



上海交通大学
SHANGHAI JIAO TONG UNIVERSITY



扩散模型赋能的无线通信新方法

陈智勇

上海交通大学

2025年9月1日

—— 饮水思源 · 爱国荣校 ——



大纲



1 研究背景与动机

2 新方法之鲁棒传输


3 新方法之内容生成

4 新方法之优化求解

5 工作总结与展望



通信与AI融合



■ 移动网络演进到**智能化6G**系统

- 移动网络演进：数字化->网络化->智能化
- 通信与AI融合是6G网络的典型应用场景
- 6G关键变量：**AI**

■ 人工智能进化到**生成式AI**时代


- 2022年11月，ChatGPT拉开新时代大幕
- 传统AI：依赖于规则和算法，执行特定任务
- 生成式AI：能依据学习到的模式创造前所未有的内容




文生文



文生图



文生视频



2023年 ITU 6G典型应用场景




2025年8月 IMT-2030 (6G) 推进组成立
6G AI特设组



生成式AI时代



■ 扩散模型 (DM) 图像视频理解与生成 ➡ 文本理解与生成



prompt: 电影质感, 摄影作品, 哈苏, 极简主义, 意境构图, 大面积留白, 雾凇, 一座苏州园林里, 树梢挂满了雾凇, 超高质量, 超精细, 最佳质量, 禅意, 东方意境



■ 扩散模型

□ 原理：学习由于噪声引起的信息衰减，然后使用学习到的模式来生成图像

□ 前向扩散过程：数据一步步加随机噪声


✓ $\mathbf{x}_t = \sqrt{\alpha_t} \mathbf{x}_{t-1} + \sqrt{1 - \alpha_t} \boldsymbol{\epsilon} \quad \boldsymbol{\epsilon} \sim N(0, I)$

✓ $\mathbf{x}_t = \sqrt{\prod_{i=1}^t \alpha_i} \mathbf{x}_0 + \sqrt{1 - \prod_{i=1}^t \alpha_i} \boldsymbol{\epsilon} \quad \boldsymbol{\epsilon} \sim N(0, I)$

□ 反向采样过程：从有大量随机噪声中生成图片

✓ $\mathbf{x}_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left(\mathbf{x}_t - \frac{1 - \alpha_t}{\sqrt{1 - \bar{\alpha}_t}} \boldsymbol{\epsilon}_{\theta}(\mathbf{x}_t, t) \right) + \sigma_t \mathbf{z}, \quad \mathbf{z} \sim N(0, I)$

深度模型所预测的噪声（用于去噪）





扩散模型能否使能通信？



优势

对复杂噪声
模式的鲁棒性

高质量数据
生成能力

强大数据分布
学习能力

鲁棒传输

内容生成

优化求解

无线传输

确保**动态信道**环
境下的准确传输

从失真信号
中**恢复内容**

在**约束**条件
下求解**优化**

扩散模型

学习**多样噪声**水
平下的噪声估计

从随机采样
中**生成内容**

拟合**条件输入**
下的**输出分布**

使能方法

扩散模型为提升接
受信信号质量**新模块**


从管道式的原始**内容恢复**
转换为创造式的**受控生成**

条件扩散模型生
成符合约束的解

扩散模型具有驱动无线传输新方法的可能！



大纲



1 研究背景与动机

2 新方法之鲁棒传输


3 新方法之内容生成

4 新方法之优化求解

5 工作总结与展望

■ 扩散模型 vs 无线传输

- 扩散模型通过加噪训练，逐步去噪生成内容。噪声公式： $x_t = \sqrt{\alpha_t}x_0 + \sqrt{1 - \alpha_t}\epsilon$
- 无线传输，例如AWGN信道，接收信号为： $y = x + n$ ，要从y中恢复x




能否通过DM去噪方式去除信道噪声，降低信道噪声影响，提升传输性能？



鲁棒传输-1：信道去噪扩散模型（CDDM）


■ 提出了CDDM：将DM重新设计在无线接收端

□ 基本思路：根据信道特点设计前向扩散，推导自适应反向采样步长与采样算法，实现从接收信号中逐步去除噪声





鲁棒传输-1: CDDM模型设计



前向过程

- 接收信号条件概率模型: 加权高斯分布

$$p(y_r|x, h) \sim N\left(y_r; \frac{1}{\sqrt{1 + \sigma^2}} W_s x, \frac{\sigma^2}{1 + \sigma^2} W_n^2\right)$$

- CDDM前向扩散过程: 同权重的高斯分布

$$x_0 = W_s x, x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} W_n \epsilon$$

- 前向过程与接受信号关系: 在第m步上

$$D_{KL}(q(x_m|x_0, h) || p(y_r|x_0, h)) = 0$$

作用

将信道加噪过程, 理解为逐步加噪,
从而在反向采样过程中逐步去噪

训练过程

- 通过分布拟合, 推导为噪声预测:

$$Loss = E_{x_0, \epsilon, t} \|\epsilon - \epsilon_\theta(x_t, h_r, t)\|_2^2$$

作用

用网络的参数分布, 拟合真实信道的后验分布

采样过程


- 根据信道噪声, 选择采样步长 m : $x_m = y_r$

- 根据后验概率分布表达式去噪采样:

$$x_{t-1} = (x_t - (1 - \alpha_t) W_n \epsilon_\theta(x_t, t) / \sqrt{1 - \bar{\alpha}_t}) / \sqrt{\alpha_t}$$

作用

对接受信号去噪, 实现一致的准确快速采样





鲁棒传输-1：条件熵减理论证明



在 $\mathbb{E}(\epsilon_{\theta,i}(\cdot)) = 0$ 条件下，网络收敛至 $\mathbb{E}(\|\epsilon_i - \epsilon_{\theta,i}(\cdot)\|_2^2) \leq \tau$ 时，

$$H(x_{t-1,i}|x_0, h) \leq H(x_{t,i}|x_0, h)$$

的充分条件是：



$$\mathbb{E}(\epsilon_{\theta,i}^2(\cdot)) \geq \frac{1 - \bar{\alpha}_t - \beta_t \gamma_{t-1}}{\gamma_{t-1}^2 - \beta_t \gamma_{t-1}} - \frac{\beta_t^2 - \beta_t \gamma_{t-1}}{\gamma_{t-1}^2 - \beta_t \gamma_{t-1}} \tau = f_\tau(t)$$

直接说明

- 网络输出**零均值**条件成立
- 条件熵降低存在一个**t范围**
- 不同t对熵减小**幅度不同**

指导


- 根据KL选择m选择**存在上限**
- 不同SNR的**增益不相同**




$u_\tau(t, h)$ 是 $H(x_{t-1,i}|x_0, h)$ 的一个上界



鲁棒传输-1: MSE实验结果



DIV2K dataset, MSE (dB) performance



□ 实验条件:

- DIV2K 高清数据集
- 衰落信道与高斯信道
- 编码器压缩率: 0.0234

□ 实验对象:

- y_r 与 x 的MSE (without CDDM) , 在不同的信噪比和信道估计误差条件下, 对比 y 与 x 的MSE (with CDDM)

□ 实验结果:


- 在所有SNR, 所有信道估计误差条件下, 衰落信道与高斯信道的MSE对比都有增益 (0.9dB@SNR=15 dB fading)




鲁棒传输-1: PSNR实验结果



DIV2K dataset, Rayleigh fading channel




DIV2K dataset, AWGN channel



- DIV2K 高清数据集
- 在所有SNR, 衰落信道与高斯信道的PSNR性能都有增益 (0.53 dB@SNR=10dB, Fading)

■ 信道噪声vs 信号干扰

	信道噪声	信号干扰
特征	无线信道总是含有 加性噪声	信号由于其天然的广播特性容易受到 干扰
模型	$y = hx + n$	$y = h_x x_c + h_z z_c + n$
方法	将扩散模型设计的 CDDM 来去噪	能否设计 DM 来去除干扰?
难点	$D_{KL}(q(x_m x, h) p(y x, h)) = 0$ ↓ 设计前向过程 已知	$D_{KL}(q(x_m x_c, h_x) p(y x_c, h_x))$ ↓ 无法设计前向过程来匹配 未知





鲁棒传输-2: 干扰消除扩散模型 (ICDM)



问题建模

特征分析:

$$y = h_x x_c + h_z z_c + n$$

整体: z

未知: $p(y|x_c, h_x)$

已知: $p(y|x, z, h_x)$

联合看待

问题建模: 对信号和干扰的联合MAP估计

$$(\hat{x}, \hat{z}) = \arg \max_{x, z} \log p_{x, z|y, h_x}(x, z|y, h_x),$$

理论证明: 求解问题可得他们的精准估计

$$\|\hat{x} - x^*\|^2 + \|\hat{z} - z^*\|^2 \leq \frac{1}{(\xi + \lambda_{\min})^2} \|\Sigma n\|^2.$$

求解方法

基本思路: 朗之万动力学迭代 $v = [x; z]$

$$\bar{v}_t = \bar{v}_{t-1} + \frac{\varsigma}{2} \nabla_v \log p_{v|y, h_x}(\bar{v}_{t-1}|y, h_x) + \sqrt{\varsigma} \epsilon_v,$$

$$\nabla_v \log p_{v|y, h_x}(\bar{v}_{t-1}|y, h_x) = \nabla_v \log p_v(\bar{v}_{t-1}) + \nabla_v \log p_{v|y, h_x}(y|\bar{v}_{t-1}, h_x)$$

需要估计

迭代结果: when $\varsigma \rightarrow 0, T \rightarrow \infty$, 理论证明收敛于该问题的解

$$\bar{v}_T \rightarrow \arg \max_v \log p_{v|y, h_x}(v|y, h_x)$$

存在问题: 对数分布梯度未知, 迭代次数多

解决思路

信号干扰先验梯度

使用 Tweedie 公式证明:
两个独立DM学习 $\nabla_v \log p_v(\bar{v}_{t-1})$

信道转移概率梯度

使用高斯分布性质推导:
 $\nabla_v \log p_{v|y, h_x}(y|\bar{v}_{t-1}, h_x)$ 表达式

快速数值迭代方法

整合高阶微分方程数值快速求解
MAP 问题



鲁棒传输-2: 干扰消除扩散模型 (ICDM)



信号干扰先验梯度

□ 构建 $\mathbf{x}_t, \mathbf{z}_t$:

$$\mathbf{x}_t = \sqrt{\bar{\alpha}_t} \mathbf{x}_T + \sqrt{1 - \bar{\alpha}_t} \boldsymbol{\epsilon}_x, \quad \mathbf{z}_t = \sqrt{\bar{\alpha}_t} \mathbf{z}_T + \sqrt{1 - \bar{\alpha}_t} \boldsymbol{\epsilon}_z$$

□ 噪声与对数梯度关系: Tweedie 公式 $\approx$ 负梯度

$$\nabla_{\mathbf{x}} \log p_{\mathbf{x}}(\mathbf{x}_t) = \ominus \frac{1}{\sqrt{1 - \alpha_t}} \boldsymbol{\epsilon}_x, \quad \nabla_{\mathbf{z}} \log p_{\mathbf{z}}(\mathbf{z}_t) = \ominus \frac{1}{\sqrt{1 - \alpha_t}} \boldsymbol{\epsilon}_z.$$

□ 训练DMs估计噪声, 可以获得梯度估计

信道转移概率梯度

□ 推导方法: 高斯边际分布+贝叶斯 已知

$$p_{\mathbf{y}|\mathbf{v}_t, \mathbf{h}_x}(\mathbf{y}|\mathbf{v}_t, \mathbf{h}_x) = \int p_{\mathbf{v}_T|\mathbf{v}_t}(\mathbf{v}_T|\mathbf{v}_t) p_{\mathbf{y}|\mathbf{v}_T, \mathbf{h}_x}(\mathbf{y}|\mathbf{v}_T, \mathbf{h}_x) d\mathbf{v}_T.$$

$$p_{\mathbf{v}_T|\mathbf{v}_t}(\mathbf{v}_T|\mathbf{v}_t) \propto p_{\mathbf{v}_t|\mathbf{v}_T}(\mathbf{v}_t|\mathbf{v}_T) p_{\mathbf{v}_T}(\mathbf{v}_T). \rightarrow \text{高斯假设}$$

□ 最终表达式: 联合计算

$$\nabla_{\mathbf{v}_t} \log p_{\mathbf{y}|\mathbf{v}_t, \mathbf{h}_x}(\mathbf{y}|\mathbf{v}_t, \mathbf{h}_x) = \zeta_t^2 \mathbf{W}^T \boldsymbol{\Theta}_t^{-1} \left(\frac{\mathbf{y}}{\zeta_t} - \mathbf{W} \mathbf{v}_t \right).$$

快速迭代算法

□ 输入: 前 p 个样本 $\{\mathbf{x}_{t-m}\}_{m=1}^p \quad \{\mathbf{z}_{t-m}\}_{m=1}^p$


□ 过程:

1. JCG模块计算梯度: 使用左侧推导计算 p 个样本对应的联合梯度

$$\mathbf{r}_{\theta}(\mathbf{x}_t, \mathbf{z}_t, \mathbf{y}, \mathbf{h}_x, t) = \mathbf{s}_{\theta}(\mathbf{x}_t, t) - \beta \bar{\mathbf{r}}_x(\mathbf{x}_t, \mathbf{z}_t, \mathbf{y}, \mathbf{h}_x) \quad \text{DM输出-推导的表达式}$$

$$\mathbf{r}_{\phi}(\mathbf{x}_t, \mathbf{z}_t, \mathbf{y}, \mathbf{h}_x, t) = \mathbf{s}_{\phi}(\mathbf{z}_t, t) - \gamma \bar{\mathbf{r}}_z(\mathbf{x}_t, \mathbf{z}_t, \mathbf{y}, \mathbf{h}_x)$$

2. 采样模块预测当前样本: 使用 $\mathbf{x}_{t-1}, \mathbf{z}_{t-1}$, 前 p 个梯度, 结合预估矫正方法预测样本






ICDM性能分析

数据集:

- CelebA人脸
- BIRDS鸟类
- Kodak真实世界

效果:


- 显著**改善重建**效果
- 大幅提升**感知质量**
LPIPS (2.47dB)
@SINR=0 dB, Rayleigh
- 大幅**缩短采样步数**至40步



■ 适用于信号估计相关场景

$$\bar{x} = x + \Delta x$$

□ 例如**信道估计**：h代替上述x，利用DM去估计误差



RIS场景下信道估计




Fig. 3. NMSE performance versus SNR under different scenarios:(a) UMi, $f_c = 28\text{GHz}$. (b) UMi, $f_c = 73\text{GHz}$. (c) InH, $f_c = 28\text{GHz}$. (d) InH, $f_c = 73\text{GHz}$.



大纲



1 研究背景与动机

2 新方法之鲁棒传输

3 新方法之内容生成

4 新方法之优化求解

5 工作总结与展望



内容生成-1：混合语义传输 (MoS)



扩散模型的受控生成

多样的条件控制

扩散模型可以根据多种形式和模态的条件生成内容

多样性与一致性

生成内容多样，仅能够保证语义一致性。

如何赋能？

设计混合语义传输，
从不同角度控制内容的定制化生成


生成通信新方法

灵活定制化通信

通信传输的对象变得灵活多样，内容可个性定制


传输内容一致性

传输内容的语义一致性和关键对象的像素一致性



语义一致

对象改变！




Stable Diffusion 结构图

一只侏儒企鹅站在
南极洲岩石上



MoS传输策略

1. 使用SAM模型划分内容
2. 对于感兴趣 (ROI) 区域采用JSCC 直接编码图像传输
3. 对于不感兴趣 (RONI) 区域采用BLIP转换为文字后编码传输
4. 接收端使用扩散模型将混合面模态信息作为条件生成内容



- ROI区域采用图像传输确保感兴趣的对象准确传输
- RONI区域采用文字传输以大幅降低通信量, 并保持语义一致性和灵活性

■ 实验设置

- ❑ 数据集：RefCOCO
- ❑ Baseline：单一模态传输
- ❑ 信道：AWGN 与 Rayleigh fading
- ❑ 指标：ROI的像素级一致 (PSNR)
RONI的图文一致 (CLIP)

■ 性能分析

- ❑ 大幅提高ROI区域的一致重建质量
(PSNR 2-3 dB)
- ❑ 符号分配比例影响大

原图



单一模态传输





PSNR:31.59 dB
CLIP: 0.271

混合模态传输



PSNR:33.04 dB
CLIP: 0.314



■ 联邦半监督学习

联邦场景

非独立同分布

联邦学习中不同用户的数据通常是有差异，非独立同分布的

少量有标签

用户难以对私有数据打标签，造成可参考的有标签数据较少

扩散模型

以类别为条件生成数据

关键挑战

数据分布差异

本地数据仍为Non-IID，导致本地模型与全局模型存在偏差，影响参数聚合后的全局模型性能

少样本性能受限

有标签数据量较少，训练得到的分类模型性能受限





Figure 1. System model


扩散模型带来的新方法：直接根据类别生成带有标签的全局样本！

■ 扩散模型赋能的联邦半监督学习


1. 联邦少
标签训练
分类器




3. 根据混淆矩阵,
筛选数据, 联邦
训练扩散模型




5. 重新训练
联邦分类器



2. 使用全局分
类器打伪标签





4. 全局扩散
模型合成全局
分布数据



- 联邦训练DM能生成全局数据, 缩小本地模型与全局模型差异
- DM根据类别生成内容, 使得内容与标签特征更贴近

■ 实验结果: CIFAR10, Fashion MNIST, SVHN 数据集




- 所提出算法可以显著提升平均分类准确率 (22.4% @ IID场景 and 35.5% @ DIR场景)

- 显著提升各种类别的召回率
- 对于fedavg下精确率高的类别, 召回率提升更多
- 选择高置信度标签数据可以显著提升性能



大纲



1 研究背景与动机

2 新方法之鲁棒传输

3 新方法之内容生成

4 新方法之优化求解

5 工作总结与展望


优化求解：优化问题中解的生成

扩散模型的解生成

分布拟合

扩散模型根据优化问题条件生成解的分布，对于解的**多峰分布拟合**效果好


扩散模型拟合分布的生成轨迹



随机探索

扩散模型基于概率密度梯度来生成轨迹，增加强化学习**探索过程的随机性**

强化学习微调扩散模型的图片生成



两者结合，
求解复杂非凸优化问题


扩散模型预训练



强化学习微调



生成**多目标组合优化**
问题的帕累托前沿






优化求解：多目标组合优化问题的解生成



MO-CMPO生成策略


一致性
模型监
督学习



GNN：图神经网络特征提取

对于变量离散的组合优化问题，采用图神经网络的节点、边和全局信息，提取问题特征

多目标
强化学习
策略优化



CM：一致性模型监督学习


CM作为少量推理步数的扩散模型，基于图结构条件生成每个单目标上的解

MO-RL：多目标RL策略优化

采样偏好权重，结合多个目标的策略分布，探索帕累托前沿



实验背景与结果

- **实验背景：**分布式MEC中，根据VR用户在虚拟空间中的互动需求，对物理空间中的资源进行部署
- **实验结果：**MAN中NR基站数据集源于OpenCellid



➤ 所提算法得到更好的帕累托前沿


[1] C. Xu, Z. Chen, M. Tao, L. Song, and W. Zhang, "Spatial Computing Communications for Multi-User Virtual Reality in Distributed Mobile Edge Computing Network," submitted to IEEE TWC, Aug. 2025.



➤ 大幅降低多目标组合优化问题的求解时延



大纲



1 研究背景与动机

2 新方法之鲁棒传输

3 新方法之内容生成

4 新方法之优化求解

5 工作总结与展望



■ 生成式AI使能无线传输

鲁棒传输

加性噪声: $y = hx + n$

加性干扰: $y = h_1x + I + n$

加性误差: $\bar{h} = h + \Delta h$

在大量场景下对抗**加性失真**



与**原始目标**接近

内容生成

文生图

文字+部分图像生图

类别控制数据生成

各种**条件**控制下的**内容**生成



生成**语义**一致

优化求解

单目标优化

多目标优化


组合优化

目标与约束**条件**下**解**生成



逼近**最优解**空间

生成式AI正在重塑无线传输各个环节---->可控生成式通信?



敬请批评指正！

—— 饮水思源 · 爱国荣校 ——