化对比及概率密度分布高度吻合进一步直观证实了 DDPM 生成信号在时域、频域和统计特性上的卓越保真度，验证了其用于小样本射频指纹数据增强的可行性与优越性。

一、理论部分

（一）DDPM 原理

在小样本辐射源 IQ 信号识别任务中，数据稀缺性显著制约了深度识别模型的泛化性能。为缓解此问题，本文采用射频扩散模型（DDPM）的数据增强策略，该方法通过建模辐射源 IQ 信号的时空分布特性，生成高质量的合成信号以扩充训练集。

辐射源 IQ 信号具有独特的调制模式（如相位噪声、频谱特征）和非平稳特性，DDPM 的似然优化框架通过在连续时间域上执行渐进式噪声注入与去除，能有效拟合此类复杂分布。

具体而言，DDPM 主要由前向扩散过程（Forward Diffusion Process, FDP）加噪、模型训练、反向扩散过程（Reverse Diffusion Process, RDP）去噪组成，见下图：




图 1 RF-DM 模型生成流程

FDP 对原始信号 x_0 逐步添加高斯噪声，给定初始信号样本 $x_0 \sim q(x_0)$ ，该过程构建马尔可夫链：

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

其中每个扩散步骤由线性高斯转移核定义：

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

式中 $\beta_t \in (0,1)$ 为噪声调度系数，控制第 t 步的噪声注入强度， β_t 与 t 的关系为：
 $(\beta_1 < \dots < \beta_t < \dots < \beta_T)$ 。通过累积 T 步扩散，信号 x_T 最终收敛于标准正态分布 $\mathcal{N}(0, \mathbf{I})$ 。任意时刻状态信号 x_t 扩散状态可表示为下式：

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \varepsilon \quad (3)$$

其中， $\bar{\alpha}_t$ 是原始信号的保留系数，随 t 增大呈指数衰减， ε 是随机噪声向量，服从标准多维高斯分布。

RDP 就是对 FDP 加噪后的信号 x_T 去噪的过程。通过训练一个 U-Net 神经网络来预测 x_T 中每一步的噪声，从而逐步去除噪声并恢复原始信号。

RDP 通过可学习参数 θ 构建逆向马尔可夫链，见下式，从噪声 $x_T \sim \mathcal{N}(0, \mathbf{I})$ 逐步重构清晰信号 x_0 ：

$$p_\theta(x_{0:T}) = p(x_T) \prod_{t=1}^T p_\theta(x_{t-1} | x_t) \quad (4)$$

其中，每一时间步的条件分布由神经网络预测，见下式。其中 $\mu_\theta(x_t, t)$ 与 $\Sigma_\theta(x_t, t)$ 分别代表 x_t 的均值与协方差。

$$p_\theta(x_{t-1} | x_t) = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t), \Sigma_\theta(x_t, t)) \quad (5)$$

具体生成步骤通过噪声预测实现，如下式。其中， $\varepsilon_\theta(x_t, t)$ 为 U-Net 预测的噪声分量，逐步消除前向过程注入的干扰。 σ_t 代表重建过程的条件方差。 $z \sim \mathcal{N}(0, \mathbf{I})$ 是独立于模型预测的随机噪声向量，确保生成多样性。

$$x_{t-1} = \frac{1}{\sqrt{1 - \beta_t}} \left(x_t - \frac{\beta_t}{\sqrt{1 - \bar{\alpha}_t}} \varepsilon_\theta(x_t, t) \right) + \sigma_t z \quad (6)$$

$$\sigma_t^2 = \frac{1 - \bar{\alpha}_{t-1}}{1 - \bar{\alpha}_t} \beta_t, \quad z \sim \mathcal{N}(0, \mathbf{I}) \quad (7)$$

RDP 的目标是最小化预测噪声与真实噪声的 L2 范数距离，从而尽可能准确的恢复原始信号。

$$L(\varepsilon_\theta) = \sum_{t=1}^T \bar{\alpha}_{x_0, \varepsilon, t} \left[\left\| \varepsilon - \varepsilon_\theta \left(\sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \varepsilon, t \right) \right\|_2^2 \right] \quad (8)$$

损失函数 $L(\varepsilon_\theta)$ 通过期望运算覆盖所有时间步与数据分布，确保神经网络精准学习辐射源 IQ 信号的相位噪声和频谱调制特征。

(二) U-Net 神经网络

U-Net 模型是一种采用编码器-解码器对称结构并结合跳跃连接的卷积神经网络。

编码器模块通过连续的卷积操作与池化层实现特征的下采样，逐步提取输入信号的高层语义特征；解码器模块借助转置卷积或上采样操作实现特征图的尺寸恢复，逐步还原信号的空间细节；瓶颈层模块通过深层卷积运算捕获信号的核心抽象特征，是连接编码器与解码器的关键信息枢纽。其独特的跳跃连接设计将编码器中不同层次的特征图直接传递至解码器对应层，有效保留了信号恢复过程中所需的细节信息与空间定位特征。

DDPM 中的 U-Net 模型在原始结构基础上引入了时间条件嵌入模块，使其能够感知扩散过程中的时间步长信息，这一改进使模型能够根据扩散过程的时间信息动态调整特征提取与恢复策略，从而更精准地建模信号生成过程中的时序依赖关系与概率分布特性。下图为改进后的 U-Net 模型示意图。




图 2 U-Net 模型示意图

二、结果

(一) 评价指标

生成信号的优劣需要合适的评价指标进行验证。为了全面验证生成信号的可行性，本文采用了 6 种常用的评价指标，具体如下：

令原始 IQ 信号为 $\mathbf{X}_r = \{x_r[n]\}_{n=1}^N$ ，生成信号为 $\mathbf{X}_g = \{x_g[n]\}_{n=1}^N$ ，其中 N 为采样点数。

均方根误差 (RMSE)，反映生成信号与原始信号的时域能量差异，值越低表明时域保真度越高。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{n=1}^N (|x_r[n] - x_g[n]|^2)} \quad (9)$$

峰值信噪比 (PSNR)，评估信号动态范围与噪声水平，值越高表明生成质量越接近无损。

$$\text{PSNR} = 10 \log_{10} \left(\frac{\max(|x_r[n]|^2)}{\text{RMSE}^2} \right) \quad (10)$$

频谱相干性（FSCS），量化频谱结构的匹配程度（值域[0,1]），接近 1 表明频域特征高度一致。其中 $S(f_k)$ 为离散傅里叶变换系数， K 为频点数。

$$\text{FSCS} = \frac{\sum_{k=1}^K |S_r(f_k) \cdot S_g^*(f_k)|}{\sqrt{\sum_{k=1}^K |S_r(f_k)|^2} \cdot \sqrt{\sum_{k=1}^K |S_g(f_k)|^2}} \quad (11)$$

Fréchet 距离（Fréchet Distance, FD），通过测量生成信号与原始信号轨迹在时空演化过程中的结构相似性，提供了一种严格的几何相似度度量。 $d(\cdot, \cdot)$ 为生成信号与原始信号对应点之间的欧氏距离函数。

$$\text{FD}(X_r, X_g) = \min \left(\max_{n \in V} d(x_r[n], x_g[n]) \right) \quad (12)$$

（二）实验验证

本文将 DDPM、VAE-GAN、WGAN 和 DCGAN 等算法进行了比较^[2-7]，见表 1。表 1 中，箭头向下代表数值越效果越好，箭头向上代表参数值越大越好。四种算法训练次数均为 1000 次，每类原始样本为 10 个，生成样本为每类 50 个。表 1 可得，DDPM 在四种生成评价指标中效果均为最佳。DDPM 算法在均方根误差（RMSE）次优算法 DCGAN 提升 64.4%；峰值信噪比（PSNR）较次优算法 DCGAN 提升 160%；频谱相干性（FSCS）较次优算法 VAEGAN 提升 58.3%；Fréchet 距离（Fréchet Distance, FD）较次优算法 DCGAN 提升 93.6%。根据实验结果进一步说明 DDPM 算法在生成射频指纹数据的可行性。

表 1 不同生成模型的生成效果对比

Models	RMSE ↓	PSNR ↑	FSCS ↑	FD ↓
DDPM	0.197	14.003	0.983	39.409
WGAN	0.692	3.035	0.194	966.036
VAEGAN	0.598	4.414	0.621	717.656
DCGAN	0.554	5.223	0.580	615.219

为了进一步说明不同生成模型的效果，本文将 4 种生成模型生成示意图进行对比，见图 3。图 3 中包含了 IQ 图、频谱图、星座图，可以看出 DDPM 在时域、频域均有不错的表现。生成模型的 IQ 图中，DDPM、WGAN、DCGAN、VAEGAN 均有不同程度的偏移，DDPM 效果明显最佳，WGAN、DCGAN 次之，VAEGAN 效果最差；频谱图中 DDPM 生成的效果十分逼近原始信号，WGAN、DCGAN、VAEGAN 均有较大程度的震荡；星座图中，DDPM 生成效果明显优于 WGAN、DCGAN、VAEGAN 生成效果。




图3 生成模型效果对比图

图4为DDPM生成的信号与真实信号之间的概率密度比较。图4中可以观察到，四种不同生成信号和原始信号的概率密度虽然有一定的误差，但整体都近似呈正态分布。尤其是最后一个生成的信号和原始信号的分布形状高度相似，生成概率密度与实际信号的概率密度几乎重叠，表明生成的信号高度相似，从而进一步说明DDPM模型生成信号的可行性，为下游任务的小样本射频指纹识别提供坚实的数据基础。




图4 DDPM 生成信号概率分布差异图

三、结论

本文针对小样本射频指纹识别（RFF）中训练数据严重不足制约模型性能的关键问题，创新性地提出了基于轻量级去噪扩散概率模型（DDPM）的数据增强框架。通过系统地研究DDPM在合成高保真射频信号方面的能力，并采用多维度评价指标（RMSE, PSNR, FSCS, FD）和可视化手段进行严格验证，得出以下主要结论：

1. DDPM在射频信号生成任务中展现出显著优势：相较于易陷入模式崩溃且训练不稳定的GAN模型（如WGAN, DCGAN）以及生成信号易模糊的VAE衍生模型（如VAEGAN），本文采用的DDPM框架通过其渐进式加噪-去噪的马尔可夫过程，结合改进的U-Net架构（融入时间条件嵌入与跳跃连接），实现了稳定高效的训练，并能精准捕捉和重建射频信号中细微的硬件损伤特征。这从根本上解决了传统生成模型在射频指纹多样性表达和细节还原上的固有缺陷。

2. 生成信号保真度卓越：实验结果表明，在每类仅10个原始样本的极低数据条件下，DDPM生成的信号在所有核心评价指标上均显著领先于对比模型：其RMSE (0.197) 和 FD (39.4) 最低，PSNR (14.003) 最高，FSCS (0.983) 接近完美。频谱图、IQ图、星座图等可视化结果一致证实，DDPM生成的信号在时域波形、频域结构及调制域特性上均与原始信号保持高度一致，概率密度分布高度重叠，证明了其卓越的综合保真度。

3. 为小样本RFF提供有效解决方案：本方法的核心价值在于有效突破了小样本条件下的数据瓶颈。利用DDPM生成的高质量、高保真合成信号扩充训练集，显著缓解了深度学习模型对大规模标注数据的依赖，降低了模型在小样本场景下的过拟合风险，从而为提升下游射频指纹识别模型的泛化能力和鲁棒性提供了坚实的数据基础，在非合作信号侦察等实际场景中具有重要的应用潜力。

展望未来，本方法在复杂信道干扰下的鲁棒性、多步扩散过程的计算效率优化以及生成信号对下游识别模型鉴别性提升的量化评估等方面仍有提升空间。后续研究将聚焦于：（1）引入更贴近实际的信道干扰模型进行训练与评估；（2）探索网络架构轻量化设计（如模型剪枝、量化）或高效采样算法以提升推理速度；（3）建

立结合下游识别性能（如分类准确率、等错误率）的生成信号鉴别性评价体系，进一步推动该技术在实战环境中的应用。

参考文献：

- [1] Dhariwal P, Nichol A. Diffusion models beat GANs on image synthesis[C]//Advances in Neural Information Processing Systems. Red Hook: Curran Associates, 2021, 34:8780-8794.
- [2] Liu S, et al. Rolling bearing fault diagnosis using variational autoencoding generative adversarial networks with deep regret analysis[J]. Measurement, 2021, 168:108371.
- [3] Li Y, Zou W, Jiang L. Fault diagnosis of rotating machinery based on combination of Wasserstein generative adversarial networks and long short term memory fully convolutional network[J]. Measurement, 2022, 191:110826.
- [4] Zhou K, Diehl E, Tang J. Deep convolutional generative adversarial network with semi-supervised learning enabled physics elucidation for extended gear fault diagnosis under data limitations[J]. Mechanical Systems and Signal Processing, 2023, 185:109772.
- [5] Fan C, et al. A novel lightweight DDPM-based data augmentation method for rotating machinery fault diagnosis with small sample[J]. Mechanical Systems and Signal Processing, 2025, 232:112741.
- [6] Lin K, et al. RF Distillation Diffusion Model: An Efficient RFF Data Augmentation Method[C]//ICASSP 2025 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE, 2025.
- [7] Chi G, et al. RF-diffusion: Radio signal generation via time-frequency diffusion[C]//Proceedings of the 30th Annual International Conference on Mobile Computing and Networking. New York: ACM, 2024.

Research on Artificial Intelligence Teaching: Taking Data Augmentation of Radio Frequency Fingerprint under Generative Models as an Example

LI Guangbo¹ LI Man¹ JIAN Rui¹ LIU Wenxiu¹ GUAN Manyu²

⁽¹⁾ College of Electronic and Information Engineering, Huaibei Institute of Technology, Huaibei 235000, China,

² College of Economics and Management, Huaibei Institute of Technology, Huaibei 235000, China)

Abstract: Radio Frequency Fingerprinting (RFF) enables individual identification by extracting unique signal features caused by hardware impairments of wireless devices, and it has important applications in fields such as military reconnaissance and Internet of Things security. Although deep learning methods have significantly improved RFF performance, they are highly dependent on large amounts of labeled data. However, in actual non-cooperative scenarios, sample scarcity leads to easy overfitting of the model and a sharp decline in performance. To address this data bottleneck, this paper proposes a few-shot radio frequency fingerprint data augmentation framework based on the Denoising Diffusion Probabilistic Model (DDPM), which alleviates data limitations by synthesizing high-fidelity signals. Compared with mainstream generative models such as Generative Adversarial Networks (GAN) and Variational Autoencoders (VAE), DDPM learns data distribution through a Markov process of progressive noise addition and denoising, featuring stable training, high generation quality, and the ability to accurately capture subtle features of hardware impairments. In experiments, with Root Mean Square Error (RMSE), Peak Signal-to-Noise Ratio (PSNR), Frequency Spectrum Coherence Score (FSCS), and Fréchet Distance (FD) as evaluation metrics, DDPM was compared with WGAN, VAEGAN, and DCGAN. The results show that: the RMSE of DDPM is as low as 0.197, a 64.4% reduction compared to the suboptimal DCGAN; the PSNR reaches 14.003, a 160% increase compared to DCGAN; the FSCS reaches 0.983, a 58.3% increase compared to VAEGAN; and the FD is only 39.4, a 93.6% reduction compared to DCGAN. Meanwhile, the visualization results of IQ diagrams, spectrograms, and constellation diagrams indicate that the signals generated by DDPM are closer to the original signals in both time-domain and frequency-domain features. The study confirms that the DDPM-based data augmentation method can effectively synthesize highly discriminative radio frequency fingerprint signals, significantly alleviate the data limitations of RFF under few-shot conditions, and provide an efficient solution for few-shot radio frequency fingerprint identification.

Keywords: Diffusion model; Data augmentation; Radio frequency fingerprint; Generative adversarial network; Variational autoencoder