arXiv:2603.00882v1 [eess.IV] 1 Mar 2026

结合物理模型与深度生成先验求解标记磁共振成像的非线性盲逆问题

Zhangxing Bian[1] Shuwen Wei[1] Samuel W. Remedios[1] Junyu Chen[2]Aaron Carass[1] Blake E. Dewey[2] Jerry L. Prince[1]约翰斯·霍普金斯大学[1] 约翰斯·霍普金斯大学医学院[2]

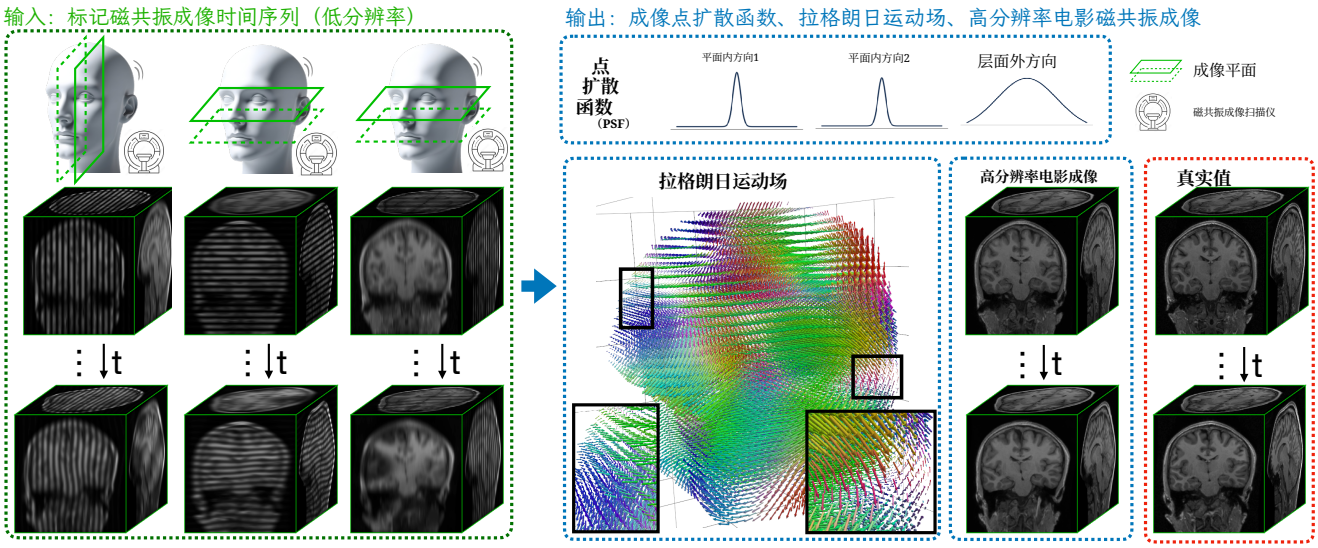

图 1. 我们研究一个非线性盲逆问题：给定一系列三维标记磁共振成像体数据，我们联合估计导致图像模糊的成像点扩散函数、高分辨率电影图像序列以及潜在运动场。无需额外训练数据。

摘要

标记磁共振成像能够以无创方式跟踪内部组织运动。它通过用周期性标记调制解剖结构来编码运动，这些标记会随组织一起变形。然而，解剖结构、标记与运动之间的相互纠缠给后处理带来了重大挑战。标记的存在和成像模糊会妨碍解剖结构分割等下游任务。*T1*弛豫导致的标记衰减会破坏运动跟踪中的亮度恒常性假设。数十年来，这些挑战一直被孤立地、以次优方式处理。与之不同的是，我们提出了一种用于标记磁共振成像的盲非线性逆向框架，首次将这些任务统一起来：解剖图像恢复、高分辨率电影图像合成和运动估计。其核心在于磁共振物理与生成先验的协同作用，使我们能够盲估计未知的正向成像模型和高分辨率底层解剖结构，同时——

间跟踪随时间变化的三维微分同胚拉格朗日运动。标记脑磁共振成像实验表明，与专用方法相比，我们的方法能够生成高分辨率解剖图像和电影图像，并实现更准确的运动估计。

1. 引言

无创跟踪内部组织运动是医学成像中的核心主题。磁共振（MR）标记编码内部组织运动，即通过印记临时的周期性饱和磁化模式（即标签） [7]。随着组织运动，标记线发生形变，从而为运动和应变提供可视化与定量的依据。标记磁共振成像广泛用于心脏运动分析 [6, 23, 45], 、肌肉生物力学 [11, 39, 40], 和脑生物力学 [8, 28]。然而，由于标记图案和成像过程产生的伪影，分析标记磁共振成像具有挑战性。标记

对比度会随时间急剧衰减（“标记衰减”），这是由于T1弛豫 [44] 以及向稳态的演进 [10],，从而违反了基于光流的方法所依据的亮度恒常性假设。此外，与T1加权（T1w）等标准结构磁共振成像相比，带标签的MR扫描的空间分辨率常常为了成像速度而被牺牲。再者，由于标签的存在，大多数解剖分割方法无法直接用于下游分析，因而目前的做法是额外采集一组电影图像序列 [13, 43]。电影图像能够在没有标记线的情况下可视化形变中的解剖结构，但需要额外的采集时间。这些因素使得难以从标记图像中准确恢复运动，并限制了其应用。

几十年来，这些挑战一直被视为标记磁共振成像分析中的独立任务：跟踪运动、合成电影图像，以及提升图像分辨率。然而，这种分而治之的做法往往会导致结果不一致，也无法充分利用数据。例如，在运动跟踪方面，光流 [17, 45] 和图像配准 [11, 62, 63] 已被应用于标记磁共振成像，但由于标记衰减违反了亮度恒常性假设 [10]，这些方法仍难以奏效。为解决这一问题，基于傅里叶的方法 [3, 11, 38, 41, 47, 57, 60] 将标记图像视为底层解剖结构受到周期载波信号（即标签）振幅调制的结果。它们提取谐波峰，以计算并跟踪随时间变化的相位图像。然而，由于标签具有低频特性，标记磁共振成像的直流分量与谐波频谱会发生重叠；标记衰减和大形变还会进一步模糊谐波峰，加剧重叠，从而违背这些基于傅里叶的方法 [12]所依赖的假设。

除了运动跟踪之外，从标记扫描合成无标记电影磁共振成像，还能减少单独采集电影磁共振成像的需求，从而简化当前的临床工作流程。近期研究 [35, 36] 将其视为二维图像到图像转换。与此同时，提高电影磁共振成像的空间分辨率，可以改善分割和配准等下游任务。尽管超分辨率（SR）已在自然图像 [32, 37, 67] 和磁共振图像 [29, 31,49, 58, 65], 中得到广泛研究，但直接对电影序列逐帧 应用相互独立的超分辨率，可能会引入时间不一致性和运动不一致细节——例如，幻觉生成的边缘／结构在不同帧间变化，并破坏组织轨迹的物理连续性。尽管已有研究探讨从标记图像合成电影图像及电影图像超分辨率，但直接从低分辨率 标记磁共振成像中恢复高分辨率 三维电影序列的研究仍然很少。

我们认为，需要采用统一方法来联合解决这三项任务，因为它们从根本上相互耦合：（1）可靠的运动跟踪要求妥善处理标记衰减和频谱重叠；（2）反过来，要解决频谱重叠，就需要将底层解剖结构（直流分量频谱）与渐隐的标记模式（谐波频谱）区分开来；（3）生成时间上连贯的电影图像取决于准确的运动估计。此外，标记磁共振成像通常以牺牲空间分辨率为代价来提高成像速度，因此会产生低分辨率数据。对电影解剖结构进行超分辨率重建，有利于后续分析的稳健性。统一的公式化方法将这些组成部分纳入一个协同循环，使它们相互促进。

为此，我们提出 InvTag，这是一种非线性 且盲反演框架，仅使用原始低分辨率标记磁共振成像数据，即可恢复：（1）高分辨率解剖结构；（2）描绘变形解剖结构的无标记电影序列；（3）生物力学上合理的三维运动场；以及（4）成像系统的各向异性点扩散函数。由于组织发生非线性微分同胚变形，该问题是非线性的；又由于关键前向模型组件（点扩散函数、标记参数和随时间变化的渐隐）未知，因此该问题是盲的。

为解决逆问题的不适定性，InvTag 融合了四个要素：(1) 一种基于物理的磁共振成像前向模型，其参数由未知的点扩散函数和标记变量确定；(2) 在广泛可获得的高分辨率 T1加权磁共振成像数据上预训练的扩散先验，用于将解剖结构正则化为符合现实的结构；(3) 一种物理信息神经网络，用于估计平滑的微分同胚运动场；以及 (4) 一种带扩散先验的坐标下降（CDDP）方案，在扩散后验解剖结构采样与未知参数的最大似然更新之间交替进行。在这一框架中，磁共振物理施加硬约束（例如模糊和标记图案的形成与消退方式），而扩散先验则提供软的数据驱动约束（例如解剖合理性）。重要的是，InvTag 无需外部标记或电影训练数据——无需配对监督或微调——因此在此类采集成本高昂且数据稀缺的领域具有实用性。

据我们所知，InvTag 是首批将磁共振物理与扩散生成先验相结合、用于解决非线性盲逆问题的框架之一。以往方法 [16, 66] 通常假设线性关系或已知的前向算子，而这一假设在实际应用中往往不现实。我们的工作超越了这一设定，通过联合解剖结构和运动共同估计未知的成像参数，从而将扩散引导反演拓展至实际的盲场景。

总而言之，我们的贡献如下：（1）InvTag，首个从三维标记磁共振成像中联合恢复高分辨率解剖结构、电影图像和运动的统一解决方案。（2）我们利用磁共振物理与深度生成先验，构建并求解了一个实用的非线性、盲 反演问题。（3）我们提出了CDDP方案，可实现稳定的反演优化。（4）在标记头部磁共振成像上的评估表明，InvTag能够生成高保真的超分辨率解剖结构、时间一致的电影序列合成，并改进运动跟踪的准-

与专业方法相比的准确性。

2. 相关工作

标记MRI运动跟踪。 标记磁共振成像运动跟踪方法通常在傅里叶域 [3, 11, 21, 38, 41, 46, 47, 57, 60]或图像域 [17, 45, 62, 63]中进行。基于傅里叶的方法——如HARP [11, 34, 38, 41, 60], Gabor滤波器 [46, 47], 和SinMod [3, 57]——根据带通滤波后标记图像的相位计算运动，并假设谐波峰彼此分离。在实际中，标记衰减、大形变和穿平面运动会造成频谱重叠 [10, 19, 22],从而违反该假设并导致跟踪误差。BRITE [12] 通过显式分离标记模式与底层低分辨率解剖结构来应对频谱重叠，但仅限于二维，且仅在圆柱体模等简单解剖结构上得到了验证。

电影序列合成。 从标记数据重建无标签电影磁共振成像序列，可以避免单独进行电影磁共振成像采集。基于HARP的解调 [42, 60]利用经过HARP滤波的复数图像的幅度来近似无标签图像，但通常会导致较低的空间分辨率。近年来，深度学习方法将标记到电影转换构建为图像到图像合成任务。Liu 等人 [35, 36] 训练了一种 Transformer，以一系列二维标记图像为输入，直接合成相应的电影帧。然而，这类数据驱动方法依赖大量标记图像和电影磁共振成像数据集（成对或非成对）进行训练，并且可能在时间维度上生成不一致的解剖结构。

超分辨率。 对于已采集的电影磁共振成像，已有研究致力于提升其空间分辨率。Woo 等人 [58] 将三个正交方向的三维体数据结合起来，利用较高的面内分辨率重建高分辨率电影体数据。尽管针对自然图像和磁共振图像 [29, 31, 32, 37, 49, 65, 67],已有大量超分辨率（SR）方法，但大多数方法都是独立地处理单幅图像。将这些方法直接应用于我们的任务，会忽略帧间的时间一致性以及每个时间点由多方向 采集提供的互补信息。

逆问题的生成先验。我们的工作与日益广泛地将深度生成模型用作逆成像问题先验的研究相关。Bora 等人 [14] 首次证明，预训练生成模型可以作为压缩感知的先验：在生成器的输出范围内寻找与测量值最匹配的图像。近年来，即插即用扩散模型已成为许多图像复原任务的最先进方法。DPS [16]等方法以及许多其他方法 [59, 61, 64, 68]使用预训练扩散模型求解线性和非线性逆问题 [66] ，而无需针对特定任务进行再训练。我们的问题有一个独特之处，即同时具有非线性和盲性，而这两方面至今仍鲜有研究。AmbientGAN [15] 学习前向算子的数据分布，Levac 等人 [30]则将这一思路扩展到联合学习图像和模糊核分布，以实现盲去模糊。相比之下，我们的方法应对一个高度非线性且多维的逆问题——以盲方式联合求解三维模糊、乘性标记模式、高分辨率解剖结构和非线性运动；此前尚无研究解决过这一问题。

3. 方法

3.1. 逆问题表述

前向模型。 设 $\Omega \subset \mathbb{R}^3$为图像域。对于每个标记方向 $\square \in \{\vec{i}, \vec{j}, \vec{k}\}$和时间 $t \in \{1, \dots, T\}$，观测到的标记图像 $g_t^{\square}$:$\Omega \to \mathbb{R}$ 建模为

$$g_t^{\square} = \mathcal{A}^{\square}(a_t) + n_t^{\square}, \tag{1}$$
$$= h_\gamma^{\square} * (q_t^{\square} \cdot a_t) + n_t^{\square}, \tag{2}$$

其中， $a_t : \Omega \to \mathbb{R}$ 表示时间 t的底层变形解剖结构，$q_t^{\square}: \Omega \to \mathbb{R}$ 表示时间 t已衰减且变形的标记模式， $h_\gamma^{\square}$ 表示方向 $\square$ （由 γ参数化）对应的点扩散函数（PSF），$*$ 表示三维卷积， $\cdot$表示标量乘法， $n_t^{\square}: \Omega \to \mathbb{R}$表示噪声。为简洁起见，省略空间变量 $\boldsymbol{r} \in \Omega$。每个方向向量 $\square$均沿着 标记传播方向，即垂直于标记线。

我们将运动表示为微分同胚 $\phi_t : \Omega \to \Omega$，它将时间 t 的坐标映射到 未变形的 参考帧。相应的图像扭曲（拉回）算子定义为

$$\big(\phi^* u\big)(\boldsymbol{r}) = u\big(\phi(\boldsymbol{r})\big)\,. \tag{3}$$

利用这一算子，时刻 t的变形解剖结构和标记模式可写为

$$a_t \;=\; \phi_t^*\, a, \qquad q_t^{\square} \;=\; \phi_t^*\, f_t(q^{\square}), \tag{4}$$

其中 a 表示参考帧中的未变形解剖结构， $q^{\square}$ 表示参考帧中的未变形方向$\square$基础标记模式，而 f_t： $\mathbb{R} \to \mathbb{R}$ 表示时刻 t的标记衰减。将（4）代入（2），并利用恒等式 $(\phi_t^*\, u) \cdot (\phi_t^*\, v) \;=\; \phi_t^*\, (u \cdot v)$ ，可得

$$g_t^{\square} \;=\; h_\gamma^{\square} * \phi_t^*\, [a \cdot f_t(q^{\square})] \;+\; n_t^{\square}. \tag{5}$$

逆问题。给定多时刻、多方向的测量值 $\{g_t^{\square}\}$，目标是联合估计

$$a, \quad \{q^{\square}\}, \quad \{h_\gamma^{\square}\}, \quad \{f_t\}_{t=0}^{T}, \quad \{\phi_t\}_{t=1}^{T}$$

使得（5）对所有$(t,\ \square)$成立。这构成一个非线性盲逆问题：非线性源于

可变形空间变换，而盲性源于未知的成像参数和衰减过程。不同于直接估计变形解剖结构 a_t 在每个时刻（如（2）中那样），公式（5）利用显式形变ϕ_t 将所有帧关联到共同解剖结构 a，从而在构造上强制时间解剖一致性：解剖结构仅通过 ϕ_t发生几何变化。

3.2. 参数化与假设

为使系统可辨识且在数值上可求解，我们对模型的每个组成部分施加一组磁共振物理先验简化。

各向异性成像点扩散函数。 我们将 $h_\gamma^\square$ 建模为标准差为 $\gamma := (\gamma_\perp, \gamma_\parallel, \gamma_{\text{thru}})$ 的各向异性三维高斯分布。对于每次采集，标记方向为 $\square$、$\gamma_\perp$ 和 $\gamma_\parallel$ 分别控制垂直于和平行于标记线方向的平面内模糊，而 γ_{thru} 控制层间模糊。卷积后对核进行归一化，以保持图像的平均强度（单位直流增益）。我们假设，这种高斯近似能够捕捉常规磁共振成像采集中的主要模糊效应；更复杂的点扩散函数模型（例如多层面串扰）留待未来研究。

基础标记模式。 未变形的基础模式 $q^\square$ 遵循标准 SPAMM 物理原理 [7]，并以正弦函数进行参数化。因此，对于标记方向 $\square$，我们写作

$$q_\alpha^\square := p_0^\square(\boldsymbol{r};\alpha) \;=\; \alpha_1 \cos(2\pi \langle \square, \boldsymbol{r}\rangle/\alpha_2 \;+\; \alpha_3) + \alpha_4 \quad (6)$$

其中 $\boldsymbol{r} \in \Omega$为空间坐标变量，$\langle\cdot,\cdot\rangle$ 表示内积。 $\alpha := \{\alpha_1, \alpha_2, \alpha_3, \alpha_4\} \in \mathbb{R}^4$，其中 α_1（振幅）、α_2（标记间距）、α_3（相位）和 α_4（直流偏移）用于参数化基础标记模式。参数 α 在所有标记方向 $\square$之间共享。尽管标称标记间距可从DICOM元数据（若可用）获得，但由于磁共振采集伪影，有效值往往会出现偏差。因此，我们将 α 视为未知量。

标记衰减。 衰减由组织的磁共振特性与成像方案决定，在我们的表述中假定其为未知。衰减过程可由施加于基础标记的仿射模型 [10]刻画：

$$f_{\beta_t}(q_\alpha^\square) := f_t(q^\square;\beta_t) \;=\; \left|\beta_{1,t}\cdot q^\square + \beta_{2,t}\right|, \quad (7)$$

其中 $\beta_t := (\beta_{1,t}, \beta_{2,t}) \in \mathbb{R}^2$ 分别表示时刻 t的振幅与直流偏移，并在所有 $\square$之间共享。记号$|\cdot|$ 表示绝对值。

运动。 我们将 ϕ_t 表示为神经场 $\phi_t(\cdot;\theta_t)$：$\Omega \to \Omega$，其中 θ_t 是物理信息神经网络（PINN）[48]的权重。该网络接收坐标 $\boldsymbol{r}$ 并输出平稳速度场 $\boldsymbol{v}_t(\boldsymbol{r};\theta_t)$，而 $\phi_t(\boldsymbol{r};\theta_t)$ 通过对 $\boldsymbol{v}_t$的指数映射计算得到：

$$\phi_{\theta_t} := \phi_t(\boldsymbol{r};\theta_t) = \exp\{\boldsymbol{v}_t(\boldsymbol{r};\theta_t)\}. \quad (8)$$

exp通过快速缩放与平方 [2]积分实现，从而促进微分同胚形变场。

参数化前向模型。 根据前文，$(t, \square)$ 的参数化前向模型可写为

$$\mathcal{A}_t^\square(a;\alpha,\gamma,\beta_t,\theta_t) \;=\; h_\gamma^\square * \phi_{\theta_t}^* \left[\, a \cdot f_{\beta_t}(q_\alpha^\square)\,\right]. \quad (9)$$

3.3. 带扩散先验的坐标下降

由于逆问题具有盲性和不适定性，我们采用坐标下降策略来求解。其核心思想是迭代更新：(A) 在固定前向模型参数的情况下，利用扩散先验更新底层解剖结构 a；(B) 在固定 a 的情况下，更新前向模型参数。经验上，与对所有变量进行联合优化相比，这种交替方案具有更好的数值稳定性和收敛鲁棒性。

(A) 通过扩散后验采样估计解剖结构。为了搜索能够解释观测结果的真实解剖结构 a，我们施加扩散先验，并将前向模型视为固定。为清晰起见，我们将继续把所有变量表示为 Ω 上的连续函数，不过在实践中，所有计算都是在离散化的体素网格上进行的。

扩散模型将生成过程定义为加噪过程的逆过程。给定观测结果 $\{g_t^\square\}$，我们通过反向时间随机微分方程（SDE）[1, 53]从后验 $p(a|\{g_t^\square\})$ 中抽取样本。

$$da_\tau = -\eta_\tau \left[a_\tau/2 + \nabla_{a_\tau} \log p_\tau(a_\tau|\{g_t^\square\})\right] d\tau + \sqrt{\eta_\tau}\, d\bar{w}, \quad (10)$$

其中，τ 表示从 1 反向运行至 0 的扩散时间，η_τ：$\mathbb{R} \to \mathbb{R} > 0$ 是扩散过程 [20]的噪声调度。$d\bar{w}$ 是反向运行的标准维纳过程。这里，a_τ 中的下标表示扩散时间τ，而非物理时间 t。根据贝叶斯法则，

$$\begin{aligned}\nabla_{a_\tau} \log p_\tau(a_\tau|\{g_t^\square\}) = \nabla_{a_\tau} \log p_\tau(a_\tau) \\ + \nabla_{a_\tau} \log p_\tau(\{g_t^\square\}|a_\tau),\end{aligned} \quad (11)$$

其中，第一项表示扩散先验，可由预训练得分函数 $s_\vartheta(a_\tau, \tau)$直接计算；第二项则确保数据一致性。

(11)中的第二项通过 DPS [16] 近似为

$$\nabla_{a_\tau} \log p(\{g_t^\square\}|a_\tau) \simeq \nabla_{a_\tau} \log p(\{g_t^\square\}|\hat{a}_0), \quad (12)$$

其中，$\hat{a}_0$ 是通过 Tweedie 公式 [18, 26, 51]得到的 $p(a_0|a_\tau)$ 后验均值估计：

$$\hat{a}_0 \simeq \frac{1}{\sqrt{\bar{\kappa}_\tau}}\left(a_\tau + [1-\bar{\kappa}_\tau]\, s_\vartheta(a_\tau,\tau)\right), \quad (13)$$

其中，i 表示离散扩散步，$\kappa_i := 1-\eta_i$，且$\bar{\kappa}_i := \prod_{j=1}^{i} \kappa_j$ 遵循 [20]。

假设存在独立同分布高斯噪声 $n_t^\square \sim \mathcal{N}(0,\sigma^2)$ 在前向模型（5）中，似然变为

$$p(\{g_t^\square\}|a) \propto \exp\left[-\tfrac{1}{2\sigma^2}\mathcal{L}_{\text{rec}}(a)\right], \quad (14)$$

其中

$$\mathcal{L}_{\text{rec}}(a) = \sum_t \mathcal{L}^t_{\text{rec}}(a) = \sum_t \sum_{\square} \left\| g^{\square}_t - \mathcal{A}^{\square}_t(a) \right\|_2^2 . \quad (15)$$

对 a_τ 求导，得到：

$$\nabla_{a_\tau} \log p(\{g^{\square}_t\}|a_\tau) \simeq -\rho \nabla_{a_\tau} \mathcal{L}_{\text{rec}}\big(\hat{a}_0(a_\tau)\big) , \quad (16)$$

这里我们明确写出 $\hat{a}_0 := \hat{a}_0(a_\tau)$ 以强调$\hat{a}_0$ 是 a_τ的函数。因此，梯度 ∇_{a_τ}相当于通过网络进行反向传播。步长 $\rho := 1/\sigma^2 \approx \rho^*/\mathcal{L}_{\text{rec}}$ 其中 ρ^* 是一个超参数。根据（10）、（11）和（16），可得

$$\begin{aligned} da_\tau = &- \eta_\tau \Big[\tfrac{1}{2} a_\tau + s_\vartheta(a_\tau, \tau) \\ &- \rho \nabla_{a_\tau} \mathcal{L}_{\text{rec}}\big(\hat{a}_0(a_\tau)\big) \Big] d\tau + \sqrt{\eta_\tau} d\bar{w}. \end{aligned} \quad (17)$$

这描述了完整的反向扩散过程：项 s_ϑ 将样本拉向“噪声较少”的解剖结构流形，而项 $\nabla_{a_\tau}\mathcal{L}_{\text{rec}}$ 则将样本推向数据保真度。对该反向随机微分方程进行离散化，并令 τ 从 1 递减至 0，得到更新后的解剖结构 a_0。

(B) 通过最大似然估计前向模型。固定 a 后，通过最小化数据残差，得到 $(\alpha, \gamma, \beta_t, \theta_t)$ 的最大似然估计：

$$\arg\min_{\alpha,\gamma,\{\beta_t\},\{\theta_t\}} \quad \mathcal{L}_{\text{rec}}\big(a; \alpha, \gamma, \{\beta_t\}, \{\theta_t\}\big). \quad (18)$$

对于低维参数（α，γ，$\{\beta_t\}$），我们使用有界的基于种群的优化器（例如差分进化 [54]），它在高度非凸景观中表现稳健，且对初始化不太敏感。经验上，与标准的基于梯度的方法（如梯度下降或 Adam [27]）相比，它收敛更快且能找到更优解。对于高维运动参数 θ_t（物理信息神经网络），我们采用 Adam 优化器以提高计算效率。

带扩散先验的坐标下降（CDDP）。综合各组成部分，算法 1 执行CDDP，以求解我们的非线性盲逆问题。我们将参考解剖结构 a 通过在 $t = 1$ 处对三个方向取平均并施加低通滤波器进行初始化。未变形基础标记初始化为全1常数图像，运动设置为恒等映射（ϕ_{θ_1} =Id），点扩散函数设置为狄拉克核（$h_\gamma = \delta$），且无模糊，衰减函数设置为恒等映射（f_{β_t} = Id）。**在第一个时间帧** t=1，我们运行 L轮循环，依次处理点扩散函数、标签、解剖结构和运动（第5-8行），以估计（$a^\star$，$\alpha^\star$，$\gamma^\star$），并在所有后续帧（t>1）中保持这些量固定（第10行）。这强制保证时间解剖一致性，并避免标签对比度随时间渐隐时发生缓慢漂移。解剖结构的更新使用预训练扩散得分 s_ϑ，其在超过80,000个 1mm 各向同性T1加权三维头部体数据上训练 [50]。在每一轮 ℓ中，

算法 1 用于非线性盲逆问题的 CDDP

1: **输入：** 测量值 $\{g^{\square}_t\}$ 对应于 $\square \in \{\vec{i}, \vec{j}, \vec{k}\}$ 和 $t = 1{:}T$；预训练扩散得分 s_ϑ
2: **输出：** 解剖结构 a、标记参数 α、点扩散函数 γ、渐隐 $\{\beta_t\}$，运动 $\{\phi_t\}$
3: **初始化：** $a \leftarrow$ 低通滤波(avg($g^{\square}_1$))；$q_\alpha \leftarrow \mathbf{1}$；$\phi_{\theta_1} \leftarrow$ Id; $h_\gamma \leftarrow \delta$; $f_{\beta_t} \leftarrow$ Id
4: **若** t=1 **则对于** $\ell = 1{:}L$ **执行**
5: 点扩散函数：$\gamma \leftarrow \min_\gamma \mathcal{L}^t_{\text{rec}}(a; \alpha, \gamma, \beta_t, \theta_t)$
6: 标签：$\alpha \leftarrow$ 分钟$_\alpha \mathcal{L}^t_{\text{rec}}(a; \alpha, \gamma, \beta_t, \theta_t)$
7: 解剖结构：$a \leftarrow$ 样本$(\alpha, \gamma, \beta_t, \theta_t, s_\vartheta)$ 如（17）
8: 运动：$\theta_t \leftarrow$ 分钟$_{\theta_t} \mathcal{L}^t_{\text{rec}}(a; \alpha, \gamma, \beta_t, \theta_t)$
9: **结束循环**
10: Set $a^\star \leftarrow a$, $\alpha^\star \leftarrow \alpha$, $\gamma^\star \leftarrow \gamma$
11: **对于** $t = 2$ 至 T **执行**
12: $\theta_t \leftarrow \theta_{t-1}$ # 从上一个运动状态初始化
13: **对于** $\ell = 1$ 到 L**执行**
14: 渐隐：$\beta_t \leftarrow$ 最小值$_{\beta_t}$ $\mathcal{L}^t_{\text{rec}}(a^\star; \alpha^\star, \gamma^\star, \beta_t, \theta_t)$
15: 运动：$\theta_t \leftarrow$ 最小值$_{\theta_t}$ $\mathcal{L}^t_{\text{rec}}(a^\star; \alpha^\star, \gamma^\star, \beta_t, \theta_t)$
16: **结束循环**
17: 设定 $\beta^\star_t \leftarrow \beta_t$, $\theta^\star_t \leftarrow \theta_t$
18: **结束循环**
19: **返回：** $a^\star$、$\alpha^\star$、$\gamma^\star$、$\{\beta^\star_t\}$ 和 $\{\phi^\star_{\theta_t}\}$

反向过程（17）采样得到更新后的 a_0。采样期间，预训练的扩散模型权重保持冻结，并使用 256 个去噪扩散隐式模型（DDIM）[52] 步。对于每个**后续帧** t>1，我们交替进行 L 次衰减和运动优化，同时保持 $(a^\star, \alpha^\star, \gamma^\star)$ 固定。我们使用 $L = 4$。运动参数从前一时刻的状态（$\theta_t \leftarrow \theta_{t-1}$）初始化，这使得大范围的拉格朗日形变跟踪成为可能，并避免了周期性标记匹配歧义 [9, 33]。

低维参数（γ，α，β_t）通过有界差分进化进行优化；参数范围的选取覆盖了常规磁共振成像中常见的典型取值。各向异性点扩散函数标准差的范围为 $\gamma_\perp$，$\gamma_\parallel$，$\gamma_{\text{thru}} \in [0, 4]$ 个体素；标记参数采用振幅 $\alpha_1 \in [0.5, 1.]$、间距$\alpha_2 \in [0.9, 1.1] \times$（标称间距）、相位 $\alpha_3 \in [-\pi, \pi]$ 和直流分量水平 $\alpha_4 \in [0, 0.5]$；衰减参数满足$\beta_{1,\,t}$，$\beta_{2,\,t} \in [0, 1]$。这些范围足以涵盖常规磁共振成像采集中常见的典型面内/层面外模糊、标记间距相对于标称值的偏差以及标记衰减。物理信息神经网络（PINN）的运动参数使用 Adam 优化。

实现细节体数据经中心裁剪和/或填充至 $192 \times 224 \times 192$ 体素，并归一化至 $[0, 1]$。去噪扩散概率模型采用五级三维 U-Net，包含 256 个去噪扩散隐式模型采样步，并在超过 80,000 个 1 mm 各向同性 T1 加权体积上预训练 [50]。对于 6 帧三维序列，我们的流程每帧运行 1.2 小时，在单个 NVIDIA A40

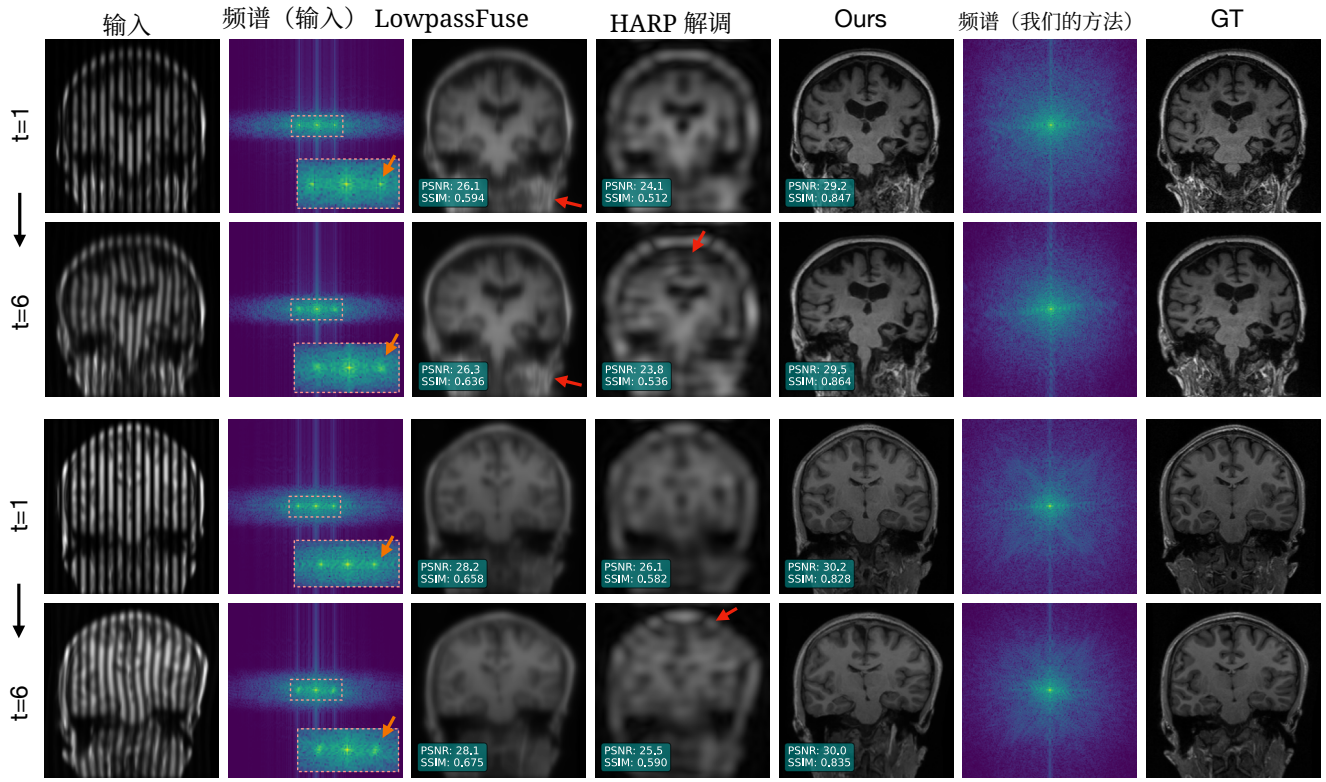

图 2. 标记到电影图像合成的定性比较。对于两位受试者，我们展示了早期（t=1）和晚期（t=6）帧。最左列显示输入的标记磁共振成像（省略了其他视图和方向），最右列显示真实电影图像。图中展示了输入和我们的方法的傅里叶频谱。橙色箭头指示减弱且模糊的谐波峰。红色箭头指示混叠伪影。

图形处理器上，峰值显存为 38GB。完整实现细节见附录 A。

4. 实验结果

我们的方法有两个主要输出：一系列高分辨率电影序列 MRI 和运动场，我们通过标记到电影图像合成和运动估计任务对其进行评估。

4.1. 实验设置

数据集与算子。 我们从 AIBL[1] 和 Sleep[2] 中分别随机选取了 20 名不重复的 T1 加权受试者用于测试。Sleep 中的 MRI 已进行面部去标识化。两个数据集均未纳入去噪扩散概率模型的训练数据，仅用于测试。标记形成与渐隐遵循磁共振物理模型 [10], , 图像则使用三维高斯核进行模糊处理。对于每名受试者，我们通过对随机生成的无散速度场（由矢势的旋度得到）使用四阶龙格－库塔方法进行积分，独立生成微分同胚形变，从而得到逼真的不可压缩运动；随后使用所得速度场对标记图像进行变形，生成标记 MRI 序列

[1]aibl.org.au/[2]openneuro.org/datasets/ds003826/versions/3.0.1

长度为 6。为涵盖成像差异，我们评估了四种设置：三种模糊配置（$\gamma_{\perp}$、$\gamma_{\parallel}$、γ_{thru}）——(1，1，1)、(0.4，0.4，4)、(0.4，1，3)，不添加噪声（涵盖各向同性和各向异性模糊）；以及 (0.4，1，3) 并添加高斯噪声（均值为零，标准差为图像动态范围的 0.01）。总计有 $(20 + 20) \times 4 = 160$ 个不重复的测试用例。

指标。 由于我们拥有来自磁共振标记模拟的真实值（GT）图像，因此可以使用基于参考图像的图像质量指标来评估从标记图像合成电影图像的效果和超分辨率性能。我们将图像强度归一化至相同的动态范围，并采用 scikit-image 实现的峰值信噪比（PSNR）和结构相似性指数（SSIM）[55]。对于运动精度，我们报告平均端点误差（EPE）、$\text{EPE}(\boldsymbol{r}) = \|\mathbf{u}^{\text{gt}}(\boldsymbol{r}) - \mathbf{u}_{\text{est}}(\boldsymbol{r})\|_2$（位移误差幅值）及其第95百分位数（EPE@95），以汇总尾部误差。我们还报告雅可比行列式为负的体素所占百分比，以评估对微分同胚性的违背（即组织折叠）。

基线方法。 对于从标记图像合成电影图像，我们比较：(i) *LowpassFuse*，它沿每个标记方向应用一维高斯低通滤波器以去除标记，并对结果取平均

方法	时间范围	峰值信噪比↑	结构相似性指数↑
LowpassFuse	t=1	26.43 ± 1.40	0.62 ± 0.06
	t=6	26.68 ± 1.39	0.66 ± 0.05
HARP 解调	t=1	24.28 ± 1.26	0.52 ± 0.04
	t=6	23.93 ± 1.17	0.54 ± 0.03
Ours	t=1	**28.38 ± 1.41**	**0.83 ± 0.04**
	t=6	**28.41 ± 1.36**	**0.84 ± 0.03**

表 1. 不同方法和时间范围下从标记图像合成电影图像的定量比较，以平均值 ± 标准差表示。

模糊、噪声	峰值信噪比↑	结构相似性指数↑	模糊、噪声	峰值信噪比↑	结构相似性指数↑
(1、1、1),	29.15	0.85	(0.4,1,3),	28.78	0.84
(0。4、0。4、4),	28.21	0.82	(0.4,1,3), √	27.30	0.79

表 2. 我们在各种成像质量下的合成结果评估。

；以及 (ii)*HARP* 解调 [42, 60]，，它对 HARP 滤波复数图像的幅值取平均，使用以标记频率为中心、半径等于真实标记频率一半的带通滤波器。对于运动估计，我们比较基于学习的方法（LKUnet [25]和 DeepTag [62, 63]）以及基于优化的方法，例如 SyN [4] 和 DRIMET [11]。DeepTag（最初为二维网格标记）通过将二维卷积替换为三维卷积，并将三个正交线标记图像相乘合成网格标记，从而适配到三维。为确保测试公平，基于学习的方法使用人类连接组计划（HCP）数据中 150 张 T1 加权脑图像生成的标记序列进行预训练 [56] 。DRIMET 对正弦变换后的 HARP（sHARP）图像进行配准，我们使用 SyN 作为其配准后端。HARP 解调[3]、LKUnet[4]、DeepTag[5]、DRIMET[6], 和 SyN [5]的实现均采用作者提供的版本。平滑度超参数通过在包含 20 个标记序列的留出验证集上进行网格搜索来选取。

4.2. 标记到电影图像结果

我们首先评估所提方法在保持时间一致性的同时，重建高分辨率解剖结构的能力。我们将其与 LowpassFuse 和基于 HARP 的解调基线方法进行比较，并在表 1 中报告两个时间点的结构相似性指数和峰值信噪比。正如图 t=6 所示，即使在标记衰减和形变变得显著的较后期帧（例如 2 ），我们的方法也能显著提升合成质量。与这两种基线方法不同，我们的方法不需要预先知道标记频率来设计带通滤波器（例如 HARP 滤波器的中心和半径），而是直接估计该信息。LowpassFuse 会产生明显的混叠伪影（块状条纹），这是因为手动选择截止频率较为困难，

频率：选择过低会使图像过度平滑，而

[3]iacl.ece.jhu.edu/index.php?title=HARP_常见问题[4]github.com/xi-jia/LKU-Net[5]github.com/DeepTag/cardiac_标记_运动_估计[6]github.com/jasonbian97/DRIMET-tagged-MRI

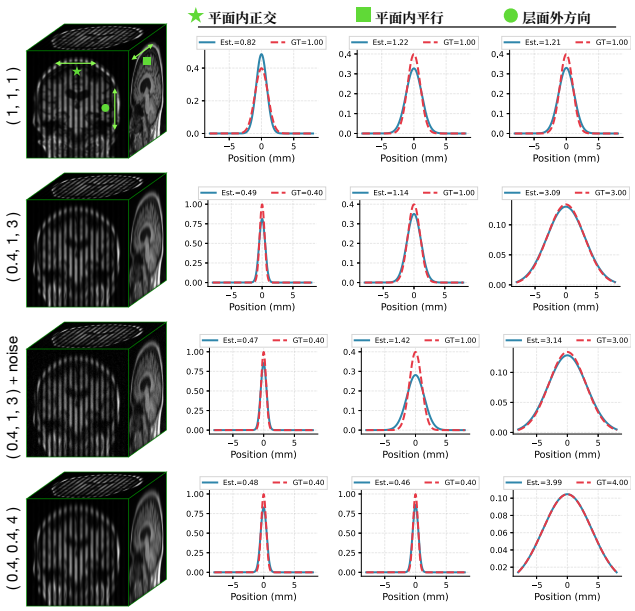

图 3. 不同模糊设置和噪声水平下估计的点扩散函数（PSF）结果。

选择过高则会留下产生混叠的残余标记图案。HARP 解调方法也存在类似问题。从输入的傅里叶频谱（图 2，第 2 列）可以看出，形变会逐渐模糊谐波峰，使其更难通过任何固定的带通滤波器分离。

在各种成像质量下进行测试。表 2和图 6（附录）表明，我们的方法在不同模糊核和噪声水平下仍然具有稳健性。

估计 PSF。我们没有学习基于数据的 PSF 先验 [15, 30]——这通常会受到域偏移的影响——而是在优化过程中盲目地联合估计成像点扩散函数。图3 展示了不同模糊和噪声条件下的 PSF 重建结果。

4.3 运动估计结果

给定一组标记磁共振成像序列，我们使用平均端点误差、95分位端点误差和负行列式来评估所得的运动精度。如表 3 所示，基于学习的配准方法（LKUnet、DeepTag）直接将原始标记磁共振成像作为输入，会因标记衰减而受到局部对比度变化的影响，并且在应用于新数据集时会遭遇域偏移。在基于优化的基线方法中，SyN 相较于基于学习的方法降低了平均误差和尾部误差，而 DRIMET 则通过显式利用 sHARP 表示进一步降低了端点误差。我们的方法取得了最低的端点误差，同时也实现了最低的 95分位端点误差。这表明其较大的局部误差更少，这对于生物力学研究中的可靠应变估计至关重要。所有基于优化的方法均报告了负行列式 $< 0.001\%$，证实它们产生的变形几乎是微分同胚的-

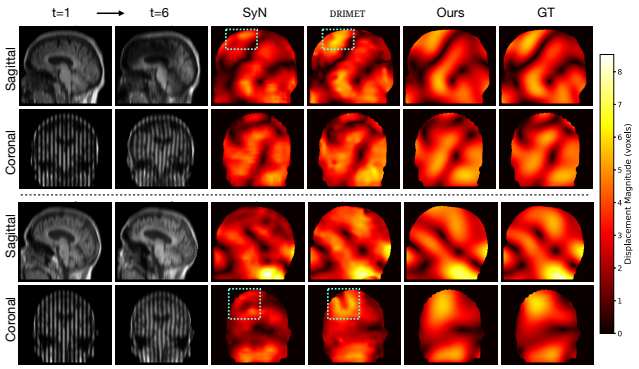

图4. 各方法的运动幅度对比。第1–2列：两个时间点的输入标记磁共振成像。最后一列：真实运动幅度。图中展示了矢状面和冠状面。

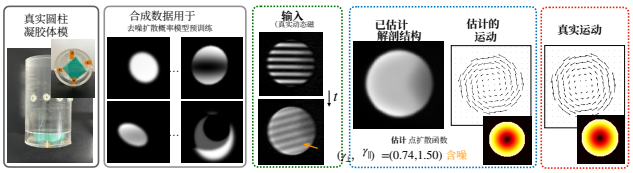

图5. **真实标记MRI：凝胶圆柱体。**

位移场。在图4 中的定性比较表明，在较大的变形区域和复杂的皮质褶皱处，我们估计的运动幅度更接近真实值，而其他方法往往会低估运动峰值，或引入虚假的空间波动。

4.4. 真实标记数据验证

为评估模型在仿真之外的泛化能力，我们在存在真实成像伪影的真实标记采集数据上评估 InvTag。我们在旋转的真实标记磁共振成像数据上测试了 InvTag，该数据来自一个**凝胶体模**（图5）。值得注意的是，扩散先验仅使用合成椭圆进行预训练。尽管存在训练测试域差距，InvTag 仍成功恢复了解剖结构，并在真实扫描仪采集效应下估计了旋转运动：场不均匀性、模糊、非高斯噪声和严重的标记衰减。

4.5. 消融研究

我们评估了三个组成部分的作用：点扩散函数估计、标记衰减估计，以及坐标下降扩散先验（CDDP）。表 4总结了结果。(A) 移除点扩散函数估计会明显降低合成质量，表明显式估计点扩散函数对于弥合低分辨率标记MRI与高分辨率扩散先验之间的分辨率差距至关重要。(B) 禁用渐隐估计，即保持时间不变的标记模式，会导致跟踪效果变差，这表明对时变标记衰减进行建模对于区分对比度变化与组织运动十分必要。(C) 将CDDP替换为使用Adam优化器对（18）中的所有参数进行同步优化

方法	Opt.	端点误差 ↓	端点误差@95 ↓	负行列式(%) ↓
LKUnet [25]	✗	1.35 ± 0.65	2.94 ± 1.30	0.043
DeepTag [62]	✗	1.27 ± 0.58	2.97 ± 1.13	0.060
SyN [4]	✓	1.06 ± 0.31	2.41 ± 0.80	< 0.001
DRIMET [11]	✓	0.79 ± 0.14	1.61 ± 0.53	< 0.001
Ours	✓	**0.60** ± **0.11**	**1.31** ± **0.22**	< 0.001

表 3. 运动估计精度的定量比较。“Opt.”表示该方法是否基于优化。

#	PSF	渐隐	CDDP	峰值信噪比↑	结构相似性指数↑	EPE↓	端点误差@95↓
A	✗	✓	✓	27.27	0.69	0.62	1.41
B	✓	✗	✓	28.21	0.80	0.71	1.56
C	✓	✓	✗	22.05	0.46	1.57	2.73
Ours	✓	✓	✓	**28.40**	**0.83**	**0.60**	**1.31**

表4. 方法组件的消融研究。省略标准差。

由于非线性盲逆问题的不适定性，导致优化失败。启用全部三个组成部分的完整模型（“我们的方法”）在所有指标上均取得最佳表现。

扩散先验强度的影响。 扫描先验权重 ρ^* 在（17）中的结果表明，InvTag 在较宽的工作范围内都具有稳健性（$\rho^* \in [50, 200]$）；只有数据项过弱（ρ^*=1）才会导致幻觉重建。完整扫描结果见附录 C。

经验可辨识性与收敛。 在 N=5次随机初始化运行中，估计的点扩散函数和标记参数的方差可忽略不计，运动精度保持稳定，证实了 CDDP 的可靠收敛。完整结果见附录 D。

5. 讨论

局限性与未来工作。 由于需要反复进行扩散采样并优化物理信息神经网络，InvTag 当前运行耗时较长。扩散模型采样的加速技术和多GPU并行化有望大幅缩短运行时间。InvTag 目前假设采用正弦标记；将其推广到高阶标记和网格标记可拓宽其适用范围。未来的重要工作包括将评估扩展至真实扫描，例如心脏磁共振标记。最后，在反演中纳入不确定性量化或可提升可解释性和临床信任。

结论。 我们提出了*InvTag*，一种用于三维标记磁共振成像的非线性且盲逆向框架，可联合恢复高分辨率解剖结构、合成电影图像并估计微分同胚运动。InvTag 是一种统一的表述，解决了长期以来被分别处理的挑战——标记到电影图像合成、超分辨率和运动估计。标记头部磁共振成像的实验结果展示了联合建模解剖结构、成像参数和运动所带来的协同效应。我们还展示了生成先验可用于解决医学成像中的非线性盲逆问题。

致谢。 本研究部分得到了美国国立卫生研究院（NIH）资助项目 U01NS112120 和约翰斯·霍普金斯探索奖的支持。

参考文献

[1] Brian DO Anderson. 反向时间扩散方程模型。《随机过程及其应用》，12 326，1982 3 313 4 ( ): – . [2] Vincent Arsigny、Olivier Commowick、Xavier Pennec 和 Nicholas Ayache. 微分同胚统计的对数欧几里得框架。载于 9th 国际医学图像计算与计算机辅助干预会议（MIC- CAI 2006），第 924–931 页。施普林格，2006。4[3] Theo Arts、Frits W Prinzen、Tammo Delhaas、Julien R Milles、Alessandro C Rossi 和 Patrick Clarysse. 通过局部正弦波建模绘制心脏位移和形变。IEEE Trans. Med. Imaging，29(5):1114–1123，2010。2, 3[4] B.B. Avants、C.L. Epstein、M. Grossman 和 J.C. Gee. 基于互相关的对称微分同胚图像配准：评估老年及神经退行性脑的自动标注。《医学图像分析》，12(1): 26–41，2008。7, 8[5] Brian B Avants、Nicholas J Tustison、Gang Song、Philip A Cook、Arno Klein 和 James C Gee. 对 ANTs 在脑图像配准中的相似性度量性能进行可复现评估。《神经影像》，54(3):2033–2044，2011。7[6] Leon Axel 和 Lawrence Dougherty. 心壁运动：改进用于磁共振成像的磁化空间调制方法。《放射学》，172(2):349–350，1989。1[7] Leon Axel 和 Lawrence Dougherty. 利用磁化空间调制进行运动磁共振成像。《放射学》，171(3): 841–845，1989。1, 4[8] P. V. Bayly、A. Alshareef、A. K. Knutsen、K. Upadhyay、R. J. Okamoto、A. Carass、J. A. Butman、D. L. Pham、J. L. Prince、K. T. Ramesh 和 C. L. J ohnson. 人脑力学的体内磁共振成像：用于脑损伤计算模型开发的新测量值与应用。《生物医学工程年鉴》，49:2677–2692，2021。1[9] Zhangxing Bian、Shuwen Wei、Yihao Liu、Junyu Chen、Jiachen Zhuo、Fangxu Xing、Jonghye Woo、Aaron Carass 和 Jerry L Prince. Momentamorph：利用动量、射击法和校正进行无监督时空配准。载于医学图像计算与计算机辅助干预国际会议，第 24–34 页。施普林格，2023年。5[10] Zhangxing Bian、Ahmed Alshareef、Shuwen Wei、Junyu Chen、Yuli Wang、Jonghye Woo、Dzung L Pham、Jiachen Zhuo、Aaron Carass 和 Jerry L Prince. 在深度学习时代，仅对原始标记磁共振进行配准是否足以估计应变？载于医学影像 2024：图像处理，第 79–85 页。国际光学工程学会，2024。2, 3, 4, 6[11] Zhangxing Bian、Fangxu Xing、Jinglun Yu、Muhan Shao、Yihao Liu、Aaron Carass、Jonghye Woo 和 Jerry L Prince. DRIMET：用于标记磁共振成像的基于深度配准的三维不可压缩运动估计，并应用于舌。载于《深度学习医学影像》，第 134–150 页。PMLR，2024。1, 2, 3, 7, 8[12] Zhangxing Bian、Shuwen Wei、Xiao Liang、Yuan-Chiao Lu、Samuel W Remedios、Fangxu Xing、Jonghye Woo、Dzung L Pham、Aaron Carass、Philip V Bayly 等。标记磁共振成像中的亮度不变跟踪估计。载于《医学影像信息处理国际会议》，第 375–389 页。施普林格，2025。2, 3[13] Timothy N Bloomer、Sven Plein、Aleksandra Radjenovic、David M Higgins、Timothy R Jones、John P Ridgway 和 Mohan U Sivananthan。采用径向长轴方向稳态自由进动的电影磁共振成像，是一种快速、准确地获取左心室体积数据的方法。《磁共振成像杂志：国际磁共振医学学会官方期刊》，14(6):685–692，2001。2[14] Ashish Bora、Ajil Jalal、Eric Price 和 Alexandros G Dimakis。利用生成模型进行压缩感知。载于《国际机器学习会议》，第 537–546 页。PMLR，2017。3[15] Ashish Bora、Eric Price 和 Alexandros G Dimakis。AmbientGAN：基于有损测量的生成模型。载于《国际学习表征会议》，2018。3, 7[16] Hyungjin Chung、Jeongsol Kim、Michael T Mccann、Marc L Klasky 和 Jong Chul Ye。用于一般含噪逆问题的扩散后验采样。arXiv 预印本 arXiv:2209.14687，2022。2, 3, 4[17] Lawrence Dougherty、Jane C Asmuth、Aaron S Blom、Leon Axel 和 Rakesh Kumar。用于标记位移估计的光流方法验证。IEEE《医学成像汇刊》，18(4):359–363，1999。2, 3[18] Bradley Efron。Tweedie 公式与选择偏倚。《美国统计学会杂志》，106(496):1602–1614，2011。4[19] Stefan E Fischer、GC McKinnon、SE Maier 和 P Boesiger。改进的心肌标记对比度。《磁共振医学》，30(2):191–200，1993。3[20] Jonathan Ho、Ajay Jain 和 Pieter Abbeel。去噪扩散概率模型。载于《神经信息处理系统进展》，第 6840–6851 页，2020。4[21] Junzhou Huang、Zhen Qian、Xiaolei Huang、Dimitris Metaxas 和 Leon Axel。心脏标记磁共振成像中的标记分离。载于《医学图像计算与计算机辅助干预国际会议》，第 289–297 页。施普林格，2008。3[22] El-Sayed H Ibrahim。心血管磁共振心肌标记：技术演进——脉冲序列、分析算法与应用。《心血管磁共振杂志》，13(1):36，2011。3[23] El-Sayed H Ibrahim。心血管磁共振心肌标记：技术演进——脉冲序列、分析算法与应用。《心血管磁共振杂志》，13(1):1–40，2011。1[24] Max Jaderberg、Karen Simonyan、Andrew Zisserman 等。空间变换网络。《神经信息处理系统进展》，28，2015。12

[25] Xi Jia、Joseph Bartlett、Tianyang Zhang、Wenqi Lu、Zhaowen Qiu 和 Jinming Duan。U-Net 与 Transformer：U-Net 在医学图像配准中是否已过时？载于《医学影像机器学习国际研讨会》，第 151–160 页。施普林格，2022。7, 8[26] Kwanyoung Kim 和 Jong Chul Ye。Noise2score：Tweedie 方法——无需干净图像的自监督图像去噪。载于《神经信息处理系统进展》，2021。4[27] Diederik P Kingma。Adam：一种随机优化方法。arXiv 预印本 arXiv:1412.6980，2014。5[28] Andrew K Knutsen、Elizabeth Magrath、Julie E McEntee、Fangxu Xing、Jerry L Prince、Philip V Bayly、John A Butman 和 Dzung L Pham。利用新型标记磁共振成像序列，改进轻度头部加速期间脑部形变的测量。《生物力学杂志》，47(1):3475–3481，2014。14[29] Pengcheng Lei、Faming Fang、Guixu Zhang 和 Tieyong Zeng。基于分解的变分网络，用于多对比度磁共振成像超分辨率与重建。载于 IEEE/CVF计算机视觉国际会议论文集，第 21296–21306 页，2023。2, 3[30] Brett Levac、Ajil Jalal、Kannan Ramchandran 和 Jonathan I Tamir。基于生成建模的双盲成像。arXiv 预印本 arXiv:2503.21501，2025。3, 7[31] Guangyuan Li、Chen Rao、Juncheng Mo、Zhanjie Zhang、Wei Xing 和 Lei Zhao。重新思考用于多对比度磁共振成像超分辨率的扩散模型。载于 IEEE/CVF计算机视觉与模式识别会议论文集，第 11365–11374 页，2024。2, 3[32] Xin Li、Yulin Ren、Xin Jin、Cuiling Lan、Xingrui Wang、Wenjun Zeng、Xinchao Wang 和 Zhibo Chen。用于图像复原与增强的扩散模型：全面综述。《国际计算机视觉杂志》，第 1–31 页，2025。2, 3[33] Xiaofeng Liu 和 Jerry L. Prince。基于标记磁共振图像进行运动估计的最短路径细化。IEEE《医学成像汇刊》，29(8):1560–1572，2010。5[34] Xiaofeng Liu、Khaled Z Abd-Elmoniem、Maureen Stone、Emi Z Murano、Jiachen Zhuo、Rao P Gullapalli 和 Jerry L Prince。基于标记磁共振图像的不可压缩形变估计算法（IDEA）。IEEE《医学成像汇刊》，31(2):326–340，2011。3[35] Xiaofeng Liu、Jerry L Prince、Fangxu Xing、Jiachen Zhuo、Timothy Reese、Maureen Stone、Georges El Fakhri 和 Jonghye Woo。用于无监督域自适应医学图像转换的注意力连续生成式自训练。《医学图像分析》，88:102851，2023。2, 3[36] Xiaofeng Liu、Fangxu Xing、Zhangxing Bian、Tomas Arias-Vergara、Paula Andrea P´erez-Toro、Andreas Maier、Maureen Stone、Jiachen Zhuo、Jerry L Prince 和 Jonghye Woo。通过轻量级时空 Transformer 合成标记磁共振成像序列与电影磁共振成像序列。载于《医学图像计算与计算机辅助干预国际会议》，第 701–711 页。施普林格，2024。2, 3[37] Zhisheng Lu、Juncheng Li、Hong Liu、Chaoyan Huang、Linlin Zhang 和 Tieyong Zeng。用于单幅图像的 Transformer 超分辨率。《IEEE/CVF计算机视觉与模式识别会议论文集》，第457–466页，2022年。2，3。[38] Hern´an Mella、Joaqu´ın Mura、Hui Wang、Michael D Taylor、Radomir Chabiniok、Jaroslav Tintera、Julio Sotelo 和 Sergio Uribe。HARP-I：一种用于根据标记磁共振图像估计运动的谐波相位插值法。《IEEE 生物医学工程汇刊》，40(4)：1240–1252，2021年。2，3[39] Kevin M Moerman、Andre MJ Sprengers、Ciaran K Simms、Rolf M Lamerichs、Jaap Stoker 和 Aart J Nederveen。连续标记磁共振成像用于测量动态三维骨骼肌组织形变的验证。《医学物理学》，39(4)：1793–1810，2012年。1[40] Mamoru Niitsu、Masanobu Kumada、Norbert G Campeau、Seiji Niimi、Stephen J Riederer 和 Yuji Itai。舌位移：通过快速标记磁化准备磁共振成像进行可视化。《放射学》，191(2)：578–580，1994年。1[41] Nael F Osman、William S Kerwin、Elliot R McVeigh 和 Jerry L Prince。使用 CINE 谐波相位（HARP）磁共振成像进行心脏运动跟踪。《磁共振医学》，42(6)：1048–1060，1999年。2，3[42] Nael F Osman、Elliot R McVeigh 和 Jerry L Prince。使用谐波相位磁共振成像显示心脏运动。《IEEE 生物医学工程汇刊》，19(3)：186–202，2000年。3，7[43] PM Pattynama、HJ Lamb、EA Van der Velde、EE Van der Wall 和 A De Roos。使用电影和自旋回波磁共振成像测量左心室：采用方差分量分析研究其可重复性。《放射学》，187(1)：261–268，1993年。2[44] Jerry L Prince 和 Jonathan M Links。《医学成像信号与系统》。Pearson Prentice Hall，Upper Saddle River，2006年。2[45] Jerry L Prince 和 Elliot R McVeigh。根据标记磁共振图像序列估计运动。《IEEE 生物医学工程汇刊》，11(2)：238–249，1992年。1，2，3[46] Zhen Qian、Albert Montillo、Dimitris N Metaxas 和 Leon Axel。使用 Gabor 滤波器组分割心脏磁共振标记线。载于《第25届 IEEE 医学与生物学工程学会年度国际会议论文集》（IEEE Cat. No. 03CH37439），第630–633页。IEEE，2003年。3[47] Zhen Qian、Dimitris N Metaxas 和 Leon Axel。使用三维 Gabor 滤波器组提取和跟踪磁共振标记片。载于《2006年 IEEE 医学与生物学工程学会国际会议论文集》，第711–714页。IEEE，2006年。2，3[48] Maziar Raissi、Paris Perdikaris 和 George E Karniadakis。物理信息神经网络：用于求解涉及非线性偏微分方程的正问题与逆问题的深度学习框架。《计算物理学杂志》，378：686–707，2019年。4[49] Samuel W Remedios、Shuo Han、Lianrui Zuo、Aaron Carass、Dzung L Pham、Jerry L Prince 和 Blake E Dewey。针对各向异性磁共振图像（有无层间隙）的自监督超分辨率。载于《医学成像仿真与合成国际研讨会》，第118–128页。施普林格，2023年。2，3

[50] Samuel W Remedios、Aaron Carass、Jerry L Prince 和 Blake E Dewey。扩散驱动的最少预处理脑部磁共振成像生成。arXiv预印本 arXiv:2510 26834，2025年。5。[51] Herbert E Robbins。统计学的经验贝叶斯方法。载于《统计学的突破》，第388–394页。施普林格，1992年。4[52] Jiaming Song、Chenlin Meng 和 Stefano Ermon。去噪扩散隐式模型。arXiv预印本 arXiv:2010 02502，2020年。5。[53] Yang Song、Jascha Sohl-Dickstein、Diederik P. Kingma、Ab- hishek Kumar、Stefano Ermon 和 Ben Poole。通过随机微分方程进行基于分数的生成建模。载于《第九届国际学习表征会议》，ICLR，2021年。4[54] Rainer Storn 和 Kenneth Price。差分进化——一种在连续空间中进行全局优化的简单高效启发式算法。《全球优化杂志》，11(4)：341–359，1997年。5[55] Stefan Van der Walt、Johannes L Sch¨onberger、Juan Nunez-Iglesias、Franc¸ois Boulogne、Joshua D Warner、Neil Yager、Emmanuelle Gouillart 和 Tony Yu。scikit-image：Python 图像处理。《PeerJ》，2：e453，2014年。6[56] David C Van Essen、Stephen M Smith、Deanna M Barch、Timothy EJ Behrens、Essa Yacoub、Kamil Ugurbil、Wu-Minn 人类连接组计划联盟等。Wu-Minn 人类连接组计划概述。《神经影像》，80：62–79，2013年。7[57] Hui Wang、Christian T Stoeck、Sebastian Kozerke 和 Amir A Amini。使用三维 SinMod 分析三维心脏形变。载于《2013年第35届 IEEE 医学与生物学工程学会年度国际会议（EMBC）论文集》，第4386–4389页。IEEE，2013年。2，3[58] Jonghye Woo、Emi Z Murano、Maureen Stone 和 Jerry L Prince。根据磁共振成像重建高分辨率舌体体积。《IEEE 生物医学工程汇刊》，59(12)：3511–3524，2012年。2，3[59] Zihui Wu、Yu Sun、Yifan Chen、Bingliang Zhang、Yisong Yue 和 Katherine Bouman。将扩散模型用作即插即用先验的原则性概率成像。《神经信息处理系统进展》，37：118389–118427，2024年。3[60] Fangxu Xing、Jonghye Woo、Arnold D Gomez、Dzung L Pham、Philip V Bayly、Maureen Stone 和 Jerry L Prince。用于根据标记磁共振图像估计运动的相位矢量不可压缩配准算法。《IEEE 生物医学工程汇刊》，36(10)：2116–2128，2017年。2，3，7[61] Tongda Xu、Xiyan Cai、Xinjie Zhang、Xingtong Ge、Dailan He、Ming Sun、Jingjing Liu、Ya-Qin Zhang、Jian Li 和 Yan Wang。重新思考扩散后验采样：从条件分数估计器到最大化后验。arXiv预印本 arXiv:2501.18913，2025年。3[62] Meng Ye、Mikael Kanski、Dong Yang、Qi Chang、Zhennan Yan、Qiaoying Huang、Leon Axel 和 Dimitris Metaxas。DeepTag：一种用于跟踪心脏标记磁共振图像运动的无监督深度学习方法。载于 CVPR，第7261–7271页，2021年。2，3，7，8[63] Meng Ye、Dong Yang、Qiaoying Huang、Mikael Kanski、Leon Axel 和 Dimitris N Metaxas。Sequencemorph：一种用于心脏图像序列运动跟踪的统一无监督学习框架。*IEEE*模式分析与机器智能汇刊，45(8)：10409–10426，2023年。2，3，7[64] Bingliang Zhang、Wenda Chu、Julius Berner、Chenlin Meng、Anima Anandkumar 和 Yang Song。通过解耦噪声退火改进扩散逆问题求解。载于计算机视觉与模式识别会议论文集，第 20895–20905 页，2025。3[65] Can Zhao、Muhan Shao、Aaron Carass、Hao Li、Blake E Dewey、Lotta M Ellingsen、Jonghye Woo、Michael A Guttman、Ari M Blitz、Maureen Stone 等。深度学习方法在磁共振成像抗锯齿与超分辨率中的应用。磁共振成像，64：132–141，2019年。2，3[66] Hongkai Zheng、Wenda Chu、Bingliang Zhang、Zihui Wu、Austin Wang、Berthy T Feng、Caifeng Zou、Yu Sun、Nikola Kovachki、Zachary E Ross、Katherine L Bouman 和 Yisong Yue。InverseBench：为物理科学中的逆问题评测即插即用扩散先验。*arXiv*，2025。2，3[67] Mingjun Zheng、Long Sun、Jiangxin Dong 和 Jinshan Pan。Smfanet：一种轻量级自调制特征聚合网络，用于高效图像超分辨率。载于欧洲计算机视觉会议，第 359–375 页。施普林格，2024。2，3[68] Yuanzhi Zhu、Kai Zhang、Jingyun Liang、Jiezhang Cao、Bihan Wen、Radu Timofte 和 Luc Van Gool。用于即插即用图像复原的去噪扩散模型。载于*IEEE/CVF*计算机视觉与模式识别会议论文集，第 1219–1229 页，2023年。3

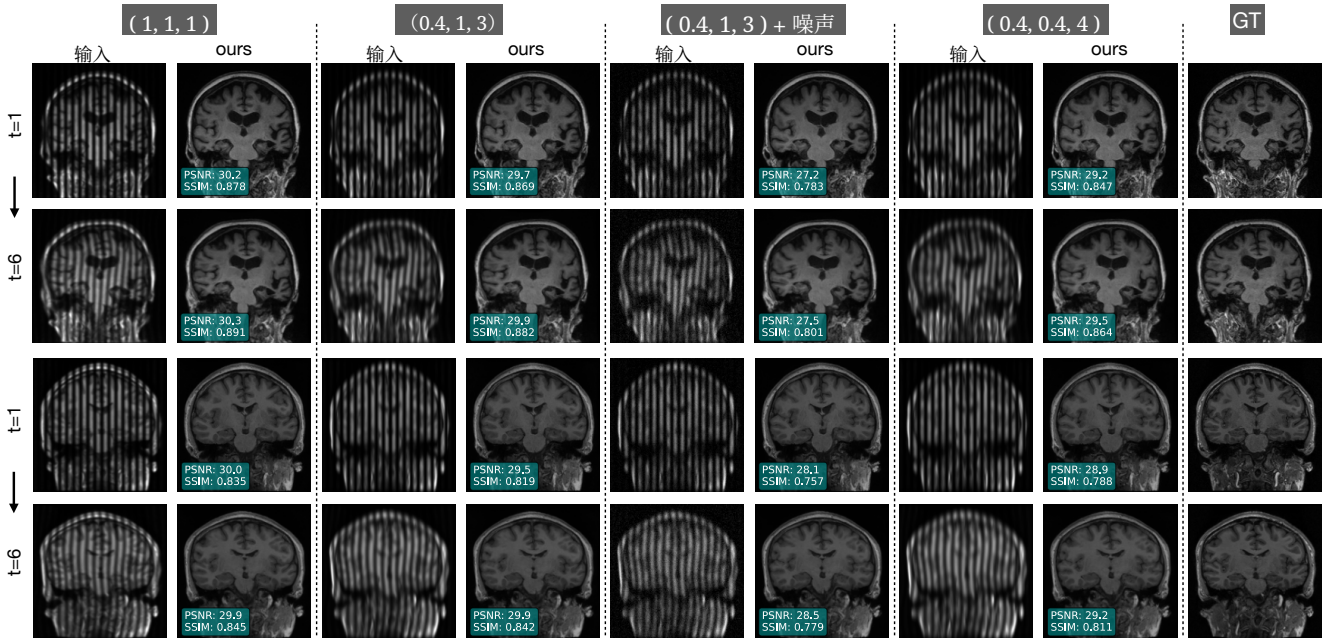

图 6. 在四种模糊设置（$\gamma_\perp, \gamma_\parallel, \gamma_{\text{thru}}$）和两种噪声水平下估计参考解剖结构的定性结果：无噪声和 $\mathcal{N}(0, 0.01)$。为简洁起见，仅展示一幅输入标记图像。真实解剖结构显示在最后一列。

点扩散函数参数		标记参数		指标	
$\gamma_\perp$	0.42 ± 0.03	α_1	0.74 ± 0.09	PSNR	28.14 ± 0.11
$\gamma_\parallel$	1.03 ± 0.06	α_2	10.1 ± 0.00	SSIM	0.81 ± 0.02
γ_{thru}	2.95 ± 0.12	α_3	-1.14 ± 0.00	EPE	$0.63 \pm \mathbf{0.03}$
		α_4	0.22 ± 0.07		

表 5. **经验可辨识性分析**。 随机初始化下， N=5 次独立运行的平均值 $\pm$ 标准差。

A. 实现细节

体数据会进行中心裁剪和/或填充至 $192\times224\times192$体素，并根据1st 时间帧的最小–最大值归一化至 $[0, 1]$ 。前向算子通过可分离一维卷积，将方向特异性点扩散函数实现为各向异性三维高斯。空间形变由可微空间变换器 [24] (torch.grid sample) 实现。去噪扩散概率模型（DDPM）采用五层三维 U-Net（带跳跃连接的编码器–解码器）。各层的通道宽度为 (16, 32, 64, 128, 256)，每层包含两个残差块。式 (17) 中的ρ 设为 $100/\mathcal{L}^t_{\text{rec}}$。物理信息神经网络（PINN） θ_t 是一个具有三个隐藏层（每层 128 个神经元）的全连接网络，输出平稳速度场；通过 7 次缩放与平方步骤获得微分同胚映射。Adam 使用 (β_1, β_2) = (0.9, 0.999)，学习率固定为 $5e^{-4}$；差分进化（来自 SciPy）采用 30 个个体、best1bin 策略、相对容差 10^{-2}，每个区块最多迭代 200 次。运动参数θ_t 在每个内循环中固定训练 2000 个 Adam 步骤。当相对变化目标函数中的数值低于 10^{-2}。

B. 不同成像条件下的定性结果

图 6 展示了四种模糊配置和两个噪声水平下估计的参考解剖结构的定性结果。在所有设置下——包括强层间模糊 $(0.4, 0.4, 4)$ 以及加性高斯噪声——恢复的解剖结构均保留了皮质细节，并与真实值高度吻合。

C. 扩散先验强度的影响

我们通过扫描权重 $\rho := \rho^*/\mathcal{L}^t_{\text{rec}}$（见式（17））， 分析了数据保真度与扩散先验强度之间的权衡。图7 表明，该方法在较宽的工作范围（$\rho^* \in [50, 200]$）内具有稳健性。过弱的数据项（$\rho^* = 1$）会使重建塌缩到先验流形上，从而产生幻觉结构（图7a）；而适当的加权能够有效平衡测量一致性与解剖合理性。

D. 经验可辨识性与收敛

尽管这一非线性盲反演的理论收敛性证明颇具挑战，我们仍提供了稳定性的经验证据。表5 显示，在 N=5 次随机初始化运行中，估计参数的方差可以忽略不计，运动估计保持稳定（EPE $= 0.63 \pm 0.03$）

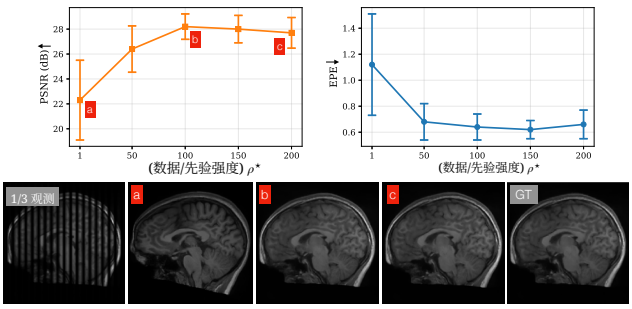

图 7. **数据保真度与先验强度**。 从强先验 ($\rho^* = 1$) 到强数据保真度 ($\rho^* = 200$) 的扫描。

尽管该问题存在不适定性和非唯一性，这一结果也补充了表4C中的消融实验：实验显示，不使用 CDDP 的联合优化会失败，而我们的协调下降方案则能可靠收敛。