跨模态 GUI　　面向快速扩散模型计算机断层成像的 DANCE

Timofey Efimov[1,2]*, Singanallur Venkatakrishnan*[2]*,Maliha Hossain*[2]*,Haley Duba-Sullivan*[2,3]*, Amirkoushyar Ziabari*[2]

[1] 卡内基梅隆大学，匹兹堡，美国[2] 橡树岭国家实验室，橡树岭，美国[3] 普渡大学，西拉法叶，美国

tefimov@andrew.cmu.edu{ziabariak,hossainm,sullivanhe}@ornl.gov svvenkatakrishnan@gmail.com

arXiv:2603.01253v1 [cs.CV] 1 Mar 2026

摘要

扩散模型已成为求解计算机断层成像（CT）逆问题的强大先验。在某些应用中，例如中子计算机断层成像，即使只进行一次扫描，采集大量测量数据也可能成本高昂，因此得到的稀疏数据集即便借助扩散模型，也难以获得高质量的重建结果。缓解这一难题的一种策略是利用互补且易于获取的成像模态；然而，这类方法通常需要使用大型数据集重新训练扩散模型。在这项工作中，我们提出在不重新训练扩散先验的情况下纳入额外模态，从而加速成本高昂模态的成像。我们还考察了不完美的辅助模态对跨模态引导的影响。我们在稀疏视角中子计算机断层成像上评估了该方法，结果表明，结合对同一样本进行的X射线计算机断层成像，可显著提高重建质量。

索引词— 图像重建、扩散模型、多模态、计算机断层成像

1 引言

计算成像通常需要求解病态逆问题，在这类问题中，从不完整或含噪测量数据中恢复未知信号 $x^\star \in \mathbb{R}^d$ 需要强有力的正则化。我们考虑标准线性逆问题：

$$y = Ax^\star + \xi, \tag{1}$$

其中， $A \in \mathbb{R}^{m\times d}$ 是前向投影算子， ξ 表示测量噪声。由于 $m \ll d$或 A条件不佳，恢复 $x^\star$ 是一个严重病态的问题，因此需要强大的先验。扩散模型 [1, 2, 3]已成为此类问题中最先进的生成式先验。通过捕捉复杂的高维分布，扩散先验在逆问题 [4, 5, 6, 7], 中取得了令人瞩目的成果，能够利用更少的测量数据进行重建，尤其适用于采集成本高、耗时长的成像应用。这对于中子计算机断层成像（NCT）等昂贵的计算机断层成像模态尤其有益，因为减少视角数量可以显著缩短采集时间并降低成本 [8]。然而，即便先验十分强大，也无法完全突破物理学和采样所施加的根本限制，往往会导致细微结构细节的丢失。

一种自然的策略是利用互补且成本低廉的模态，以获取更多结构信息。在材料科学中，**中子计算机断层成像（NCT）**和**X 射线计算机断层扫描（XCT）**便体现了这种互补性 [9, 10, 11]：NCT 对轻元素（如氢）高度敏感，而 XCT 则侧重于电子密度。由于每种模态都能揭示独特特征，对同一样本进行低成本 XCT 扫描，可为改进超稀疏 NCT 重建图像提供有价值的辅助引导。在其他计算成像应用中，现有的跨模态扩散方法 [12, 13, 14, 15, 16] 通常会将辅助引导直接嵌入先验，因此需要针对特定模态重新训练——这一过程需要大量数据、计算成本高昂，而且容易导致泛化能力不佳。

本文利用在几何结构上训练的通用扩散先验，使其能够跨模态应用而无需重新训练。为解决从稀疏测量数据中重建高保真数据时的这些局限，我们引入了轻量级跨模态一致性网络，利用辅助 XCT 数据在测试时细化重建图像。该网络强化了昂贵模态的当前估计与辅助观测之间的一致性，在保留预训练先验通用性的同时提供高效的跨模态引导。在此框架下，我们表明，即使引导模态受到噪声、模糊或稀疏采样的影响而退化，辅助引导仍能改善重建图像；同时，跨模态一致性能够加速并稳定扩散先验的测试时自适应。最后，为支持这一研究方向，我们贡献了首个涵盖多种采集设置的配准的中子与X射线计算机断层扫描数据集。

本稿由 UT-Battelle, LLC 根据与美国能源部（DOE）签订的合同 DE-AC05-00OR22725 撰写。相关研究得到橡树岭国家实验室GRO项目资助，该项目由美国能源部赞助，并由橡树岭科学与教育研究所管理；同时也得到橡树岭国家实验室LDRD人工智能倡议计划的支持。美国政府保留相关权利；出版商接受本文发表即表示承认，美国政府拥有非独占、已付清、不可撤销、全球范围内的许可，可为美国政府目的出版或复制本稿的已发表版本，或允许他人这样做。DOE 将按照 DOE 公共获取计划（ http://energy.gov/downloads/doe-public-access-plan），向公众开放这些由联邦政府资助的研究成果。

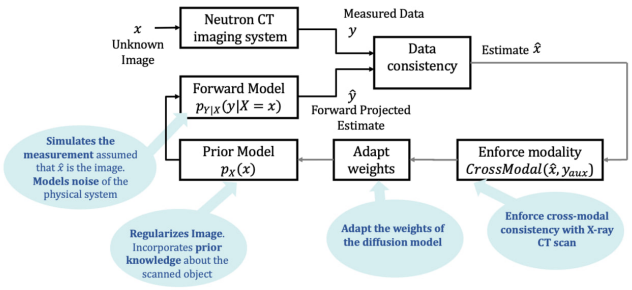

图 1：跨模态方法将拟合主模态测量数据与强制执行跨模态一致性解耦。首先，我们微调扩散模型的权重，使其更好地满足数据一致性损失，然后通过任意基于扩散的逆问题求解器获得重建估计。完成这一步后，我们通过轻量级图像转换模型强制执行跨模态一致性。跨模态一致性模块可以作为独立模块无缝集成，而无需修改先验。

2 背景

2.1 用于逆问题的扩散模型

扩散模型通过去噪分数匹配，在多个噪声水平上估计分数函数，从而学习从数据分布中进行采样。对于逆问题，重建算法通常交替执行以下步骤：(i) 应用无条件扩散先验；(ii) 通过 y 强制实施数据一致性。这一迭代过程在无需针对特定任务重新训练的情况下，平衡了先验信息与测量保真度。遵循这一框架的算法包括 DPS [4], DPnP [7], FPS-SMC（用于线性逆问题） [17], 以及 D3IP [5]。其中一个关键挑战是训练数据与测试数据之间存在分布偏移，例如噪声水平或结构特征不匹配的 CT。D3IP 算法 [5] 通过测试时微调解决了这一问题，即将在通用几何形状上训练的先验适配到 MRI 和 CT 等特定领域。

2.2 基于深度先验的跨模态逆问题

近期研究探索了通过联合训练或跨模态条件控制，将辅助模态融入基于深度先验的重建中 [12, 13, 14, 15, 16]。然而，这类方法需要针对每个模态对重新训练，而且往往假设辅助数据的退化模型过于简单。相比之下，我们的方法利用基于通用微观结构表征训练的通用扩散先验，并结合轻量级跨模态一致性模块。这种设计无需重新训练，可适用于任意辅助退化，并能将单模态方法无缝扩展至跨模态场景。

3 算法

我们方法的关键区别在于将扩散先验与跨模态一致性机制显式解耦。图1描述了该方法的总体框图。在此，我们首先对目标模态应用单模态扩散先验，并强制

算法 1跨模态分布外扩散逆问题求解器（改编自 D3IP [5]）

需要： θ（微观结构的通用扩散先验）、N、T'、K、η、λ、y_{main}（观测到的主模态）、y_{aux}（观测到的辅助模态）、A（主模态的前向模型）、步数、学习率 γ

$\mathcal{L}(x,\ y_{\text{main}},\ \text{DiffSolver}_\theta) \leftarrow \|y_{\text{main}} - A\,\text{DiffSolver}_\theta(x \mid y_{\text{main}})\|_2^2$
$\theta_{T'} \leftarrow \theta$
$X_{T'} \leftarrow \sqrt{\bar{\alpha}_{T'}}\,A^\dagger y_{\text{main}} + \sqrt{1-\bar{\alpha}_{T'}}\,\epsilon, \epsilon \sim \mathcal{N}(0, I)$
对 $t = T'$ **至** 1 **执行**
  $\theta_t^{(0)} \leftarrow \theta_t$
  对 $i = 1$**至**Num_steps**执行**
    $x_t^{\{i\}}, y_{\text{main}}^{\{i\}} \sim \text{MC}((X_t, y_{\text{main}})\ K)$
    $g \leftarrow \nabla_\theta \mathcal{L}\left(x_t^{\{i\}}, y^{\{i\}}{}_{\text{主体}}, \text{DiffSolver}_\theta^t\right)\Big|_{\theta=\theta_t^{(i-1)}}$
    $\theta_t^{(i)} \leftarrow \theta_t^{(i-1)} - \gamma\, g$
  结束循环
  $\theta_{t-1} \leftarrow \theta_t^{(\text{Num_steps})}$
  $\hat{X}_{0|t} \leftarrow \text{DiffSolver}_{\theta_{t-1}}^t(X_t \mid y_{\text{main}})$
  if t 取模 $2 = 0$**且**$t > 1$**则**
    $X_{0|t}$
  else
    $\tilde{X}_{0|t} \leftarrow \hat{X}_{0|t}$
  结束条件判断
  $X_{t-1} \leftarrow \sqrt{\bar{\alpha}_{t-1}}\,\tilde{X}_{0|t} + \sqrt{1-\bar{\alpha}_{t-1}}\,\epsilon, \epsilon \sim \mathcal{N}(0, I)$
结束循环
返回 X_0

仅与中子CT投影保持数据一致性，而不涉及跨模态引导。此后，我们才将估计结果通过一个轻量级跨模态一致性模块，使其与辅助X射线图像对齐。这种分离使我们能够避免在跨模态引导下重新训练扩散先验，而是用一个易于训练的网络来分离引导。随后，我们应用域适应步骤来引导扩散权重，以更好地捕捉图像的真实概率分布。我们的方法与D3IP [5] 的关键区别在于跨模态一致性步骤，该步骤在算法的每一步对预测的中子CT重建强制执行跨模态对齐。

在算法1中，我们用 θ 表示在椭圆上训练的通用扩散先验的参数，该先验类似于微观结构，遵循 D3IP 工作 [5]。在 D3IP 中，对于主模态的前向模型 A，我们使用一个基于扩散的逆问题求解器，记为 $\text{DiffSolver}_\theta(\cdot \mid y_{\text{main}})$，它根据观测数据生成重建估计。随后，D3IP 的域适应步骤通过最小化数据一致性损失，将先验参数 θ 微调至目标分布

$$\mathcal{L}(x, y_{\text{main}}, \text{DiffSolver}_\theta) = \|y_{\text{main}} - A\,\text{DiffSolver}_\theta(x \mid y_{\text{main}})\|_2^2, \tag{2}$$

确保先验忠实于测量数据。在每个反向扩散步骤 t中，算法都会维护一个含噪潜变量 X_t 和适配后的参数 θ_t。D3IP 的关键机制是在域适应与预测之间交替进行：给定 (X_t, θ_t)，首先通过对损失函数进行梯度下降来更新权重

$$\theta_t \leftarrow \theta_t - \gamma\,\nabla_{\theta_t}\|y_{\text{main}} - A\,\text{DiffSolver}_{\theta_t}(X_t \mid y_{\text{main}})\|_2^2, \tag{3}$$

并紧接着使用适应后的求解器进行预测

一次重建

$$\hat{X}_{0|t} = \mathrm{DiffSolver}^{t}_{\theta_t}(X_t \mid y_{\mathrm{main}}), \tag{4}$$

这种交替结构逐步提升重建质量，同时引导先验参数朝目标域调整。为了处理大量三维数据，每次内迭代都会从三维体数据中抽取部分切片，从而无需一次处理整个体数据即可高效完成适配。跨模态一致性仅在每隔一次迭代时强制执行，以便从测量数据中获取更多信息，同时降低运行额外网络所带来的计算开销。

我们的关键贡献是提出了一种跨模态细化模块，可将辅助 XCT 数据整合到 D3IP 中，而无需重新训练扩散先验。获得 $\hat{X}_{0|t}$ 后，我们使用跨模态网络对其进行细化，即 Cross-modalModel($\hat{X}_{0|t}$, y_{aux})，该网络利用退化的辅助模态信息（例如 XCT）生成 $\tilde{X}_{0|t}$。跨模态网络能够捕获 NCT 与 XCT 之间的共享信息，并去除辅助模态中的伪影。这一步不仅提升了 NCT 图像的重建效果，还能更好地引导域适应，为算法执行早期阶段的域适应提供更好的起点。

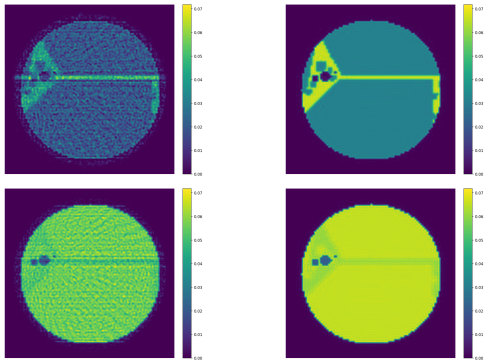

图 2：配对的退化 NCT/XCT 样本（左）及其高质量重建图像（右）。这些示例展示了用于跨模态转换的训练数据。

跨模态模型联合利用 NCT 估计结果和通过 X 射线计算机断层扫描快速获取的辅助样本。具体而言，将通过 DiffSolver 获得的当前估计$\hat{x}$ 与退化的 XCT 观测数据拼接后，输入 Pix2Pix 网络进行处理。使用退化的 XCT 观测数据是出于对真实场景的考虑：微观结构扫描可能受到噪声、模糊或用于重建的视角数量不足等因素的影响。这是我们方法的主要优势之一，因为它不需要干净的辅助信息，同时仍能捕获关键的跨模态信息。

该网络经过训练，可将广泛的采集条件——包括噪声、模糊、视角数量和稀疏度水平的变化——映射到如图 2 所示的“理想”参考场景，该场景具有极低的噪声和模糊、512 个视角以及密集采样。这一设计具有两个互补的目的。首先，通过使不断演化的 NCT 重建与相应的 XCT 信息保持一致，确保不同模态之间的一致性。其次，移除缺乏明确前向模型的未知伪影，例如传感器噪声和运动引起的模糊。通过同时以$\hat{x}$ 和辅助模态为条件，网络学会利用跨模态冗余，并生成信息量更丰富的重建图像。

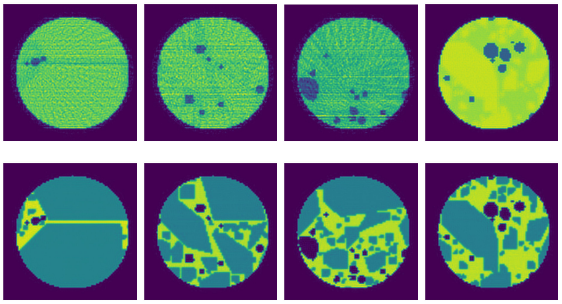

图3：XCT 图像（上排）与对应理想 NCT 图像（下排）的比较。与 NCT 相比，XCT 的质量差异很大。

4 实验结果

4.1 数据集收集与实验设置

我们在模拟跨模态 CT 数据上评估了该框架，其中，中子计算机断层成像（NCT）和 X 射线计算机断层扫描（XCT）的微结构数据投影 [18]，是在具有平行束几何的受控前向模型下生成的。10 个独特的二维体数据用于训练，另有 3 个具有不同微结构的独立体数据用于测试。对于每个体数据，我们模拟了不同退化条件下的重建，包括噪声、模糊、稀疏度水平和视角数量。我们将每个退化的 NCT/XCT 样本与其标签（理想重建）配对，并训练 Pix2Pix 图像到图像的转换网络 [19]。如图 2 所示，该网络学习 NCT 与 XCT 之间的一致特征，并移除退化伪影。NCT 的退化模拟使我们能够在算法的每次迭代中接入中间重建，并整合跨模态信息。所有实验均在 NVIDIA H100 GPU 上完成。Pix2Pix 模型的执行时间可以忽略不计，占总重建时间的比例不到 1%。

4.2 重建结果

图3展示了 XCT 引导样本及其对应的理想 NCT 标签示例。与 NCT 相比，XCT 的质量差异很大，且部分信息具有模态特异性。尽管如此，XCT 仍能提供结构线索，引导稀疏视角 NCT 重建。

表1总结了单模态方法（即 D3IP，采用扩散先验且不使用第二模态）和跨模态方法（即本文提出的方法，使用第二辅助模态）的重建性能。实验在不同优化步数和投影视角数下进行，每次执行 10 轮先验约束与数据一致性交替迭代，且投影数据不含测量噪声。结果以峰值信噪比（PSNR）和结构相似性指数（SSIM）表示，各项比较中的最佳分数以粗体标出。

主要定量结果见表1。在大多数设置和视角数量下，尤其是在稀疏视角情况下，跨模态方法在峰值信噪比和结构相似性指数方面均优于基线方法 D3IP。在低视角范围 （8–32 个视角）中，跨模态一致性带来的增益最大，峰值信噪比最高提升 $+1.63$ dB，结构相似性指数最高提升 $+0.13$ （5 步，32 个视角）。这些结果表明，投影数据稀缺时，跨模态引导尤为重要。在高视角

范围（128–256 个视角）中，峰值信噪比的提升较小，偶尔还会略有下降（例如，5 步、128 个视角时为 -0.20 dB），但结构相似性指数始终有所提升，最高提升 $+0.15$（5 步和 10 步，256 个视角）。这表明，即使重建结果已经相当出色，跨模态模块仍能增强结构保真度和感知清晰度，使微观结构中的密度差异更加明显。

在 5% 高斯测量噪声下，跨模态方法始终优于基线方法 D3IP，在各种设置下，峰值信噪比平均提升约 $+0.5$ dB，结构相似性指数平均提升 $+0.02$。这表明该方法具有良好的抗噪能力，并证实即使在测量条件恶化时，模型也能有效整合中子 CT投影与辅助 XCT 参考数据中的信息。

表1：不同视角数、无测量噪声，以及在强制执行先验与数据一致性的交替步骤之间进行 $T = 10$ 次迭代时，单模态与跨模态方法的重建质量对比（峰值信噪比 [dB] / 结构相似性指数）。 Δ = 跨模态 − 单模态。

步骤	#视角	单模态		跨模态		Δ	
		峰值信噪比 ↑	结构相似性指数 ↑	峰值信噪比 ↑	结构相似性指数 ↑	PSNR	SSIM
5	8	20.10	0.374	**21.17**	**0.375**	**+1.07**	**+0.001**
	16	23.34	0.455	**23.97**	**0.471**	**+0.63**	**+0.016**
	32	25.82	0.490	**27.45**	**0.620**	**+1.63**	**+0.130**
	64	28.62	0.648	**29.12**	**0.762**	**+0.50**	**+0.114**
	128	**28.74**	0.662	28.54	**0.777**	-0.20	**+0.115**
	256	28.53	0.658	**29.50**	**0.812**	**+0.97**	**+0.154**
10	8	20.33	0.381	**21.73**	**0.405**	**+1.40**	**+0.024**
	16	23.23	0.451	**24.73**	**0.510**	**+1.50**	**+0.059**
	32	27.01	0.557	**28.11**	**0.636**	**+1.10**	**+0.079**
	64	**29.16**	0.694	28.90	**0.745**	-0.26	**+0.051**
	128	29.37	0.730	**29.73**	**0.818**	**+0.36**	**+0.088**
	256	28.58	0.657	**29.30**	**0.811**	**+0.72**	**+0.154**
20	8	20.54	0.381	**21.87**	**0.422**	**+1.33**	**+0.041**
	16	23.44	0.466	**24.79**	**0.508**	**+1.35**	**+0.042**
	32	**26.85**	0.558	26.93	**0.599**	**+0.08**	**+0.041**
	64	28.85	0.665	**29.56**	**0.772**	**+0.71**	**+0.107**
	128	29.83	0.759	**29.97**	**0.816**	**+0.14**	**+0.057**
	256	30.07	0.768	**30.21**	**0.812**	**+0.14**	**+0.044**

图4比较了稀疏视角设置下 8、16、32 和 64 个视角的重建图像。仅使用 8 个视角时，由 XCT 引导的跨模态重建能更好地还原形状和边界，与真实值高度吻合，并能更准确地捕捉细小特征（例如深蓝色区域）。在 16–64 个视角下也能观察到类似的改进：跨模态一致性使边界更加清晰，减少模糊，并改善了低密度区域的重建。总体而言，跨模态重建图像的视觉保真度高于单模态重建图像，尤其是在稀疏视角条件下，XCT 引导的作用最为显著。

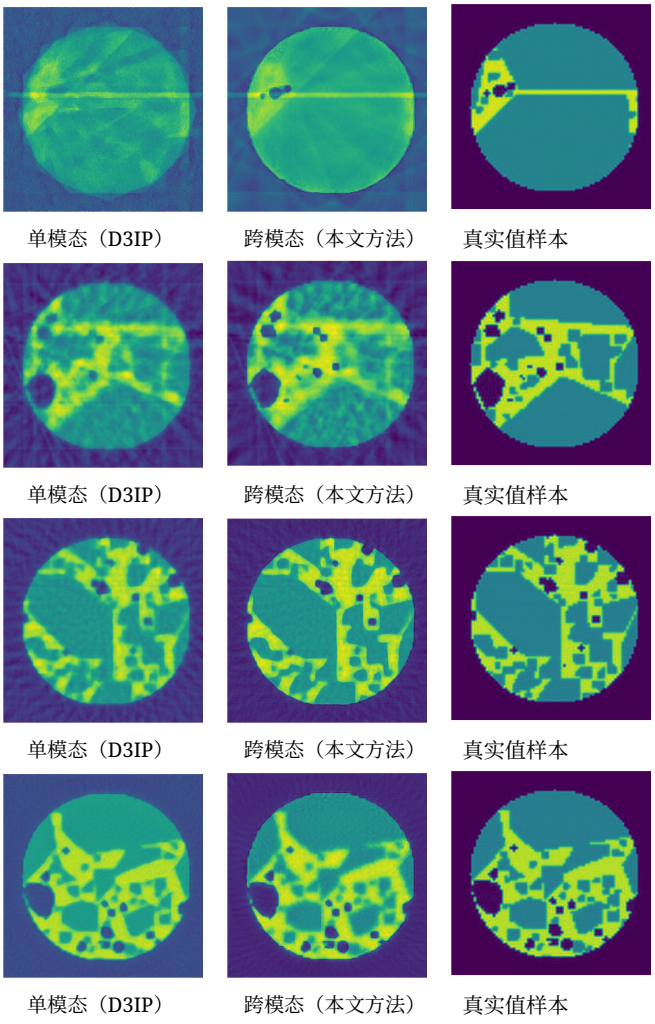

图4：在不同数量的投影视角（8、16、32、64、1、4 和视角，分别对应各行）下，对 D3IP 与我们的跨模态引导算法进行定性比较。每行中，第一列显示单模态（D3IP）重建图像，第二列显示我们的跨模态引导算法重建图像，第三列显示真实值样本。

5 结论

在本研究中，我们提出了一种算法，利用扩散先验和跨模态信息引导图像重建。具体而言，该算法引入了一种轻量级跨模态一致性模块，无需重新训练扩散模型，并且能够很好地推广至受损的跨模态信息。我们展示了该算法带来的改进具有双重效果：它不仅提升了中间阶段和最终的重建质量，还能在域适应设置下更准确地微调扩散先验的权重。我们在模拟稀疏中子 CT 数据上验证了该算法，并利用更易获取的 X 射线计算机断层扫描数据进行引导。为展示其泛化能力，我们在不理想条件（即稀疏/含噪）下模拟了 X 射线计算机断层扫描的采集设置。平均而言，跨模态引导使重建图像的峰值信噪比提高了 +0.73 dB，结构相似性指数提高了 +0.073；其中，峰值信噪比的最大增益出现在稀疏视角条件（8–32 个视角）下。未来，我们计划在真实的中子/ X射线CT配对数据上开展实验，并为跨模态重建提供理论保证。

6 致谢

作者谨向耶鲁大学的 Yuejie Chi 教授致谢，感谢他在扩散模型和逆问题方面给予的指导。

7 参考文献

[1] Jonathan Ho、Ajay Jain 和 Pieter Abbeel，“去噪扩散概率模型”，载于*NeurIPS*，2020年。[2] Yang Song 和 Stefano Ermon，“通过估计数据分布的梯度进行生成建模”，*NeurIPS*，2019年。[3] Alexander Quinn Nichol 和 Prafulla Dhariwal，“改进去噪扩散概率模型”，载于国际机器学习会议（*ICML*）论文集。PMLR，2021年，第8162–8171页。[4] Hyungjin Chung、Dohyun Ryu、Michael T. McCann、Marc L. Klasky 和 Jong Chul Ye，“使用预训练二维扩散模型求解三维逆问题”，载于*IEEE/CVF*计算机视觉与模式识别会议（*CVPR*）论文集，2023年，第2586–2595页。[5] Hyungjin Chung 和 Jong Chul Ye，“用于三维逆问题高效分布外适应的深度扩散图像先验”，载于欧洲计算机视觉会议（*ECCV*），Cham，2024年，第432–455页，Springer Nature Switzerland。[6] Bahjat Kawar、Michael Elad、Stefano Ermon 和 Jiaming Song，“去噪扩散恢复模型”，载于神经信息处理系统进展（*NeurIPS*），2022年，第35卷，第23593–23606页。[7] Xingyu Xu 和 Yuejie Chi，“用于即插即用图像重建的可证明鲁棒的基于分数的扩散后验采样”，载于神经信息处理系统进展（*NeurIPS*），2024年，第37卷，第36148–36184页。[8] Singanallur Venkatakrishnan、Amirkoushyar Ziabari、Jacob Hinkle、Andrew W Needham、Jeffrey M Warren 和 Hassina Z Bilheux，“用于加速中子断层扫描的基于卷积神经网络的非迭代重建”，机器学习：科学与技术，第2卷，025031，2021年2，no. pp. .[9] Felix H Kim、Dayakar Penumadu、Jens Gregor、Nikolay Kardjilov 和 Ingo Manke，“颗粒材料的高分辨率中子与X射线成像”，岩土与地质环境工程学报，第139卷，723，2013年5，715no. pp. – .

[10] Jelle Vlassenbroeck、VeerleCnudde、Bert Masschaele、Manuel Dierick、Luc Van Hoorebeke 和 Patric Jacobs，“作为无损材料评估技术的 X 射线计算机断层扫描与中子计算机断层成像的比较与批判性研究”，2007。

[11]Shaun S Gleason、Vincent C Paquit、Hassina Z Bilheux、Keely J Willis、Alyssa M Deleon、WM McNuttz 和 Udaya C Kalluri，“用于植物系统生物学研究的 X 射线与中子成像”，载于*FutureofInstrumentation*国际研讨会，2010年。

[12] Timofey Efimov、Harry Dong、Megna Shah、Jeff Simmons、Sean Donegan 和 Yuejie Chi，“利用多模态扩散模型，通过辅助信息加速成像”，载于*ICASSP 2025-2025 IEEE*声学、语音与信号处理国际会议（*ICASSP*）。IEEE，2025年，第1–5页。

[13] Qiong Lyu与Ge Wang，“使用扩散模型与分数匹配模型实现计算机断层成像与MRI图像之间的转换，”*arXiv*预印本*arXiv:2209.12104*，2022。

[14] Mengfei Xia、Yu Zhou、Ran Yi、Yong-Jin Liu与Wenping Wang，“用于高效图像到图像转换的扩散模型转换器，”*IEEE*模式分析与机器智能汇刊，第PP卷，第99期，2024年，2025年2月在线发表；提前获取。[15] Hyungjin Chung、Jong Chul Ye、Peyman Milanfar与Mauricio Delbracio，“面向逆问题的潜在扩散模型提示调优，”*arXiv*预印本 *arXiv:2310.01110*，2023。[16] X. Li、K. Shang、M. D. Butala与G. Wang，“通过结合随机医学测量嵌入的零空间去噪扩散实现跨模态增强稀疏CT成像，”《亚历山大工程学报》，第126卷，第565–577页，2025年。[17] Ziluo Dou与Yang Song，“用于线性逆问题求解的扩散后验采样：一种滤波视角，”载于第十二届国际学习表征会议（*ICLR*）论文集，2024年。[18]Amir Ziabari、Mohamed Alnaggar与Amani Cheniour，“基于PyCMG的体积混凝土微观结构仿真，”
h
t
t
p
s://
doi.ccs.ornl.gov/dataset/4de41b4c-88d3-58cc-a6a5-07d3348a6576，2025年4月，数据集。[19] Phillip Isola、Jun-Yan Zhu、Tinghui Zhou与Alexei A. Efros，“基于条件对抗网络的图像到图像转换，”载于*IEEE*计算机视觉与模式识别会议论文集，2017年，第1125–1134页。