

GENRE-CMR: 多样化多领域心脏 MRI 重建的泛化深度学习

Kian Anvari Hamedani¹, Narges Razizadeh², Shahabedin Nabavi^{3,*},
and Mohsen Ebrahimi Moghaddam³

¹ Department of Medical Biophysics, University of Toronto, Toronto, Ontario,
Canada

kian.anvari@mail.utoronto.ca

² Department of Radiology and Diagnostic Imaging, University of Alberta,
Edmonton, Alberta, Canada

razizade@ualberta.ca

³ Faculty of Computer Science and Engineering, Shahid Beheshti University, Tehran,
Iran

{s_nabavi,m_moghaddam}@sbu.ac.ir

<https://github.com/kiananvari/GENRE-CMR>

摘要 加速心血管磁共振成像 (CMR) 重建仍然是一个关键挑战, 因为扫描时间和图像质量之间存在权衡关系, 特别是在推广到多样化的采集设置时。我们提出了一种基于生成对抗网络 (GAN) 的架构 GENRE-CMR, 该架构采用残差深度展开重构框架来提高重构保真度和泛化能力。该架构将迭代优化展开为一系列卷积网络, 并通过残差连接增强从浅层到深层阶段的渐进特征传播。为了进一步提升性能, 我们整合了两个损失函数: (1) 边缘感知区域 (EAR) 损失, 引导网络关注结构信息丰富的区域并有助于防止常见的重构模糊; 以及 (2) 统计分布对齐 (SDA) 损失, 通过一个对称 KL 散度公式在不同数据分布中正则化特征空间。广泛的实验验证了 GENRE-CMR 在训练和未见数据上超越了最先进的方法, 在各种加速因子和采样轨迹下的未见分布中达到了 0.9552 的 SSIM 和 38.90 dB 的 PSNR 值。消融研究表明每个提出的组件对重构质量和泛化能力的贡献。我们的框架为高质量 CMR 重建提供了一个统一且稳健的解决方案, 为在异构采集协议中的临床适应性部署铺平了道路。

Keywords: 加速 MRI · 心脏 MRI · CMR 重建。

1 介绍

心血管磁共振成像 (CMR) 在非侵入性心血管评估中扮演着关键角色, 提供高分辨率、多参数的信息而不使用电离辐射 [1]。它被认为是评价心脏功能、灌注、存活心肌、纤维化和先天异常的金标准 [2]。然而, 由于固有的采集过程较慢, 受限于顺序 k 空间采样以及对高空间和时间分辨率的需求, 广泛临床应用受到限制。这使得 CMR 容易受生理运动 (心脏、呼吸) 的影响, 可能会引入伪影并损害图像质量 [3]。最近的研究还探讨了可变形配准和运动估计策略以更好地捕捉时空心脏动态 [4–6]。此外, 复杂的心脏解剖结构和多样化的成像协议, 涵盖各种对比度 (如 Cine、T1/T2 Mapping、LGE)、轨迹 (例如均匀、3D k -t 高斯/径向) 以及解剖视图 (例如长轴、短轴、主动脉), 延长了扫描时间并增加了重建复杂性 [7,8]。扫描仪硬件和软件的差异进一步阻碍了不同站点之间的稳健且一致的重建 [9]。

近期深度学习 (DL) 的进展显示了通过从欠采样 k 空间到高质量图像的直接映射来加速 CMR 图像重建的可能性 [10–14]。来自 CMRxRecon 挑战赛的领先解决方案 [8,15] 在性能上超过了传统方法 [18–20], 这已在 [16,17] 中进行了回顾。然而, 由于获取协议、扫描仪供应商、解剖覆盖范围和患者特征的变化导致领域变化, DL 模型通常无法很好地泛化到临床环境中 [9]。通过稳健的领域自适应和领域鲁棒性重建策略解决这种泛化差距对于在实际临床实践中安全可靠地部署基于 DL 的重建技术至关重要 [21,22]。

近期的一些研究探讨了领域稳健的 MRI 重建。一种方法 [23] 表明, 使用包含合成相位信息的自然图像数据集训练的网络可以泛化到未见对比度和解剖结构中。一个自监督的方法 [24] 引入了 Robust SSDU, 即使是从嘈杂且欠采样的训练数据也能恢复出干净的重建结果。另一个框架 [25] 提出了 MRPD, 它利用在自然图像上预先训练的大规模潜在扩散模型, 并将其适应到 MRI 重建中, 在无监督设置下展示了前所未有的跨领域泛化能力。最近, LowRank-CGNet [26] 被提出, 集成了低秩张量建模与共轭梯度数据一致性来处理多样化的解剖结构、对比度和欠采样伪影。尽管这些方法提供了重要的进展, 但许多依赖于重型扩散模型、外部自然图像先验或结构性假设, 并没有联合集成展开优化、对抗学习和显式的领域对齐。

为了解决这些挑战, 我们提出了一种基于生成对抗网络 (GAN) 架构的可泛化的 CMR 重建框架。该生成器结合了一个残差深度展开网络, 模仿了基于压缩感知的迭代优化过程, 逐步细化从欠采样输入数据中获得的中间 k 空间估计值。为了提高解剖学保真度并减少模糊, 我们引入了边缘感知重建

(EAR) 损失, 强调恢复临床上相关的边界。为了解决领域变化问题, 我们包括了一个统计分布对齐 (SDA) 损失, 以在不同的 CMR 领域之间对齐潜在特征。此外, 受到基于提示的 MRI 重建 [31] 最新工作的启发, 我们将提示学习整合进来, 以便在一个统一模型中实现跨越不同对比度、轨迹和解剖视图的自适应重建。我们的主要贡献是:

- 我们提出了一种适用于 CMR 的可泛化的残差深度展开重建框架, 该框架将基于压缩感知的逆问题求解集成到了 GAN 生成器中。这种设计能够从高度欠采样的 k 空间数据中实现准确的重建。在 CMRxRecon 2025 数据集上的实验表明, 我们的方法在图像质量和跨分布场景下的泛化能力方面都优于现有的最先进的方法。
- 我们提出了 EAR 损失函数, 该函数增强了精细解剖细节的重建, 并减轻了基于深度学习的方法中常见的模糊伪影。
- 为了解决由于对比度、轨迹、解剖覆盖范围和扫描器设置的变异性导致的领域偏移问题, 我们引入了明确减少不同 CMR 领域间分布差异的 SDA 损失, 以促进鲁棒性泛化。

2 材料与方法

2.1 数据集

我们在 CMRxRecon 2025 数据集 [27] 上评估了我们的方法, 该数据集是一个大规模、多中心、多厂商的基准测试, 专门设计用于评估心脏 MRI 重建模型在临床多样化环境中的鲁棒性。该数据集包含来自多个机构和扫描仪供应商 (包括 GE、Philips、Siemens 和 UIH) 的超过 600 名受试者的数据。它涵盖了广泛的患者人群, 包括健康志愿者以及患有各种心脏病理 (如心肌病、心肌梗死和心律失常) 的个体, 还包括儿科病例。该数据集包含了多种 CMR 模态 (例如 Cine、T1/T2 Mapping、LGE 和灌注), 以及不同的采样轨迹 (笛卡尔、径向和高斯) 和磁场强度 (1.5T、3T 和 5T)。每个案例都包括全采样和欠采样的 k -空间数据、采样掩码和重建的真实结果。

2.2 一种残差深度展开重构框架

在我们的 2024 年一体化 Patch-GAN 重建模型 [10] 的基础上, 该框架引入了具有改进连接的残差级联展开, 同时通过提出的 EAR 和 SDA 项增强了原始损失函数。




图 1. GENRE-CMR 方法概述。

具体而言，我们通过在连续的级联模块之间引入残差连接来扩展早期的展开模型，从而能够更有效地传播特征并减轻训练过程中的梯度消失。

该架构由一个生成器和一个对抗性训练的展开判别器组成。

生成器遵循一个级联结构，展开一个迭代重建过程，在每个步骤中逐步细化欠采样的 k 空间。

这些残差路径直接将特征图从浅层重建器传递到更深层的重建器，鼓励重用早期阶段的表示，并促进更好的收敛性和重建精度。

该模型接受来自各种供应商（飞利浦、西门子、UIH 和 GE）的多线圈 k 空间数据，以及不同的采集协议，从而考虑跨中心的真实世界领域偏移。

该网络学习一个灵敏度图，并使用线圈组合层生成中间和最终重建。

此外，还使用了一个展开的判别器来通过对抗训练增强重建质量。

我们提出的 GENRE-CMR 框架的完整流程在算法 1 中进行了形式化，该算法将残差展开、对抗训练以及所提出的 EAR 和 SDA 损失整合到了一个统一的重建管道中。

总损失结合了三个组成部分：数据保真度损失 ($\mathcal{L}_{\text{Fidelity}}$)、边缘感知重建损失 ($\mathcal{L}_{\text{EAR}}$) 和统计分布对齐损失 ($\mathcal{L}_{\text{SDA}}$)，每个部分分别由超参数 λ_1 , λ_2 , 和 λ_3 加权。在我们 2024 年的研究 [10] 中，我们将物理 k 空间一致性和 SSIM 损失结合在一起。在 2025 年，我们通过引入 $\mathcal{L}_{\text{EAR}}$ 以实现更锐利的边缘保留

和引入 $\mathcal{L}_{\text{SDA}}$ 以实现明确的跨域对齐来扩展此公式，从而定义了方程 1 中的复合损失。

$$\mathcal{L}_{\text{total}} = \lambda_1 \mathcal{L}_{\text{Fidelity}} + \lambda_2 \mathcal{L}_{\text{EAR}} + \lambda_3 \mathcal{L}_{\text{SDA}} \quad (1)$$

保真度损失 $\mathcal{L}_{\text{Fidelity}}$ 对应我们在先前工作中引入的总损失 [10]，它结合了图像域和物理 k 空间域的一致性项以确保高质量重建。为了更好地保留精细的解剖结构并防止心脏 MR 图像中高频细节的模糊，我们提出了 EAR 损失。这种损失侧重于边缘周围的局部区域，在这些区域内诊断特征最为关键，隔离边缘信息并在这些区域内仅比较真实图像和重构图像。首先，我们使用 3×3 Sobel 滤波器 S_x 和 S_y 从真实图像 I_{gt} 中提取水平和垂直梯度，生成梯度图 $G_x = S_x * I_{\text{gt}}$ 和 $G_y = S_y * I_{\text{gt}}$ ，其中 $*$ 表示卷积。边缘幅度图计算为

$$M = \sqrt{G_x^2 + G_y^2} \quad (2)$$

为了扩大边缘周围的影响力区域，我们将边缘图 M 与一个 5×5 平均核 A 进行卷积，得到一个平滑后的地图 $M_s = A * M$ 。在阈值处理 M_s 后 $\tau = 0$ ，生成了一个二进制掩码 $B \in \{0, 1\}^{H \times W}$ 如下：

$$B_{i,j} = \begin{cases} 1 & \text{if } M_s(i,j) \geq \tau \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

该二进制掩码随后被应用于重建图像 I_{rec} 和真实值 I_{gt} ，生成包含边缘区域的掩码版本： $\tilde{I}_{\text{rec}} = B \odot I_{\text{rec}}$ 和 $\tilde{I}_{\text{gt}} = B \odot I_{\text{gt}}$ ，其中 $\odot$ 表示逐元素乘法。最后，EAR 损失使用掩码图像之间的结构相似性指数（SSIM）损失定义。

$$\mathcal{L}_{\text{EAR}} = 1 - \text{SSIM}(\tilde{I}_{\text{rec}}, \tilde{I}_{\text{gt}}) \quad (4)$$

这种针对性设计确保了模型因边缘区域周围的结构退化而受到惩罚，从而产生更清晰且更具诊断价值的重建结果。EAR 损失计算的示例如图 2 所示。

SDA 损失鼓励来自不同域的输入的中间特征表示在分布上对齐。假设训练数据是从五个不同的分布 $\mathcal{D}_1, \mathcal{D}_2, \dots, \mathcal{D}_5$ 中抽取的，并且是顺序处理的，使得每连续五组样本 $\{x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(5)}\}$ 包括每个分布的一个数据。每个样本都通过由 16 个重构器组成的残差深度展开网络进行传递。对于每个样本




图 2. EAR 损失计算的示例。左上：原始/重构图像。右上：从图像中提取的二值边缘掩码。左下：融合在图像上的边缘掩码。右下：使用掩码提取的图像边缘。

$x_t^{(i)}$ ，我们从重构器 $l \in \{1, \dots, 16\}$ 的输出中提取特征向量 $\mathbf{f}_t^{(i,l)} \in \mathbb{R}^d$ 。对于每个重构器，我们计算一组 $\mathcal{F}_l = \{\mathbf{f}_t^{(1,l)}, \dots, \mathbf{f}_t^{(5,l)}\}$ ，假设是从特定于域的特征分布中抽取的样本。

假设这些是多元高斯分布 $\mathcal{N}(\mu_i^l, \Sigma_i^l)$ [28]，我们使用对称 KL 散度定义 SDA 损失：

$$\mathcal{L}_{\text{SDA}}^{(l)} = \frac{1}{10} \sum_{i < j} [D_{\text{KL}}(\mathcal{N}(\mu_i^l, \Sigma_i^l) \| \mathcal{N}(\mu_j^l, \Sigma_j^l)) + D_{\text{KL}}(\mathcal{N}(\mu_j^l, \Sigma_j^l) \| \mathcal{N}(\mu_i^l, \Sigma_i^l))] \quad (5)$$

总 SDA 损失通过对所有子网络层求和获得：

$$\mathcal{L}_{\text{SDA}} = \sum_{l=1}^{16} \mathcal{L}_{\text{SDA}}^{(l)} \quad (6)$$

为了保持时间域的多样性，在训练过程中使用了滑动窗口机制：在最初的 5 个样本（每个域一个）之后，对于每个新的输入样本，通过将其与训练序列中最近的 4 个样本进行比较来计算 SDA 损失。这强制执行特定领域的特征局部对齐，并促进领域不变表示的学习。

2.3 实现细节

在我们的方法中，生成器和判别器使用 AdamW 进行了优化（学习率 0.002，权重衰减 0.1，梯度裁剪 0.1，步进调度程序的步长为 11，伽玛值为

Algorithm 1 提出的用于 CMRI 重建的 GENRE-CMR 方法

Require: $k^{(0)}$: 邻近多线圈子采样 k 空间
 $k^{(G)}$: 真实的多线圈 k 空间
 $P^{(t)}$: 展开步骤中的判别提示 t
 $\mathcal{M}$: 子采样掩码
 $\eta^{(t)}$: 展开步骤中的可学习步长 t
 Label_{real} : 零填充矩阵, Label_{fake} : 全一填充矩阵
 $\lambda_1, \lambda_2, \lambda_3$: 损失权重 (保真度, EAR, SDA)
 SDAWindow : 域对齐的滑动窗口大小 (例如, 4)
 $\mathcal{D}$: 训练域集 (供应商 / 轨迹 / 对比度)

Ensure: θ_{Gen} : 生成器权重
 θ_{Disc} : 判别器权重

- 1: $k^{(ACS)} \leftarrow \text{Auto_calibration_signal}(k^{(0)})$; $I^{(ACS)} \leftarrow \text{FFT}^{-1}(k^{(ACS)})$
- 2: $S_m \leftarrow \text{APU}_{\text{net}}^{(\text{SME})}(I^{(ACS)})$; $S'_m \leftarrow \text{Conjugate_Symmetry}(S_m)$ // 敏感性估计
- 3: 初始化残差特征 $F^{(-1)} \leftarrow 0$, 特征库 $\{\mathcal{B}^{(l)}\}_{l=1}^T$ // 容量 SDA 窗口
- 4: 设 $T =$ 展开步骤的数量 (例如, 16)
- 5: **for** $\text{iteration} = 1, 2, \dots$ **do**
- 6: $\mathcal{L}_{\text{Gen}} \leftarrow 0$
- 7: **for** $t = 0, 1, \dots, T - 1$ **do**
- 8: $I_{MC} \leftarrow \text{FFT}^{-1}(k^{(t)})$; $I_{SC} \leftarrow S'_m \cdot I_{MC}$
- 9: $\hat{F}^{(t)} \leftarrow \text{APU}_{\text{net}}^{(t)}(I_{SC}, P^{(t)})$; $F^{(t)} \leftarrow \hat{F}^{(t)} + F^{(t-1)}$ // 残差展开
- 10: $I'_{RF} \leftarrow \text{Repeat_interleaved}(F^{(t)})$; $I_{SS} \leftarrow I'_{RF} \cdot S_m$; $G_k \leftarrow \text{FFT}(I_{SS})$
- 11: $k^{(t+1)} \leftarrow k^{(t)} - \eta^{(t)} \mathcal{M}(k^{(t)} - k^{(0)}) + G_k$
- 12: $\mathcal{L}_{\text{Phys}}^{(t)} \leftarrow \text{MSE}(\text{Mag}(k_{\text{central}}^{(t+1)}), \text{Mag}(k^{(G)})) + \text{MSE}(\Phi(k_{\text{central}}^{(t+1)}), \Phi(k^{(G)}))$
- 13: $\mathcal{L}_{\text{SSIM}}^{(t)} \leftarrow \text{SSIM_Loss}(\text{CC}(\text{FFT}^{-1}(k_{\text{central}}^{(t+1)})), \text{CC}(\text{FFT}^{-1}(k^{(G)})))$
- 14: $\mathcal{L}_{\text{Fidelity}}^{(t)} \leftarrow \mathcal{L}_{\text{Phys}}^{(t)} + \mathcal{L}_{\text{SSIM}}^{(t)}$
- 15: $I_{\text{rec}} \leftarrow \text{CC}(\text{FFT}^{-1}(k_{\text{central}}^{(t+1)}))$; $I_{\text{gt}} \leftarrow \text{CC}(\text{FFT}^{-1}(k^{(G)}))$
- 16: $M \leftarrow \sqrt{(\text{Sobel}_x(I_{\text{gt}}))^2 + (\text{Sobel}_y(I_{\text{gt}}))^2}$; $M_s \leftarrow \text{AvgPool}_{5 \times 5}(M)$; $B \leftarrow \mathbb{K}[M_s \geq \tau]$
- 17: $\tilde{I}_{\text{rec}} \leftarrow B \odot I_{\text{rec}}$; $\tilde{I}_{\text{gt}} \leftarrow B \odot I_{\text{gt}}$
- 18: $\mathcal{L}_{\text{EAR}}^{(t)} \leftarrow 1 - \text{SSIM}(\tilde{I}_{\text{rec}}, \tilde{I}_{\text{gt}})$
- 19: $z^{(t)} \leftarrow \text{GlobalAvgPool}(F^{(t)})$; $\text{UpdateFeatureBank}(\mathcal{B}^{(t)}, z^{(t)}, \text{domain}(k^{(0)}))$
- 20: $\mathcal{L}_{\text{SDA}}^{(t)} \leftarrow \text{SymKL_AcrossDomains}(\{\mathcal{B}^{(l)}\}_{l=1}^T, \text{SDAWindow})$
- 21: $\mathcal{L}_{\text{step}}^{(t)} \leftarrow \lambda_1 \mathcal{L}_{\text{Fidelity}}^{(t)} + \lambda_2 \mathcal{L}_{\text{EAR}}^{(t)} + \lambda_3 \mathcal{L}_{\text{SDA}}^{(t)}$
- 22: $\text{Input}_{real} \leftarrow \text{Concat}(I_{\text{gt}}, \text{CC}(\text{FFT}^{-1}(k_{\text{central}}^{(0)})))$
- 23: $\text{Input}_{fake} \leftarrow \text{Concat}(I_{\text{rec}}, \text{CC}(\text{FFT}^{-1}(k_{\text{central}}^{(0)})))$
- 24: $\text{Pred}_{real} \leftarrow \text{Discriminator}(\text{Input}_{real})$; $\text{Pred}_{fake} \leftarrow \text{Discriminator}(\text{Input}_{fake})$
- 25: $\mathcal{L}_{real} \leftarrow \text{BCE_Loss}(\text{Label}_{real}, \text{Pred}_{real})$; $\mathcal{L}_{fake} \leftarrow \text{BCE_Loss}(\text{Label}_{fake}, \text{Pred}_{fake})$
- 26: $\mathcal{L}_{Disc} \leftarrow \frac{1}{2}(\mathcal{L}_{real} + \mathcal{L}_{fake})$; $\theta_{Disc} \leftarrow \text{AdamW}(\mathcal{L}_{Disc}, \theta_{Disc})$
- 27: $\mathcal{L}_{\text{Gen}} \leftarrow \mathcal{L}_{\text{Gen}} + \mathcal{L}_{\text{step}}^{(t)}$
- 28: **end for**
- 29: $\text{Input}_{fake} \leftarrow \text{Concat}(\text{CC}(\text{FFT}^{-1}(k_{\text{central}}^{(T)})), \text{CC}(\text{FFT}^{-1}(k_{\text{central}}^{(0)})))$
- 30: $\text{Pred}_{fake} \leftarrow \text{Discriminator}(\text{Input}_{fake})$
- 31: $\mathcal{L}_{\text{GAN-Gen}} \leftarrow \text{BCE_Loss}(\text{Label}_{real}, \text{Pred}_{fake})$
- 32: $\mathcal{L}_{\text{Total-Gen}} \leftarrow \mathcal{L}_{\text{Gen}} + \mathcal{L}_{\text{GAN-Gen}}$
- 33: $(\lambda_1, \lambda_2, \lambda_3) \leftarrow \text{UpdateLossWeightsByCoV}(\{\mathcal{L}_{\text{Fidelity}}^{(t)}\}, \{\mathcal{L}_{\text{EAR}}^{(t)}\}, \{\mathcal{L}_{\text{SDA}}^{(t)}\})$
- 34: $\theta_{Gen}, \theta_{\text{SME}} \leftarrow \text{AdamW}(\mathcal{L}_{\text{Total-Gen}}, \theta_{Gen}, \theta_{\text{SME}})$
- 35: **end for**
- 36: **return** θ_{Gen} // 最终生成器权重




图 3. 动态调整训练过程中的损失组件权重。该图展示了每个损失权重随时间的变化情况，使得在整个优化过程中能够对不同的损失项进行自适应的强调。

0.1)。生成器使用了 16 个重构模块、16 条自动校准线和长度为 5 的相邻 k 空间。我们分别使用了加速因子 8、16 和 24，并采用了 k-t 均匀、k-t 高斯和 k-t 径向轨迹。通过从较低的加速因子开始，训练了 20 个周期并以批次大小 1 应用课程学习 [29]。模型性能评估使用 SSIM、PSNR 和 NMSE 进行。为了平衡损失项，我们采用了变异系数 (CoV) 加权 [30]，根据标准差与均值的比率动态调整每个损失权重 ($\lambda_1, \lambda_2, \lambda_3$)，优先考虑变化较大的损失。这些权重的变化如图所示 3。

3 实验结果与讨论

为了评估我们提出的方法的性能，我们使用了已见（训练）和未见分布进行了广泛的实验。定量结果汇总在表 1 中，并通过表 2 的消融研究检查了各个架构组件的有效性。还提供了重建图像的质量对比图 4，在三个不同的采样轨迹下加速因子为 16。

表 1. 最先进的 MRI 重建方法与所提出的方法对比。指标包括 SSIM、PSNR 和 NMSE。最佳值用粗体显示。

方法	训练分布			未见分布		
	SSIM	PSNR	NMSE	SSIM	PSNR	NMSE
PromptMR [31]	0.9685	41.80	0.0129	0.9450	37.85	0.0198
SR-GAN [10]	0.9702	42.05	0.0120	0.9473	38.01	0.0191
PromptMR+ [11]	0.9728	42.40	0.0115	0.9498	38.22	0.0187
类型-心肌梗死	0.9743	42.64	0.0111	0.9552	38.90	0.0160

表 1 展示了我们的方法 GENRE-CMR 与其他几种最先进的方法的比较评估，包括 PromptMR [31]、SR-GAN [10] 和 PromptMR+ [11]。我们的模型在所有三项指标 SSIM、PSNR 和 NMSE 上均取得了最高分，在训练分布和未见数据分布中都是如此。具体来说，GENRE-CMR 在训练分布上获得了 42.64 dB 的 PSNR 和 0.9743 的 SSIM，并且在未见数据上保持了强大的泛化能力，PSNR 达到 38.90 dB，SSIM 达到 0.9552。这些结果表明 GENRE-CMR 能够从训练数据中学习有效的表示形式，同时未见的数据分布上保持稳健的性能。NMSE 的持续降低进一步证明了该模型能够保留图像细节并抑制重建误差的能力。

表 2. 消融研究结果展示了所提出方法中不同组件的影响。评估指标包括 SSIM、PSNR 和 NMSE，最佳得分用粗体突出显示。

消融研究	未见分布		
	SSIM	PSNR	NMSE
Baseline	0.9473	38.01	0.0191
Without SDA Loss	0.9500	38.25	0.0183
Without EAR Loss	0.9515	38.43	0.0178
Without Residual Connections	0.9523	38.21	0.0171
提出的方法	0.9552	38.90	0.0160

如图 4 所示，所提出的方法在各种欠采样轨迹下与现有技术相比提供了视觉上更优越的重建结果。由 GENRE-CMR 重构的图像显示出更锐利的解剖边界和减少的混叠伪影，特别是在具有挑战性的区域如心肌边界和小血管中尤为明显。这种视觉保真度突显了将残差展开与边缘感知重建相结合的好处。

为了评估架构中各个组件的贡献，我们进行了系统性的消融研究。表 2 报告了在从完整管道中移除某些模块时，在未见过分布上的性能表现。去除 SDA 损失导致明显的性能下降，证实其在提高跨分布泛化能力中的作用。类似地，消除 EAR 损失也导致 SSIM 和 PSNR 降低，表明它在重建过程中保持边缘方面的有效性。禁用级联子网络之间的残差连接同样引起性能下降，证明特征沿深度传递对于有效的分层表示学习至关重要。在完整配置中，所提出的方法优于所有消融变体，达到了最高的 SSIM (0.9552)、PSNR (38.90) 和最低的 NMSE (0.0160)。这展示了结合残差连接、EAR 损失和 SDA 损失




图 4. 在加速因子为 16 的情况下，三种不同采样轨迹的重建结果定性比较。

在我方展开重建框架中的协同效益。与我们的 2024 全功能模型 [10] 相比，所提出的 GENRE-CMR 在分布内和分布外评估中均表现出色。消融研究证实， $\mathcal{L}_{\text{EAR}}$ 和 $\mathcal{L}_{\text{SDA}}$ ，在 2024 版本中缺失的组件是边缘保真度和领域鲁棒性显著提升的原因。

4 结论

在这项工作中，我们提出了一种可泛化的深度学习框架用于心脏磁共振成像 (CMR) 重建，该框架基于 GAN 架构。生成器采用残差深度展开结构驱动，模仿迭代优化步骤，并结合压缩感知概念有效解决了潜在的逆问题。为了增强对临床相关解剖结构的保存，我们引入了 EAR 损失函数，它明确促进了更清晰边界的重建并减少了常见的模糊伪影。我们将 SDA 损失整合以提高在不同分布下的鲁棒性，从而应对由于成像中心和设备差异、图像对比度、采样模式、解剖变异性和采集协议导致的领域转移挑战。在 CMRxRecon

2025 数据集上的全面实验和消融研究证明了我们的方法始终优于最先进的方

法。虽然有效，但该框架在训练过程中可能需要大量的计算资源，要求使用强大的 GPU 才能达到最佳性能。这是高级深度学习方法中常见的挑战，未来的工作可能会探索更高效的架构或培训策略以减少资源需求。作为重要的未来发展方向，我们计划与专家放射科医生一起进行临床评估，以评估诊断准确性和实际应用性，进一步实现临床整合。

参考文献

1. Arnold, J. & McCann, G. Cardiovascular magnetic resonance: applications and practical considerations for the general cardiologist. *Heart*. **106**, 174-181 (2020)
2. Vasquez, M. & Nagel, E. Clinical indications for cardiovascular magnetic resonance. *Heart*. **105**, 1755-1762 (2019)
3. Nabavi, S., Simchi, H., Moghaddam, M., Abin, A. & Frangi, A. A generalised deep meta-learning model for automated quality control of cardiovascular magnetic resonance images. *Computer Methods And Programs In Biomedicine*. **242** pp. 107770 (2023)
4. Zakeri, A., Hokmabadi, A., Bi, N., Wijesinghe, I., Nix, M., Petersen, S., Frangi, A., Taylor, Z. & Gooya, A. DragNet: Learning-based deformable registration for realistic cardiac MR sequence generation from a single frame. *Medical Image Analysis*. **83** pp. 102678 (2023)
5. Bi, N., Zakeri, A., Xia, Y., Cheng, N., Taylor, Z., Frangi, A. & Gooya, A. SegMorph: concurrent motion estimation and segmentation for cardiac MRI sequences. *IEEE Transactions On Medical Imaging*. (2024)
6. Kebriti, S., Nabavi, S. & Gooya, A. FractMorph: A Fractional Fourier-Based Multi-Domain Transformer for Deformable Image Registration. *ArXiv Preprint ArXiv:2508.12445*. (2025)
7. Enders, J., Zimmermann, E., Rief, M., Martus, P., Klingebiel, R., Asbach, P., Klessen, C., Diederichs, G., Bengner, T., Teichgräber, U. & Others Reduction of claustrophobia during magnetic resonance imaging: methods and design of the "CLAUSTRO" randomized controlled trial. *BMC Medical Imaging*. **11** pp. 1-15 (2011)
8. Wang, Z., Wang, F., Qin, C., Lyu, J., Ouyang, C., Wang, S., Li, Y., Yu, M., Zhang, H., Guo, K. & Others Cmrrecon2024: A multimodality, multiview k-space dataset boosting universal machine learning for accelerated cardiac mri. *Radiology: Artificial Intelligence*. **7**, e240443 (2025)

9. Guan, H. & Liu, M. Domain adaptation for medical image analysis: a survey. *IEEE Transactions On Biomedical Engineering*. **69**, 1173-1185 (2021)
10. Anvari Hamedani, K., Razizadeh, N., Nabavi, S. & Ebrahimi Moghaddam, M. An All-in-One Approach for Accelerated Cardiac MRI Reconstruction. *International Workshop On Statistical Atlases And Computational Models Of The Heart*. pp. 464-475 (2024)
11. Xin, B., Ye, M., Axel, L. & Metaxas, D. Rethinking deep unrolled model for accelerated MRI reconstruction. *European Conference On Computer Vision*. pp. 164-181 (2024)
12. Xu, R., Özer, C. & Oksuz, I. Hypercmr: Enhanced multi-contrast cmr reconstruction with eagle loss. *International Workshop On Statistical Atlases And Computational Models Of The Heart*. pp. 152-163 (2024)
13. Xu, R. & Oksuz, I. Segmentation-aware MRI subsampling for efficient cardiac MRI reconstruction with reinforcement learning. *Image And Vision Computing*. **150** pp. 105200 (2024)
14. Yiasemis, G., Moriakov, N., Sonke, J. & Teuwen, J. Deep multi-contrast cardiac mri reconstruction via vsharp with auxiliary refinement network. *International Workshop On Statistical Atlases And Computational Models Of The Heart*. pp. 183-192 (2024)
15. Wang, C., Lyu, J., Wang, S., Qin, C., Guo, K., Zhang, X., Yu, X., Li, Y., Wang, F., Jin, J. & Others CMRxRecon: A publicly available k-space dataset and benchmark to advance deep learning for cardiac MRI. *Scientific Data*. **11**, 687 (2024)
16. Lyu, J., Qin, C., Wang, S., Wang, F., Li, Y., Wang, Z., Guo, K., Ouyang, C., Tänzer, M., Liu, M. & Others The state-of-the-art in cardiac mri reconstruction: Results of the cmrxrecon challenge in miccai 2023. *Medical Image Analysis*. **101** pp. 103485 (2025)
17. Wang, F., Wang, Z., Li, Y., Lyu, J., Qin, C., Wang, S., Guo, K., Sun, M., Huang, M., Zhang, H. & Others Towards Universal Learning-based Model for Cardiac Image Reconstruction: Summary of the CMRxRecon2024 Challenge. *ArXiv Preprint ArXiv:2503.03971*. (2025)
18. Pruessmann, K., Weiger, M., Scheidegger, M. & Boesiger, P. SENSE: sensitivity encoding for fast MRI. *Magnetic Resonance In Medicine: An Official Journal Of The International Society For Magnetic Resonance In Medicine*. **42**, 952-962 (1999)
19. Griswold, M., Jakob, P., Heidemann, R., Nittka, M., Jellus, V., Wang, J., Kiefer, B. & Haase, A. Generalized autocalibrating partially parallel acquisitions (GRAPPA). *Magnetic Resonance In Medicine: An Official Journal Of The International Society For Magnetic Resonance In Medicine*. **47**, 1202-1210 (2002)

20. Lustig, M., Donoho, D. & Pauly, J. Sparse MRI: The application of compressed sensing for rapid MR imaging. *Magnetic Resonance In Medicine: An Official Journal Of The International Society For Magnetic Resonance In Medicine*. **58**, 1182-1195 (2007)
21. Nabavi, S., Hamedani, K., Moghaddam, M., Abin, A. & Frangi, A. Multiple Teachers-Meticulous Student: A Domain Adaptive Meta-Knowledge Distillation Model for Medical Image Classification. *ArXiv Preprint ArXiv:2403.11226*. (2024)
22. Nabavi, S., Hamedani, K., Moghaddam, M., Abin, A. & Frangi, A. Statistical Distance-Guided Unsupervised Domain Adaptation for Automated Multi-Class Cardiovascular Magnetic Resonance Image Quality Assessment. *ArXiv Preprint ArXiv:2409.00375*. (2024)
23. Ouyang, C., Schlemper, J., Biffi, C., Seegoolam, G., Caballero, J., Price, A., Hajnal, J. & Rueckert, D. Generalizing deep learning mri reconstruction across different domains. *ArXiv Preprint ArXiv:1902.10815*. (2019)
24. Millard, C. & Chiew, M. Clean self-supervised MRI reconstruction from noisy, sub-sampled training data with Robust SSDU. *Bioengineering*. **11**, 1305 (2024)
25. Gao, Z. & Zhou, S. MRPD: Undersampled MRI reconstruction by prompting a large latent diffusion model. *ArXiv Preprint ArXiv:2402.10609*. (2024)
26. Patel, J., Kadota, B., Sheagren, C., Chiew, M. & Wright, G. Low-Rank Conjugate Gradient-Net for Accelerated Cardiac MR Imaging. *International Workshop On Statistical Atlases And Computational Models Of The Heart*. pp. 334-344 (2024)
27. Xu, D. CMRxRecon2025. (IEEE Dataport,2025), <https://dx.doi.org/10.21227/b6xs-gv29>
28. Liang, C., Chen, W., Zhao, X., Wang, J., Cao, L. & Zhang, J. Distribution Optimization Under Gaussian Hypothesis for Domain Adaptive Semantic Segmentation. *2025 IEEE/CVF Winter Conference On Applications Of Computer Vision (WACV)*. pp. 9280-9290 (2025)
29. Bengio, Y., Louradour, J., Collobert, R. & Weston, J. Curriculum learning. *Proceedings Of The 26th Annual International Conference On Machine Learning*. pp. 41-48 (2009)
30. Groenendijk, R., Karaoglu, S., Gevers, T. & Mensink, T. Multi-Loss Weighting with Coefficient of Variations. *2021 IEEE Winter Conference On Applications Of Computer Vision (WACV)*. pp. 1468-1477 (2021)
31. Xin, B., Ye, M., Axel, L. & Metaxas, D. Fill the k-space and refine the image: Prompting for dynamic and multi-contrast MRI reconstruction. *International Workshop On Statistical Atlases And Computational Models Of The Heart*. pp. 261-273 (2023)