

基于非零水平集保凸算法的左心室 MRI 分割

李季^{1,2,3}, 刘艾汶^{1,2*}, 秦柳^{1,2}

(1.重庆工商大学数学与统计学院,重庆 400067; 2.重庆工商大学数学统计智能计算与监测重庆市重点实验室,重庆 400067; 3.电子科技大学信息与通信工程学院,四川 成都 611731)

摘要:心脏左心室分割临床应用要求是分割的左心室保持凸形且包含左心室腔、小梁和乳头肌,提出一个包含改进距离正则项和非零水平集保凸项的心脏核磁共振成像分割模型,其利用水平集轮廓的曲率来保持凸性,从而使轮廓最终演化为凸形。使用 ACDC MICCAI 2017 数据集进行模型评估,该模型在心脏舒张末期和收缩末期阶段的平均 Dice 系数分别为 0.961 和 0.936,平均豪斯多夫距离分别为 4.89 和 5.79。同时该模型无需对训练数据进行人工标注和学习,分割精度和鲁棒性均可以达到与基于深度学习的左心室分割模型相同的分割性能。

关键词:非零水平集;保凸;水平集方法;左心室分割;距离正则化;双阱势函数

中图分类号:TP391 **文献标志码:**A

引用格式:李季,刘艾汶,秦柳. 基于非零水平集保凸算法的左心室 MRI 分割[J]. 山东大学学报(理学版),2025,60(7):32-47.

Left ventricular MRI segmentation based on nonzero level sets convexity preserving algorithm

LI Ji^{1,2,3}, LIU Aiwen^{1,2*}, QIN Liu^{1,2}

(1. School of Mathematics and Statistics, Chongqing Technology and Business University, Chongqing 400067, China; 2. Chongqing Key Laboratory of Statistical Intelligent Computing and Monitoring, Chongqing Technology and Business University, Chongqing, 400067, China; 3. School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, Sichuan, China)

Abstract: Accurate segmentation of the left ventricle in clinical applications requires maintaining a convex shape that encompasses the left ventricle cavity, trabeculae, and papillary muscles. The nonzero level set convexity preserving model, a novel cardiac magnetic resonance imaging segmentation model incorporating an enhanced distance regularization term and a nonzero level set convexity preserving term is introduced. By leveraging the curvature of the level set contour, the model effectively promotes convexity, ensuring the contour evolves into a convex shape. Evaluated on the ACDC MICCAI 2017 datasets, the model achieved a mean Dice coefficient of 0.961 and 0.936 in end-diastole and end-systole phases, respectively, alongside a mean Hausdorff distance of 4.89 and 5.79. Notably, the model eliminates the need for manual annotation of training data and time-consuming learning processes, while achieving segmentation accuracy and robustness comparable to deep learning-based left ventricle segmentation models.

Key words: nonzero level set; convexity preserving; level set method; left ventricle segmentation; distance regularization; double well potential function

0 引言

心血管疾病是一种发病率和死亡率很高的心脏和血管疾病,是全人类主要死亡原因之一,已成为全球公共卫生负担。全世界约 3.76 亿人死于心血管疾病,占世界疾病总死亡人数的 51.7%^[1]。无创左心室功能评

收稿日期:2024-03-01; 网络出版时间:2024-11-12 11:59:26

基金项目:国家自然科学基金资助项目(11901071);重庆市自然科学基金面上项目(CSTB2023NSCQ-LZX0054);重庆市教委自然科学基金项目(KJQN202000816)

第一作者:李季(1987—),男,讲师,博士,研究方向为医学图像处理的偏微分方程方法、医学图像分割。E-mail:breeze_forever@163.com

*通信作者:刘艾汶(1997—),男,硕士研究生,研究方向为医学图像处理的偏微分方程方法、医学图像分割。E-mail:liuaiwen@ctbu.edu.cn

估是心血管疾病诊断和治疗的重要组成部分。心脏核磁共振成像(magnetic resonance imaging, MRI)已被证明是一种准确且可重复的非侵入性左心室功能定量评估方法^[2-4]。在心脏 MRI 定量分析中,左心室分割是一项重要的基础性工作。左心室分割具有以下困难:图像噪声;运动伪影;在图像采集过程中,由于患者体位运动、心脏周期性运动和患者的呼吸运动等不可抗力影响而产生的局部体积效应;MRI 装置中 B0 和 B1 场不均匀性导致的强度不均匀性;小梁、乳头肌和心肌灰度重叠。这些因素使得左心室分割仍是一个具有挑战性的问题。

根据国内外的研究情况, MRI 分割主要分为以下几类方法:活动轮廓模型^[5]和水平集模型^[3,6-15]、阈值分割方法^[16-17]、基于图割的分割方法^[18-19]、高斯混合模型^[20-21]以及基于深度学习的分割方法^[22-28]。近年来,基于深度学习的 MRI 分割模型已广泛应用于心脏 MRI 分割。Dong 等^[22]提出了一种基于全卷积网络(fully convolutional networks, FCN)和可变形模型的左心室 MRI 自动分割方法,该模型提出了一种基于特征融合和迁移学习的深度学习网络,并结合残差模块对左心室进行分割,同时利用可变形模型的初始化对粗分割结果进行优化,以此来左心室精确分割。Chartsias 等^[23]提出了一种基于循环一致性原理的潜在空间分解方法来进行心脏 MRI 分割,该方法使用少量标注图像,可以达到与完全监督网络相当的性能。Zhang 等^[24]提出了一种多尺度卷积长短期记忆(convolutional long short-term memory, ConvLSTM)模型来进行心肌分割。基于 ResNet 56 CNN(residual network 56 convolutional neural network)模型提取心脏周期连续帧中左心室相关的低分辨率和高分辨率图像特征,通过多层 ConvLSTM 模型来进行心肌分割。Du 等^[25]提出了基于扩张残差和混合金字塔池化网络(dilated residual and hybrid pyramid pooling network, DRHPPN)集成的多任务深度学习框架,将其运用于血池和心肌联合分割。该框架由 3 个紧密相连的渐近子网络组成:采用初始化模块实现心血管图像的初始多级特征表示;扩展残差网络(dilated residual network, DRN)作为特征提取和像素分类主体对分割区域进行初步预测;再提出混合金字塔池化网络(hybrid pyramid pooling network, HPPN)用于局部信息向全局信息聚合,以此来准确地分割血池和心肌。Xie 等^[26]提出基于卷积神经网络(convolutional neural network, CNN)的心肌中线检测算法,该算法使用水平集自动初始化取代传统水平集初始化过程,并使用中轴线指导水平集函数来分割左心室。Tragakis 等^[27]提出了全卷积 Transformer(fully convolutional Transformer, FCT)模型,是医学图像分割领域中首个采用全卷积 Transformer 架构的模型。FCT 模型结合了 CNN 在图像表达方面的成熟学习能力和 Transformer 捕捉输入图像长距离语义依赖优势,使其能够有效地分割多模态医学图像。Kato 等^[28]提出 adaptive t-vMF(tangent von Mises-Fisher)相似度参数算法,使用验证精度自动确定 t-vMF 相似度的参数 κ 的损失函数,称为 adaptive t-vMF Dice loss。将该损失函数应用于 FCT 模型后,可以在简单类图像上应用更紧凑的相似度,在困难类图像上应用更广泛的相似度,并且可以实现基于类准确性的自适应训练。使用 adaptive t-vMF Dice loss 的 FCT 模型在 ACDC MIC-CAI 2017 后在线排行榜取得最高得分,成为该领域中的 SOTA(state-of-the-art)模型。

与深度学习的方法相比,使用水平集方法对心脏左心室进行分割具有以下优点:无需大量数据集和专家手动标注;各种先验知识(如解剖学知识)可以轻松融入水平集框架;能达到亚像素分割精度。水平集模型可分为基于边缘的模型和基于区域的模型两类。基于边缘的水平集模型中, Li 等^[7]提出的距离正则化水平集演化(distance regularized level set evolution, DRLSE)模型是代表性模型之一。DRLSE 模型在水平集演化过程中内在地保持水平集函数的正则性,并且水平集演化派生为梯度流来最小化具有距离正则化功能的能量泛函和驱动水平集向期望位置运动的外部能量。距离正则化项可以有效避免水平集函数重新初始化,从而消除由重新初始化引起的数值误差。Shi 等^[8]在 DRLSE 模型的基础上提出了一种心脏左心室 MRI 分割的保凸水平集方法(convexity preserving level set evolution, CPLSE),该模型引入保凸项,在零水平集上进行保凸,虽然能将左心室腔、小梁和乳头肌包含进去,但是也会将不需分割的区域包含进去,且在心脏收缩末期阶段分割精度偏低。Kim 等^[9]提出了利用距离正则化水平集在 3 个短轴心脏 MRI 切片上对左、右心室和心肌增强帧进行心内膜和心外膜边界的自动分割方法。Ciecholewski^[10]提出了一种利用膨胀/收缩力的基于边缘的活动轮廓模型,该模型允许活动轮廓节点移动来找到对象边缘,它可以使每个节点的膨胀/收缩力保持较大值,直到节点接近对象边缘。接近对象边缘后,这些节点的膨胀/收缩力将自动阻尼。Wali 等^[11]使用交替方向乘数方法(alternating direction method of multipliers, ADMM)代替经典梯度下降法,极大地减少了 DRLSE 模型的计算成本。基于区域的水平集模型中, Li 等^[6]提出经典的区域可变拟合能量(region-scal-

able fitting, RSF)模型,RSF模型使用一个轮廓和两个拟合函数来定义数据拟合项,以此来局部近似轮廓两侧的图像灰度,并将该能量项并入具有正则化的变分水平集公式中共同推动曲线的演化。RSF模型在可控尺度上利用局部区域的灰度信息,并且数据拟合项中的核函数能提取局部区域灰度信息使其能够应对图像灰度不均匀。Li等^[29]提出了一种局部强度聚类(local intensity clustering, LIC)的水平集方法,能够同时分割图像并估计偏置场,估计的偏置场可以用于灰度不均匀性校正(或偏差校正)。Wang等^[12-14]基于RSF模型完成了一系列减少局部强度拟合方法耗时的工作。

本文基于DRLSE模型和CPLSE模型,通过改进距离正则项以及使用能更快达到收敛条件的非零水平集^[15,30]实现对左心室的精确分割。改进的距离正则项有效避免了水平集函数重新初始化,解决了水平集函数不稳定的问题。同时,本文模型可以保证心脏左心室MRI分割结果包含腔、小梁和乳头肌并保持凸形的高精度分割结果。实验结果验证了所提模型分割性能的精确性和鲁棒性。

1 相关工作

1.1 DRLSE模型

DRLSE模型^[7]具有保持水平集函数正则性的内在能力,其拥有独特的前向和后向(forward and backward, FAB)扩散效应,可以保持期望的符号距离函数性质,从而保证了水平集演化的稳定性和水平集函数及其导数计算的准确性。令 I 为图像域 Ω 上的图像, $\phi:\Omega\rightarrow\mathbf{R}$ 为水平集函数,DRLSE模型的能量泛函定义为

$$E(\phi)=\mu R(\phi)+\lambda L(\phi)+\alpha A(\phi), \quad (1)$$

其中, $\mu>0$, $\lambda>0$ 和 $\alpha\in\mathbf{R}$;第一项 $R(\phi)$ 为距离正则项,用于保证水平集函数的正则性;第二项 $L(\phi)$ 为加权长度项,用于计算水平集轮廓的线积分;第三项 $A(\phi)$ 为加权面积项,其作用是计算水平集轮廓内部面积。

DRLSE模型中的距离正则项基于双阱势(double well potential, DWP)函数,其定义为

$$p(s)=\begin{cases} \frac{1}{(2\pi)^2}(1-\cos(2\pi s)), & |s|\leq 1, \\ \frac{1}{2}(s-1)^2, & s>1. \end{cases} \quad (2)$$

因此,距离正则项定义为

$$R(\phi)\triangleq\int_{\Omega}p(\nabla(\phi))dx. \quad (3)$$

对于长度项和面积项,首先定义边缘检测函数

$$g\triangleq\frac{1}{1+|\nabla G_{\sigma}*I|^2}, \quad (4)$$

其中, G_{σ} 为标准差为 σ 的高斯核函数。利用式(4)中的卷积对图像进行平滑处理,降低图像噪声。边缘指示函数 g 的数值在对象边缘位置时通常数值较小,而在其他区域数值较大。进而定义长度项和面积项分别为

$$L(\phi)\triangleq\int_{\Omega}g\delta(\phi)|\nabla\phi|dx, \quad (5)$$

$$A(\phi)\triangleq\int_{\Omega}gH(-\phi)dx, \quad (6)$$

其中, H 和 δ 分别表示Heaviside函数和Dirac函数。在实际应用中, H 和 δ 通由光滑函数 H_{ε} 和 δ_{ε} 近似,分别定义为

$$H_{\varepsilon}(x)=\begin{cases} \frac{1}{2}\left[1+\frac{x}{\varepsilon}+\sin\left(\frac{\pi x}{\varepsilon}\right)\right], & |x|\leq\varepsilon, \\ 0, & x<-\varepsilon, \\ 1, & x>\varepsilon, \end{cases} \quad (7)$$

$$\delta_{\varepsilon}(x)=\begin{cases} \frac{1}{2\varepsilon}\left[1+\cos\left(\frac{\pi x}{\varepsilon}\right)\right], & |x|\leq\varepsilon, \\ 0, & |x|>\varepsilon, \end{cases} \quad (8)$$

其中, δ_ε 是 H_ε 的导数。

使用变分法和梯度下降流方法最小化能量泛函式(1),其演化方程为

$$\frac{\partial \phi}{\partial t} = \mu \operatorname{div}(d_p(|\nabla \phi|) \nabla \phi) + \lambda \delta_\varepsilon(\phi) \operatorname{div}\left(g \frac{\nabla \phi}{|\nabla \phi|}\right) + \alpha g \delta_\varepsilon(\phi), \quad (9)$$

其中, $\operatorname{div}(\cdot)$ 为散度算子, d_p 基于式(2)定义为

$$d_p(s) \triangleq \frac{p'(s)}{s}. \quad (10)$$

1.2 RSF 模型

RSF 模型^[6]在处理灰度不均匀图像方面有显著的优势。在 RSF 模型中,函数 f_1 和 f_2 用来拟合水平集轮廓内外局部区域内的图像灰度,通过引入高斯核函数利用图像的局部邻域信息来处理图像强度不均匀。RSF 模型在点 x 处的数据拟合项定义为

$$\varepsilon(\phi, f_1, f_2) = \sum_{i=1}^2 \lambda_i \int_{\Omega} K(x-y) |I(y) - f_i(x)|^2 M_i(\phi_y) dy, \quad (11)$$

其中, λ_i 是常数。特征函数 $M_1(\phi)$, $M_2(\phi)$ 定义为 $M_1(\phi) = H(\phi)$, $M_2(\phi) = 1 - H(\phi)$ 。 $K(\cdot)$ 是高斯核函数,其细节详见文献[2]。

引入长度项和距离正则项后,RSF 模型在整个图像域上的能量泛函表示为

$$E(\phi, f_1, f_2) = \sum_{i=1}^2 \lambda_i \int_{\Omega} K(x-y) |I(y) - f_i(x)|^2 M_i(\phi_y) dy + \nu \int_{\Omega} |\nabla H(\phi(x))| dx + \frac{\mu}{2} \int_{\Omega} (|\nabla \phi(x)| - 1)^2 dx, \quad (12)$$

其中, ν , μ 是常数。

2 模型介绍

2.1 非零水平集

左心室是心脏关键组成部分,具有复杂的结构,主要由一种三维连续纤维构成的心肌组成。心肌由心脏的3层肌肉组成,具有自主收缩和传导电信号的能力,承担着泵血和将氧气与养分输送到全身各部位的重要作用。图1展示了典型的心脏磁共振图像,其中包含了关于心室结构的关键信息。在图1中,蓝色轮廓代表心内膜,黄色箭头标示心肌,红色箭头标示乳头肌(乳头肌是心室内壁上的肌肉突起,通过腱索与心室内的二尖瓣或三尖瓣相连。在心室收缩时可以拉动腱索,使瓣膜闭合,防止血液回流),而绿色箭头则指向左心室腔。图1展示了在舒张末期(end-diastolic, ED)和收缩末期(end-systolic, ES)阶段的左心室 MRI,其中图1(a)为 ED 阶段,图1(b)为 ES 阶段。ED 和 ES 阶段的心脏 MRI 分割对于心脏定量分析和疾病诊断非常重要,其反映了心脏周期运动中的不同状态。

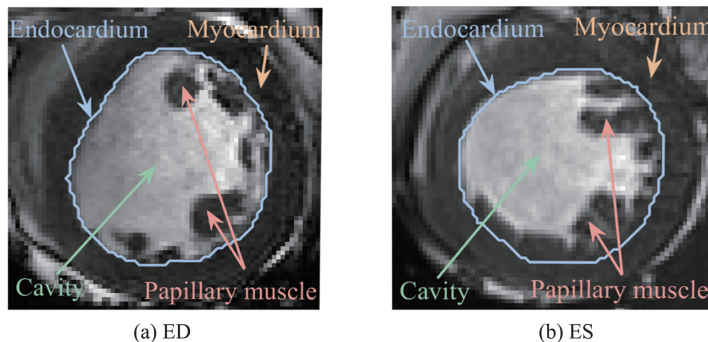


图1 短轴 MRI 在 ED 和 ES 阶段典型示例

Fig.1 Short axis cine MRI view of one representative patient in ED and ES phases

非零水平集(nonzero level set)在图像分割领域具有诸多优点:能够处理复杂的图像边界和拓扑结构,对于不规则形状和噪声干扰具有鲁棒性;可以自适应收敛到图像中不同对象的边界且无需任何先验知识;能够灵活引入到内部和外部能量项中;能更快到达收敛边界^[15,30]。

本文基于 DRLSE 模型并引入 CPLSE 模型中的保凸项,结合改进距离正则项并使用非零水平集进行左心室分割。如图 2(a),设 $\Omega \in \mathbf{R}^2$ 为图像域, $I(x): \Omega \rightarrow \mathbf{R}$ 为给定灰度图像, $\phi_k(x): \Omega \rightarrow \mathbf{R}$ 为定义在图像域 Ω 上的非零水平集函数,其表达式为

$$\{x: \phi_k(x) = k\}, \quad (13)$$

其中 k 为任意常数。

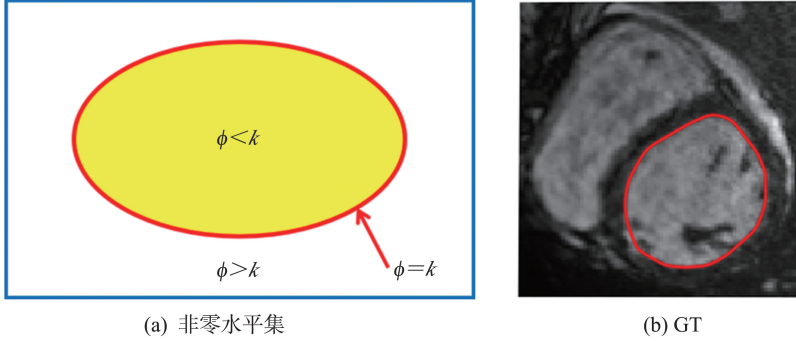


图2 非零水平集和 GT 示意图
Fig.2 Nonzero level sets and GT

2.2 改进距离正则项

水平集函数的正则性由水平集曲线演化内在保持。DRLSE 模型分割边界模糊的图像时,其分割结果不够理想。为使水平集曲线更加平滑和分割结果更加精确,本文基于新双阱势(new double well potential, NDWP)函数来提出改进距离正则项。NDWP 定义为

$$p_{\text{new}}(|\nabla\phi_k|) = \begin{cases} |\nabla\phi_k|^2(1-|\nabla\phi_k|) + \frac{1}{2}(|\nabla\phi_k|^2-1)^2 + \frac{1}{2}(|\nabla\phi_k|^2-1), & |\nabla\phi_k| \leq 1, \\ \frac{1}{2}(|\nabla\phi_k|-1)^2, & |\nabla\phi_k| > 1. \end{cases} \quad (14)$$

由式(14)可知,NDWP 有最小值 $|\nabla\phi_k|=0$ 和 $|\nabla\phi_k|=1$ 。由式(10)可得 NDWP 的扩散率 $d_p(|\nabla\phi_k|)$ 为

$$d_{p_{\text{new}}}(|\nabla\phi_k|) = \begin{cases} (2|\nabla\phi_k|-1)(|\nabla\phi_k|-1), & |\nabla\phi_k| \leq 1, \\ 1 - \frac{1}{|\nabla\phi_k|}, & |\nabla\phi_k| > 1. \end{cases} \quad (15)$$

其对应演化偏微分方程为

$$\frac{\partial\phi_k}{\partial t} = \begin{cases} \text{div}((2|\nabla\phi_k|-1)(|\nabla\phi_k|-1)\nabla\phi_k), & |\nabla\phi_k| \leq 1, \\ \text{div}\left(\left(1 - \frac{1}{|\nabla\phi_k|}\right)\nabla\phi_k\right), & |\nabla\phi_k| > 1, \end{cases} \quad (16)$$

同时,

$$\lim_{|\nabla\phi_k| \rightarrow 0} d_{p_{\text{new}}} = \lim_{|\nabla\phi_k| \rightarrow \infty} d_{p_{\text{new}}} = 1. \quad (17)$$

因此得到

$$|\mu d_{p_{\text{new}}}(\nabla\phi_k)| \leq \mu, \quad (18)$$

这说明改进距离正则项的 NDWP 扩散率有界。水平集函数演化实质上是梯度流,距离正则项在水平集函数演化时起重要作用,其在最小化能量的同时,约束水平集函数的梯度模,避免传统水平集方法的重新初始化。

- 1) 当 $|\nabla\phi_k| > 1$ 时, $d_{p_{\text{new}}}(|\nabla\phi_k|) > 0$, 曲线正向扩散,扩散会使得 $|\nabla\phi_k|$ 越来越小,使得 $|\nabla\phi_k| \rightarrow 1$ 。
- 2) 当 $\frac{1}{2} < |\nabla\phi_k| \leq 1$ 时, $d_{p_{\text{new}}}(|\nabla\phi_k|) < 0$, 曲线反向扩散,扩散使得 $|\nabla\phi_k|$ 越来越大,使其恢复 $|\nabla\phi_k| \rightarrow 1$ 。
- 3) 当 $|\nabla\phi_k| \leq \frac{1}{2}$ 时, 曲线正向扩散,扩散会使得 $|\nabla\phi_k|$ 越来越小,使其趋于 $|\nabla\phi_k| \rightarrow 0$ 。

因此,水平集函数演化结果向 $|\nabla\phi_k| \rightarrow 1$ 或 $|\nabla\phi_k| \rightarrow 0$ 进行。

基于 NDWP 的改进正则项表示为

$$R_{\text{new}}(\phi_k) = \mu \operatorname{div}(d_{p_{\text{new}}}(|\nabla\phi_k|)\nabla\phi_k). \quad (19)$$

2.3 非零水平集保凸项

在临床应用中,心脏左心室通常呈椭圆形。然而,在二维心脏 MRI 中,左心室呈椭圆形,且左心室的理想分割结果是包含左心室腔、小梁和乳头肌并保持凸形^[8]。图 2(b) 为左心室 MRI 黄金分割标准(ground truth, GT)。由于乳头肌与左心室腔的图像强度存在较大差异,仅根据图像灰度进行分割易造成误分割现象。因此,引入非零水平集保凸项能有效提升左心室 MRI 分割精度。利用数学中的曲率表达式^[31]可以得到水平集函数 ϕ 的曲率表达式

$$\kappa = \operatorname{div}\left(\frac{\nabla\phi}{|\nabla\phi|}\right). \quad (20)$$

如图 3,曲线在 $\kappa \geq 0$ 的位置为凸,在 $\kappa < 0$ 的位置为凹。引入曲率符号函数(curvature sign indicator, CSI)

$$s(\kappa) = \begin{cases} 1, & \kappa \geq 0, \\ 0, & \kappa < 0, \end{cases} \quad (21)$$

可以得到非零水平集保凸项的定义为

$$C(\phi_k) = \int_{\Omega} (1-s(\kappa))\kappa H_{\varepsilon}(-\phi_k) dx. \quad (22)$$

当非零水平集分割轮廓达到对象边界时,若轮廓曲率 $\kappa < 0$,保凸项使得轮廓继续移动,直到轮廓保持凸形。非零水平集保凸项有助于提升分割精确度,并实现临床应用中左心室 MRI 分割的理想结果。

2.4 本文模型

针对左心室 MRI 分割可能产生的误分割问题,基于 DRLSE 模型中的长度项和面积项与本文提出的非零水平集保凸项和改进距离正则项,构建基于非零水平集保凸算法的左心室 MRI 分割模型,称为 NCPLSE (nonzero convexity preserving level set evolution) 模型,其能量泛函为

$$E(\phi_k) = R_{\text{new}}(\phi_k) + s(\kappa)L_g(\phi_k) + s(\kappa)A_g(\phi_k) + C(\phi_k), \quad (23)$$

其中,第一项为 2.2 节提出的改进距离正则项,第二项为长度项,第三项为面积项,第四项为具有非负系数的保凸项。

式(23)中, $\kappa < 0$ 时,激活保凸项并禁用长度项和面积项,确保轮廓最终演化为凸形; $\kappa \geq 0$ 时,激活数据项并禁用保凸项,使轮廓最终停止在对象边界上。

NCPLSE 模型的梯度下降流方程为

$$\begin{aligned} \frac{\partial\phi_k}{\partial t} = & \mu \operatorname{div}(d_{p_{\text{new}}}(|\nabla\phi_k|)\nabla\phi_k) + \lambda s(\kappa)\delta_{\varepsilon}(\phi_k) \operatorname{div}\left(g \frac{\phi_k}{|\nabla\phi_k|}\right) \\ & + \alpha s(\kappa)g\delta_{\varepsilon}(\phi_k) + \beta(1-s(\kappa))\kappa\delta(\phi_k). \end{aligned} \quad (24)$$

其数值解迭代方案为

$$\phi_k^{t+1} = \phi_k^t + \Delta t \Gamma(\phi_k^t), \quad (25)$$

其中, $\Gamma(\phi_k^t)$ 是式(24)等号右端部分使用有限差分格式在 $\phi_k = \phi_k^t$ 处的导数近似, Δt 为时间步长。有关水平集方法数值实现的更多细节,请参考文献[7]。

3 实验结果

3.1 实验数据集

本文使用 ACDC MICCAI 2017^[32] 数据集评估 NCPLSE 模型分割性能。ACDC 数据集包含 150 位匿名患者,共分为 5 个均匀分布的亚组:扩张型心肌病(dilated cardiomyopathy, DCM)、肥厚型心肌病(hypertrophic cardiomyopathy, HCM)、心肌梗死伴左室射血分数改变(myocardial infarction with altered left ventricular ejection fraction, MINF)、右心室异常(abnormal right ventricle, ARV)和健康(normal, NOR)组。此外,ACDC 数据集包含 100 位匿名患者组成的训练集及对应 GT 和 50 位匿名患者组成测试数据集。NCPLSE




图3 曲率和凸性示意图

Fig.3 Illustration of curvature and convexity

模型实验基于 MATLAB 2022b(64 bit)完成,运行设备配置为 Intel Core i7-13700KF,4.1 GHz 和 5.1 GHz CPU, 24 GB RAM 以及 Windows 11(64 bit)。

3.2 算法流程

NCPLSE 模型实现步骤如下。

Step 1 初始化非零水平集函数。

Step 2 使用 RSF 模型(12)进行预分割。

Step 3 基于式(24)进行非零水平集演化。

能量泛函式(24)各项系数设置为 $\lambda=1$, $\alpha=-2$, $\beta=3$, $\mu=0.2$ 。参数 $\Delta t=1$, $\varepsilon=1.5$, $\sigma=0.8$ (与 DRLSE 和 CPLSE 模型保持一致)。

3.3 评价指标

使用 Dice 系数^[8]豪斯多夫距离(Hausdorff distance, HD)^[33]2个指标来定量化评估 NCPLSE 模型分割性能。Dice 系数通常用于评估模型分割结果与 GT 的一致性,其定义为

$$DC(S, G) = \frac{2|S \cap G|}{|S| + |G|}, \quad (26)$$

其中, $|\cdot|$ 表示区域面积, S 表示分割结果, G 表示 GT。Dice 系数取值范围介于 0 和 1 之间,其中 1 表示完全一致,而 0 则表示完全不一致。

HD 用于比较两个点集的形状相似性或匹配程度,常用于评估模型分割结果与 GT 之间的差异程度,定义为

$$HD(S, G) = \max(\max_{a \in S}(\min_{b \in G}(d(a, b))), \min_{b \in G}(\min_{a \in S}(d(a, b)))), \quad (27)$$

其中 $d(a, b)$ 表示欧式距离。HD 作为形状相似性或匹配程度的度量,为 Dice 系数提供了重要补充。模型分割结果与 GT 的 HD 越小,表示分割精度越高。

3.4 模型评估分析

图 4 展示了 NCPLSE 模型分割心脏左心室 MRI 的迭代过程,其中图 4(a)为非零水平集初始化结果,图 4(b)~(g)为迭代 10、40、70、100、130 和 160 次的分割结果,图 4(h)为最终分割结果。图 4 清晰地展示了非零水平集轮廓从初始化到逐渐突出,最终收敛为凸形轮廓。NCPLSE 模型的迭代过程验证了 NCPLSE 模型保凸机制的有效性。

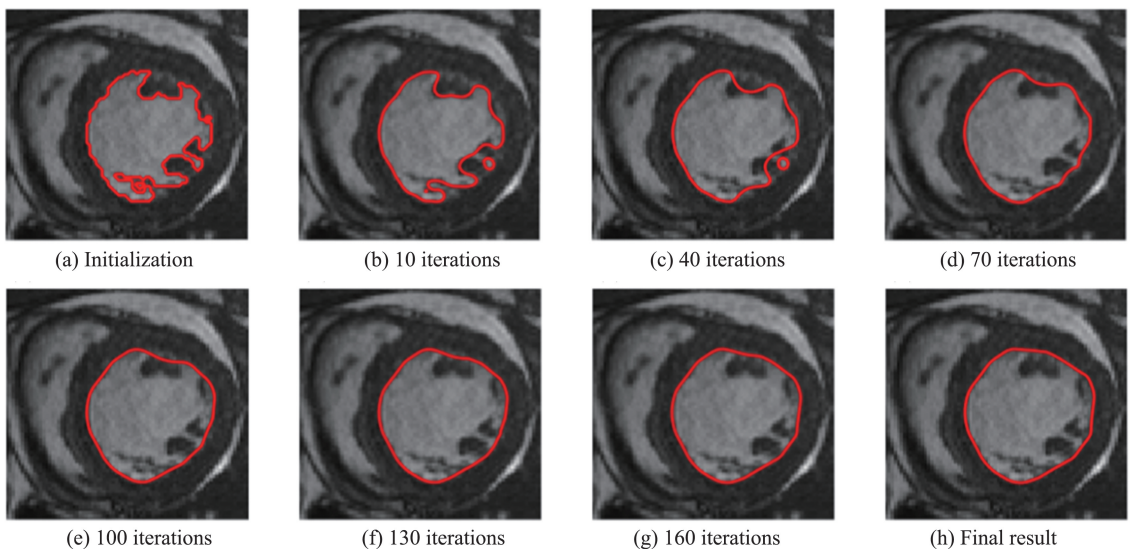


图 4 迭代过程图

Fig.4 Evolution of the proposed model

图 5 展示了在 ED 和 ES 阶段不同病理的左心室 MRI 分割结果,包括 DCM、HCM、MINF、ARV、NOR 组,来验证 NCPLSE 模型分割左心室 MRI 的泛化能力。图 5 中,1、2 行和 7、8 行为原始图像,3、4 和 9、10 行中蓝色轮廓为 GT,5、6 和 11、12 行中红色轮廓为分割结果。从图 5 可以观察到,MRI 装置中 B0 和 B1 场的不均匀性导致左心室 MRI 边界变得模糊和灰度不均匀,这为左心室分割带来了一定挑战。值得注

意的是,小梁、乳头肌和心肌的图像灰度相似,容易导致小梁和乳头肌被误分割为心肌,进而导致左心室分割结果呈现非凸形。然而,尽管面临这些复杂挑战,NCPLSE 模型仍能够取得令人满意的分割结果。

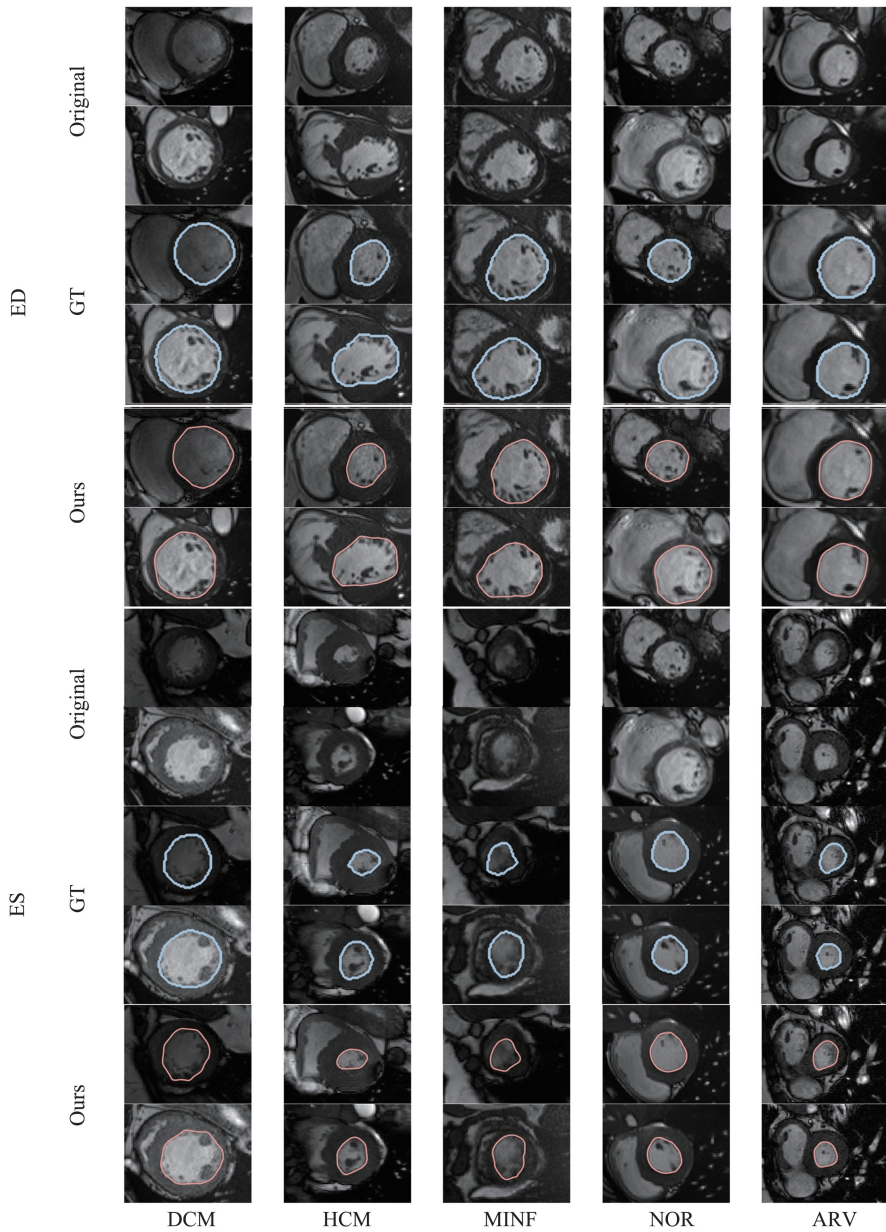



图 5 不同病理在 ED 和 ES 阶段分割结果

Fig.5 Segmentation results in ED and ES phases for different pathologies

图 6 展示了 NCPLSE 模型从左心室 MRI 基底 (base) 到心尖 (apex) 部切片的分割结果。图 6 中,1,2 行是原始图像,3,4 行中蓝色轮廓为 GT,5,6 行中红色轮廓为 NCPLSE 模型分割结果。图 6 展示的分割结果验证了 NCPLSE 模型分割左心室 MRI 不同切片上的泛化能力。






图6 基底到心尖部左心室 MRI 切片分割结果

Fig.6 Segmentation results of LV from base to apex slice

表1展示了ACDC MICCAI 2017数据集中,10例匿名患者心脏MRI典型分割结果的平均Dice和HD。每例匿名患者在ED和ES阶段共包含8~15帧图像。NCPLSE模型在10例匿名患者组成的小样本数据集上,ED和ES阶段的平均Dice为0.971和0.955,平均HD为2.02和2.22。分割结果验证了NCPLSE模型无需任何先验知识和模型训练,就能在小样本数据集上取得卓越的分割性能。

表1 ACDC MICCAI 2017数据集上选取案例的分割结果

Table 1 Segmentation results for selected cases on ACDC MICCAI 2017 data sets

Patient	Mean Dice		Mean HD	
	ED	ES	ED	ES
1	0.971	0.949	2.055	2.976
2	0.969	0.959	2.256	1.931
3	0.976	0.954	1.747	3.256
4	0.970	0.960	2.610	2.511
5	0.961	0.960	2.664	2.286
6	0.978	0.967	1.138	1.543
7	0.970	0.964	2.038	2.038
8	0.970	0.949	1.973	1.919
9	0.966	0.942	2.068	2.354
10	0.974	0.948	1.677	1.398

图7展示了ED和ES阶段不同精度的分割结果,包括最佳(best, B),中位数(medium, M)和最差(worse, W)Dice。每种精度均展示3帧MRI切片的分割结果,其中,蓝色轮廓代表GT,红色轮廓代表分割结果。结果表明,由于小梁、乳头肌和心肌图像灰度相似,第3行和第6行的图像分割难度更大。如图7所示,NCPLSE模型的分割结果可以满足左心室分割的临床应用要求。

3.5 模型对比分析

为验证改进距离正则项和非零水平集对分割结果的有效提升,图8与表2展示了ACDC MICCAI 2017数据集ED和ES阶段不同病例组分割结果的平均Dice和HD。图8(a)为平均Dice对比,图8(b)为平均HD对比,横坐标表示ACDC数据集分成的10个亚组,即心脏ED和ES阶段DCM、HCM、MINF、ARV、NOR组。图8中“Ours”代表NCPLSE模型,“Non_zero LSE and Old PF”代表基于原始距离正则项的非零水平集模型(即基于非零水平集的CPLSE模型,且DR term表示距离正则项),“New PF and Zero_LSE”代表基于改进距离正则项的CPLSE模型,“CPLSE”代表CPLSE模型。表2为图8模型平均Dice和HD对比的具体

数据展示。此外,CPLSE 模型为引入保凸项的 DRLSE 模型。实验结果表明,非零水平集和改进距离正则项的引入,均对分割精度有显著提升。




图 7 不同分割精度分割结果典型示例

Fig.7 The typical examples of segmentation results with different accuracy performances

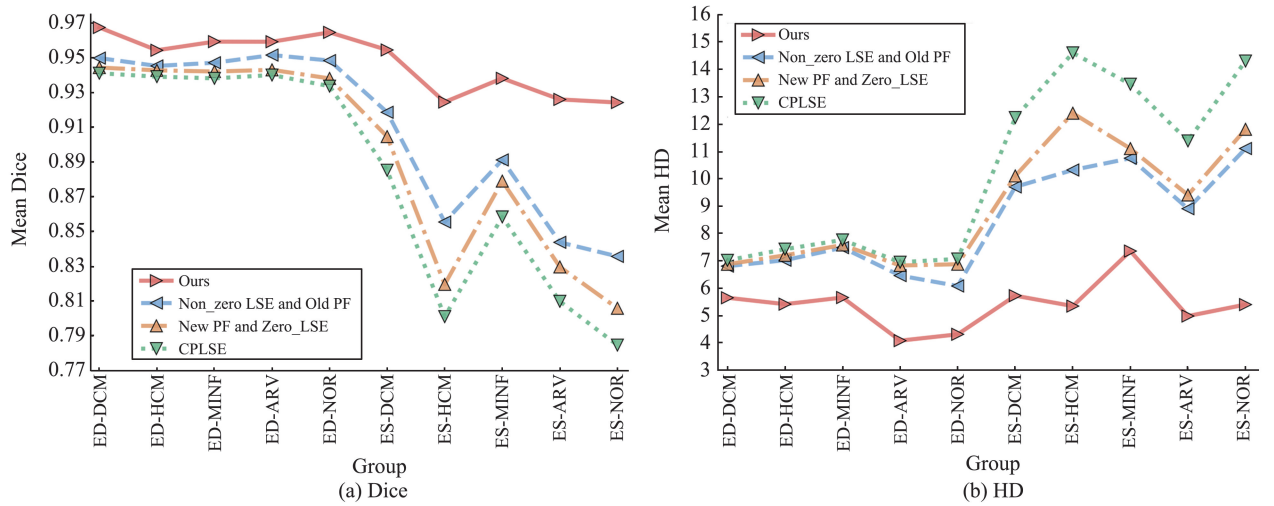


图 8 ED 和 ES 阶段不同病理组平均 Dice 和 HD 对比展示
Fig.8 Mean Dice and HD in ED and ES phases

表 2 心脏 ED 和 ES 阶段不同病理组平均 Dice 和 HD 对比

Table 2 Mean Dice and HD in ED and ES phases

Model	Dice									
	ED					ES				
	DCM	HCM	MINF	ARV	NOR	DCM	HCM	MINF	ARV	NOR
CPLSE	0.941	0.939	0.937	0.940	0.934	0.885	0.801	0.859	0.810	0.785
Zero LSE+new DR term	0.945	0.943	0.9422	0.943	0.938	0.905	0.820	0.879	0.830	0.806
Nonzero LSE+original DR term	0.950	0.945	0.947	0.952	0.949	0.919	0.856	0.891	0.844	0.836
NCPLSE	0.968	0.954	0.960	0.959	0.965	0.955	0.925	0.938	0.926	0.924

Model	HD									
	ED					ES				
	DCM	HCM	MINF	ARV	NOR	DCM	HCM	MINF	ARV	NOR
CPLSE	7.0	7.4	7.8	6.9	7.1	12.2	14.6	13.5	11.4	14.3
Zero LSE+new DR term	6.9	7.2	7.6	6.8	6.9	10.1	12.4	11.1	9.4	11.8
Nonzero LSE+original DR term	6.8	7.0	7.5	6.5	6.1	9.7	10.3	10.8	8.9	11.1
NCPLSE	5.7	5.4	5.7	4.1	4.3	5.7	5.3	7.4	5.0	5.4

注:加粗字体为最优结果。

图9展示了ACDC MICCAI 2017数据集ED和ES阶段左心室MRI分割结果的Dice和HD分布情况,来进一步验证NCPLSE模型分割结果的鲁棒性和精确性。图9(a)、(b)分别为ED和ES阶段Dice展示,图9(c)、(d)分别为ED和ES阶段HD展示。其中,“Ours”代表NCPLSE模型,“Non_zero_CPLSE”代表基于原始距离正则项的非零水平集模型(即基于非零水平集的CPLSE模型),“New_CPLSE”代表基于改进距离正则项的CPLSE模型,“CPLSE”代表CPLSE模型。结果表明,NCPLSE模型的分割精度完全优于CPLSE模型。

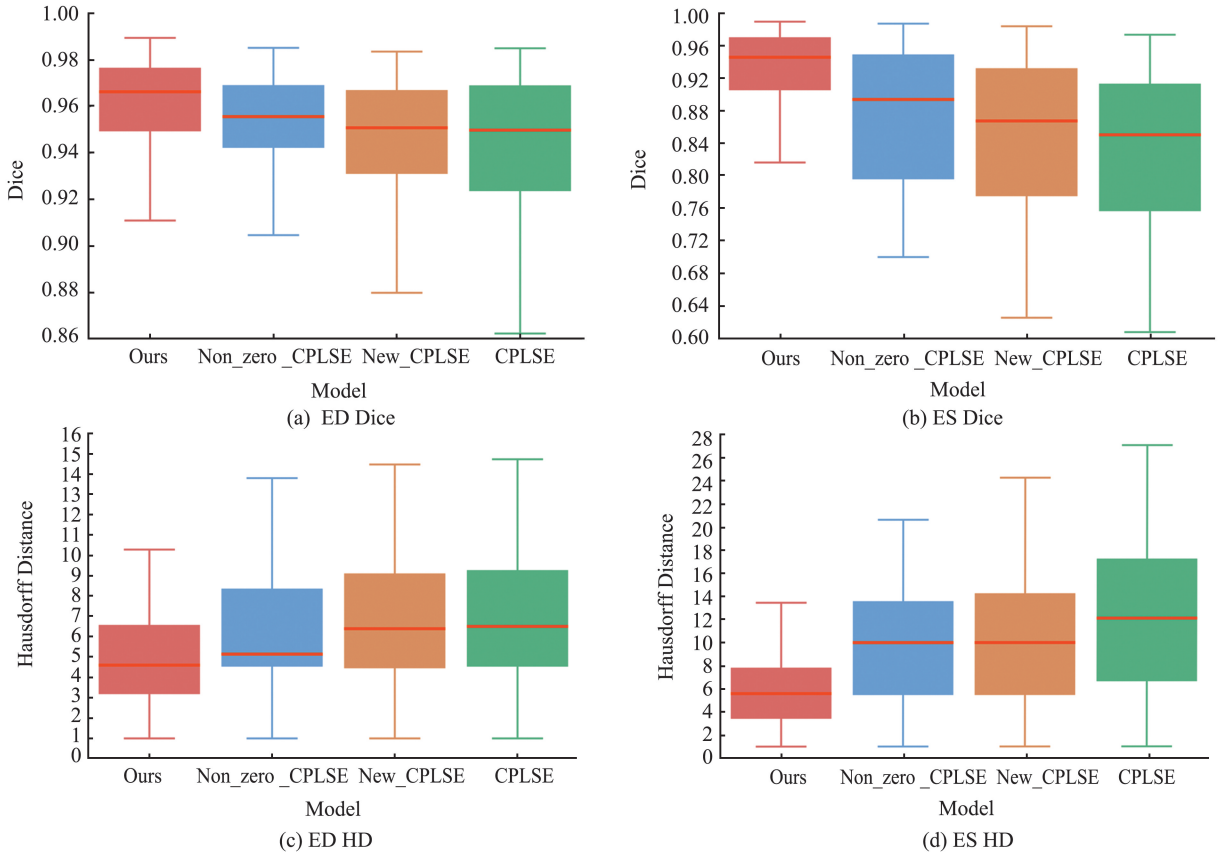


图9 模型在ED和ES阶段Dice和HD

Fig.9 Dice values and HD in ED and ES phases

表3展示了NCPLSE模型和ACDC MICCAI 2017在线排行榜中基于深度学习的SOTA模型在ED和ES阶段分割结果的平均Dice和HD。排行榜中,NCPLSE模型分割结果的平均Dice值与其他SOTA模型相当,但平均HD在心脏ED和ES阶段相比Isensee等^[34]提出的算法分别减少了33.78%和15.94%。实验结果表明,NCPLSE模型分割结果与GT更加相似,更具临床应用价值。值得注意的是,NCPLSE模型是非深度学习模型,可以无需训练直接进行临床应用。深度学习算法需要大量训练数据及对应人工标注,这在实际应用中通常无法满足。为了评估模型的分割效率,表4展示了不同模型在ACDC MICCAI 2017数据集上的处理时间。NCPLSE模型在无需训练的情况下,仅使用CPU计算0.68 s就能获得满意的分割结果。ACDC MICCAI 2017数据集中,每名匿名患者在ED和ES阶段共包含8—15帧MRI切片。因此,NCPLSE模型仅需5.44—10.2 s就可以分割一个主题。对比深度学习模型在使用训练集调整参数后的分割效率,NCPLSE模型在计算效率上并不是最优的,但通过优化和使用快速水平集优化算法,如ADMM算法^[11]和窄带技术^[44],可显著减少计算时间。

表5展示了ACDC MICCAI 2017在线排行榜前6名左心室MRI分割模型的平均Dice。基于非深度学习的NCPLSE模型能在该数据集上取得与基于深度学习的SOTA模型相当的平均Dice。值得注意的是,Guo等^[45]提出的nnFormer模型在5对象小样本数据集进行分割时,比表3中Isensee等^[34]提出的算法的平均Dice高出1.1%,在完整测试数据集上,并没有明显提升。如表3和表5所示,基于非深度学习的NCPLSE模型在小样本数据集和完整测试数据集均超越ACDC MICCAI 2017比赛结果第一名的平均Dice,且ES阶段

平均 Dice 达到 0.936,平均 HD 显著减少;在 ACDC MICCAI 2017 在线排行榜上也取得与基于深度学习的 SOTA 模型相当的分割性能。

表 3 左心室分割结果定量比较
Table 3 Quantitative comparison of LV segmentation with state-of-the-art model

User	Mean Dice		Mean HD	
	ED	ES	ED	ES
Isensee 等 ^[34]	0.968	0.931	7.4	6.9
Khened 等 ^[35]	0.964	0.917	8.1	9.0
Zotti 等 ^[36]	0.957	0.905	6.6	8.7
Baumgartner 等 ^[37]	0.963	0.911	6.5	9.2
Wolterink 等 ^[38]	0.961	0.918	7.5	9.6
Painchaud 等 ^[39]	0.961	0.911	6.1	8.3
Rohé 等 ^[40]	0.957	0.900	7.5	10.8
Patravali 等 ^[41]	0.950	0.900	14.9	14.4
Grinias 等 ^[42]	0.950	0.860	10.2	14.5
Shi ^[8]	0.924	0.822	7.3	13.3
Yang ^[43]	0.864	0.775	47.9	53.1
NCPLSE	0.961	0.936	4.9	5.8

注:加粗字体为最优结果。

表 4 模型分割时间成本定量比较
Table 4 Quantitative comparison of LV segmentation time-cost

User	Processor	No training	Time/s
Isensee 等 ^[34]	GPU	×	1.00~2.00
Khened 等 ^[35]	GPU	×	0.30
Zotti 等 ^[36]	GPU	×	0.40
Baumgartner 等 ^[37]	GPU	×	1.10
Wolterink 等 ^[38]	GPU	×	0.40
Painchaud 等 ^[39]	GPU	×	1.00
Rohé 等 ^[40]	CPU	×	6.00
Patravali 等 ^[41]	GPU	×	0.30
Grinias 等 ^[42]	GPU	×	1.00
Shi 等 ^[8]	CPU	√	3.00
Yang 等 ^[43]	GPU	×	5.00
NCPLSE	CPU	√	0.68

注:加粗字体为使用 CPU 作为处理器。

表 5 ACDC MICCAI 2017 在线排行榜左心室得分排行榜 Top 6
Table 5 Top 6 results of Left ventricular scores on ACDC post-2017-MICCAI online leaderboard^①

User	Model	Mean Dice	Published time	Processor
Kato 等 ^[28]	FCT	0.967	2023	GPU
Tragakis 等 ^[27]	FCT	0.959	2022	GPU
Rahman 等 ^[47]	MERIT	0.961	2023	GPU
Rahman 等 ^[48]	MERIT-GCASCADE	0.961	2023	GPU
	PVT-GCASCADE	0.959	2023	GPU
Zhou 等 ^[49]	nnFormer	0.957	2022	GPU
Ours	NCPLSE	0.951	—	CPU

注:加粗字体为本文算法结果。

图 10 展示了 NCPLSE 模型与 Ma 等^[46]提出的 ALF(adaptive local fitting)模型、DRLSE 模型、CPLSE 模型以及 ADMM 模型等水平集模型对初始化鲁棒性的比较结果。基于 3 帧具有代表性的心脏 MRI,以 3 种形状进行水平集初始化来对比上述模型的初始化鲁棒性。图 10(a)展示了利用 3 种不同半径圆形进行初始化时,NCPLSE 模型、ADMM 模型和 CPLSE 模型均能有效分割左心室,而 ALF 和 DRLSE 模型分割结果差

① <https://paperswithcode.com/sota/medical-image-segmentation-on-automatic>

异显著。图 10(b)展示了在左心室边界较弱的 MRI 中,NCPLSE 在 3 种不同边长矩形初始化中都可以得到理想的凸形分割结果,而其余模型的分割结果差异较大。图 10(c)展示的图片中,小梁、乳头肌与心肌图像相似,仅 NCPLSE 模型和 CPLSE 模型的分割结果为凸形,且在视觉上与 GT 吻合。而如表 3 所示,NCPLSE 模型分割结果的平均 Dice 高于 CPLSE 模型。图 11 展示了 NCPLSE 模型与 ALF、CPLSE、DRLSE 及 ADMM 模型对多组测试 MRI 分割的平均 Dice。NCPLSE 模型分割结果平均 Dice 明显高于其余 4 种水平集模型。因此,NCPLSE 模型在初始化鲁棒性、保持凸形和分割精度等方面优于上述 4 种水平集模型。




图 10 初始化鲁棒性对比

Fig. 10 Segmentation results in different initial contours comparison with different methods

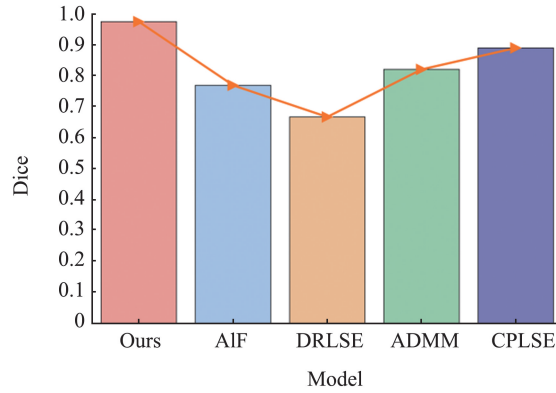


图 11 不同水平集模型平均 Dice 对比

Fig.11 Mean Dice values of different methods

4 结论

本文提出了一种基于新双阱势函数的改进距离正则项和非零水平集保凸项的非零水平集心脏左心室 MRI 分割模型 NCPLSE 模型。NCPLSE 模型能使分割轮廓快速演化为凸形,这与左心室临床应用中左心室期望分割结果应包含左心室腔、小梁和乳头肌并保持凸形一致。使用 ACDC MICCAI 2017 数据集对 NCPLSE 模型进行了实验验证,并取得了满意的左心室 MRI 分割结果。NCPLSE 模型在无需对训练数据进行人工标注和反复训练的情况下,分割精度和鲁棒性与需要大量重复训练和人工标注的基于深度学习的模型相当。此外,在节约时间成本的情况下,NCPLSE 模型分割结果的平均 HD 能超越基于深度学习的模型,分割结果更具临床应用意义。在未来的工作中,我们将继续拓展非零水平集为双非零水平集模型,以同时精确分割心脏左、右心室 MRI。

参考文献:

- [1] GAIDAI O, CAO Y, LOGINOV S. Global cardiovascular diseases death rate prediction[J]. *Current Problems in Cardiology*, 2023, 48(5):101622.
- [2] ZENG X, STAIB L, SCHULTZ R, et al. Volumetric layer segmentation using coupled surfaces propagation[C]//1998 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (Cat. No.98CB36231). Santa Barbara: IEEE, 1998:708-715.
- [3] PRATONDO A, CHUI C K, ONG S H. Robust edge-stop functions for edge-based active contour models in medical image segmentation[J]. *IEEE Signal Processing Letters*, 2016, 23(2):222-226.
- [4] LYNCH M, GHITA O, WHELAN P F. Left-ventricle myocardium segmentation using a coupled level-set with a priori knowledge[J]. *Computerized Medical Imaging and Graphics*, 2006, 30(4):255-262.
- [5] CHAN T F, VESE L A. Active contours without edges[J]. *IEEE Transactions on Image Processing*, 2001, 10(2):266-277.
- [6] LI C, KAO C, GORE J, et al. Minimization of region-scalable fitting energy for image segmentation[J]. *IEEE Transactions on Image Processing*, 2008, 17(10):1940-1949.
- [7] LI Chunming, XU Chenyang, GUI Changfeng, et al. Distance regularized level set evolution and its application to image segmentation[J]. *IEEE Transactions on Image Processing*, 2010, 19(12):3243-3254.
- [8] SHI Xue, LI Chunming. Convexity preserving level set for left ventricle segmentation[J]. *Magnetic Resonance Imaging*, 2021, 78:109-118.
- [9] KIM Y C, KIM S M, CHOE Y H. Robust semi-automated quantification of cardiac MR perfusion using level set: application to hypertrophic cardiomyopathy patient data[J]. *Computers in Biology and Medicine*, 2016, 71:162-173.
- [10] CIECHOLEWSKI M. An edge-based active contour model using an inflation/deflation force with a damping coefficient[J]. *Expert Systems with Applications*, 2016, 44:22-36.
- [11] WALI S, LI C, IMRAN M, et al. Level-set evolution for medical image segmentation with alternating direction method of multipliers[J]. *Signal Processing*, 2023, 211:109105.

- [12] WANG Lei, CHANG Yan, WANG Hui, et al. An active contour model based on local fitted images for image segmentation [J]. *Information Sciences*, 2017, 418-419:61-73.
- [13] WANG Lei, CHEN Guangqiang, SHI Dai, et al. Active contours driven by edge entropy fitting energy for image segmentation[J]. *Signal Processing*, 2018, 149:27-35.
- [14] WANG Lei, ZHANG Libo, YANG Xiaodong, et al. Level set based segmentation using local fitted images and inhomogeneity entropy[J]. *Signal Processing*, 2020, 167:107297.
- [15] SHI Xue, LI Chunming. Anatomical knowledge based level set segmentation of cardiac ventricles from MRI[J]. *Magnetic Resonance Imaging*, 2022, 86:135-148.
- [16] LEE H, CODELLA N, CHAM M, et al. Automatic left ventricle segmentation using iterative thresholding and an active contour model with adaptation on short-axis cardiac MRI[J]. *IEEE Transactions on Biomedical Engineering*, 2010, 57(4):905-913.
- [17] FLETT A S, HASLETON J, COOK C, et al. Evaluation of techniques for the quantification of myocardial scar of differing etiology using cardiac magnetic resonance[J]. *JACC: Cardiovascular Imaging*, 2011, 4(2):150-156.
- [18] BERNIER M, JODOIN P M, HUMBERT O, et al. Graph cut-based method for segmenting the left ventricle from MRI or echocardiographic images[J]. *Computerized Medical Imaging and Graphics*, 2017, 58:1-12.
- [19] LI Lei, WU Fuping, YANG Guang, et al. Atrial scar quantification via multi-scale CNN in the graph-cuts framework[J]. *Medical Image Analysis*, 2020, 60:101595.
- [20] BALAFAR M A. Gaussian mixture model based segmentation methods for brain MRI images[J]. *Artificial Intelligence Review*, 2014, 41(3):429-439.
- [21] LIU Jie, ZHUANG Xiahai, WU Lianming, et al. Myocardium segmentation from DE MRI using multicomponent gaussian mixture model and coupled level set[J]. *IEEE Transactions on Biomedical Engineering*, 2017, 64(11):2650-2661.
- [22] DONG Suyu, LUO Gongning, WANG Kuanquan, et al. A combined fully convolutional networks and deformable model for automatic left ventricle segmentation based on 3D echocardiography[J]. *BioMed Research International*, 2018, 2018:1-16.
- [23] CHARTSIAS A, JOYCE T, PAPANASTASIOU G, et al. Factorised spatial representation learning: application in semi-supervised myocardial segmentation[M]//FRANGI A F, SCHNABEL J A, DAVATZIKOS C, et al. *Medical Image Computing and Computer Assisted Intervention—MICCAI 2018*: 11071. Cham: Springer, 2018:490-498.
- [24] ZHANG D, ICKE I, DOGDAS B, et al. A multi-level convolutional LSTM model for the segmentation of left ventricle myocardium in infarcted porcine cine MR images[C]//2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018). Washington: IEEE, 2018:470-473.
- [25] DU Xiuquan, SONG Yuhui, LIU Yueguo, et al. An integrated deep learning framework for joint segmentation of blood pool and myocardium[J]. *Medical Image Analysis*, 2020, 62:101685.
- [26] XIE Liping, SONG Yi, CHEN Qiang. Automatic left ventricle segmentation in short-axis MRI using deep convolutional neural networks and central-line guided level set approach[J]. *Computers in Biology and Medicine*, 2020, 122:103877.
- [27] TRAGAKIS A, KAUL C, MURRAY-SMITH R, et al. The fully convolutional transformer for medical image segmentation [C]//2023 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). Waikoloa: IEEE, 2023:3649-3658.
- [28] KATO S, HOTTA K. Adaptive t-vMF dice loss: an effective expansion of dice loss for medical image segmentation[J]. *Computers in Biology and Medicine*, 2024, 168:107695.
- [29] LI Chunming, HUANG Rui, DING Zhaohua, et al. A level set method for image segmentation in the presence of intensity inhomogeneities with application to MRI[J]. *IEEE Transactions on Image Processing*, 2011, 20(7):2007-2016.
- [30] LIU Y, CAPTUR G, MOON J C, et al. Distance regularized two level sets for segmentation of left and right ventricles from cine-MRI[J]. *Magnetic Resonance Imaging*, 2016, 34(5):699-706.
- [31] WIJNTJES M W A, SATO A, HAYWARD V, et al. Local surface orientation dominates haptic curvature discrimination[J]. *IEEE Transactions on Haptics*, 2009, 2(2):94-102.
- [32] BERNARD O, LALANDE A, ZOTTI C, et al. Deep learning techniques for automatic MRI cardiac multi-structures segmentation and diagnosis: is the problem solved? [J]. *IEEE Transactions on Medical Imaging*, 2018, 37(11):2514-2525.
- [33] HUTTENLOCHER D P, KLANDERMAN G A, RUCKLIDGE W J. Comparing images using the Hausdorff distance[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1993, 15(9):850-863.
- [34] ISENSEE F, JAEGER P F, FULL P M, et al. Automatic cardiac disease assessment on cine-MRI via time-series segmentation and domain specific features[M]//POP M, SERMESANT M, JODOIN P M, et al. *Statistical Atlases and Computational*

- Models of the Heart. ACDC and MMWHS Challenges: Vol. 10663. Cham; Springer, 2018:120-129.
- [35] KHENED M, ALEX V, KRISHNAMURTHI G. Densely connected fully convolutional network for short-axis cardiac cine MR image segmentation and heart diagnosis using random forest[M]//POP M, SERMESANT M, JODOIN P M, et al. Statistical Atlases and Computational Models of the Heart: ACDC and MMWHS Challenges. Cham: Springer, 2018:140-151.
- [36] ZOTTI C, LUO Z, LALANDE A, et al. Convolutional neural network with shape prior applied to cardiac MRI segmentation [J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(3):1119-1128.
- [37] BAUMGARTNER C F, KOCH L M, POLLEFEYS M, et al. An exploration of 2D and 3D deep learning techniques for cardiac MR image segmentation[M]//POP M, SERMESANT M, JODOIN P M, et al. Statistical Atlases and Computational Models of the Heart: ACDC and MMWHS Challenges. Cham: Springer, 2018:111-119.
- [38] WOLTERINK J M, LEINER T, VIERGEVER M A, et al. Automatic segmentation and disease classification using cardiac cine MR images[M]//POP M, SERMESANT M, JODOIN P M, et al. Statistical Atlases and Computational Models of the Heart: ACDC and MMWHS Challenges. Cham: Springer, 2018:101-110.
- [39] PAINCHAUD N, SKANDARANI Y, JUDGE T, et al. Cardiac segmentation with strong anatomical guarantees[J]. IEEE Transactions on Medical Imaging, 2020, 39(11):3703-3713.
- [40] ROHÉ M M, SERMESANT M, PENNEC X. Automatic multi-atlas segmentation of myocardium with SVF-net[M]//POP M, SERMESANT M, JODOIN P M, et al. Statistical Atlases and Computational Models of the Heart: ACDC and MMWHS Challenges. Cham: Springer, 2018:170-177.
- [41] PATRAVALI J, JAIN S, CHILAMKURTHY S. 2D-3D fully convolutional neural networks for cardiac MR segmentation[M]//POP M, SERMESANT M, JODOIN P M, et al. Statistical Atlases and Computational Models of the Heart: ACDC and MMWHS Challenges. Cham: Springer, 2018:130-139.
- [42] GRINIAS E, TZIRITAS G. Fast fully-automatic cardiac segmentation in MRI using MRF model optimization, substructures tracking and B-spline smoothing[M]//POP M, SERMESANT M, JODOIN P M, et al. Statistical Atlases and Computational Models of the Heart: ACDC and MMWHS Challenges. Cham: Springer, 2018:91-100.
- [43] YANG Xin, BIAN Cheng, YU Lequan, et al. Class-balanced deep neural network for automatic ventricular structure segmentation[M]//POP M, SERMESANT M, JODOIN P M, et al. Statistical Atlases and Computational Models of the Heart: ACDC and MMWHS Challenges. Cham: Springer, 2018:152-160.
- [44] LI C, XU C, KONWAR K M, et al. Fast distance preserving level set evolution for medical image segmentation[C]//2006 9th International Conference on Control, Automation, Robotics and Vision. Singapore: IEEE, 2006:1-7.
- [45] GUO F, NG M, GOUBRAN M, et al. Improving cardiac MRI convolutional neural network segmentation on small training datasets and dataset shift: a continuous kernel cut approach[J]. Medical Image Analysis, 2020, 61:101636.
- [46] MA Dongdong, LIAO Qingmin, CHEN Ziqin, et al. Adaptive local-fitting-based active contour model for medical image segmentation[J]. Signal Processing: Image Communication, 2019, 76:201-213.
- [47] RAHMAN M M, MARCULESCU R. Multi-scale hierarchical vision transformer with cascaded attention decoding for medical image segmentation[EB/OL]. (2023-03-29) [2024-08-26]. <https://doi.org/10.48550/arXiv.2303.16892>.
- [48] RAHMAN M M, MARCULESCU R. G-CASCADE: efficient cascaded graph convolutional decoding for 2D medical image segmentation[C]//2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). Waikoloa: IEEE, 2024:7713-7722.
- [49] ZHOU Hong-Yu, GUO Jiansen, ZHANG Yinghao, et al. nnFormer: volumetric medical image segmentation via a 3D transformer[J]. IEEE Transactions on Image Processing, 2023, 32:4036-4045.

(编辑:李艺)