

一种新的舌癌图像快速自动分割方法

陈之锋¹, 邓旋², 卢振泰²

1. 南方医科大学南方医院口腔科, 广东 广州 510515; 2. 南方医科大学生物医学工程学院, 广东 广州 510515

【摘要】目的:研究一种新的舌癌图像自动分割算法以实现舌癌肿瘤的快速准确分割。**方法:**通过引入一种基于局部均方差的自适应尺度算子实现演化曲线在演化过程中的自动调整,从而更高效地向真实目标边界运动,并且克服舌癌肿瘤图像中目标边界不清和图像灰度不均匀等不良因素带来的影响。此外,为加快曲线的收敛速度,本文提出了一种新的能量项评估演化曲线轮廓内部和轮廓外部区域灰度的分布差异,以此引导曲线自适应地调整演化速度,减少完成分割任务所需的迭代次数。**结果:**使用本方法对22幅舌癌肿瘤MRI图像进行分割,分割结果与真实结果之间的重叠率Dice值为0.82,豪斯多夫距离HD值为1.732 mm。**结论:**将本文算法与其它现有的几种活动轮廓模型进行定性和定量对比分析,实验结果表明本文算法在对细节及弱边缘灰度的处理上表现更加优异,可用于舌癌肿瘤的精确定割,为临床分析提供辅助信息。

【关键词】舌癌;图像分割;局部均方差;自适应尺度;活动轮廓模型

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2020)08-1022-08

A new and fast method for automatic tongue cancer image segmentation

CHEN Zhifeng¹, DENG Xuan², LU Zhentai²

1. Department of Stomatology, Nanfang Hospital, Southern Medical University, Guangzhou 510515, China; 2. School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China

Abstract: Objective To develop a novel method for automatic tongue cancer image segmentation, thereby realizing the quick and accurate segmentation of tongue tumor. **Methods** An adaptive scaling operator based on local mean-square error was introduced to realize the automatic adjustment of the evolution curve during the evolution process, thus making the curve move more efficiently to the real target boundary and overcoming the effects of bad factors such as unclear target boundary, edge blur and uneven gray level in tongue cancer image. In addition, in order to accelerate the convergence speed of the curve, a new energy term was proposed to evaluate the intensity distribution difference between the inner and outer regions of the evolution curve contour, so as to guide the curve to adjust the evolution speed adaptively and reduce the number of iterations required to complete the segmentation task. **Results** Twenty-two MRI images of tongue cancer were segmented by the proposed method. The overlap ratio (Dice value) between the segmented results and the real results was 0.82, and the Hausdorff distance (HD) was 1.732 mm. **Conclusion** The qualitative and quantitative comparisons between the proposed method and other existing active contour models reveals that the proposed algorithm is advantageous in the processing of details and weak edge gray level, and that it can be used for accurate segmentation of tongue tumor, thereby providing auxiliary information for clinical analysis.

Keywords: tongue cancer; image segmentation; local mean-square error; adaptive scale; active contour model

前言

舌癌在世界范围内已成为一种日益普遍的疾病,死亡率很高。目前舌癌的最佳治疗方法是切除足够的

肿瘤边缘并立即重建^[1-3]。医生主要根据舌癌图像的形态学特征进行手术切除,因此准确地分割肿瘤区域对于舌癌的临床诊断和治疗评估具有重要意义。手工分割病变区域是一个耗时、繁琐的过程,它的成功与否很大程度上取决于用户的使用体验,且临床上舌癌图像往往灰度不均匀,肿瘤区域的边界模糊,且与周边灰度相差较小,存在大量灰度分布不均匀的区域。这给医生在实际选取肿瘤区域和进一步对病灶区域进行病理分析带来了巨大挑战。在过去的工作中,许多研究者

【收稿日期】2020-05-04

【基金项目】广东省自然科学基金(2017A030313891)

【作者简介】陈之锋, 硕士, 主治医师, E-mail: czf2007@smu.edu.cn

【通信作者】卢振泰, 副教授, 硕士生导师, E-mail: luzhentai@163.com

提出了很多不同的模型来解决这些问题,如阈值分割、区域分裂和合并^[4]、偏置场校正^[5]等方法。活动轮廓模型作为图像分割的一个重要方法分支,由于其具有封闭光滑的边界轮廓,并且能够处理图像噪声、强度异质性和不连续的物体边界而受到研究者的广泛关注。其基本思想是通过最小化给定的能量函数使曲线变形,从而达到期望的分割结果。活动轮廓模型主要有两类:基于边缘和基于区域的活动轮廓模型。基于边缘的分割模型由于图像的梯度而产生较小的变化,这些图像梯度用边缘指示函数表示^[6-7]。现有的基于边缘的活动轮廓模型中较典型的是距离正则化水平集演化方法的模型(DRLSE模型),该方法被提出是用以解决水平集函数在演化过程中由于不规则性导致数值误差,从而破坏演化的稳定性这一问题^[8]。其原理是在数值实现中应用有限差分的形式,并使用较大的时间步长减少迭代次数,同时保证足够的数值精度。然而,如果处理对象存在弱边缘,该方法存在边界泄漏的问题。基于区域的活动轮廓模型不使用图像梯度,而是使用图像灰度的统计信息控制物体边界内外的轮廓,因此基于区域的模型对弱边缘、不均匀性和对比度等不敏感,不会产生边界泄漏的问题^[9]。

曲线的轮廓要完成其功能一般需要两个部分的力:内部约束力和外部约束力。内部约束力由弹性能和弯曲能组成,其中弹性能负责收缩轮廓,弯曲能负责弯曲轮廓,内部约束力在图像域中可使曲线弯曲或收缩。外部约束力负责定义基于边界信息的函数,控制零水平集的重新初始化和约束曲线长度的变化,通常由图像数据如曲线、边缘和终止函数计算。在算法的实现过程中,用内部能量项和外部能量项表示曲线运动时的内部约束力和外部约束力,分别促使曲线朝目标边界演化。基于区域的模型中一部分是Mumford-Shah^[10]泛函模型,它是一个分段光滑模型,其中最具有代表性的就是Chan等^[11]等提出的分段常数模型(C-V模型)。分段常数模型在一定程度上处理了图像的不均匀性,但它使分割过程变得复杂从而增加了计算成本。该类模型假设所有图像都是同质的,因此在处理非均匀性图像上依然存在缺陷。Li等^[7]为了更具体地将图像的局部区域灰度信息引入能量泛函,应用高斯核函数提出了基于局部二值拟合的活动轮廓模型(LBF模型)。从局部小邻域到全像域,由于高斯函数的加入考虑了轮廓内外两侧的图像局部灰度信息,因此该方法能够从具有灰度不均匀性的图像中准确捕获到目标。然而,该模型仅仅利用了轮廓内外的局部灰度的均值信息,并没有实现进一步局部信息的表达,因而只能

实现对部分灰度不均匀图像的准确分割。此外,该方法对初始参数非常敏感,当参数发生细微变化时,其分割结果相差很大,因此该方法不适用于对具有弱边缘和灰度不均匀的舌癌肿瘤图像进行分割。

考虑到现有的大多数活动轮廓模型均对初始参数较为敏感,且在弱边缘和模糊边界处理上不尽人意。笔者提出了一种基于局部均方差的自适应尺度活动轮廓模型(Adaptive Scale active contour model based on Local mean Square Difference for tongue cancer tumor segmentation, ASLSD),该方法将一种基于局部均方差的自适应尺度算子用来平衡内部能量项中轮廓内外灰度分布的差异,使演化曲线在演化过程中实时地根据局部灰度信息自适应地收缩和弯曲,更高效地向真实目标边界运动,进而解决了舌癌肿瘤图像中目标边缘模糊以及图像灰度不均匀等问题。此外,本文方法还引入了一种新的能量项来评估演化曲线轮廓内外局部区域灰度的均值差异,以此引导曲线自适应地调整演化速度,加快曲线的收敛速度。

1 材料与方法

1.1 局部均方差

均方差在统计学中通常用来反映数据分布的离散程度,本文中假定目标边界内外像素的灰度数据是两个具有不同分布的数据集: φ_1 和 φ_2 ,且认为每个数据集中的数据是平稳分布的,也即数据集的方差较小。令演化曲线运动时其轮廓内外像素的灰度分布数据集分别为 φ_3 和 φ_4 ,如图1所示。实线表示所分割的目标边界,虚线表示演化曲线的边界,实线内的数据集为 φ_1 ,实线外灰度数据集为 φ_2 ;虚线内的数据集为 φ_3 ,虚线外灰度数据集为 φ_4 。当实线和虚线重合时,则说明已准确分割目标,此时 φ_1 和 φ_3 、 φ_2 和 φ_4 同分布;当实线与虚线不重合时,则表明演化曲线未运动到目标边界,此时 φ_3 和 φ_4 数据集的离散程度大于 φ_1 和 φ_2 数据集,且 φ_3 和 φ_4 数据集之间的离散程度也相差很大。根据这一信息,本文提出局部均方差这一概念用以衡量演化曲线在运动过程中轮廓内外局部邻域灰度分布的离散差异程度。

局部均方差由两个部分的差异表示:局部邻域灰度均值差异LMD和局部邻域灰度均值的方差差异LVD,其计算公式如下:

$$LMD = \gamma \int_{\Omega} |LM_1(x) - LM_2(x)|^2 dx \quad (1)$$

$$LVD_i =$$

$$\int_{\Omega} \frac{|S^2(LM_1(x)) - S^2(LM_2(x))|^{\frac{1}{2}}}{S(LM_i(x))} dx, \quad i = 1, 2 \quad (2)$$

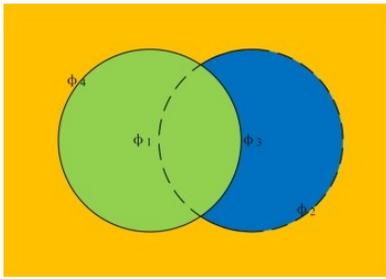


图1 目标边界和演化曲线边界数据分布关系图

Fig.1 Data relationship between target boundary and evolution curve boundary

实线表示目标边界,虚线表示演化曲线边界

其中, γ 是一个负常数, $S(\cdot)$ 是标准差函数, 用以计算局部灰度均值的标准差。 $LM_1(x)$ 和 $LM_2(x)$ 分别是轮廓内部和外部的局部邻域灰度的加权平均值, 其表达式定义如下:

$$LM_i(x) = \frac{\int_{\Omega} P(x, y) I(y) Q_i(\phi(y)) dy}{\int_{\Omega} P(x, y) Q_i(\phi(y)) dy} \quad (3)$$

其中, $P(\cdot)$ 是计算邻域距离权重系数的函数, 其计算表达式如下:

$$P(x, y) = \begin{cases} \frac{1}{N}, & D(x, y) \leq r \\ 0, & \text{other} \end{cases} \quad (4)$$

其中, N 是局部邻域内像素点的总个数, r 为局部邻域的半径, $D(x, y)$ 表示像素 x 与 y 之间的欧氏距离。在式(3)中, $P(\cdot)$ 相当于一个均值平滑算子, 对灰度分布不均匀性的区域进行平滑, 使得数据分布更均匀。由式(1)可知, $LM_1(x)$ 和 $LM_2(x)$ 的差异 LMD 越大, 则演化曲线越逼近真实目标边界, 因此将其作为新的能量项引入到能量函数, 加快曲线的收敛速度。由式(2)可以看出, 当 LVD_1 大于 LVD_2 时, 说明演化曲线轮廓内局部邻域灰度均值的离散程度低于轮廓外局部邻域均值的离散程度, 此时曲线应该朝 ϕ_4 区域运动, 反之则朝 ϕ_3 区域运动。因此, 将 LVD 作为内部约束力的权重系数, 负责调节演化曲线在图像域中的运动, 实现内部约束力尺度的自适应调整。

1.2 ASLSD

本文所提出的 ASLSD 的能量函数定义如下:

$$E^{ASLSD} = \mu \int_{\Omega} \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx + \nu \int_{\Omega} |\nabla H_{\epsilon}(\phi(x))| dx + LMD + LVD_i \int_{\Omega} \left(\int_{(y \in N_x) \neq x} \frac{|I(y) - LM_i(x)|^2}{D(x, y)} dy \right) Q_i(\phi(x)) dx \quad (5)$$

N_x 表示以 x 为中心的局部邻域, 式(5)中前两项用来形成演化曲线运动的外部约束力; 第3项是本文提出的新能量项, 加速曲线演化收敛; 最后一项是内部能量项, 产生内部约束力, 驱动曲线朝目标边界演化。采用梯度下降法最小化总能量函数, 得到对应的曲线演化方程为:

$$\frac{\partial \phi(x)}{\partial t} = \delta(\phi(x)) LVD_2 \int_{(y \in N_x) \neq x} \frac{|I(y) - LM_2(x)|^2}{D(x, y)} dy + \delta(\phi(x)) LMD + \mu \left(\nabla^2 \phi - \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right) + \nu \delta(\phi) \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - \delta(\phi(x)) LVD_1 \int_{(y \in N_x) \neq x} \frac{|I(y) - LM_1(x)|^2}{D(x, y)} dy \quad (6)$$

LMD、LVD₁、LVD₂ 分别由式(1)和式(2)给出, $\text{div}(\cdot)$ 是一个散度算子。

1.3 ASLSD 的算法实现

本文算法的实现过程如下。

步骤1: 初始化水平集函数 ϕ ;

步骤2: 根据式(4)计算欧氏距离 $D(x, y)$ 和均值平滑算子 $P(x, y)$;

步骤3: 根据式(3)计算演化曲线轮廓内外局部灰度均值 $LM_1(x)$ 和 $LM_2(x)$;

步骤4: 根据式(1)和(2)计算局部邻域灰度均值差异 LMD 和其对应的方差差异 LVD_1 、 LVD_2 ;

步骤5: 根据式(6)计算演化方程得到 $\frac{\partial \phi}{\partial t}$;

步骤6: 更新水平集函数 ϕ^{t+1} , 根据公式:

$$\phi^{t+1} = \phi^t + \frac{\partial \phi}{\partial t} \Delta t \quad (7)$$

由于临床舌癌肿瘤的 MRI 图像中存在大量无关信息, 因此在进行舌癌肿瘤分割实验前先做预处理。预处理包括感兴趣区域勾画及灰度归一化两个过程, 勾画由一位有着5年临床经验的口腔科医生完成, 其工作除了勾画 MRI 图像中的舌体部位之外, 还需要勾画舌癌肿瘤的实际边界作为分割的金标准。灰度归一化过程是采样灰度变换归一化方法, 将勾画得到的感兴趣区域的灰度拉伸得到具有整个灰度级的图像。在进行图像预处理之后, 应用 ASLSD 算法对舌癌肿瘤进行分割。首先初始化零水平集函数, 然后计算演化曲线轮廓内外的局部均值 $LM_1(x)$ 和 $LM_2(x)$, 最后当达到设定的迭代次数之后, 输出最终的分割结果。图2为整个分割实验的流程图。

2 结果

共收集了22幅舌癌肿瘤的 MRI 图像, 其中包含

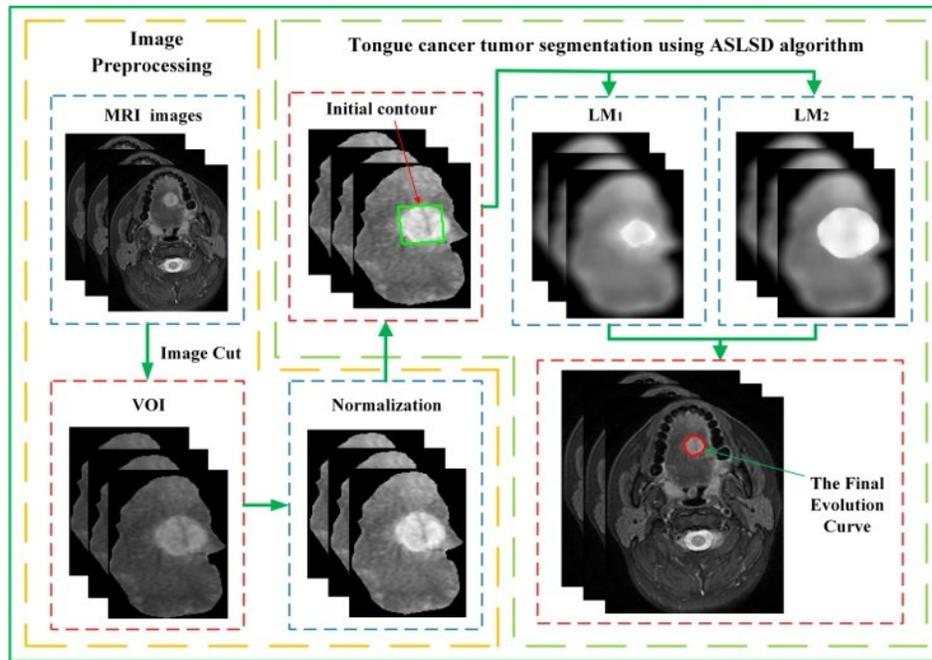


图2 舌癌肿瘤分割实验的流程图

Fig.2 Flowchart of tongue cancer image segmentation

5幅冠状面成像和17幅横断面成像。使用本文所提出的ASLSD模型对该数据集进行分割,并将结果与一些典型的活跃轮廓模型进行比较。此外,通过将ASLSD结果与未引入局部均方差的结果进行比较,以此评估ASLSD模型的性能。在本文中采用两个广泛使用的指标:重叠率(Dice)和豪斯多夫距离(HD),进一步定量评估各模型的分割性能。本文实验是在Intel[®]Core™ 3.60 GHz CPU、8.0 GB RAM的PC机上使用Matlab R2017b平台实现的。

2.1 与未引入均方差模型分割结果的比较

为验证所引入的局部均方差的有效性,将ASLSD模型与未引入均方差前的模型进行比较。因为局部均方差分为LMD和LVD两部分,因此实验也分为两部分进行,迭代次数为2 000。在对比是否加入LVD中的实验中,未引入LVD的模型其内外部能量项尺度参数设置为1,其它参数与ASLSD模型相同。

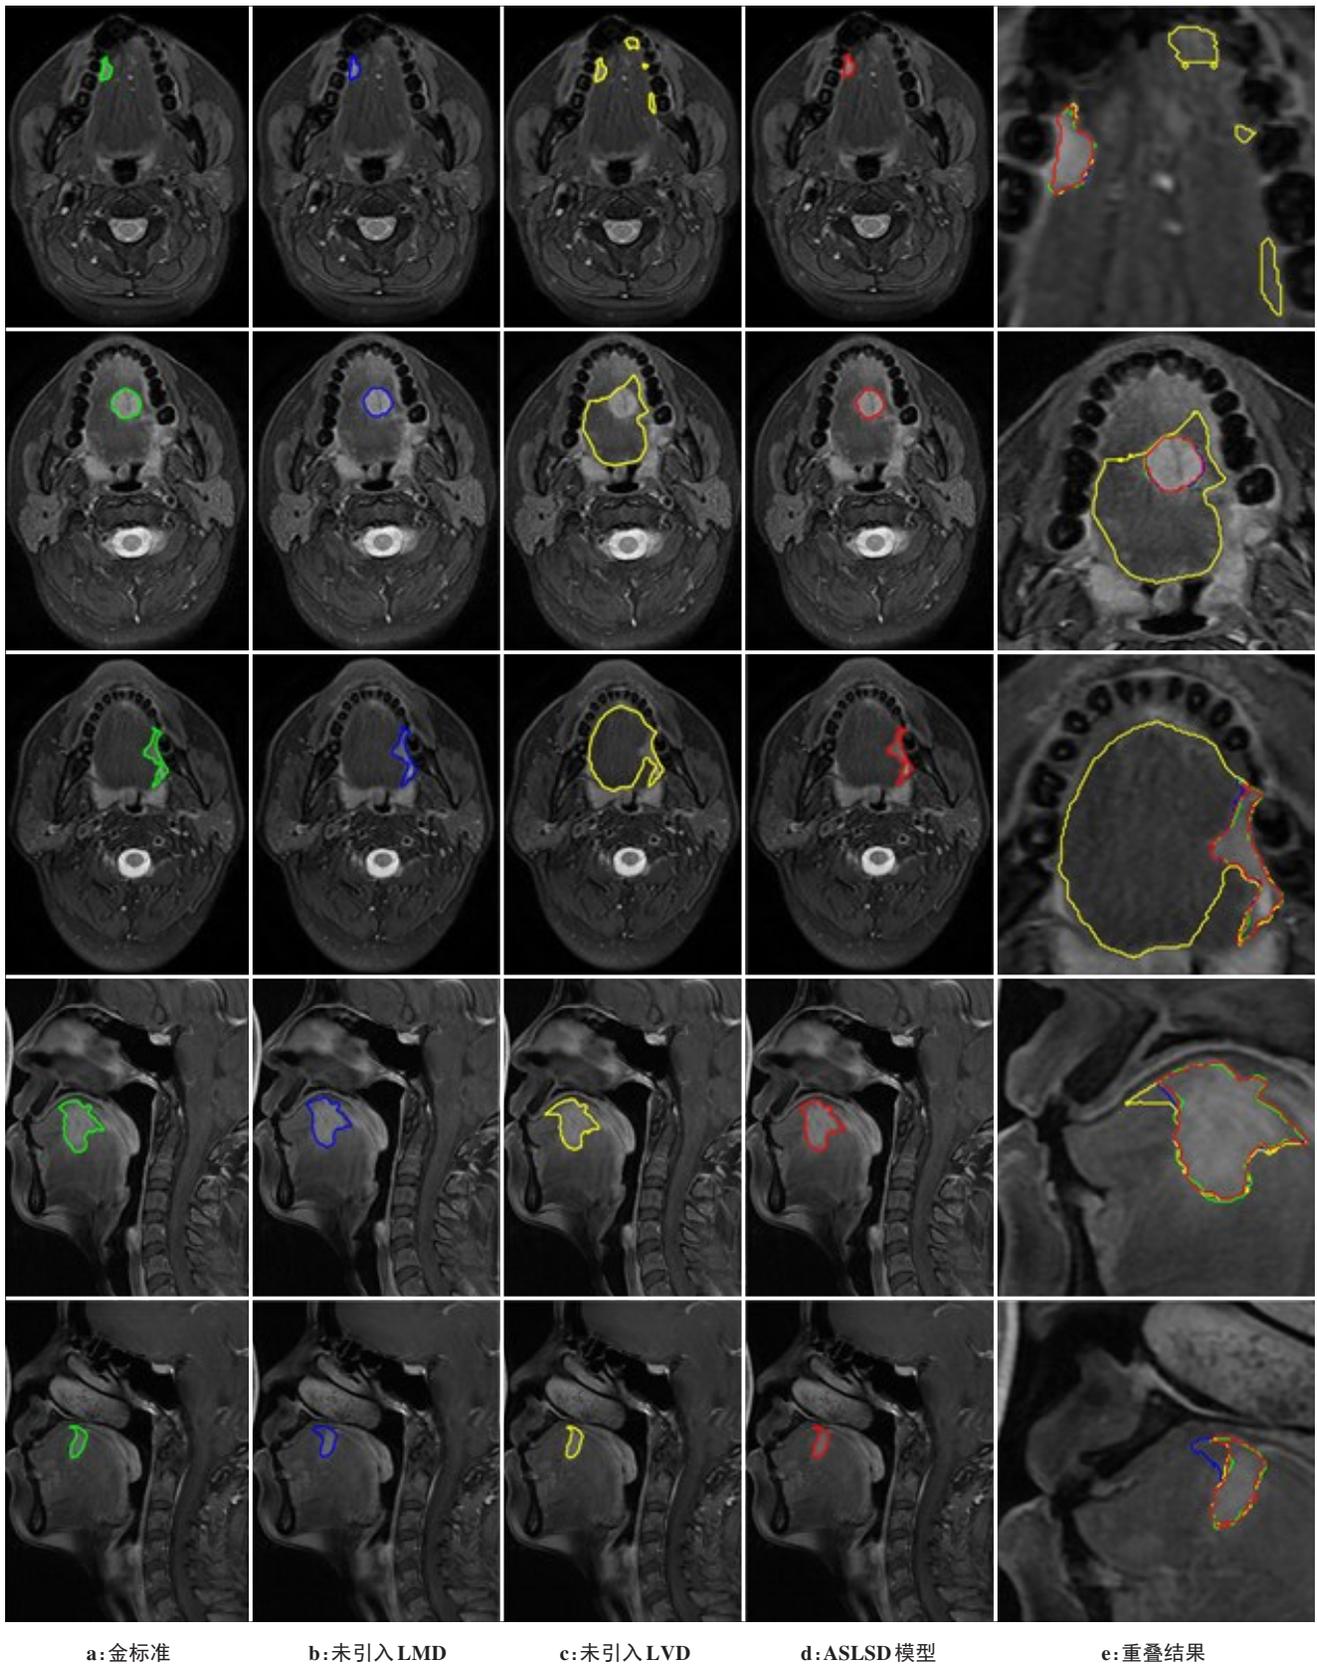
图3显示引入LMD、LVD前后ASLSD模型的舌癌肿瘤分割结果,前3行是舌癌肿瘤MRI横断面图像,后2行是冠状面图像。图3a为医生勾画的金标准ground truth(绿色曲线);图3b是未引入LMD时的ASLSD模型的分割结果(蓝色曲线);图3c是未引入LVD时的ASLSD模型的分割结果(黄色曲线);图3d是本文所提出的ASLSD模型分割结果(红色曲线);图3e是前4者重叠显示的结果。从图3e第5行的冠状面图像的肿瘤分割中可以看到,未引入LMD的最

终演化曲线中部分未停留在肿瘤边界,对非目标区域也进行了分割,其余图像结果相差不大。但是未引入LVD时的ASLSD模型其结果大部分均没有准确地对目标进行分割,与引入LVD之后的模型结果相差很大,这说明本文所提出的均方差中的LVD部分能够更精确地驱动曲线演化,提高分割精度。

图4是引入LMD、LVD前后ASLSD模型对图3中第1行的MRI断层图像分割过程中LVD值的变化曲线。a为应用未引入LMD的ASLSD模型(橙色曲线)与引入后的模型(蓝色曲线)在曲线演化过程中LVD1的变化曲线;b是ASLSD模型分割过程中LVD1(蓝色曲线)和LVD2(橙色曲线)值的变化曲线。结合图3和图4可以看出,引入LMD之后,虽然最终的分割结果与未引入时相差不大,但是引入LMD之后模型的LVD值却能够迅速达到收敛,这肯定了本文所提出均方差中的LMD部分在曲线收敛方面优越的表现。图4b反映了ASLSD模型在分割达到最优时LVD1和LVD2的值分别稳定于不同的值且该值不等于1,这直接说明内部能量项和外部能量项权重系数设置成1时并不能得到最优解,本文所提出均方差中的LVD部分能够自适应地改变内部能量项和外部能量项所占尺度,使曲线更逼近于目标的真实边界。

2.2 与不同模型分割结果的比较

为验证本文模型在分割舌癌肿瘤图像上的优越性,将ASLSD模型分别与DRLSE、LBF、RSF模型比较,图5显示了不同模型调整到最优参数后的分割结



a: 金标准 b: 未引入 LMD c: 未引入 LVD d: ASLSD 模型 e: 重叠结果

图 3 对 5 组病人图像引入 LMD、LVD 前后 ASLSD 模型的舌癌肿瘤分割结果

Fig.3 Results of tongue cancer image segmentation for 5 patients in ASLSD model before and after the introduction of LMD and LVD

果,不同行代表对不同 MRI 图像的分割结果。a 为医生勾画肿瘤区域的金标准;b、c、d、e 分别对应 DRLSE 模型^[8]、LBF 模型^[7]、RSF 模型^[12]和本文所提出

ASLSD 模型的分割结果;f 为各模型分割结果的重叠显示。从 f 图可以看出,与金标准轮廓最接近的是本文所提出的 ASLSD 模型。DRLSE 模型在对一些灰

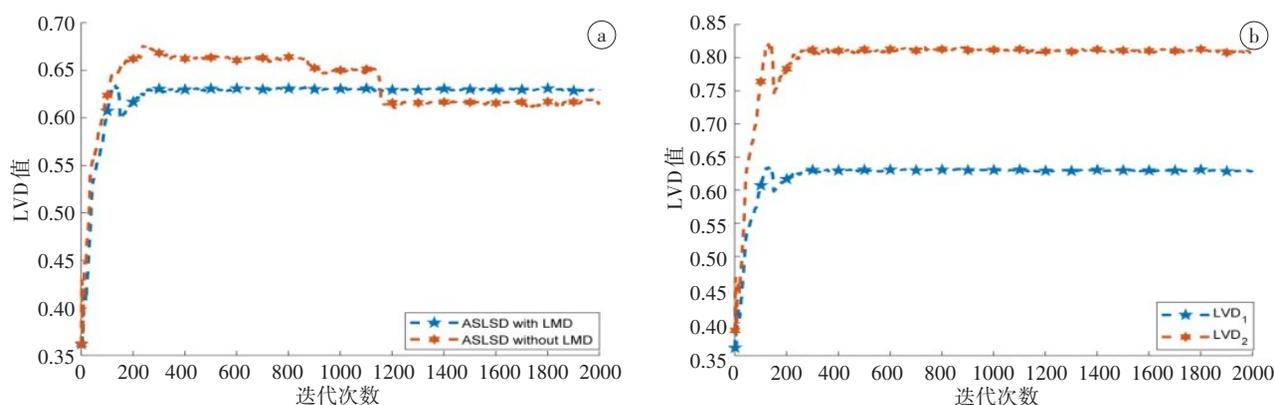


图4 引入LMD前后LVD1的变化曲线及分割过程中LVD1、LVD2的变化曲线

Fig.4 Variation curves of LVD1 with and without LMD and the variation curves of LVD1 and LVD2 during segmentation

a是未引入LMD的ASLSD模型(橙色曲线)与引入后的模型(蓝色曲线)在曲线演化过程中LVD1的变化曲线;b是ASLSD模型分割过程中LVD1(蓝色曲线)和LVD2(橙色曲线)值的变化曲线

度不均匀和边界模糊的区域,并没有实现准确的分割,其分割结果未包含所需要分割的全部目标区域。LBF模型的分割结果相对DRLSE模型在灰度不均匀区域的分割方面性能更好,但是对于边界模糊的区域其最终的演化曲线并没有停留在目标区域真实边界上。RSF模型也没有克服灰度不均匀和边界模糊带来的不良影响,其分割结果大部分都包含了非目标区域。本文所提出的ASLSD模型对目标均进行了准确分割,且在模糊边缘的处理上保持鲁棒。

为更直观地比较本文模型在舌癌肿瘤分割上的优越性,笔者应用两种常用分割度量指标:重叠率Dice及豪斯多夫距离HD来定量评估各个模型的分割性能。其中本文所提出的ASLSD模型具有最高的Dice值(0.951)和HD值(3.136 mm),DRLSE、LBF、RSF模型的Dice值和HD值依次为0.691、0.622、0.797和16.982、99.414、24.109 mm。图6为应用不同模型对22幅舌癌肿瘤MRI图像进行分割后得到的Dice及HD构成的盒状图。不难观察出在HD方面,LBF模型稳定性最差且存在最大的HD值,DRLSE模型和RSF模型相对较好,但HD值也较大,而ASLSD模型不仅稳定性最好且HD值也保持最低;在Dice值方面,DRLSE、LBF和RSF模型表现也不如ASLSD模型。综上所述,相比于现有的活动轮廓模型,本文所提出的ASLSD模型在舌癌肿瘤图像分割上表现更好,并且具有更高的分割精度。

3 讨论

通过与DRLSE、LBF、RSF模型比较,验证了ASLSD模型在舌癌肿瘤分割上的优越性,但是本文算法依然存在一些限制。首先,该算法在分割一些

孔洞较深且较窄的区域时,可能会出现凌乱的力场,导致演化曲线不能正确收敛。如图5第5行和第6行所示,ASLSD模型最终的演化曲线停留在目标区域的凹陷部位边缘,并没有实现对整个肿瘤区域的准确分割。在最近的研究中,Wang等^[13]提出了梯度向量流模型(GVF模型)解决活动轮廓模型在凹区域不能收敛的局限性,该模型引入了新的面积能量,有效地扩大了捕获范围,然而它在弱边缘问题的处理上存在缺陷,无法保留图像薄弱边缘细节。此后,Zhang等^[14]提出了基于流形的梯度向量流模型(GVFOM模型),该模型是在流形上设计的,并且将外力场的两个分量作为嵌入四维欧氏空间中的二维流形,在保持GVF模型的优点同时,又弥补了其在弱边缘保护、深窄凹性收敛等方面的缺陷,但是它在分割灰度不均匀的图像上表现很差,不能对边界不清、灰度不均匀的舌癌肿瘤图像进行准确分割。

此外,由于所得到的Dice和HD度量值完全依赖于医生在MRI图像上对舌癌肿瘤的勾画,不同的医生即使采用相同的图像数据描绘导管区域时也可能有不同的理解和解释,因此应考虑不同观察者之间的变异性。不同的医生在勾画同一组织或器官时其实际勾画区域在重叠率的一致性方面上平均占80.9%~89.4%,依然存在少部分区域由于观察者之间主观的差异性导致没有达到一致。

综上所述,ASLSD模型在凹区域和观察者之间的变异性等方面依然存在不足,然而本文方法在边界不清及灰度不均匀的图像处理上远优于其它现有的活动轮廓模型,且在分割舌癌肿瘤MRI图像上其所用迭代次数更少,分割精度更高。此外,ASLSD模型通过引入局部灰度均方差,实现了自适应地调整

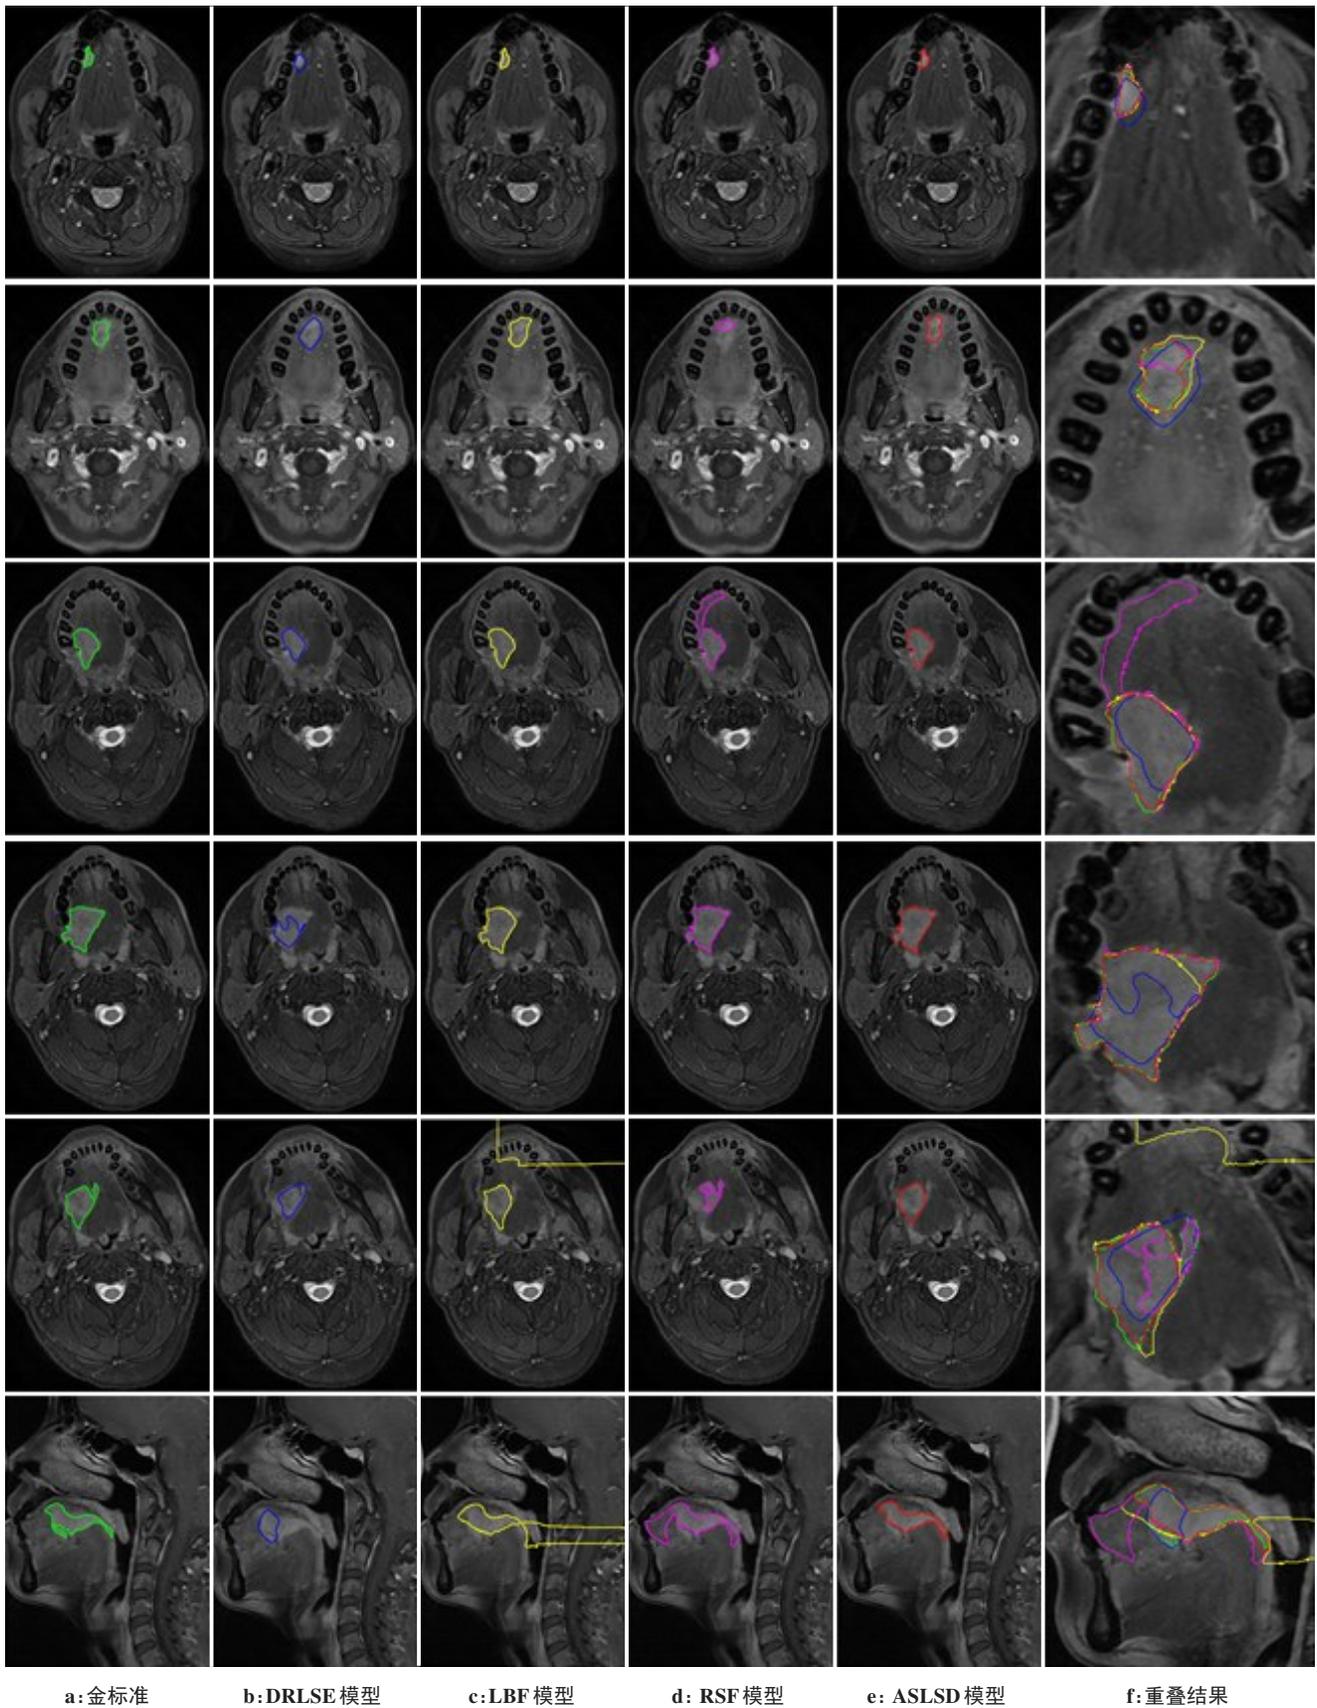


图5 对6组病人图像引入不同模型的舌癌肿瘤分割结果对比

Fig.5 Comparison of results of tongue cancer image segmentation for 6 groups of patients in different models

曲线演化内部约束力的尺度,使曲线朝肿瘤边界运动的同时,更加精确地逼近目标边缘。因此本文算

法有望成为一种临床辅助工具,为舌癌诊断以及治疗计划的确定提供参考信息。

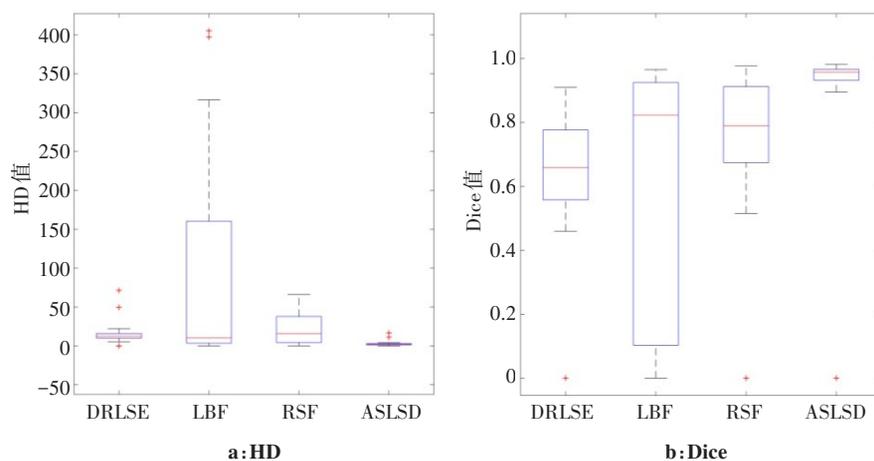


图6 不同模型分割的HD和Dice值

Fig.6 Hausdorff distance and Dice values of tongue cancer image segmentation in different models

【参考文献】

- [1] JEONG W H, LEE W J, ROH T S, et al. Long-term functional outcomes after total tongue reconstruction: consideration of flap types, volume, and functional results[J]. *Microsurgery*, 2017, 37(3): 190-196.
- [2] SULTANA J, BASHAR A, MOLLA M R. New management strategies of oral tongue cancer in Bangladesh[J]. *J Maxillofac Oral Surg*, 2014, 13(4): 394-400.
- [3] MONTERO P H, PATEL S G. Cancer of the oral cavity[J]. *Surg Oncol Clin N Am*, 2015, 24(3): 491-508.
- [4] WELLS W, GRIMSON E, KIKINIS R, et al. Adaptive segmentation of MRI data[J]. *IEEE Trans Med Image*, 1996, 15(4): 429-442.
- [5] VOVK U, PERNUS F, LIKAR B. A review of methods for correction of intensity inhomogeneity in MRI[J]. *IEEE Trans Med Image*, 2007, 26(3): 405-421.
- [6] ESTELLERS V, ZOSSO D, BRESSON X, et al. Harmonic active contours[J]. *IEEE Trans Image Process*, 2014, 23(1): 69-82.
- [7] LI C M, GORE J, DING Z H. Implicit active contours driven by local binary fitting energy[J]. *IEEE Conf Comput Vision Pattern Recogn*, 2007(1): 1-7.
- [8] LI C M, XU C Y, GUI C F, et al. Distance regularized level set evolution and its application to image segmentation[J]. *IEEE Trans Image Process*, 2010, 19(12): 3243-3254.
- [9] DING K, XIAO L, WENG G. Active contours driven by local pre-fitting energy for fast image segmentation[J]. *Pattern Recogn Lett*, 2018, 104: 29-36.
- [10] MUMFORD D, SHAH J. Optimal approximations by piece-wise smooth functions and associated variational problems[J]. *Commun Pure Appl Math*, 1989, 42(5): 577-685.
- [11] CHAN T F, VESE L A. Active contour without edges[J]. *IEEE Trans Image Process*, 2001, 10(2): 266-277.
- [12] WANG L, LI C M, QUAN S S, et al. Active contours driven by local and global intensity fitting energy with application to brain MR image segmentation[J]. *Comput Med Imaging Graph*, 2009, 33(7): 520-531.
- [13] WANG W, WANG Y, WU Y, et al. Quantification of full left ventricular metrics via deep regression learning with contour-guidance[J]. *IEEE Access*, 2019, 7: 47918-47928.
- [14] ZHANG Z Y, DUAN C R, LIN T, et al. GVFOM: a novel external force for active contour based image segmentation[J]. *Inform Sci*, 2020, 506: 1-18.

(编辑:黄开颜)