

基于改进水平集模型的心脏图像分割算法

张帅帅¹⁾, 刘瑞霞^{2)✉}, 单珂^{2)✉}, 郭振华³⁾

1) 齐鲁工业大学(山东省科学院)数学与统计学院, 济南 250353 2) 齐鲁工业大学(山东省科学院)山东省人工智能研究院, 济南 250014

3) 浪潮电子信息产业股份有限公司, 济南 250101

✉通信作者, 刘瑞霞, E-mail: liurx@sdas.org; 单珂, E-mail: shank@sdas.org

摘要 近年来, 基于变分水平集方法的心脏医学图像分割在图像处理中得到广泛的应用, 然而, 由于图像灰度不均匀性和梯度下降法中的符号距离函数导致图像在分割中有计算复杂、运算成本较高的问题. 为了解决这些问题, 本文在自适应局部拟合 (Adaptive local fitting, ALF) 模型的基础上修改并加入边缘检测函数, 提出了一种改进的活动轮廓模型, 并与图像分割的快速计算算法——乘子交替方向法 (Alternating direction method of multipliers, ADMM) 相结合来求解水平集方程. 本文提出的新水平集图像分割模型, 包含了图像的邻域信息, 可以更好的解决图像不均匀的问题; 利用传统的梯度下降法来分割图像会有耗时长、计算成本高等问题, 而用 ADMM 算法代替传统算法, 原本复杂的问题可以被拆分成若干个简单的子问题, 逐一解决这些子问题能够更快速并准确地解决整个问题, 进而解决了传统模型存在耗时长、计算复杂、计算成本高的问题. 实验结果表明新模型不仅对灰度不均匀的图像具有较强的鲁棒性, 还具有更高的分割效率和精度.

关键词 图像分割; 活动轮廓模型; 乘子交替方向法; 邻域信息; 变分法

分类号 O1

Research on cardiac image segmentation algorithm based on improved level set modeling

ZHANG Shuaishuai¹⁾, LIU Ruixia^{2)✉}, SHAN Ke^{2)✉}, GUO Zhenhua³⁾

1) School of Mathematics and Statistics, Qilu University of Technology (Shandong Academy of Sciences), Jinan 250353, China

2) Qilu University of Technology (Shandong Academy of Sciences) Shandong Artificial Intelligence Institute, Jinan 250014, China

3) Inspur Electronic Information Industry Co., Ltd., Jinan 250101, China

✉Corresponding author, LIU Ruixia, E-mail: liurx@sdas.org; SHAN Ke, E-mail: shank@sdas.org

ABSTRACT In recent years, cardiac medical image segmentation using the variational level-set method has been widely applied in image processing. However, the uneven grayscale of images and the symbolic distance function in the gradient descent method lead to issues such as computational complexity and high computational cost during segmentation. To address these challenges, this paper introduces modifications to the edge detection function based on the adaptive local fitting model and develops an improved active contour model. This model is combined with fast computational image segmentation algorithm, alternating direction method of multipliers (ADMM), to solve the level-set equations. The proposed approach, called the neighbor level set minimized with the ADMM method, incorporates a data fitting term that leverages neighbor region information for enhanced medical image segmentation. The introduction of the edge detection function smooths homogeneous regions and enhances edge information. The proposed model effectively addresses common issues in medical image segmentation, such as intensity inhomogeneity, and produces accurate and fast

收稿日期: 2024-09-12

基金项目: 山东省自然科学基金联合基金重点资助项目 (ZR2023LHZ009); 山东省重点研发计划 (科技型中小企业创新能力提升工程) 资助项目 (2024TSGC0216)

results. The problem of inaccurate segmentation is resolved by introducing a new level set active contour model that incorporates neighborhood information to precisely segment the region of interest. The model mitigates the impact of grayscale variations by leveraging local contextual information, which improves segmentation accuracy. The main purpose of this paper is to propose a new model for medical image segmentation based on a neighborhood-level set framework and the ADMM method. Our energy function comprises three terms: the data fitting term, the length term, and the regularization term, which together balance the fitting energy and ensure a smooth boundary. The ADMM method is then employed to minimize the energy function and achieve the final segmentation result. Traditional segmentation methods, such as gradient descent, are often time-consuming, computationally complex, and costly. In contrast, the proposed approach breaks down a complex problem into several simpler sub-problems that can be solved sequentially to enable faster and more accurate resolution using the ADMM algorithm. This approach also effectively addresses the challenges posed by level-set equations. Experimental results demonstrate that the new model is not only robust to uneven grayscale images but also achieves higher segmentation efficiency and accuracy. The model demonstrates the ability to quickly generate curves and accurately represent the contours of cardiac images. To evaluate its effectiveness, we conduct comparative experiments using the Dice coefficient and Jaccard index as evaluation metrics. The experimental results show that our proposed model consistently achieves higher Dice coefficients and Jaccard indices compared with other existing models. This achievement highlights its superior segmentation performance. In conclusion, our improved level-set contour model, combined with the fast computational ADMM algorithm, provides an effective solution to the challenges commonly encountered in medical image segmentation. It offers significant improvements in accuracy, computational efficiency, and cost-effectiveness.

KEY WORDS image segmentation; active profile model; multiplier alternating direction method; neighborhood information; calculus of variations

随着医疗进步发展, 图像分割在医学方面有着越来越重要的作用^[1], 原来的图像分割主要是依靠人工来分割, 这不仅耗费了大量的时间, 也对医生的专业技术有一定的要求, 随着科技的进步, 图像分割方法有很多, 例如阈值分割方法^[2-3]、深度学习法^[4-11]、变分水平集法^[12-13]等, 这些方法相比于人工方法来说所需时间更短, 且不需要耗费很多财力物力, 其中, 水平集方法受到了研究者的广泛欢迎。

阈值法是一种高效、简单的分割方法, 适用于灰度对比度明显、背景简单的图像。它具有计算快速、实现容易等优点, 尤其适用于实时应用。但是, 在处理噪声较多、灰度分布复杂或具有多个目标区域的图像时, 阈值法的表现较差。深度学习方法在图像分割中的应用近年来取得了显著进展, 尤其是在医学图像处理、自动驾驶、遥感图像等领域。深度学习的图像分割方法如 LSBC、RSF, 特别是基于卷积神经网络(CNN)和其变种(如 U-Net+CE、U-Net+DIC、ACLEPF 等)的模型, 展现出了强大的能力。然而, 这些方法也有一些优缺点, 如对数据依赖、计算资源高和训练时间长。1988 年, 由 Kass 等^[14]提出了第一个水平集活动轮廓模型, 也称“蛇”模型, 活动轮廓模型的思想是通过定义一个能量函数, 使得轮廓能够根据图像中的特征自动演化和适应, 从而实现感兴趣区域的分割。它依赖于图像边缘信息^[15-16]或者图像区域信息^[17-18]

来进行轮廓的检测与分割。

在 2002 年, 由 Chan 和 Vese 提出了经典的 Chan-Vese(CV)模型^[19], 该模型通过全局最小化能量函数来实现分割, 但是 CV 模型有计算复杂度高、参数选择困难等问题, 为了克服上述出现的问题, Li 等^[20]提出了局部二值拟合(Local binary fitting, LBF)模型。由于 LBF 模型对初始轮廓敏感且鲁棒性较低, Ding 等^[21]提出了一种利用局部预拟合能量(Local pre-fitting energy, LPF)的主动轮廓模型, 该模型增强了局部特征的利用, 同时也增强了鲁棒性, 但是该模型在分割多目标时困难, 参数的选择和对低对比度的噪声处理不理想, 为此 Ding 等^[22]将区域可扩展拟合和优化 LoG(Laplacian of Gaussian energy)能量相结合, 提出了一种活动轮廓模型(LoGRSF), 该模型主要利用局部区域内的像素信息进行二值拟合, 实现图像分割, 对有复杂纹理和弱边缘的图像能够有效的提取目标函数并进行分割, 分割效率得到提升。与 LBF 模型相似的局部图像拟合(Local image fitting, LIF)模型^[23]主要利用原图像和拟合图像的差值推动轮廓演化, 该模型有较强的适应性且分割精度也到了提升, 但对初始位置依赖, 对有复杂背景或者重叠目标难以处理。Ma 等^[24]提出了一种自适应局部拟合(Adaptive local fitting, ALF)模型, 该模型不仅有 LIF 模型的优点且解决了其具有的问题, 但其在大规模图像

上计算效率较低且适应性仍然有限. 与 ALF 模型相比, Li 等^[25]提出的区域图像分割算法 (Local intensity clustering, LIC) 模型, 该模型可以对初始轮廓有更好的鲁棒性且适应性强. 随着研究者的不断研究, 对于有极端高噪声和灰度不均匀的图像, 宗静静等^[26]提出一种混合活动轮廓模型, 结合了区域可伸缩模型和最大似然比分类准则, 提高了分割的鲁棒性和准确性, 实现了灰度异质图像的高质量分割. 在 2022 年, Yang 等^[27]将水平集进化 (Level set evolution, LSE) 模型与区域和边缘协同水平集 (Region and edge synergetic level set, RESLS) 模型相结合, 提出了一种新的基于边缘和区域的混合活动轮廓模型, 该模型因为同时考虑到了图像的全局信息和局部信息, 可以对噪声和灰度不均匀的图像有较好的图像分割效果. 为了解决图像因纹理和噪声造成的分割不精确的问题, Sajadi 等^[28]提出了一种局部二值模糊模型和 CV 模型相结合的算法, 该算法不仅对现存模型的局限问题和纹理复杂的图像有较好的分割效果. Wang 等^[29]充分利用图像中的小区域灰度信息, 提出了一种局部预分段拟合偏置校正模型, 该模型可以使初始轮廓准确定位感兴趣区域.

水平集方法分割模型虽有诸多优点, 但是其计算效率低, 耗时长的问题一直存在. 在 1976 年, Gabay 和 Mercier 提出了 ADMM (Alternating direction method of multipliers) 方法来求解凸优化问题的方法; 在 2011 年, 该算法因可用来求分布式凸优化一类的问题才受到关注, ADMM 的主要优势在于它可以将一个复杂的问题转化为几个简单的子问题, 这使其在机器学习^[30]、信号处理^[31]、传染预测^[32]、计算机图像^[33]等方面得到了广泛应用.

为了提高水平集模型的分割准确率, 本文提出了一种改进优化的水平集模型和乘子交替方向法相结合来分割心脏图像的方法. 该方法引入了边缘检测函数以准确检测目标函数的边缘; 除了在优化的模型中利用数据项和长度项来平衡拟合方程, 还加入正则项使模型能够在噪声、模糊等复杂情况下更有效地分割图像. 用 ADMM 方法代替梯度下降法求解水平集模型, 将模型划分为几个简单的子问题, 通过求解几个子问题进而间接的解决原问题. 解决了梯度下降法存在噪声影响下分割结果不准确等问题, 此外, ADMM 方法还可以在非凸的情况下分割模型. 通过多次实验验证, 模型表现出较强的鲁棒性, 能够在复杂场景中有效捕捉目标边界, 实现精确分割. 本文方法在处理噪

声干扰和边界模糊等问题上具有优势, 为图像分割领域提供了可靠的技术支持和应用前景.

1 背景

LBF 模型被认为是经典的图像分割模型之一, 它和 CV 模型不同之处在于该模型是以局部区域来推动曲线演化的分割模型, 相较于 CV 模型, 该模型有更强的鲁棒性. LBF 模型:

$$E^{\text{LBF}} = \int_{\text{in}(C)} k_1 \left(\int K_{\sigma}(x-y) |I(y) - f_1(x)|^2 H_{\varepsilon}(\phi(y)) dy \right) dx + v \int \delta_{\varepsilon}(\phi(y)) |\nabla \phi(x)| dx + \int_{\text{out}(C)} k_2 \left(\int K_{\sigma}(x-y) |I(y) - f_2(x)|^2 (1 - H_{\varepsilon}(\phi(y))) dy \right) dx + \mu \int |\nabla \phi(x) - 1|^2 dx \quad (1)$$

式中, E 代表能量函数, f 代表可微函数, ϕ 代表水平集函数, K 是加权函数, f_1 和 f_2 是拟合 x 点附近图像强度的两个函数, 将 x 点称为上述积分的中心点, C 是曲线轮廓, $I(y)$ 代表图像 I 在 y 点像素值, σ 代表比例参数且大于 0, $\nabla \phi$ 代表水平集函数 ϕ 的梯度算子, ε 是一个参数, 控制着平滑程度, k_1 , k_2 , v , μ 是每一项的权重且取正数.

$$w(s) = \begin{cases} \frac{1}{a} e^{-|s|^2/2\varepsilon^2}, & |s| < \Theta \\ 0, & \text{else} \end{cases} \quad (2)$$

式中, Θ 是本区域半径, a 是常数, 满足 $\int w(s) ds = 1$, K_{σ} 是高斯核函数.

$$K_{\sigma} = \frac{1}{2\pi\sigma^2} e^{-|x|/2\sigma^2} \quad (3)$$

$$H_{\varepsilon}(x) = \frac{1}{2} + \frac{1}{\pi} \arctan\left(\frac{x}{\varepsilon}\right) \quad (4)$$

Ma 等^[24]提出的 ALF 模型可以鲁棒的准确的分割医学图像, 但是该模型有计算度复杂, 消耗时间长的问题, 该模型的能量模型如下:

$$E = \sum_{i=1}^2 \lambda_i \int \int w^x(x-y) |I(x) - f_i(x) + B(x)C(y)|^2 M_i(\phi(x)) dy dx + \alpha \int |\nabla H(\phi(x))| dx + \frac{\beta}{2} \int (|\nabla \phi(x) - 1|^2) dx \quad (5)$$

其中, λ_i 、 α 和 β 是正数, 代表每一项的权重, $B(x)$ $C(y)$ 是偏置场函数. $M_1(\phi(x)) = H(\phi(x))$, $M_2(\phi(x)) = 1 - H(\phi(x))$, $w_{i,j}^x = \frac{1}{1 + \sigma_{i,j}^2}$.

ALF 模型可以更好的分割心脏图像, 但在分割过程中容易受到噪声和其他组织的干扰, 导致分割不准确. 为了解上述存在的问题, 本文引入了边缘检测函数, 利用邻域灰度值等信息建立了基

于水平集方法的分割模型, 该模型对噪声和灰度值不均匀的图像具有更好的包容性.

2 提出模型

医学图像中因为存在噪声和图像灰度不均匀等问题, 造成图像分割精度不高、结果不准确. 为了解决这些问题, 本文提出的模型主要利用邻域信息来分割感兴趣区域, 采用乘子交替方向法 (ADMM) 来最小化能量方程, 把能量方程分割为几个子问题, 通过解决这些子问题来近似解决原来的方程.

2.1 新的能量方程

设 I 是一幅灰度图像, 图像域为 $\Omega \rightarrow \mathbf{R}$, 本论文提出的模型为:

$$E = \int_{\Omega} (\eta_1 H(\phi(x)) - \eta_2 (1 - H(\phi(x))) + g |\nabla \phi| + \frac{\beta}{2} (|\nabla \phi| - 1)^2) dx \quad (6)$$

其中, g 是边缘检测函数, $g = \frac{1}{1 + |\nabla K_{\sigma} * I|^2}$. Ω , β 是正数, η_1 、 η_2 分别为:

$$\begin{cases} \eta_1 = \lambda_1 \int |I(x) - (f_1(x) + B(x)C(y))|^2 dy \\ \eta_2 = \lambda_2 \int |I(x) - (f_2(x) + B(x)C(y))|^2 dy \end{cases} \quad (7)$$

2.2 利用 ADMM 最小化能量方程

公式 (6) 的约束问题如下:

$\min \int_{\Omega} \eta_1 v - \eta_2 (1 - v) + g |p| + (|p| - 1)^2$, 令 $v = H(\phi(x))$, $\phi = \phi$, $p = \nabla \phi$. 由原变量和对偶变量构成的增广拉格朗日函数为:

$$L(\phi, \varphi, v, p; \wedge) = \int \eta_1 v - \eta_2 (1 - v) + g |p| + (|p| - 1)^2 + (\lambda_{\varphi}, \varphi - \phi) + \frac{r_{\varphi}}{2} (\varphi - \phi)^2 + (\lambda_u, v - H(\phi)) + \frac{r_v}{2} (v - H(\phi))^2 + (\lambda_p, p - \nabla \phi) + \frac{r_p}{2} (p - \nabla \phi)^2 \quad (8)$$

其中 $\wedge = (\lambda_{\varphi}, \lambda_u, \lambda_p)$ 是拉格朗日算子, r_{φ}, r_v, r_p 是常数. 交替方向乘子法:

$$\begin{cases} \phi^{k+1} = \arg \min L(\phi^k, v^k, \varphi^k, p^k; \wedge^k) \\ v^{k+1} = \arg \min L(\phi^{k+1}, v^k, \varphi^k, p^k; \wedge^k) \\ \varphi^{k+1} = \arg \min L(\phi^{k+1}, v^{k+1}, \varphi^k, p^k; \wedge^k) \\ p^{k+1} = \arg \min L(\phi^{k+1}, v^{k+1}, \varphi^{k+1}, p^k; \wedge^k) \end{cases} \quad (9)$$

2.2.1 关于子问题 ϕ 的解

从公式中 (8) 提取相关部分并化简可得:

$$\min \left(\int \left(\frac{r_{\varphi}}{2} \left(\phi - \left(\varphi + \frac{\lambda_{\varphi}}{r_{\varphi}} \right) \right)^2 + \frac{r_p}{2} \left| \nabla \phi - \left(p + \frac{\lambda_p}{r_p} \right) \right|^2 \right) \right) \quad (10)$$

欧拉-拉格朗日方程为:

$$(r_{\varphi} - r_p \Delta) \phi = -r_p \operatorname{div} p - \operatorname{div} \lambda_p + r_{\varphi} \left(\varphi + \frac{\lambda_{\varphi}}{r_{\varphi}} \right) \quad (11)$$

利用快速傅里叶变换求公式:

$$\phi = \Gamma^{-1} \left(\frac{-\Gamma(D) \Gamma(r_p p + \lambda_p) + r_{\varphi} \Gamma \left(\varphi + \frac{\lambda_{\varphi}}{r_{\varphi}} \right)}{r_{\varphi} - r_p \Gamma(\Delta)} \right) \quad (12)$$

其中, Γ 是快速傅里叶变换, Γ^{-1} 是反傅里叶变换; D 和 Δ 分别为一阶和二阶差分算子, 表达式为: $D = \operatorname{div}(\cdot) = D_x(\cdot) + D_y(\cdot)$, $\Delta = D_x^+ D_x^+ + D_y^+ D_y^+$.

2.2.2 关于子问题 v 的解

关于 v 的子问题表达式如下:

$$\min \left(\int \left(\frac{r_v}{2} \left(v - \left(H(\varphi) + \frac{\lambda_v}{r_v} \right) \right)^2 + \eta_1 v - \eta_2 (1 - v) \right) \right) \quad (13)$$

上式可以写为:

$$\begin{cases} F(v) = \frac{r_v}{2} (v - q)^2 + \eta_1 v - \eta_2 (1 - v) \\ q = H(\phi) + \frac{\lambda_v}{r_v} \end{cases} \quad (14)$$

其中, $v = H(\phi(x))$.

公式 (14) 利用牛顿迭代法求解公式如下:

$$v^{k+1} = v^k - \frac{F(v)^'}{F(v)''} \quad (15)$$

$F(v)'$ 和 $F(v)''$ 分别为 $F(v)$ 一阶导数和二阶导数, 表达式如下:

$$\begin{cases} F(v)' = r_v (v - q) + r_1 + r_2 \\ F(v)'' = r_v \end{cases} \quad (16)$$

2.2.3 关于子问题 φ 的解

对 φ 的求解本文采用同样的方法, 过程如下:

$$\min \left(\int \left(\frac{r_{\varphi}}{2} \left(\varphi - \left(\phi + \frac{\lambda_{\varphi}}{r_{\varphi}} \right) \right)^2 + \frac{r_v}{2} \left(H(\varphi) - \left(v + \frac{\lambda_v}{r_v} \right) \right)^2 \right) \right) \quad (17)$$

上式可以写为:

$$\begin{cases} F(\varphi) = \frac{r_{\varphi}}{2} (\varphi - z)^2 + \frac{r_v}{2} (H(\varphi) - u)^2 \\ z = \phi + \frac{\lambda_{\varphi}}{r_{\varphi}} \\ u' = v + \frac{\lambda_v}{r_v} \end{cases} \quad (18)$$

利用牛顿迭代法求解公式:

$$\varphi^{k+1} = \varphi^k - \frac{F(\varphi)^'}{F(\varphi)''} \quad (19)$$

其中, 一阶导数和二阶导数表达式如下:

$$\begin{cases} F'(\varphi) = r_{\varphi} (\varphi - z) + r_v (H(\varphi) - u) \\ F''(\varphi) = r_{\varphi} \end{cases} \quad (20)$$

2.2.4 关于子问题 p 的解

对子问题 p 的问题, 本文采用梯度下降法来求解, 首先在公式中提取相关部分并争利化简可得:

$$\min \left(\int \left((|p|-1)^2 + g|p| + \frac{r_p}{2} \left| p - \left(\nabla \phi + \frac{\lambda_p}{r_p} \right) \right|^2 \right) dx \right) \quad (21)$$

然后利用梯度下降法求解 p :

1) 初始化

$$p = p_0 = 0 \quad (22)$$

2) 计算当前目标函数值和梯度

$$\text{目标函数: } f(p) = (|p|-1)^2 + g|p| + \frac{r_p}{2} \left| p - \left(\nabla \phi + \frac{\lambda_p}{r_p} \right) \right|^2 \quad (23)$$

$$\begin{aligned} \text{梯度函数: } \text{grad_}f = & 2(|p|-1) \text{div} \frac{p}{|\nabla p|} + g \times \text{div} \frac{p}{|\nabla p|} + \\ & r_p \left| p - \left(\nabla \phi + \frac{\lambda_p}{r_p} \right) \right| \text{div} \frac{p}{|\nabla p|} \end{aligned} \quad (24)$$

3) 更新 p

$$p_{k+1} = p_k - \alpha \times \text{grad_}f \quad (25)$$

式中, α 表示变量, 用于调节 $\text{grad_}f$ 在计算是对 p_{k+1} 的影响.

模型被分解为四个子问题, 其中子问题 v 和子问题 ϕ 本文采用同样的牛顿迭代方法来求解; 子问题 ϕ 本文采用快速傅里叶变换来求解; 子问题 p 采

用梯度下降法求解. 为验证所提方法的性能, 本文通过实验对图像分割进行验证. 图 1 是本文的流程.

3 实验结果

所有实验都是在一台机器上进行的, 所使用的数据集来自国际医学图像计算和计算机辅助干预 (MICCAI) 会议 2017 自动心脏诊断挑战赛 (Automatic cardiac diagnosis challenge, ACDC) 数据集和 Sunnybrook cardiac MRI 数据集, 对数据集进行了可视化, 并依据数据集提供的左心室内外膜坐标文本文件, 提取和制作了相应了标签图像. 在本文的实验中, 本文采用的评价标准是 Dice 系数、Jaccard(J)、Hausdorff distance(HD)、Sensitivity (Sen)、Accuracy(Acc)、平均绝对距离 (MAD).

$$\text{Dice}(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (26)$$

$$\text{Acc} = \frac{\text{TN} + \text{TP}}{\text{TN} + \text{TP} + \text{FN} + \text{FP}} \quad (27)$$

$$\text{Sen} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (28)$$

$$\text{MAD} = \frac{1}{N} \sum_{i=1}^N |d(m_i, a_i)| \quad (29)$$

其中, A 代表不同模型分割的目标区域, B 代表人工分割的期望分割结果. TN、TP、FN、FP 分别为




图 1 本文所提方法的流程图
Fig.1 Flowchart of the proposed method

真阴性、真阳性、假阴性、假阳性, d 表示数据中第 m_i 的值和数据中值 a_i 的距离, 它们基本的统计指标, 可以使用预期的分割结果和真实值进行评估.

用提出的模型分割了图片如图 2, 第一行至第

三行图分别为整个心脏、舒张状态下的左心脏和收缩期的左心脏分割结果. 从分割结果来看, 本文的模型不仅对初始轮廓具有较强的鲁棒性, 而且分割结果的精度也非常高. 表 1 中列出了收缩期的左心脏分割有关实验数据 (left14).




图 2 心脏图像分割. (a) 原图; (b) 初始轮廓; (c) 分割后图像; (d) 本文模型分割结果

Fig.2 Heart image segmentation: (a) original image; (b) initial contour; (c) segmented image; (d) segmentation result using our model

表 1 心脏图像分割的实验评比数据

Table 1 Experimental evaluation data for cardiac image segmentation

Image	Dice	J	MAD	Sen	Acc
Left55	0.98	0.97	0.03	0.97	0.97
Left58	0.98	0.96	0.04	0.96	0.96
Left14	0.97	0.96	0.02	0.97	0.97

图 3 是心脏磁共振图像来展示 CV 模型、ALF 模型、ACLEPF 模型和本文所提模型的分割结果相比较. 首先用简单的图像来展示本文提出的模型和其他三种模型的分割性能, 如图 3 第一行图所示, 放大了感兴趣区域以便更好地观察分割结果, 可以看出本文模型和 CV 模型分割结果较好, 但是本文模型的分割结果更为平滑. 图 3 第二行和第三行图分别是左心脏和整个心脏图像的分割结果, CV 模型虽然分割结果比较准确, 但是图像边缘结果不平滑; ALF 模型的分割结果明显不准确; ACLEPF 模型的分割图像曲线轮廓不演化, 分割效果最差; 深度模型 U-Net+CE 和 U-Net+DIC 分割结果出现多分割或者不能准确分割, 分割效果较差; 本文所提模型的分割结果比较准确且边缘

平滑. 有关左心脏分割的实验数据在表 1 的中列出 (left55).

图 4 是心脏 MRI 数据集经过 300 次的迭代不能准确分割图像; LGD 型最终的分割结果可以明显看出轮廓演化不准确, 最后分割结果包含了多余的部分, 且有一部分没被包括; 本文所提模型的分割结果不仅准确, 而且分割边缘光滑, 得到了更多的真实边界. 表 1 中列出了分割结果的评价标准 (left58). 表 2 列出了本文的实验数据和其他模型的 Dice 和 HD 比较, 本文提出的方法 Dice 值均高于现有模型, HD 值均低于现有模型, 从而可以看出本文的分割效果好于现有模型.

图 5 是本文方法和近年来基于深度学习模型 (ViT-FRD、RAU-Net、TMS-Net) 分割方法的对比,




图 3 不同模型分割对比. (a) 原图; (b) CV 模型; (c) ALF 模型; (d) ACLEPF 模型; (e) U-Net+CE 模型; (f) U-Net+DICE 模型; (g) 本文模型

Fig.3 Segmentation and comparison of different models: (a) original image; (b) segmentation result of the CV model; (c) segmentation result of the ALF model; (d) segmentation result of the ACLEPF model; (e) segmentation result of the U-NET + CE model; (f) segmentation result of the U-NET + DICE model; (g) segmentation result of our model




图 4 不同模型分割结果. (a) 原图; (b) ALF 模型; (c) LGD 模型; (d) ACLEPF 模型; (e) 本文模型

Fig.4 Segmentation results of different models: (a) original image; (b) segmentation result of ALF model; (c) segmentation result of LGD model; (d) segmentation result of ACLEPF model; (e) segmentation result of our model

表 2 不同模型下的 Dice 和 HD 比较

Table 2 Comparison of Dice and HD under different models		
Model	Dice	HD
LBF	0.11	124.62
CV	0.84	107.3
LoGRSF	0.83	9.57
U-Net+CE	0.89	4.05
U-Net+DIC	0.88	3.95
ViT-FRD	0.87	3.86
RAU-Net	0.85	3.94
TMS-Net	0.86	3.75
This work	0.89	3.13

第一行和第三行图是对不同状态下整个心脏的分割,第二行图是对左心室的分割.表 2 中列出本文所提方法和深度学习方法的对比数据,可以看出本文所提方法分割更加准确,在处理细节方面有更好的优势.

用本文提出的方法对不同数据集的心脏图像进行分割,如图 6 所示,第一行和第二行图采用

ACDC 数据集,第三行和第四行图采用 Sunnybrook cardiac MRI 数据集,其中第一、二、四行图是对不同状态下左心室的分割,第三行图是对整个心脏的分割.用本文提出的方法进行分割,可以明显看出,本文提出的模型可以较准确的分割心脏图像,对初始轮廓具有较强的鲁棒性.

4 结论

本文提出了一种新的图像分割算法模型,在传统的 ALF 模型基础上优化并引入边缘检测函数,帮助模型增强了边缘信息,更精确地捕捉到图像边界信息,从而在处理复杂场景时具有更强的表现力.这一改进使得新模型在分割含有噪声、边缘模糊等图像时,有较强的鲁棒性,可以精准分割图像.传统算法通常面噪声干扰下分割结果不够精确的问题,ADMM 方法能够有效应对这些挑战,把原始问题拆分为几个简单的子问题,通过逐步求解这些子问题,从而间接解决原问题.此外,ADMM 方法还可以在非凸情况下对模型进行分割,表现出更强的适应性和鲁棒性.实验结果表明,本文提




图5 本文方法和深度学习方法对比. (a) 原图; (b) ViT-FRD 模型; (c) RAU-Net 模型; (d) TMS-Net 模型; (e) 本文方法

Fig.5 Comparison between the proposed method and deep learning methods: (a) original image; (b) segmentation result of the ViT-FRD model; (c) segmentation result of the RAU-Net model; (d) segmentation result of the TMS-Net model; (e) segmentation result of the proposed method




图6 不同数据集中的心脏图像分割. (a) 原图; (b) 初始轮廓模型; (c) 分割后的图像; (d) 简化后的图像

Fig.6 Cardiac image segmentation across different datasets: (a) original image; (b) initial outline model of the different images; (c) segmented image; (d) simplified image

出的模型在分割含有噪声和偏差的图像时,展现出优异的性能;与其他方法相比,该模型能够更有效地应对图像中的噪声干扰,从而提升分割的精度,其良好的鲁棒性使得模型在复杂环境下依然

能够保持稳定的表现.

参 考 文 献

[1] Ma B Y, Jiang S F, Yin D, et al. Image segmentation metric and its

- application in the analysis of microscopic image. *Chin J Eng*, 2021, 43(1): 137
(马博渊, 姜淑芳, 尹豆, 等. 图像分割评估方法在显微图像分析中的应用. 工程科学学报, 2021, 43(1): 137)
- [2] Yang Y, Zhao X, Huang M, et al. Multispectral image based germination detection of potato by using supervised multiple threshold segmentation model and Canny edge detector. *Comput Electron Agric*, 2021, 182: 106041
 - [3] Huo F C, Sun X T, Ren W J. Multilevel image threshold segmentation using an improved Bloch quantum artificial bee colony algorithm. *Multimedia Tools Appl*, 2020, 79(3): 2447
 - [4] Liu H X, Fang J X, Zhang Z J, et al. A novel active contour model guided by global and local signed energy-based pressure force. *IEEE Access*, 2020, 8: 59412
 - [5] Yang Y Y, Feng C, Wang R F. Automatic segmentation model combining U-Net and level set method for medical images. *Expert Syst Appl*, 2020, 153: 113419
 - [6] Yang Y Y, Shu X, Wang R F, et al. Parallelizable and robust image segmentation model based on the shape prior information. *Appl Math Modell*, 2020, 83: 357
 - [7] Wang L, He L, Mishra A, et al. Active contours driven by local Gaussian distribution fitting energy. *Signal Process*, 2009, 89(12): 2435
 - [8] Cong M, Wu T, Liu D, et al. Prostate MR/TRUS image segmentation and registration methods based on supervised learning. *Chin J Eng*, 2020, 42(10): 1362
(丛明, 吴童, 刘冬, 等. 基于监督学习的前列腺 MR/TRUS 图像分割和配准方法. 工程科学学报, 2020, 42(10): 1362)
 - [9] Fan C Y, Su Q, Xiao Z F, et al. ViT-FRD: A vision transformer model for cardiac MRI image segmentation based on feature recombination distillation. *IEEE Access*, 2023, 11: 129763
 - [10] Ma J, Li W F. Efficient image segmentation of cardiac conditions after basketball using a deep neural network. *Electronics*, 2023, 12(2): 466
 - [11] Uslu F, Bharath A A. TMS-Net: A segmentation network coupled with a Run-time quality control method for robust cardiac image segmentation. *Comput Biol Med*, 2023, 152: 106422
 - [12] Yang Y J, Zhong Q X, Duan Y P, et al. A weighted bounded Hessian variational model for image labeling and segmentation. *Signal Process*, 2020, 173: 107564
 - [13] Ni K, Wu Y Q, Han B. Segmentation of metallographic images based on improved CV model. *Chin J Eng*, 2017, 39(12): 1866
(倪康, 吴一全, 韩斌. 基于改进 CV 模型的金相图像分割. 工程科学学报, 2017, 39(12): 1866)
 - [14] Kass M, Witkin A, Terzopoulos D. Snakes: active contour models. *Int J Comput Vision*, 1988, 1(4): 321
 - [15] Lu X D, Zhou J. Applications of evolutionary programming in Markov random field to IR image segmentation // 2008 *IEEE/ASME International Conference on Advanced Intelligent Mechatronics*. Xi'an, 2008: 1082
 - [16] Shrivakshan G T, Chandrasekar C. A comparison of various edge detection techniques used in image processing. *Int J Comput Sci Issues*, 2012, 9(5): 269
 - [17] Zhou Y, Starkey J, Mansinha L. Segmentation of petrographic images by integrating edge detection and region growing. *Comput Geosci*, 2004, 30(8): 817
 - [18] Yau H T, Lin Y K, Tsou L S, et al. An adaptive region growing method to segment inferior alveolar nerve canal from 3D medical images for dental implant surgery. *Comput Aided Des Applic*, 2008, 5(5): 743
 - [19] Vese L A, Chan T F. A multiphase level set framework for image segmentation using the Mumford and Shah model. *Int J Comput Vision*, 2002, 50(3): 271
 - [20] Li C M, Kao C Y, Gore J C, et al. Implicit active contours driven by local binary fitting energy // 2007 *IEEE Conference on Computer Vision and Pattern Recognition*. Minneapolis, 2007: 1
 - [21] Ding K Y, Xiao L F, Weng G R. Active contours driven by region-scalable fitting and optimized Laplacian of Gaussian energy for image segmentation. *Signal Process*, 2017, 134: 224
 - [22] Ding K Y, Xiao L F, Weng G R. Active contours driven by local pre-fitting energy for fast image segmentation. *Pattern Recognit Lett*, 2018, 104: 29
 - [23] Zhang K H, Song H H, Zhang L. Active contours driven by local image fitting energy. *Pattern Recognit*, 2010, 43(4): 1199
 - [24] Ma D D, Liao Q M, Chen Z Q, et al. Adaptive local-fitting-based active contour model for medical image segmentation. *Signal Process Image Commun*, 2019, 76: 201
 - [25] Li C M, Xu C Y, Anderson A W, et al. MRI tissue classification and bias field estimation based on coherent local intensity clustering: a unified energy minimization framework // *International Conference on Information Processing in Medical Imaging*. Williamsburg, 2009
 - [26] Zong J J, Qiu T S, Zhu G W. A PET-CT lung tumor segmentation method based on active contour model. *J Electron Inf Technol*, 2021, 43(12): 3496
(宗静静, 邱天爽, 朱广文. 一种基于活动轮廓模型的 PET-CT 肺肿瘤分割方法. 电子与信息学报, 2021, 43(12): 3496)
 - [27] Yang Y Y, Hou X Y, Ren H L. Efficient active contour model for medical image segmentation and correction based on edge and region information. *Expert Syst Appl*, 2022, 194: 116436
 - [28] Sajadi M, Tavakoli M B, Setoudeh F, et al. A novel image segmentation utilizing FUZZY-based LBP and active contour model. *The Imaging Sci J*, 2022, 70(3): 139
 - [29] Wang G N, Zhang F Z, Chen Y Y, et al. An active contour model based on local pre-piecewise fitting bias corrections for fast and accurate segmentation. *IEEE Trans Instrum Meas*, 2023, 72: 1
 - [30] Wang J X, Yu F X, Chen X, et al. Admm for efficient deep learning with global convergence // *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Anchorage, 2019: 111
 - [31] Basit A, Wang W Q, Wali S, et al. Transmit beamspace design for FDA-MIMO radar with alternating direction method of multipliers. *Signal Process*, 2021, 180: 107832
 - [32] Zhang Y, Cheung W K, Liu J M. A unified framework for epidemic prediction based on poisson regression. *IEEE Trans Knowl Data Eng*, 2015, 27(11): 2878
 - [33] Zhang J Y, Peng Y, Ouyang W Q, et al. Accelerating ADMM for efficient simulation and optimization. *ACM Trans Graphics*, 2019, 38(6): 163