

融合上下文增强与结构感知损失的二维心脏磁共振图像分割

杨余浩¹, 任泽民^{1,2*}, 谢齐星¹

¹重庆科技大学数理科学学院, 重庆

²重庆科技大学重庆智能数学与自主智能研究院, 重庆

收稿日期: 2026年9月10日; 录用日期: 2026年10月1日; 发布日期: 2026年10月14日

摘要

针对心脏磁共振图像中结构形态差异大、组织对比度低引发的右心室拓扑碎裂与心肌边界模糊问题, 本文提出一种融合深层选择性上下文增强与结构感知损失的二维心脏分割方法。该方法以nnU-Net为基础框架, 在编码器阶段采用分层优化策略: 深层嵌入轻量级上下文增强模块, 利用多尺度空洞卷积和通道注意力机制来增强深层语义建模; 浅层保留原高分辨率特征提取模块, 以兼顾全局结构感知与精细边界的表达。在损失函数设计中, 引入Laplacian算子的类别感知窄带边界曲率损失, 以增强模型对器官边界结构的学习。此外, 总损失函数采用基于Sigmoid函数的课程学习调度策略来渐进式增强边界结构约束力, 从而平衡基础区域分割学习与局部边界结构优化。实验表明, 本文方法在ACDC数据集上对RV、MYO、LV的Dice分别达到0.9078、0.9064、0.9485, 平均Dice达0.9209。相比于基线, 本文在边界敏感的RV和MYO表现更优。

关键词

心脏磁共振图像分割, 上下文增强, 结构感知损失, nnU-Net, 课程学习

A Method for 2D Cardiac MRI Segmentation Integrating Context Enhancement and Structure-Aware Loss

Yuhao Yang¹, Zemin Ren^{1,2*}, Qixing Xie¹

¹School of Mathematics and Physics Science, Chongqing University of Science and Technology, Chongqing

²Chongqing Research Institute of Intelligent Mathematics and Autonomous Intelligence (RI-IM-AI*), Chongqing University of Science and Technology, Chongqing

*通讯作者。

文章引用: 杨余浩, 任泽民, 谢齐星. 融合上下文增强与结构感知损失的二维心脏磁共振图像分割[J]. 图像与信号处理, 2026, 15(4): 479-489. DOI: 10.12677/jisp.2026.154043

Abstract

To address the challenges of right ventricular topological fragmentation and obscure myocardial boundaries—which are primarily induced by pronounced structural morphological variations and low tissue contrast in cardiac magnetic resonance images—this paper proposes a novel two-dimensional cardiac segmentation method that synergistically integrates deep selective context enhancement with a structure-aware loss function. Building upon the foundational architecture of the nnU-Net, the proposed framework adopts a hierarchical optimization strategy within the encoder phase. Specifically, a lightweight context enhancement module is embedded into the deeper layers, leveraging multi-scale dilated convolutions and channel attention mechanisms to fortify deep semantic modeling. Concurrently, the original high-resolution feature extraction modules are preserved in the shallower layers, thereby achieving an optimal balance between global structural perception and the precise delineation of fine-grained boundaries. Regarding the loss function design, we introduce a class-aware narrow-band boundary curvature loss predicated on the Laplacian operator to amplify the model's capacity for learning complex organ boundary structures. Furthermore, the overall loss objective employs a curriculum learning scheduling strategy governed by a Sigmoid function. This strategy progressively intensifies the structural constraints on boundaries, effectively orchestrating a balance between fundamental regional segmentation learning and localized boundary optimization. Comprehensive experiments demonstrate that the proposed method achieves Dice Similarity Coefficients of 0.9078, 0.9064, and 0.9485 for the right ventricle (RV), myocardium (MYO), and left ventricle (LV), respectively, on the ACDC dataset, culminating in an average DSC of 0.9209. Compared to the baseline model, our approach exhibits superior performance, particularly in segmenting the boundary-sensitive RV and MYO regions.

Keywords

Cardiac Magnetic Resonance Image Segmentation, Context Enhancement, Structure-Aware Loss, nnU-Net, Curriculum Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

心脏磁共振成像凭借非侵入性、无电离辐射和软组织高对比度等优势，被广泛用于心脏结构与功能评估[1]-[3]。在临床诊断中，射血分数、心室容积和心肌质量等指标依赖于左心室(LV)、右心室(RV)和心肌(MYO)的准确分割[4]。然而，传统的人工勾画不仅耗时费力，且依赖医师的主观经验，难以满足大规模的临床分析需求。因此，高精度的自动化心脏 MRI 分割具有重要的临床意义与研究价值。

心脏 MRI 分割任务面临多方面因素挑战。右心室(RV)壁较薄，且在不同切片中的形态变化较大，容易出现局部断裂和孤立碎片；心肌(MYO)与周围组织对比度较低，导致边界模糊和轮廓锯齿现象；左心室(LV)血池虽然整体对比度尚可，但乳头肌与心肌内膜之间相似度较高，易误判。针对上述难题，心脏 MRI 分割出现了许多经典的方法。但相关研究仍表明，右心室分割和心脏多结构分割中在形态不规则、边界不清晰和结构连续性保持等存在明显局限[5]-[11]。

随着深度学习技术的不断发展, U-Net 及其改进模型在医学图像分割中得到了广泛应用[12]-[18]。Transformer 和 Mamba 类模型主要增强长程依赖建模能力[19]-[25], 但其复杂的模型结构在样本规模有限的心脏 MRI 分割任务中可能带来参数量增加、训练不稳定以及局部边界细节弱化等问题。与此同时, 传统交叉熵损失和 Dice 损失主要关注区域重叠, 对边界偏移、局部断裂和拓扑异常的约束不足[14] [26]-[28]。因此, 如何保持 U-Net 局部细节表达能力, 同时增强深层上下文建模, 是提升心脏 MRI 分割能力的关键。

基于上述分析, 本文将提出一种融合深层选择性上下文增强与结构感知损失的二维心脏 MRI 分割方法。

本文主要贡献如下:

(1) 在编码器深层提出深层选择性上下文增强方法, 通过轻量级多尺度空洞卷积和通道注意力机制增强深层语义建模能力, 同时保持浅层边界细节表达, 从而兼顾全局感受野拓展与精细边界保护。

(2) 构建类别感知窄带边界曲率损失, 利用形态学操作提取真实边界附近的窄带区域, 并通过 Laplacian 二阶响应约束边界局部形态变化, 使模型更加关注边界连续性和结构稳定性。

(3) 总损失函数采用基于 Sigmoid 函数的课程学习调度策略来渐进式增强边界结构约束力, 从而平衡基础区域分割学习与局部边界结构优化。

2. 相关工作

2.1. 基于 CNN 的医学图像分割

卷积神经网络(CNN)是一种通过局部感受野、权值共享和池化层, 自动提取空间特征并用于分类或识别的深度学习模型。作为 CNN 的典型代表, U-Net 采用编码器-解码器结构, 通过跳跃连接融合深层语义与浅层细节, 已成为医学图像分割中的经典基础框架[12]。在其基础上, 3DU-Net 和 V-Net 进一步扩展了体数据建模能力, 并通过 Dice 损失缓解前景与背景类别不平衡问题[13] [14]。在后续研究中, Attention U-Net、UNet++和 MultiResUNet 分别从注意力门控、密集跳跃连接和多尺度卷积建模等角度对 U-Net 进行改进[15]-[17]。nnU-Net 则通过自动化配置预处理、网络结构和训练策略, 提升其在多类医学图像分割任务中稳定性[18]。对于心脏 MRI 分割而言, CNN 仍具有较好的局部边界表达能力, 但其深层上下文建模能力仍有提升空间[5]-[11]。

2.2. 视觉 Transformer 与状态空间模型(Mamba)

为弥补 CNN 全局建模能力不足的问题, Transformer 编码器被引入到医学图像分割任务。TransUNet 将 Transformer 编码器嵌入 U-Net 框架, 从而捕获长程依赖[19]。Swin-Unet 和 Swin UNETR 则通过窗口注意力和层次化结构增强多尺度语义表达[20] [21]。近年来, Mamba 及其视觉变体通过选择性状态空间模型实现线性复杂度的长序列建模[22] [23]。U-Mamba 和 Swin-UMamba 则将 Mamba 用于医学图像分割任务[24] [25]。这些方法提升了全局依赖建模能力, 仍存在因模型复杂度较高而导致的训练成本增加及局部细节弱化等问题。因此, 探索轻量化的上下文增强策略是缓解上述问题的有效途径。

2.3. 边界与拓扑感知损失函数

传统交叉熵损失和 Dice 损失主要优化像素分类与区域重叠, 但对边界偏移、局部断裂和结构不连续问题的约束不足[14]。边界损失通过距离场约束预测轮廓与真实轮廓之间的差异[26]。clDice 则通过骨架相似性增强拓扑连通性[27]。相关拓扑保持损失证明结构先验有助于改善医学图像分割中的形态错误[28]。但全局边界或拓扑约束容易增加计算开销, 并在训练早期引入则可能引发不稳定性。心脏 MRI 分割中边

界错误主要集中于 RV 薄壁、MYO 内外膜和心尖切片等区域。针对这些特点, 本文将采用窄带边界约束思路, 即仅在真实边界附近引入结构监督, 以更集中地优化难分边界区域。

3. 方法

3.1. 总体网络架构

本文以 nnU-Net 为基础框架, 在保持原有 U 形拓扑流向与残差卷积块(Residual Blocks)不变的前提下, 对网络的特征提取与梯度回传机制进行了改进。整个网络架构图见图 1。首先, 设计轻量级上下文增强模块 DeepContextBlock2D, 并将其嵌入在编码器(Encoder)下采样过程的深层阶段; 其次, 在网络输出端, 除计算传统的 Dice 与交叉熵混合损失外, 并联注入具有动态权重的类别感知窄带边界曲率损失; 最后, 总损失函数采用基于 Sigmoid 函数的课程学习调度策略来渐进式增强边界结构约束力, 从而平衡基础区域分割学习与局部边界结构优化。




Figure 1. The overall framework of the proposed model integrating context enhancement and structure-aware loss for 2D cardiac MRI segmentation

图 1. 融合上下文增强与结构感知损失的二维心脏磁共振图像分割模型整体框架

3.2. 深层选择性上下文增强方法

在 CNN 编码器逐层下采样的过程中, 浅层特征通常保留较高的空间分辨率, 能够表达局部纹理、灰度过渡和边界细节; 深层特征虽经分辨率压缩, 但包含抽象语义信息。由于左心室(LV)、右心室(RV)和心肌(MYO)之间存在明确的解剖空间关系, 基于 CNN 的心脏 MRI 分割仅依赖局部卷积难以充分建模不同心脏结构之间的整体关联。为此, 本文提出一种深层选择性上下文增强方法, 在保持浅层边界细节表达能力的基础上, 仅对编码器深层语义特征进行多尺度上下文建模, 以增强模型对心室与心肌整体形态关系的感知能力。

具体构建模块为轻量级上下文增强模块 DeepContextBlock2D, 如图 2 显示。该模块采用三个并行的深度空洞卷积, 用于提取不同尺度的上下文信息, 扩张率分别设置为 $d \in \{1, 2, 3\}$ 。对于 3×3 卷积核, $d=1, 2, 3$ 分别对应约 3×3 、 5×5 和 7×7 的有效感受野, 可在连续尺度上补充局部至较大范围的上下文信息; 同时采用连续的小扩张率能够减少过大间隔采样可能带来的栅格化影响。考虑到该模块位于编码

器深层, 本文将 1、2、3 作为固定扩张率, 以兼顾感受野扩展、局部连续性与计算开销。三个分支的输出相加后, 通过点卷积进行通道融合, 具体如下:

$$F_{\text{ctx}} = \text{PWConv}(\text{DWConv}_{d=1}(X) + \text{DWConv}_{d=2}(X) + \text{DWConv}_{d=3}(X)) \quad (1)$$

其中, (X) 表示输入特征, (DWConv_d) 表示扩张率为 d 的深度卷积, PWConv 表示点卷积操作。与直接使用大卷积核相比, 该多尺度设计能够在扩大有效感受野的同时控制参数数量和计算量, 从而以较低代价增强深层特征的上下文表达能力。




Figure 2. DeepContextBlock2D Module

图 2. DeepContextBlock2D 模型

为了进一步突出关键通道响应, 模块引入轻量级通道门控机制。该机制首先对输入特征进行全局平均池化, 再通过两层通道映射和 Sigmoid 激活生成通道权重, 用于自适应增强与心脏结构边界和形态相关的特征通道。其中, 中间通道数设置为 $\max(C/8, 16)$, 在压缩通道维度、控制额外参数数量的同时, 为较低通道数阶段保留最小的表征容量。最终, 所提模块采用带可学习缩放因子的残差连接来输出增强后的特征:

$$Y = X + \gamma \cdot F_{\text{ctx}} \odot G(X) \quad (2)$$

其中, $G(X)$ 表示通道门控权重, $\odot$ 表示逐通道加权, γ 为可学习缩放参数, 初始化为 10^{-3} 。 γ 采用小正值初始化, 使上下文增强模块在训练初期接近恒等映射, 仅以较小幅度向主干特征中注入上下文信息; 相比直接以 $\gamma=1$ 叠加增强分支, 该设置可减小随机初始化阶段对原有特征分布的扰动, 同时保留增强分支的非零贡献。随着训练进行, γ 可通过反向传播自适应调整上下文分支的实际贡献, 从而兼顾训练稳定性与上下文增强能力。

在模块嵌入位置上, 本文未在网络所有编码阶段引入 DeepContextBlock2D 模块, 而是将其作用于编码器后部的高语义特征层, 即 Stage 2、Stage 3 以及 Bottleneck 对应的特征层。为此, 编码阶段采用分层优化策略: 浅层网络维持原生卷积通路, 用于保留心肌薄壁边界、心室轮廓和局部纹理响应; 深层特征则通过嵌入轻量化上下文增强模块来扩大感受野, 实现左心室(LV)、右心室(RV)和心肌(MYO)之间的全局空间关系建模。

综上, 该方法将轻量级多尺度上下文建模与选择性深层嵌入策略相结合, 在不显著增加网络复杂度的前提下, 提升模型对心脏解剖结构整体关系和局部形态变化的感知能力。该方法在一定程度上缓解了传统局部卷积对全局结构建模不足的问题, 同时避免对浅层边界细节造成干扰, 从而提高心脏 MRI 多结

构分割的准确性和稳定性。

3.3. 类别感知窄带边界曲率损失

在心脏 MRI 分割任务中, 左心室(LV)、右心室(RV)和心肌(MYO)在形态结构、边界清晰度和类别面积上存在明显差异, 如心肌(MYO)呈薄壁环状结构, 内外膜边界容易受到图像噪声、灰度过渡模糊以及局部伪影影响; 右心室(RV)形态相对不规则, 其边界预测也更容易出现局部偏移。传统 Dice 与交叉熵损失主要从整体区域重叠和像素分类角度优化模型, 对边界附近的困难样本缺乏针对性约束。为此, 本文引入类别感知窄带边界曲率损失, 将结构监督重点集中在真实心脏结构边界邻域内, 方案如图 3 显示。




Figure 3. Class-Aware Narrow-Band boundary curvature loss

图 3. 类别感知窄带边界曲率损失

本文首先对每一类真实标签 Y_c 分别构建边界窄带区域。对于类别 $c \in \{RV, MYO, LV\}$, 其二值掩码经过形态学膨胀和腐蚀操作后得到类别边界窄带:

$$B_c = (Y_c \oplus S_{3 \times 3}) - (Y_c \ominus S_{3 \times 3}) \quad (3)$$

其中, $(S_{3 \times 3})$ 表示 3×3 结构元素, $\oplus$ 和 $\ominus$ 分别表示二值膨胀和二值腐蚀操作。通过该方式, 附加结构损失仅作用于真实边界邻域, 避免大面积背景区域对边界优化产生干扰。

针对边界窄带区域, 本文利用 Laplacian 算子刻画预测概率图的局部二阶空间变化, 确保预测边界的局部形态一致性。由于边界曲率变化会引起局部二阶空间响应变化, 因此本文利用 Laplacian 响应作为边界曲率变化的近似约束, 以增强预测轮廓的局部形态一致性。设 P_c 表示类别 c 的预测概率图, Δ 表示 Laplacian 算子, 则边界一致性项和曲率约束项分别定义为:

$$L_{\text{boundary}} = \frac{1}{\sum_c |B_c|} \sum_c w_c \sum_{p \in B_c} |\Delta P_c(p) - \Delta Y_c(p)| \quad (4)$$

$$L_{\text{curvature}} = \frac{1}{\sum_c |B_c|} \sum_c w_c \sum_{p \in B_c} |\Delta P_c(p)| \quad (5)$$

其中, w_c 表示类别 c 的权重。本文根据心脏不同结构的分割难度设置类别敏感度权重。心肌(MYO)由于具有薄壁环状结构且边界更易发生断裂和偏移, 因此其被赋予更高权重; 左心室(LV)形态相对规则, 其权重相对较低。具体权重设置为 $w_{RV} = 1.20$ 、 $w_{MYO} = 1.50$ 、 $w_{LV} = 0.80$ 。该类别感知设计使模型在训练过程中更加关注 MYO 和 RV 等边界困难区域。

为降低结构化损失在训练初期对主损失优化的干扰, 本文进一步采用动态权重调度策略。设当前训练轮数为 e , 结构损失权重为 $\lambda(e)$, 则总损失函数表示为:

$$L_{\text{total}} = L_{\text{DiceCE}} + \lambda(e)(L_{\text{boundary}} + L_{\text{curvature}}) \quad (6)$$

其中, $\lambda(e)$ 随训练过程逐步增大, 使模型在训练早期主要学习目标区域的大体位置和整体轮廓, 在训练后期逐渐强化边界邻域内的局部结构约束。通过这种渐进式引入方式, 边界曲率损失能够在不破坏主干网络初期收敛过程的前提下, 对心肌薄壁结构和心室边界进行更细致的形态约束。

4. 实验与分析

4.1. 数据集与预处理

本文采用公开心脏磁共振数据集 ACDC 验证所提方法的有效性。该数据集包含正常受试者及心力衰竭、心肌梗死、右心室异常和肥厚型心肌病等多种心脏疾病类型病例。本文实验选用经专家标注的 100 名患者数据。每名患者包含舒张末期(ED)和收缩末期(ES)两个关键时相, 共形成 200 个二维短轴 cine-MRI 图像序列。标注类别包括右心室(RV)、心肌(MYO)和左心室(LV)。

实验基于 nnU-Net 的 2D 配置进行数据预处理与训练划分。在预处理阶段, 图像被转换为 nnU-Net 标准格式, 并采用 Z-score 进行强度归一化。根据 nnU-Net 自动规划结果, 本文 2D 输入 patch 大小设置为 256×256 。训练阶段采用 nnU-Net 默认的数据增强策略, 包括随机旋转、缩放、镜像、强度扰动等, 以提高模型对不同心脏形态和成像差异的适应能力。

4.2. 实验环境与评估指标

所有实验基于 PyTorch 和 nnU-Net 框架实现, 运行环境为搭载单张 NVIDIA A100 服务器。本文方法以 nnU-Net 为基础框架, 采用 nnU-Net 默认优化策略和学习率调度方式。为确保公平性, TransUNet、UNet++、U-Mamba 等对比模型均在统一的验证划分下重新训练与推理, 并将预测结果统一恢复至原始图像尺寸后进行病例级评价。

本文采用 Dice 相似系数(Dice Similarity Coefficient, DSC)作为主要评价指标。分别计算右心室(RV)、心肌(MYO)和左心室(LV)三类结构的 Dice 值, 并进一步计算三类结构的平均 Dice。Dice 值越高表示预测分割结果与专家标注之间的区域重叠程度越高。对于可视化分析, 在同一验证病例和同一切片的条件下, 对比 nnU-Net、TransUNet、UNet++、U-Mamba 与本文方法的预测结果, 以分析不同模型在心室边界和心肌薄壁区域的局部结构表现。

4.3. 定量结果对比分析

为了验证所提方法的有效性, 本文与主流模型进行了对比, 包括经典 CNN 系列(U-Net [12], Attention U-Net [15], UNet++ [16]), 基于 Transformer 的模型(TransUNet [19], Swin-Unet [20]), 基于 Mamba 的模型架构(U-Mamba [24], VM-UNet [29]), 以及强基线 nnU-Net [18]。实验结果详见表 1。本文方法在心脏的三类结构上 Dice 系数分别达到 0.9078、0.9064、0.9485, 其中右心室(RV)、心肌(MYO)的 Dice 系数和平均 Dice 系数优于 nnU-Net 基线。与其他对比模型相比, 本文方法在难处理的右心室(RV)、心肌(MYO)取得较好的结果, 并在平均的 Dice 系数也取得了较优表现。

本文方法在强基线的基础上进一步提升了分割性能, 以 0.9209 的平均 Dice 系数优于强基线的结果。尤为关键的是, 在传统算法极易失效的右心室(RV)和心肌(MYO)类别上, 本文方法分别实现了 0.9078 和 0.9064 的优异成绩, 较基线模型提升了 0.54% 和 1.40%, 优于其他所有对比方法。在对比度相对较高的左心室(LV)类别上, 本文方法亦取得较好的 Dice 指标。

Table 1. Quantitative performance comparison of different methods on the ACDC dataset
表 1. 不同方法在 ACDC 数据集上的性能对比

模型(Model)	RV	MYO	LV	Mean (Dice)
U-Net	0.8850	0.8710	0.9400	0.8987
Attention U-Net	0.8905	0.8821	0.9432	0.9053
UNet++	0.8923	0.8996	0.9482	0.9134
TransUNet	0.8945	0.8969	0.9458	0.9124
Swin-Unet	0.8972	0.8940	0.9498	0.9137
nnU-Net	0.9024	0.8924	0.9536	0.9161
VM-UNet	0.8985	0.8991	0.9502	0.9159
U-Mamba	0.9001	0.9012	0.9510	0.9174
Ours	0.9078	0.9064	0.9485	0.9209

4.4. 定性可视化分析

我们给出了可视化的定性分析结果，如图 2 所示。图中按列依次展示原始图像、人工标注(GT)、nnU-Net、TransUNet、UNet++、U-Mamba 以及本文方法的分割结果；按行展示不同病例或不同切片层面的代表性结果。这些样本涵盖了目标区域较小、心肌薄壁明显、边界对比度较低以及右心室形态不规则等较具挑战性的分割场景。




Figure 4. ACDC qualitative results figure
图 4. ACDC 定性结果图

从图 4 可以看出，nnU-Net 作为强基线方法整体表现较好，但在部分困难切片中仍存在局部边界偏移或轮廓细节不够稳定的问题。TransUNet 和 UNet++在若干样本中能够较好地恢复主要结构，但在 RV 的局部轮廓和 MYO 的环形边界处仍可观察到不同程度的欠分割或过分割现象。U-Mamba 在部分困难样

本中对 RV 区域的预测偏差较为明显，局部形态一致性相对不足。

相比之下，本文方法在多组可视化样本中表现出更稳定的分割轮廓，尤其在 RV 边界不规则区域以及 MYO 薄壁结构附近，能够较好地保持边界连续性和心肌环形结构完整性。以第一行和第四行的困难切片为例，本文方法的预测结果在 RV 与 MYO 的相对位置关系、轮廓平滑性以及 GT 的整体一致性方面均表现出更好的视觉效果。这表明，深层上下文增强与类别感知窄带边界曲率约束相结合，有助于提升模型对复杂心脏结构边界的刻画能力。

4.5. 消融实验与机制探讨

为了剖析本文所提各个模块的有效性，我们设计了逐步叠加组件的消融实验。在完全相同的训练超参数下，我们在基础模型上依次添加轻量级上下文增强模块(DCE)和窄带边界约束损失(SABL)。

Table 2. Quantitative analysis of ablation experiments for each module (ACDC)

表 2. 各模块消融实验定量分析(ACDC)

模块配置(Configuration)	RV (Dice)	MYO (Dice)	LV (Dice)	Mean (Dice)
Baseline	0.9024	0.8924	0.9536	0.9161
Baseline + DCE	0.9055	0.8995	0.9521	0.9190
Baseline + DCE + SABL (Ours)	0.9078	0.9064	0.9485	0.9209

消融实验的结果显示在表 2 中。

(1) 语义收益验证：单纯引入 DCE 模块后，模型在心肌(MYO)类别上的增益最为显著，Dice 值跃升了 0.71 个百分点。这一现象表明对于环形且跨越多个感受野尺度的 MYO 结构，利用空洞卷积构建的多尺度通道校准机制，能够帮助网络在深层更好地理解心肌纤维的空间包络关系。

(2) 边界锐化验证：在引入 SABL 损失后，RV 和 MYO 的 Dice 指标进一步提升，分别达到 0.9078 和 0.9064。这表明，课程学习指导下的 Laplacian 曲率约束，有助于缓解 DCE 可能引起的边缘模糊问题，增强模型对解剖结构边界特征的特征能力。

5. 结论

医学图像分割面临从“盲目追求模型规模”向“精准结合解剖先验”的范式转变。针对二维心脏磁共振图像中组织结构复杂、边界模糊导致分割瓶颈，本文摒弃了重构庞大主干网络的常规路线，提出了一种高效的定向优化分割方法。在保留 nnU-Net 基础特征提取能力的同时，在深层阶段集成了兼具多尺度感受野与通道门控的上下文增强模块；在优化层面上，突破全局损失的限制，提出了基于二阶曲率响应的窄带边界损失，并通过课程学习平滑了训练轨迹。实验表明，所提方法在低额外参数开销下显著提升边界敏感类别的分割精度与拓扑纯度。后续，我们将探索将此窄带曲率约束拓展至复杂的 3D 医学体数据分割任务中。

基金项目

本研究受重庆科技大学硕士研究生创新计划项目(项目编号：YKJCX2521204)，国家自然科学基金(61601068, 62061016)，重庆市教委科学技术研究重点项目(KJZD-K202001503)等资助。

参考文献

[1] World Health Organization (2026) Cardiovascular Diseases (CVDs).

- <https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-%28cvds%29>
- [2] Salerno, M., Sharif, B., Arheden, H., Kumar, A., Axel, L., Li, D., *et al.* (2017) Recent Advances in Cardiovascular Magnetic Resonance: Techniques and Applications. *Circulation: Cardiovascular Imaging*, **10**, e003951. <https://doi.org/10.1161/circimaging.116.003951>
 - [3] Geva, T. (2006) Magnetic Resonance Imaging: Historical Perspective. *Journal of Cardiovascular Magnetic Resonance*, **8**, 573-580. <https://doi.org/10.1080/10976640600755302>
 - [4] Bernard, O., Lalande, A., Zotti, C., Cervenansky, F., Yang, X., Heng, P., *et al.* (2018) Deep Learning Techniques for Automatic MRI Cardiac Multi-Structures Segmentation and Diagnosis: Is the Problem Solved? *IEEE Transactions on Medical Imaging*, **37**, 2514-2525. <https://doi.org/10.1109/tmi.2018.2837502>
 - [5] 曾嘉涛, 张贺晔, 刘华锋. 基于深度学习的心脏图像分割研究现状[J]. 中国图象图形学报, 2023, 28(6): 1811-1828.
 - [6] Chen, C., Qin, C., Qiu, H., Tarroni, G., Duan, J., Bai, W., *et al.* (2020) Deep Learning for Cardiac Image Segmentation: A Review. *Frontiers in Cardiovascular Medicine*, **7**, Article ID: 25. <https://doi.org/10.3389/fcvm.2020.00025>
 - [7] 苏新宇, 王丽嘉, 聂生东, 等. 基于心脏磁共振短轴电影图像的右心室分割新进展[J]. 波谱学杂志, 2019, 36(3): 377-391.
 - [8] 刘鹏, 钟玉敏, 王丽嘉. 基于密集多尺度 U-Net 网络的电影心脏磁共振图像右心室自动分割[J]. 波谱学杂志, 2020, 37(4): 456-468.
 - [9] 王丽嘉, 苏新宇, 李亚, 等. 基于 COLLATE 融合多图谱的心脏电影 MRI 右心室分割[J]. 波谱学杂志, 2018, 35(4): 407-416.
 - [10] 曾安, 陈旭宙, 姬玉柱, 等. 基于自注意力和三维卷积的心脏多类分割方法[J]. 广东工业大学学报, 2023, 40(6): 168-175.
 - [11] 高媛, 宋金超. 基于卷积神经网络的心脏射血分数评估研究[J]. 建模与仿真, 2025, 14(4): 649-655.
 - [12] Ronneberger, O., Fischer, P. and Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W.M. and Frangi, A.F., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 234-241. https://doi.org/10.1007/978-3-319-24574-4_28
 - [13] Çiçek, Ö., Abdulkadir, A., Lienkamp, S.S., Brox, T. and Ronneberger, O. (2016) 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. In: Ourselin, S., Joskowicz, L., Sabuncu, M.R., Unal, G. and Wells, W., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 424-432. https://doi.org/10.1007/978-3-319-46723-8_49
 - [14] Milletari, F., Navab, N. and Ahmadi, S. (2016) V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. 2016 *Fourth International Conference on 3D Vision (3DV)*, Stanford, 25-28 October 2016, 565-571. <https://doi.org/10.1109/3dv.2016.79>
 - [15] Schlemper, J., Oktay, O., Schaap, M., Heinrich, M., Kainz, B., Glocker, B., *et al.* (2019) Attention Gated Networks: Learning to Leverage Salient Regions in Medical Images. *Medical Image Analysis*, **53**, 197-207. <https://doi.org/10.1016/j.media.2019.01.012>
 - [16] Zhou, Z., Rahman Siddiquee, M.M., Tajbakhsh, N. and Liang, J. (2018) UNet++: A Nested U-Net Architecture for Medical Image Segmentation. In: Stoyanov, D., *et al.*, Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 3-11. https://doi.org/10.1007/978-3-030-00889-5_1
 - [17] Ibtchaz, N. and Rahman, M.S. (2020) Multiresunet: Rethinking the U-Net Architecture for Multimodal Biomedical Image Segmentation. *Neural Networks*, **121**, 74-87. <https://doi.org/10.1016/j.neunet.2019.08.025>
 - [18] Isensee, F., Jaeger, P.F., Kohl, S.A.A., Petersen, J. and Maier-Hein, K.H. (2020) NnU-Net: A Self-Configuring Method for Deep Learning-Based Biomedical Image Segmentation. *Nature Methods*, **18**, 203-211. <https://doi.org/10.1038/s41592-020-01008-z>
 - [19] Chen, J., Mei, J., Li, X., Lu, Y., Yu, Q., Wei, Q., *et al.* (2024) TransUNet: Rethinking the U-Net Architecture Design for Medical Image Segmentation through the Lens of Transformers. *Medical Image Analysis*, **97**, Article 103280. <https://doi.org/10.1016/j.media.2024.103280>
 - [20] Cao, H., Wang, Y., Chen, J., Jiang, D., Zhang, X., Tian, Q., *et al.* (2023) Swin-Unet: Unet-Like Pure Transformer for Medical Image Segmentation. In: Karlinsky, L., Michaeli, T. and Nishino, K., Eds., *Lecture Notes in Computer Science*, Springer, 205-218. https://doi.org/10.1007/978-3-031-25066-8_9
 - [21] Hatamizadeh, A., Nath, V., Tang, Y., Yang, D., Roth, H.R. and Xu, D. (2022) Swin UNETR: Swin Transformers for Semantic Segmentation of Brain Tumors in MRI Images. In: Crimi, A. and Bakas, S., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 272-284. https://doi.org/10.1007/978-3-031-08999-2_22
 - [22] Gu, A. and Dao, T. (2024) Mamba: Linear-Time Sequence Modeling with Selective State Spaces. *Proceedings of the*

First Conference on Language Modeling. arXiv:2312.00752

- [23] Zhu, L., Liao, B., Zhang, Q., *et al.* (2024) Vision Mamba: Efficient Visual Representation Learning with Bidirectional State Space Model. *Proceedings of the 41st International Conference on Machine Learning*, Vienna, 21-27 July 2024, 62429-62442.
- [24] Ma, J., Li, F. and Wang, B. (2024) U-Mamba: Enhancing Long-Range Dependency for Biomedical Image Segmentation. <https://arxiv.org/abs/2401.04722>
- [25] Liu, J., Yang, H., Zhou, H., Xi, Y., Yu, L., Li, C., *et al.* (2024) Swin-UMamba: Mamba-Based UNet with Imagenet-Based Pretraining. In: Linguraru, M.G., *et al.*, Eds., *Lecture Notes in Computer Science*, Springer, 615-625. https://doi.org/10.1007/978-3-031-72114-4_59
- [26] Kervadec, H., Bouchtiba, J., Desrosiers, C., Granger, E., Dolz, J. and Ben Ayed, I. (2021) Boundary Loss for Highly Unbalanced Segmentation. *Medical Image Analysis*, **67**, Article 101851. <https://doi.org/10.1016/j.media.2020.101851>
- [27] Shit, S., Paetzold, J.C., Sekuboyina, A., Ezhov, I., Unger, A., Zhylka, A., *et al.* (2021) CIDice—A Novel Topology-Preserving Loss Function for Tubular Structure Segmentation. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 20-25 June 2021, 16560-16569. <https://doi.org/10.1109/cvpr46437.2021.01629>
- [28] Byrne, N., Clough, J.R., Valverde, I., Montana, G. and King, A.P. (2023) A Persistent Homology-Based Topological Loss for CNN-Based Multiclass Segmentation of CMR. *IEEE Transactions on Medical Imaging*, **42**, 3-14. <https://doi.org/10.1109/tmi.2022.3203309>
- [29] Ruan, J., Li, J. and Xiang, S. (2025) Vm-UNet: Vision Mamba UNet for Medical Image Segmentation. *ACM Transactions on Multimedia Computing, Communications, and Applications*, 1-17. <https://doi.org/10.1145/3767748>