

# 基于融合 U-Net 和水平集的肝脏 CT 图像分割

张宇豪 徐磊 白一清

(上海理工大学 光电信息与计算机工程学院 上海 200093)

**摘要:**为了弥补 U-Net 模型和水平集方法分割肝脏 CT 图片的不足之处,提出了一种将两者进行融合的分割算法。该算法在训练阶段使用 U-Net 模型作为先验网络对肝脏进行分割,然后将其输出的分割结果作为先验特征图送入到水平集方法中进一步分割;通过计算两次分割结果的差异,反向传播误差,更新网络参数,最终得到一个完整的分割算法模型。通过在公开数据集 3Dircadb 上进行实验对比,所提出分割算法的灵敏性和 Dice 系数的平均值分别可以达到 94.85% 和 95.18%,面积重叠误差和相对面积误差的平均值仅有 9.97% 和 7.69%。与其他常见的分割算法相比,该算法获得了更好的分割结果。

**关键词:**U-Net;水平集方法;先验网络;先验特征图

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 510.4050

## Liver CT image segmentation based on fusion of U-Net and level set

Zhang Yuaho Xu Lei Bai Yiqing

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

**Abstract:** In order to make up for the shortcomings of the U-Net model and the level set method in segmenting liver CT images, this paper proposes a segmentation algorithm which combines U-Net model with the level set method. The algorithm uses the U-Net model as a prior network to segment the liver in the training phase, and then sends its output segmentation result as a prior feature map to the level set method for further segmentation; by calculating the difference between the two segmentation results, back propagation error, update network parameters, and finally get a complete segmentation algorithm model. Through experimental comparisons on the public data set 3Dircadb, this paper proposes that the sensitivity of the segmentation algorithm and the average Dice coefficient can reach 94.85% and 95.18%, respectively, and the average area overlap error and relative area error are only 9.97% and 7.69%. Compared with other common segmentation algorithms, this algorithm obtains better segmentation results.

**Keywords:** U-Net; level set method; prior network; prior feature map

## 0 引言

图像分割一直是医学图像处理中最基本的问题。相比于其他图像分割,医学图像分割要求的精度会更高。由于涉及到病人隐私,医学图像公开的数据很少,已标注的训练数据更少。在数据量不足的情况下,只有对分割算法进行优化,才能达到医学应用中的精准度。

自从 Osher 等<sup>[1]</sup>提出水平集方法 (level set method, LSM)以来,该算法在医学图像分割领域取得了极大的成就。水平集算法是一种将图像信息融合到能量方程中的分割算法<sup>[1]</sup>。该算法通过求解最小化能量方程,驱动初始轮廓曲线演化,从而完成对目标区域的分割。Mumford 等<sup>[2]</sup>提出了 Mumford-Shah(MS)模型,该模型是一种优化图像全局能量方程的分割模型<sup>[2]</sup>,在分割目标区域时,不仅使用

到图像的边缘梯度信息,而且还考虑到待分割区域的全局区域信息和长度信息。MS 模型在数值计算上比较复杂,而且对噪声比较敏感,不适合分割灰度不均匀的医学图像。Chan 等<sup>[3]</sup>在 MS 模型的基础上通过改进能量方程,从而简化了模型求解过程,这就是著名的 CV 模型。CV 模型使得曲线在演化过程中不依赖图像的梯度信息,适用于弱边缘图像分割和带有噪声的图像分割,但是在灰度不均匀处表现较差,并且需要对初始轮廓进行重复初始化。Li 等<sup>[4]</sup>在此基础上提出一种无需重新初始化的水平集模型,进一步提高水平集算法在分割医学图像中的应用。为了进一步解决由于医学图像中的弱边界、灰度不均匀等特点而造成轮廓线发生错误移动,产生错误分割结果的问题,一系列优秀的模型被提出<sup>[5-7]</sup>,使得水平集在医学图像分割中具有更好

的抗噪性。

近年来随着计算机算力的提高,卷积神经网络也逐渐被应用于医学图像分割。文献[8]提出的全卷积神经网络(fully convolutional network, FCN)首先被用来进行图像分割,并且在医学图像分割领域中取得了较好的结果。随后而来的文献[9]提出的 U-Net 创新性地使用了上采样和特征融合技术,使其在医学图像分割中获得了广泛的认可。在 U-Net 的基础上,许多学者又提出了一些优秀的分割网络<sup>[10-11]</sup>。虽然这些神经网络能够获得较为精确的分割结果,但是受到训练数据集数量的限制,部分神经网络模型无法训练到更高的分割精度。所以神经网络在医学图像分割领域仍然存在一些不足。也有一些学者将水平集算法和神经网络模型融合在一起,利用神经网络提取图像深层次信息,获得图像的先验信息,然后利用水平集算法对目标图像进行分割,从而可以获得更加平滑、精确的分割效果。

本文提出了一种融合 U-Net 和水平集的模型用于医学图像分割。在训练阶段:将训练数据分为已标注数据集和未标注数据集。首先利用已标注的数据集训练出一个先验网络,先验网络输出的结果称为先验特征图;然后将未标注的训练数据送入到先验网络中,把得到的先验特征图送到水平集中进行曲线演化,演化出的结果当作真实标签与先验特征图进行误差计算、反向传播进一步更新网络参数,

最终得到分割模型。在验证阶段:首先把未标注的数据送到分割模型中得到粗分割结果,再把粗分割结果送到水平集中进行曲线演化,得到最后的细分割结果。接下来的小结将会详细介绍本文提出的分割算法。

## 1 算 法

图 1 是本文提出的 ULSM-Net 网络模型架构。首先将训练数据送入到 U-Net 网络模型中,利用 U-Net 网络模型提取深层次的图像信息。根据 U-Net 所分割出的目标区域,可以得到目标的大致像素区域;然后将该区域作为水平集方法的初始轮廓,进一步演化曲线,分割目标区域。本文将训练数据分为已标记的数据和未标记的数据。首先使用已标注的数据来训练网络参数,此时得到的网络称为先验网络;然后将未标注的训练数据送入到先验网络中,得到的结果作为水平集的初始轮廓进行曲线演化,将曲线演化的结果作为真实标签进行误差校正,反向传播再一次更新网络参数,得到最终的网络参数值,该阶段为训练阶段,如图 1(a)所示。在测试阶段,如图 1(b)所示,首先把数据送入到先验网络中进行粗分割,然后将分割结果送入水平集算法中进行细分割;细分割的结果就作为最终的输出结果。接下来将详细地介绍一下改进之后的分割算法具体是如何实现。

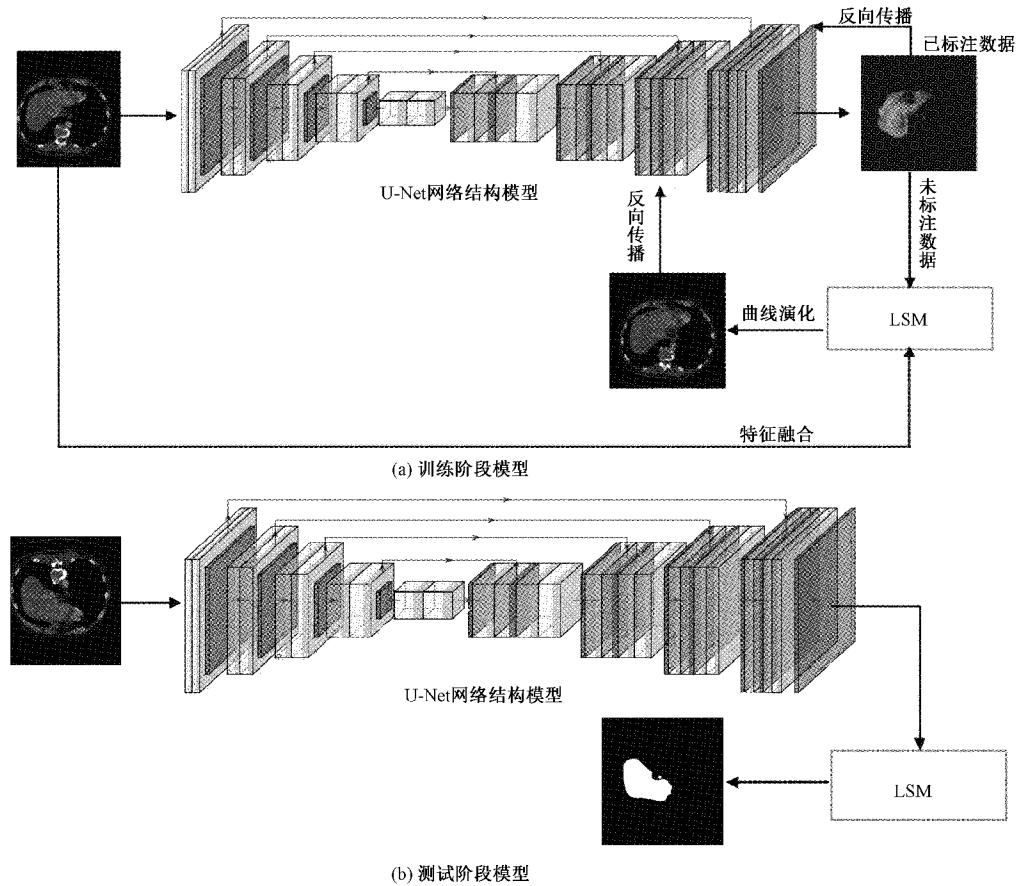


图 1 ULSM-Net 模型框架

### 1.1 U-Net

U-Net 因为其网络结构呈现一个“U”型而得名。该网络左侧为编码器，右侧为解码器。编码器有 4 个子模块，每个子模块包含两个卷积层，子模块之后有一个最大池化层进行下采样。解码器同样包含 4 个子模块，图像分辨率通过上采样操作依次上升，直到与输入图像的分辨率一致。该网络中还使用了跳跃连接，将上采样结果与编码器中具有相同分辨率的子模块的输出进行连接，作为解码器中下一个子模块的输入。本文使用二分类交叉熵(BCE-Loss)作为网络模型的损失函数：

$$L(y; x; \theta) = -\frac{1}{N} \sum_{i=1}^N [y^i \ln P(x^i; \theta) + (1-y^i) \ln(1-P(x^i; \theta))] \quad (1)$$

式中：N 是图片中所有像素点的数目， $(x^i, y^i)$  代表着像素点  $x^i$  和其对应的标签  $y^i$ ， $\theta$  代表着网络参数， $P(x^i; \theta)$  代表着网络预测像素点  $x^i$  属于某一类别的可能性。

### 1.2 水平集算法

传统的水平集方法往往是利用求解能量方程最小化来分割图像中的目标区域。能量方程通常具有如下形式：

$$E(\varphi, C) = \mu E_{data}(\varphi) + \nu E_{smooth}(\varphi) + E_{shape}(\varphi, C) \quad (2)$$

式中： $\varphi(\cdot)$  是符号距离函数，C 是待分割图像的目标区域， $\mu$  和  $\nu$  是调节函数的权值项，它们一般是常数。 $E_{data}(\cdot)$  是数据项，其通常表示图像目标区域与背景区域之间的像素值分布，具有如下形式：

$$E_{data}(\varphi) = \int_{\Omega} H_s(\varphi(x)) \log(P_o(x)) d\Omega + \int_{\Omega} (1 - H_s(\varphi(x))) \log(P_b(x)) d\Omega \quad (3)$$

式中： $\Omega$  代表着整个图像区域， $P_o(\cdot)$  代表着属于目标区域的概率， $P_b(\cdot)$  代表着属于背景区域的概率，本文使用 U-Net 网络可以求出某一像素点所对应的概率。 $H_s(\cdot)$  是海维塞德函数，在实际中用平滑函数  $H_\epsilon(\cdot)$  来近似，其表达式如下：

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

$E_{smooth}(\cdot)$  是平滑项，主要是用来平滑目标曲线边界，其形式如下所示：

$$E_{smooth}(\varphi) = \int_{\Omega} \delta_s(\varphi(x)) |\nabla \varphi(x)| d\Omega \quad (5)$$

式中： $\delta_s(\cdot)$  是狄克拉函数，在实际中用平滑函数  $\delta_\epsilon(\cdot)$  来近似，其表达式如下：

$$\delta_\epsilon(x) = H'_\epsilon(x) = \frac{1}{\pi} \frac{\epsilon}{\epsilon^2 + x^2} \quad (6)$$

$E_{shape}(\cdot)$  是目标边界正则项，本文利用 U-Net 所提取的深层次图像信息作为水平集的先验边界形状，然后与水平集演化之后所得的边界形状作对比，通过计算均方误差来衡量两者之间的差异，于是可以得出  $E_{shape}(\cdot)$  的表达式：

$$E_{shape}(\varphi) = (C_{LSM}(\varphi(x)) - C_{U-Net}(\varphi(x)))^2 \quad (7)$$

式中： $C_{LSM}(\cdot)$  是水平集方法演化的目标边界曲线弧长， $C_{U-Net}(\cdot)$  是 U-Net 分割出的先验目标边界曲线弧长。使用变分法来进行求解式(2)的最优值，可以实时地更新演化曲线的位置变动。

### 1.3 ULSM-Net

本文提出融合 U-Net 和水平集的方法称为 ULSM-Net。首先将已标注的数据送入到 U-Net 网络中进行训练。由已标注数据训练出的网络称为先验网络，先验网络的权重参数值并不是最终结果值，需要后续操作进一步训练、校正。接着把未标注的数据集送入到先验网络中，会得到一个目标的分割结果图，称之为先验特征图。从先验特征图中可以得到每一个像素属于目标或者背景的概率，将这些概率结果代入到式(3)中，就可以求出水平集能量泛函的  $E_{data}(\cdot)$  项。与此同时，可以将已知的目标像素区域作为水平集的初始轮廓，进行曲线演化，演化的结果就作为本次网络训练的真实标签。然后将先验网络输出的预测结果值与水平集演化的结果值代入到式(1)中，计算两者的交叉熵损失，然后反向传播误差，进一步优化校正网络权重参数。

先验网络输出的结果代表着每个像素划分为目标区域或者背景区域的概率(如图 2(a)所示，其中白色代表目标区域，黑色代表背景区域)，该结果本身存在着一定的误差，所以无法直接令该结果的轮廓作为下一步水平集曲线演化的初始轮廓，否则会加大反向传播时的误差，降低分割算法的准确率。不妨假设真实目标区域轮廓为  $shape_{gt}$ ，先验网络预测轮廓为  $shape_{U-Net}$ ，演化目标轮廓为  $shape_{LSM}$ 。因为先验网络预测轮廓  $shape_{pred}$  只是网络预测的结果，并不是真实的目标轮廓，如果让水平集直接在轮廓  $shape_{pred}$  基础上进行演化，那么由于网络预测存在误差，就会导致水平集  $shape_{LSM}$  直接在错误的基础之上进行演化。本意是想让近似于  $shape_{gt}$ ，但是由于  $shape_{pred} = F_{U-Net}(input)$ ， $shape_{LSM} = F_{LSM}(shape_{pred})$ ，经过以上非线性变换， $shape_{LSM}$  与  $shape_{gt}$  之间的误差会随之增大，违背了本意，所以不能直接使用预测的结果作为水平集曲线演化的初始轮廓。应该在预测结果的基础之上重新选取新的 ROI 作为水平集曲线演化的初始轮廓(如图 2(b)所示)。

通过将水平集融入到 U-Net 网络中，使得水平集方法可以从先验网络中学习到演化曲线的初始轮廓，U-Net 网络又可以从水平集的演化结果中学习到一些未标注训练数据的权重参数，这样就保证改进后的算法使用较少的标注数据，得到了更为平滑的分割结果。

## 2 优化与实施细节

为了进一步提高改进算法的准确性，降低参数计算量，本文又进一步做了如下优化措施。

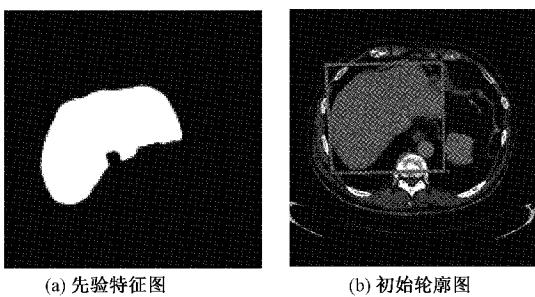


图 2 先验特征图的初始轮廓示意图

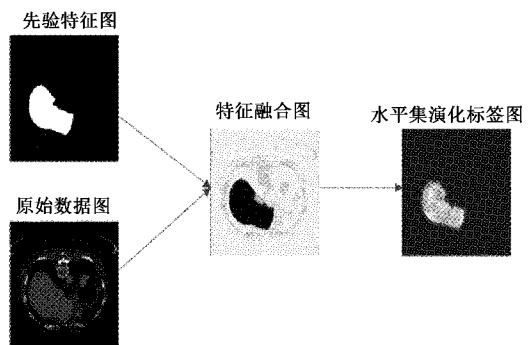


图 3 特征融合示意图

## 2.1 深度可分离卷积

深度可分离卷积<sup>[12]</sup>是一种可分卷积操作,其可以分解为两个更小的操作:逐通道卷积和逐点积。逐通道卷积是针对每一个输入通道采取不同的卷积核。逐点卷积就是采用 $1 \times 1$ 的卷积核进行通道融合,这样整体的效果与标准卷积差不多,但是计算参数量却减少了很多,整体而言加速了网络的训练。

## 2.2 进行图像特征融合

在使用未标注的训练数据集训练网络时,本文将输出的先验特征图像与原始的图像进行像素值加权融合,如图 3 所示,该操作会使得目标区域的边缘梯度值增大。在后续水平集演化过中,可以驱使曲线迅速向目标区域演化,同时降低由于医学图像本身存在灰度不均匀和边界轮廓模糊等问题造成的曲线演化误差,使得水平集演化的结果更加的接近真实标签,从而提高算法分割的精准度<sup>[13]</sup>。

## 2.3 实施细节

本文采取如图 1 所示的网络架构,将前 3 层和后 3 层

的卷积模块替换成深度可分离卷积来降低参数量。对于训练数据集,将其分为已标注部分和未标注部分,其所占比例大致为 7:3;该网络使用 python 语言和 pytorch 框架来实现,并在 Core i9-9900KF@3.6 GHz, 32 GB RAM 和单个 NVIDIA GTX 1080Ti 的计算机上运行。使用交叉验证方法训练改进后的网络模型。

## 3 实验结果与分析

为了证明本文提出算法的有效性,在同一个公开数据集 3Dircadb 上对原始的 U-Net 模型、水平集方法和改进之后的算法进行了对比,其结果如图 4~7 分别代表着 4 组患者不同序列层级的肝脏 CT 图片分割结果;其中子图(a)代表着原始 CT 图片;子图(b)代表专家标注的真实标签;子图(c)代表原始 U-Net 网络的分割结果;子图(d)代表原始水平集算法的曲线演化结果;子图(e)代表本文提出算法的分割结果。

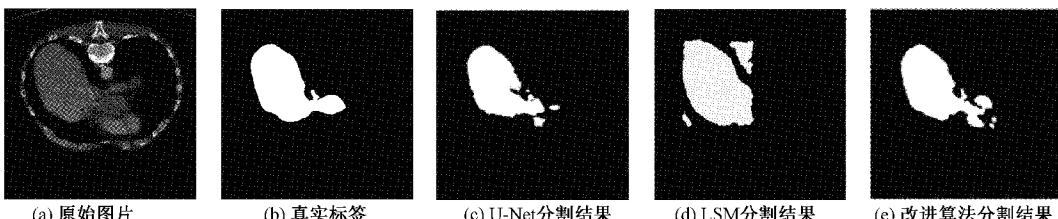


图 4 患者 1 的肝脏分割结果

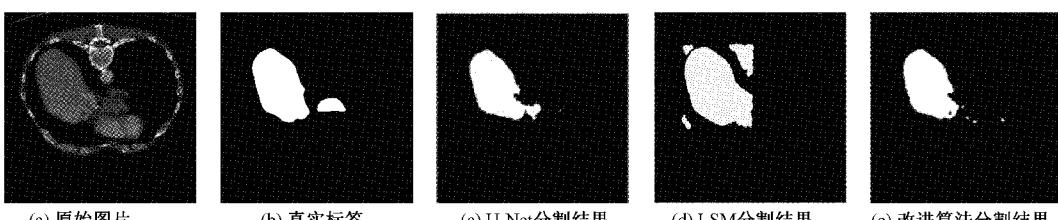


图 5 患者 2 的肝脏分割结果

从图中可以看出,相比于改进之后的算法,原始的水平集方法会将周围部分非肝脏区域包含在内,如图 4~7 的子图(d)中的右上角区域。(注:为了便于对比分割结果

之间的差异,本文将水平集轮廓曲线演化的结果进行了二值化处理)。经过分析可知,这是因为原始 CT 图片存在灰度不均匀和弱边界问题,传统水平集是基于图像全局区域

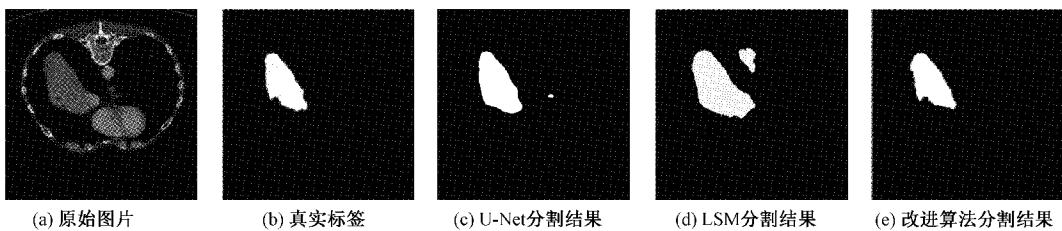


图 6 患者 3 的肝脏分割结果

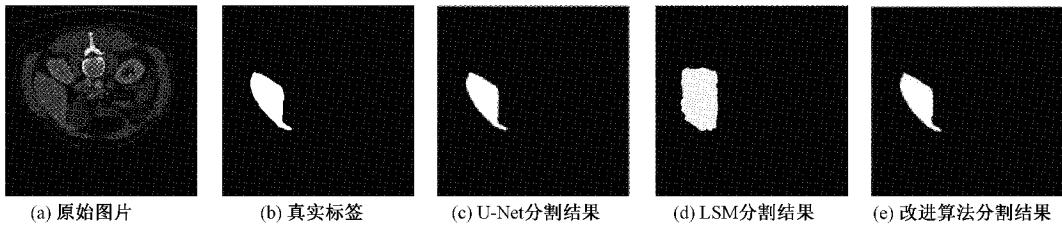


图 7 患者 4 的肝脏分割结果

信息的分割算法,所以对于这些问题十分敏感。

相比于传统的 U-Net 网络,改进之后的算法分割出来的结果更为精确(下面各图的子图(c)和(e)相比,改进之后的结果子图(c)就更接近真实值),这是因为在训练阶段改进后的分割方法使用未标注的数据进一步训练网络模型,一方面增强数据集的数量,降低了网络的过拟合;另一方面,改进之后的算法会从后续的水平集算法中学习一些图像信息,优化分割结果;而在测试阶段,本文算法使用水平集方法进一步对已训练模型的输出结果进行优化,所以最终的输出结果会更加的精准。

为进一步定量分析算法之间的差异性,本文采用常见的几种评价指标来衡量各个算法之间的优劣,它们分别是灵敏度(Sensitivity)、阳性预测值(positive predictive value, PPV)、Dice Score(DSC)、面积重叠误差(area overlap error, AOE)和相对面积差(relative area difference, RAD)<sup>[14]</sup>。

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (8)$$

$$\text{PPV} = \frac{TP}{TP + FP} \quad (9)$$

$$\text{DSC} = \frac{2TP}{2TP + FP + FN} \quad (10)$$

$$\text{AOE} = 1 - \frac{TP}{TP + FP + FN} \quad (11)$$

$$\text{RAD} = \frac{|FN - FP|}{2TP + FP + FN} \quad (12)$$

表 1 所示为本文提出改进之后的融合算法其 DSC、PPV 和 Sensitivity 的平均值分别可以达到 95.18%、96.47% 和 94.85%,并且 AOE 和 RAD 仅为 9.97% 和 7.69%。而原始水平集算法的 DSC、PPV 和 Sensitivity 的平均值为 84.82%、85.24% 和 84.21%,AOE 和 RAD 的平均值为 17.84% 和 16.64%;原始 U-Net 模型的 DSC、PPV 和 Sensitivity 的平均值为 92.11%、91.35% 和 91.17%,AOE 和 RAD 的平均值为 11.47% 和 10.27%;由此可见改进后的算法分割结果更加精准。对此进行分析可以知道,由于融合之后的分割算法相当于在原始 U-Net 网络上进行二次训练,在标注数据集数量不变的前提下增加了训练数据集的数量,从而改进了网络的权重,提高了分割精度;因为原始的水平集方法在分割灰度不均匀和边界轮廓模糊的医学图片存在局限性,并且无法有效利用到图像深层次信息,所以水平集曲线演化的结果不够理想,分割精度存在较大误差。

表 1 分割评价标准结果对比

对比算法	灵敏度		阳性预测值		Dice Score		面积重叠误差		相对面积差		%
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	
LSM <sup>[4]</sup>	84.21	0.95	85.24	1.40	84.82	1.50	17.84	1.37	16.64	1.97	
LBF <sup>[7]</sup>	87.97	1.01	87.59	1.25	88.76	1.45	14.66	1.43	14.28	1.86	
U-Net <sup>[9]</sup>	91.17	1.33	91.35	1.91	92.11	2.20	11.47	1.77	10.27	2.17	
SegNet <sup>[15]</sup>	92.48	1.21	93.96	1.79	93.43	2.33	10.24	1.89	8.01	2.01	
<b>Ours</b>	<b>94.85</b>	<b>1.17</b>	<b>96.47</b>	<b>1.54</b>	<b>95.18</b>	<b>1.79</b>	<b>9.97</b>	<b>1.55</b>	<b>7.69</b>	<b>1.80</b>	

## 4 结 论

本文提出了一种将传统水平集方法与 U-Net 网络融合的分割算法, 称为 ULSM-Net。与原始的 U-Net 分割网络相比, 改进后的算法使用更少的标注训练数据集, 得到的分割结果更加光滑平整; 与原始的水平集方法相比, 改进后的算法能够有效利用图像的深层次信息, 在分割存在弱边缘的目标区域时也可以获得较好的分割结果。为了进一步优化算法, 本文使用深度可分离卷积来降低网络的参数数量, 提高算法的效率; 与此同时, 为了优化水平集曲线演化的效果, 本文将 U-Net 输出的先验特征图与原始图像进行像素加权叠加, 增强目标区域的梯度值, 提高水平集的曲线演化精度。经过实验结果数据对比, 本文提出的算法与分别单独使用 U-Net 和水平集方法相比取得了更好的分割结果。但是利用基于图像先验信息的水平集演化得到的标签与专家标注的真实标签相比, 仍然存在一定的误差, 所以本文提出的分割算法同样存在一些不足之处。接下来的工作就是如何进一步优化水平集演化结果, 使其在基于先验信息的基础之上, 演化出的结果更一步的接近专家标注的真实标签。

## 参考文献

- [1] OSHER S, SETHIAN J A. Fronts propagating with curvature-dependent speed: Algorithms based on Hamilton-Jacobi formulations [J]. Journal of Computational Physics, 1988, 79(1):12-49.
- [2] MUMFORD D, SHAH J. Optimal approximations by piecewise smooth functions and associated variational problems[J]. Communications on Pure & Applied Mathematics, 1989, 42(5):577-685.
- [3] CHAN T F, VESE L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2):266-277.
- [4] LI C M, XU C Y, GUI C F, et al. Level set evolution without re-initialization: A new variational formulation[C]. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005:430-436.
- [5] 刘莹, 李筠, 杨海马, 等. 结合区域生长与水平集算法的宫颈癌图像分割[J]. 电子测量与仪器学报, 2020, 34(9):146-152.
- [6] 刘明, 杨胜寒, 高诚辉. 基于水平集方法的划痕形状表面视觉测量[J]. 仪器仪表学报, 2020, 41(2):184-194.
- [7] ZHANG K H, SONG H H, ZHANG L. Active contours driven by local image fitting energy [J]. Pattern Recognition, 2010, 43(4): 1199-1206.
- [8] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015:3431-3440.
- [9] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.
- [10] 雷军明, 王成钢, 刘雪燕. 基于改进 U-Net 的视网膜血管图像分割[J]. 信息技术与信息化, 2019, 10: 168-169.
- [11] ZHANG Z X, LIU Q J, WANG Y H. Road extraction by deep residual u-net[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(5): 749-753.
- [12] ZHANG X Y, ZHOU X Y, LIN M X, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018:6848-6856.
- [13] 包立君, 刘宛予, 浦昭邦. 融合图像局部能量和梯度的水平集分割方法[J]. 哈尔滨工业大学学报, 2011, 43(3): 44-48.
- [14] 丁亮, 张永平, 张雪英. 图像分割方法及性能评价综述[J]. 软件, 2010(12): 78-83.
- [15] BADRINARAYANAN V, KENDALL A, CIPOLLA R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.

## 作者简介

张宇豪, 硕士研究生, 主要研究方向为医学图像处理、通用目标检测。

徐磊, 博士研究生, 讲师, 主要研究方向为人工智能、数字图像处理等。

白一清, 本科生, 主要研究方向为数字图像处理。

E-mail: oswald@usst.edu.cn