

基于解的空间约束的超声前列腺图像分割算法^{*}

石勇涛^{1,2} 尤一飞¹ 高 超¹ 李 伟¹ 雷帮军^{1,2} 储志杰¹

(1. 三峡大学计算机与信息学院 宜昌 443002;

2. 湖北省水电工程智能视觉监测重点实验室(三峡大学) 宜昌 443002)

摘 要: 超声前列腺图像分割是一项极具挑战的任务,目前传统检测算子面对灰度对比不显著的部位难以去辨别,神经网络则忽视了超声图像信噪比低的影响且消耗大量算力。为解决以上问题提出一种高效的基于解的空间约束的超声前列腺图像分割算法,将分割问题转化为求边界点问题,首先对法向量算子改进,改善其检测能力;然后使用降噪自编码器根据形状约束克服噪声优化解的空间;最后引入迭代算子将解的范围限制在极小的区域实现精准分割。实验表明,模型交并比型(IoU)达94.4%,DSC值约97.05%,精度高于当前热门的神经网络算法,且更轻量化。

关键词: 超声前列腺图像分割;解的空间约束;降噪自编码器;形状约束

中图分类号: TP391.41;R697.3 **文献标识码:** A **国家标准学科分类代码:** 520.6

Ultrasonic prostate segmentation algorithm based on solution space constraint

Shi Yongtao^{1,2} You Yifei¹ Gao Chao¹ Li Wei¹ Lei Bangjun^{1,2} Chu Zhijie¹

(1. College of Computer and Information Technology, China Three Gorges University, Yichang 443002, China;

2. Hubei Key Laboratory of Intelligent Vision Based Monitoring for Hydroelectric Engineering, China Three Gorges University, Yichang 443002, China)

Abstract: Ultrasound prostate image segmentation is a very challenging task. At present, traditional detection operators are difficult to identify the parts with insignificant gray contrast. Neural networks ignore the effect of low signal-to-noise ratio of ultrasonic images and consume a lot of computing power. In order to solve the above problems, this paper proposes an efficient segmentation algorithm of ultrasonic prostate images based on spatial constraints of solutions, which transforms the segmentation problem into a boundary point problem. Firstly, the normal vector operator is improved to improve its detection ability. Then the denoising autoencoder is used to overcome the space of the noise optimization solution according to the shape constraint. Finally, iteration operator is introduced to limit the range of solution to a very small area to achieve accurate segmentation. Experiments show that the IoU of this model is 94.4% and the DSC value is about 97.05%, which is higher than the current popular neural network algorithm and lighter.

Keywords: ultrasound prostate image segmentation; spatial constraint of the solution; denoising autoencoder; shape constraint

0 引 言

前列腺疾病成为当前全球最常见的人体内脏疾病之一,是威胁男性健康最大的隐患。近年来由于我国经济水平和生活质量的不断提高,显著的人口老龄化问题和生活方式的改变导致我国男性的前列腺癌发病率有明显增长,

前列腺炎在中青年的发病率高达50%^[1]。

在临床实践中,经直肠超声(transrectal of ultrasound, TRUS)是图像引导前列腺癌活检和医治的常规成像形式。从超声图像中分割前列腺并对其进行定位和估量对于前列腺疾病的治疗有着重要意义^[2]。对前列腺的分割极其考验医生的专业素养,并且这一方式费时、费力。

收稿日期:2022-11-30

^{*} 基金项目:国家自然科学基金(61871258)、水电工程智能视觉监测湖北省重点实验室建设(2019ZYD007)项目资助

由于探头与患者接触不良、成像过程中回声信息容易受干扰,TRUS 图像总携带一些噪声伪影,具有灰度不连续的特征,它会丢失图像边缘的对比度,掩盖目标信息,给医师的后续处理带来了困难。因此,自从前列腺超声技术出现以来,如何克服斑点噪声带来的影响并实现精准的自动化分割一直以来受到研究人士的高度关注。

目前医学影像领域有许多优秀的自动分割算法^[3-6]。计算机分割作为最主流的自动化分割手段,主要分为两类:一类是依据具体的分割问题而提出的基于不同特征的传统方法。基于形状的分割如 Yan 等^[7]开发了一种局部活动形状模型,通过部分活动形状模型估计阴影区域的缺失边界以解决分割问题;基于轮廓的分割如 Wang 等^[8]提出一种改进的基于先验形状的水平集分割算法,通过高斯模型建立先验形状统计模型,并使用余弦函数表达传统先验形状和局部强度信息的能量项拟合,以解决 TRUS 和 MRI 中的前列腺分割问题。然而上述传统方法也存在各自的缺陷,文献^[7]在分割过程中受前列腺不规则形状的影响,造成局部区域分割不准确;文献^[8]针对 TRUS 图像前列腺边界模糊问题处理不足,相比于对 MRI 图实现的分割效果更差一些。另一类则是端到端训练的深度学习学习方法。Hambarde 等^[9]提出一种基于放射组的深监督 U-net(deeply supervised U-net)模型,利用其对称的 U 形结构对图像进行上采样、下采样并融合对应特征图的方式来分割病变前列腺。Wang 等^[10]提出具有深度注意特征的前列腺分割网络(deep attentional features,DAFs),充分利用不同层的编码信息来解决 TRUS 图像中前列腺边界分割问题;陈洪涛等^[11]建立双通道收缩路径和扩张路径构成双通道 U-net(DU-net),将双通道输出的特征图融合得到分割图像,对混淆区域的边界有着良好的辨别。深度学习虽然实现了不错的分割性能,但现有方法仍存在如下问题:1)提取特征存在冗余,如 Deeply Supervised U-net 模型在训练时会为每个像素取一个 patch,而超声图中每相邻像素的 patch 是非常相似的,造成了很多冗余;2)由于深度学习大多要处理图片每个像素点,而且部分结构极其复杂的神经网络如 DAFs 加大了算力的负担,造成模型训练缓慢;3)由于医学图像涉及患者隐私而且标注成本极高,导致 TRUS 图像数据稀少,而小规模数据集应用到神经网络模型极易导致过拟合,而且这些原始数据集在分割之前要做相应的预处理工作,如 DU-net 需要先采用特定的扩散算法对图像作强化处理。

关于该领域的发展方向,Jiang 等^[12]认为神经网络虽然取得了良好的结果,但这类方法没考虑个体数据的特征,并认为加入传统机器学习方法可以有效弥补这一缺陷,机器学习与深度学习的结合会是一个新的发展趋势,因此本文贯彻这一方向。受 Hodge 的法向量轮廓算子的思路^[13],根据前列腺边界处的灰度变化设计对应的边界算子就能很好地定位相应的边界点,有效限制了边界点的范围区间,并且本文对传统法向量算子进行改进,加入邻

域信息形成联合法向量算子,实验表明改进的算子能检测出更多真实边界点,效果明显优于传统边界算子;为克服噪声的干扰,这里引入降噪自编码器模型(denoising auto-encoder,DAE)^[14]来处理,对该模型的使用并不是常用的通过学习图像来进行去噪,而是学习前列腺的形状特征并充分利用其良好的泛化能力去重构一个尽可能匹配的前列腺边界。最后为更进一步精细的定位边界点,提出一种混合上述两类边界的迭代算子通过逐步约束边界解的搜索空间寻找真实边界点进而实现分割。这种混合模型方案有效避免了神经网络学习语义信息的困难和 TRUS 图像噪声的影响;逐步约束边界解的范围的方式弥补了传统算子在分割精细度上存在瓶颈的不足。

本文不需要依赖大量数据集便可实现快速精准的分割,减少了内存消耗。同时结合邻域边界法向量算子的边缘检测能力和降噪自编码器的去噪及对前列腺形状特征的学习能力细化边界。逐步约束解的空间得到的边界准确度更高,实现的分割精度更好。

1 构造解的空间

一般深度学习需要逐步分类图像每一像素,TRUS 图像前列腺位置相对固定,逐像素搜索易夹杂大量冗余信息。Chan 等^[15]认为前列腺图像 I_0 是由两个近似分段常数函数强度的区域组成的,他们的值为 I_0^i 和 I_0^o ,本文进一步假设需要检测的目标由带有该值的区域表示,这里表示边界为 S_0 ,因此目标内部和外部分别表示为 $S_{(inside)}$ 和 $S_{(outside)}$ 。根据灰度信息构造的能量函数为:

$$E_{(in)}(S) + E_{(out)}(S) = \int_{S_{(inside)}} |I_0(x, y) - C_1|^2 dx dy + \int_{S_{(outside)}} |I_0(x, y) - C_2|^2 dx dy \quad (1)$$

拟合项最小化如下:

$$\inf_S \{E_{(in)}(S) + E_{(out)}(S)\} \approx 0 \quad (2)$$

式中: $E_{(in)}$ 表示前列腺内部能量函数; $E_{(out)}$ 表示前列腺外部能量函数; S 表示任意变量曲线; C_1 表示曲线内部灰度平均值; C_2 表示曲线外部灰度平均值。

通过式(1)、(2)看出,当曲线 S 位于前列腺内部时, $E_{(in)}(S) \approx 0, E_{(out)}(S) > 0$;当曲线 S 区域与前列腺区域部分相交, $E_{(in)}(S) > 0, E_{(out)}(S) > 0$;曲线 S 正好在前列腺边界上时, $E_{(in)}(S) \approx 0 \approx E_{(in)}(S_0), E_{(out)}(S) \approx 0 \approx E_{(out)}(S_0)$;当曲线 S 位于前列腺外部时, $E_{(in)}(S) > 0, E_{(out)}(S) \approx 0$ 。曲线位置情况分类如图 1 所示。

TRUS 图像噪声的干扰影响了能量函数的拟合过程,造成分割曲线 S 和 S_0 差别过大。为减少噪声干扰,本文受 Hodge 的启发,将能量函数离散化,先利用先验知识对超声图像中的待分割区域做初始定位,形成一个宽泛的轮廓曲线,对曲线进行等间距采样,将该曲线离散化表示 $P_{Boundary} = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$,并沿各点切面垂线方向作法线,法线由负到正指向前列腺外部,长度为

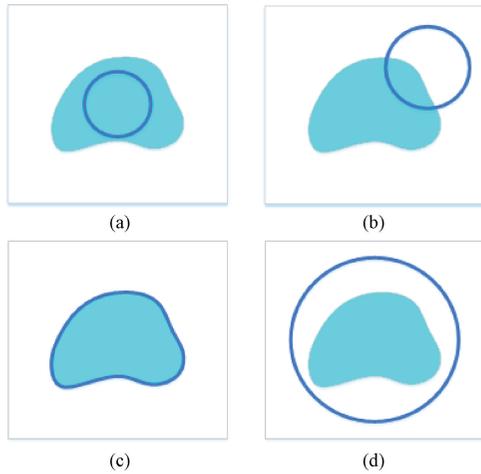


图1 曲线位置情况分类

d_{vector} , 法向量贯穿了真实边界。本文在法向量上搜索真实边界点, 真实边界点作为本问题的解被限定到一个固定的范围, 100 根法向量固定的范围构成了本文解的空间, 如图 2 所示。

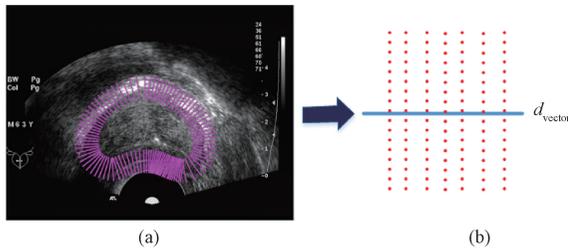


图2 法向量解空间示意图

图 2(a) 解的范围 $\text{Range}_{\text{solutionspace}}$, 这里 $\text{Range}_{\text{solutionspace}} = d_{\text{vector}}$ 。由于 TRUS 图像前列腺边界存在由内向外逐步由暗到亮的过渡的特征, 理想的真实边界点往往就是该点法向量上灰度突变处。通过这一方式, 将最优解限制在局部法向量上, 极大减少解的搜索区间。根据法向量上的局部灰度变化找出最优解, 得到的边界一般是符合边缘特征的, 然而法线虽然覆盖了真实边界, 但是若搜索范围太大容易被图像的部分伪影误导从而得到不正确的解。因此, 如何避开噪声并优化解的空间并对法向量上正确采样边界点是本文的关键。

2 求解空间

为解决第 1 节的问题, 将问题具体化, 列出以下算法主要针对法向量上的最优解进行计算, 算法主要根据有图像边缘信息以及形状信息, 逐步优化解的空间。

2.1 法向量边界算子

为求出法向量上的最优解, 对每根法向量上设置边界算子。该边界算子的描述如下。

假设在法向量上任意一点 $p(x, y)$ 的索引值为 ind ,

沿点 p 正负方向各取 m 长度的灰度向量, 并定义一段表示各点灰度的点集 $f = [f_{ind+m}, f_{ind+m-1}, \dots, f_{ind}, \dots, f_{ind-m+1}, f_{ind-m}]$, f_i 表示行索引值为 i 的点的灰度值。前列腺轮廓边界的带状图如图 3 所示。

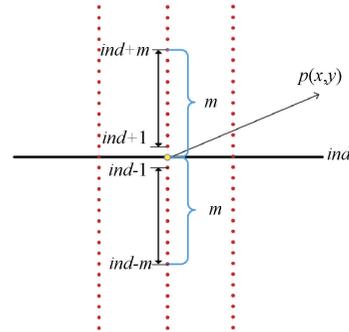


图3 边界算子示意图

$$C_{ind} = \sum_{i=ind+1}^{ind+m} f_i - \sum_{i=ind-m}^{ind-1} f_i \quad (3)$$

$$\text{Range}_{\text{solutionspace}} \in [m, d_{\text{vector}} - m] \quad (4)$$

$$ind = \text{argmax} C_{ind} \quad (5)$$

式中: i 表示灰度向量的取值范围; ind 表示某点的行索引值; C 为所有 C_{ind} 构成的集合。式(3)计算沿方向上某点上半区域与下半区域的累积灰度值的灰度差, 在法向量上滑动该点做相同处理并构成集合 C_{ind} , 式(4)给出了点 p 的滑动范围, 即解的空间范围, 由于是在定长的法向量上定义的算子, 解的范围相对于 d_{vector} 两端各减少了 m 长度。式(5)确定最佳分割点, 即在 C 中取灰度差最大时对应的行索引, 就是法向量上最优解的位置。通过这种方式对每根法向量都遍历一遍, 即可得到大致的轮廓边界。

图 4 所示是各法向量上所计算得出的每根法向量符合理想的边界点组成的前列腺轮廓, 但是该轮廓在整体观感上不够光滑, 很多边界点严重脱离了真实边界且相邻点之间不连续, 不符合前列腺边界特征, 这里将这些点称为噪声分割点。噪点产生的主要原因在于 Hodge 的每根法向量只考虑自身经过的灰度信息, 最终求解得到的边界点就比较片面, 容易受自身法向量所覆盖的图像噪声信息误导。因此考虑邻域法向量灰度信息可以有效滤除噪点, 改

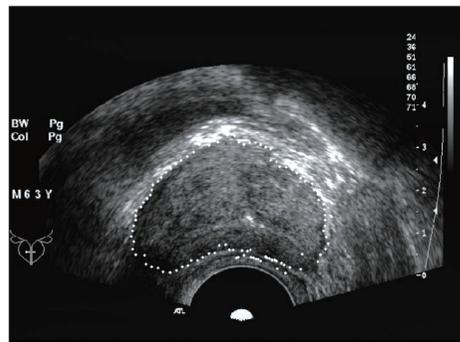


图4 法向量算子效果

善相邻边界点落差很大的现象。

2.2 邻域法向量边界算子

针对 2.1 节对邻域信息考虑的不足,对算子进行改进,在该算子的基础上加入邻域信息,即将单根法向量的邻域法向量充分考虑进来,对 $\vec{n}_k[ind]$ 的位置进行矫正。边界算子 C 的改进如图 5 所示。

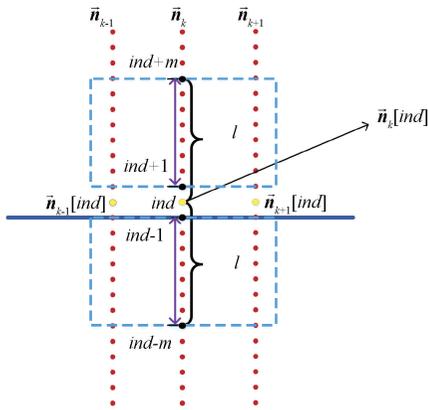


图 5 邻域法向量算子示意图

图 5 包含 3 根法向量分别为 \vec{n}_k 及其邻域的 \vec{n}_{k-1} 和 \vec{n}_{k+1} 。在法向量 \vec{n}_k 上取索引值为 ind 的点,则该点可以表示为 $\vec{n}_k[ind]$,其前后邻域法向量上相同索引值的点在图中已标识出来。 $\vec{n}_k[ind]$ 的边界算子为:

$$C_{neigh} = \sum_{N=k-num}^{k+num} C_{ind} \quad (6)$$

式中, num 表示点 $\vec{n}_k[ind]$ 处单侧邻域点的个数; N 代表邻域部分法向量的个数。式(6)计算的是图 4 上边界方框与下边界方框的灰度差,而不再仅仅是单根法向量上的灰度信息。因此,边界算子 C_{neigh} 包含的灰度信息远大于,从而避免少数分割点因为局部的灰度噪声导致噪声分割点的产生。

改进边界算子后得到的效果如图 6 所示,相比于图 4,图 6 有更加平滑的轮廓,有效恢复单个噪点,接近真实边界。然而其中存在问题:1)图 6 边界下半部分的异常点,原因是大量异常点错误的邻域信息影响了该边界算子

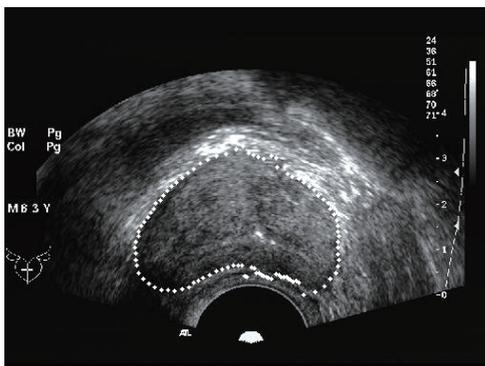


图 6 算子改进后的分割结果

的分割效果;2)另一个重要原因是改进后的算子并没有有效约束法向量上解的空间范围,边界算子在滑动过程中容易受部分阴影的误导。因此该分割效果还不满足当前医疗机构的要求,针对上述问题,如何对根据语义信息得到的不规则的边界加入形状特征约束来缩小解的空间范围对于当前的分割任务是十分必要的。

2.3 优化解的空间

为融入前列腺边界特征信息以及对解的空间进行优化,本文加入 DAE 模型进行后续处理。Vincent 设计的降噪自动编码器是自编码器(autoencoder, AE)^[16]的一种变形,如图 7 所示,DAE 在 AE 模型的基础上加入对输入数据进行部分损坏处理,并将该数据输入到训练好的编码器里进行编码、解码,重建一个“干净”的数据,数据破损处理可增强模型的泛化能力。

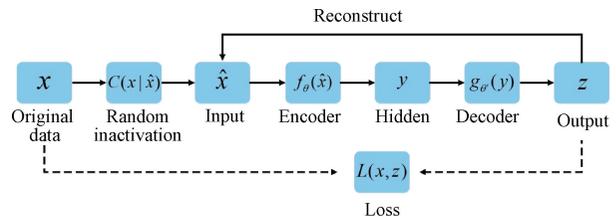


图 7 降噪自编码器

医学图像领域中,DAE 大多应用于图像整体的去噪处理,如代豪等^[17]设计的基于模块化降噪自编码器的视网膜 OCT 图像降噪方法主要针对 OCT 成像中光线散射等因素引起的噪声干扰问题。本文不是对 TRUS 图像进行去噪而是去尽可能拉回上述异常边界点到真实边界,优化解的空间。充分利用 DAE 模型的去噪能力过滤掉不规则的噪点以及对前列腺的特征学习能力重构一个新的前列腺边界。

在数据处理阶段,本文采用随机数据失活的方式,即将一定比例的数据强制赋值为 0,被赋值为 0 的数据对网络不起任何作用。对 n 维的边界点集 $x = \{x_1, x_2, \dots, x_n\}$ 进行随机失活^[18]处理,获得破损数据 $\tilde{x} = \{\tilde{x}_1, \tilde{x}_2, \dots, 0, \dots, 0, \dots, \tilde{x}_n\}$,即加噪过程。再将破损的 \tilde{x} 作为输入,利用图 7 的模型接受训练来填充这些人为引入的“空白”。编码部分为:

$$y = f_{\theta}(\tilde{x}) = s(w \cdot \tilde{x} + b) \quad (7)$$

式中: f_{θ} 表示编码函数; $\theta = \{w, b\}$, w 表示网络连接权重, b 表示偏置值。由式(7)得到编码后的中间数据 y 。

然后解码器通过式(8)将中间数据映射回“重构”向量 z 。

$$z = g_{\theta'}(y) = s(w' \cdot y + b') \quad (8)$$

式中: $g_{\theta'}$ 表示解码函数; $\theta' = \{w', b'\}$ 。 w' 表示网络连接权重, b' 代表偏置值,其中 $w' = w^T$ 。

最后,每一个训练的 x_i 被映射到对应的 y_i 和 z_i 。为使最终输出的 z 和原始输入数据 x 尽量相似,建立了重

构数据 z 与原始数据之间的损失函数。这里使用传统的均方误差 $L(x, z) = \|x - z\|^2$ 来不断优化网络参数。图7步骤只需要循环执行直到损失收敛即可。DAE 的损失函数为：

$$\{\theta, \theta'\} = \operatorname{argmin} \frac{1}{n} \sum_{i=1}^n L(x_i, z_i) = \operatorname{argmin} \frac{1}{n} \sum_{i=1}^n L(x_i, g_{\theta'}(f_{\theta}(x_i))) \quad (9)$$

2.4 迭代算子

加入 DAE 模型主要针对领域法向量边界上的噪点进行处理,它能将突兀的噪点一定程度上拉回到正常的边界上,保证输出的边界是光滑、没有缺口的,但 DAE 在实际处理过程中会处理每一个点,可能造成部分点有所移动,因为它只是通过对前列腺特征的学习来输出自己的分割边界,结果并不一定准确。尽管如此,该模型还是有效地让异常点恢复到正常边界,缩小了解的空间。本文为细化分割求出最优解,将邻域法向量边界算子得到的边界点和后续的 DAE 点集结合起来,充分融合前者的语义信息与后者的形状特征信息,引入迭代算子来缩小解的范围。思路如图8所示。

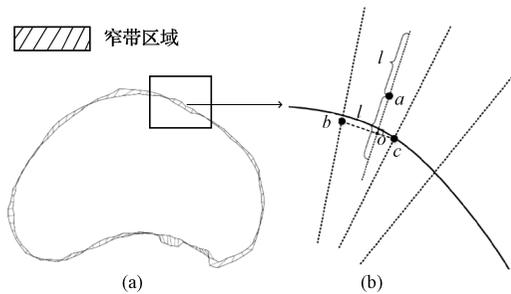


图8 迭代算子示意图

图8(a)将两类边界区域叠放在一起,重合的部分代表两类点已收敛在真实边界上,而突出的阴影部分就是两类点形成的窄带,也就是两边存在争议的地方,可以看出,本文需要获得的最优解就在窄带区间内,相比于初始工作搜索范围更小了。图8(b)为窄带的局部示意图,本文认为真实边界点位于两类边界点之间,作出单个 DAE 点与两法向量点连线之间的距离线段 ao 。 ao 是一条经过真实边界的线段,也是该区域解的空间范围。后续处理类似于2.1节,沿 ao 方向作出法线,定义灰度向量 l ,滑动并计算得出最优分割点。相比之下,迭代算子很大程度上综合了前列腺图像边界的语义信息和形状特征信息,利用两者的相互作用将最优解的搜索范围限定在一个固定的足够小的区域进而实现细化分割。

3 实验

3.1 实验步骤

为衡量本文方法的可靠性,本次实验采用的超声前列腺图像全部由某家医院所提供的,总共150张图片,每幅

图片的分辨率为 576×768 pixels,每个像素的大小是 $0.138 \text{ mm} \times 0.138 \text{ mm}$,并且由经验丰富的放射科医生为每幅图片提供了目标边界的分割标签。不同于深度学习网络,本文实验训练、测试 DAE 时使用的是边界坐标作为输入,故选择分割标签上的100个点来代表真实边界;每个点由横纵坐标来表示;一共获得132幅图片的边界坐标。通过数据增广(即对分割边界坐标平移、旋转和放缩)将132幅图片边界数增加到13200用于训练。具体分割流程如图9所示。

分割流程中,一阶段采用邻域法向量算子对输入的原图进行初始分割并提取带有坐标的边界点集,二阶段将其输入到已经训练好的 DAE 模型进行去噪重构处理。为了细化分割,本文将一阶段得到的邻域法向量点集和二阶段的 DAE 点集综合起来作循环迭代处理,此时获得了第2轮迭代的法向量灰度差 $C_{\text{ind}}^{(2)}$ 。 $C_{\text{ind}}^{(2)}$ 可能受到外部噪声点的污染,使得该点不在真实边界上,因此依旧需要将点集 $C_{\text{ind}}^{(2)}$ 送入降噪自编码器内产生新的点集 $z^{(2)}$,该区域内新的点应当被限定在更小范围内。当解的空间滑动范围不大于 threshold 时,边界默认已收敛,迭代结束并输出最终分割结果。设定的阈值 threshold 代表像素距离,这里根据经验默认为2。

本文实验随机选取未经训练的编号为24号、130号、157号、413号、738号以及1024号的图片来测试本文方法的分割效果。

3.2 实验环境与参数

本文在训练环境为 NVidia GeForce GTX 1660s 的设备上对上述的数据集进行训练,中间隐藏层设置为2000,迭代训练5000轮得出最优模型以对测试集进行测试。

3.3 评估指标

为了对本文方法进行定量的评估,现采用并并比 (IoU)^[19]、相似系数 (Dice)^[20] 以及敏感度 (Sensitivity) 3个指标进行对比评价。

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

$$\text{Dice} = \frac{2TP}{2TP + FP + FN} \quad (11)$$

$$\text{Sensitivity} = \frac{TP}{FN + TP} \quad (12)$$

式中: FN 表示真值图像重合区域以外的部分, TP 表示真值图与分割图的重合部分, FP 指的是分割轮廓重叠区域以外的部分。图10所示为邻域法向量处理的效果和最终迭代的结果图并标出精度。

结合图10可以看出,邻域法向量算子由于没有约束解的空间,即便加入邻域信息也无法实现对边界的精准定位,平均交并比 (mIoU) 只有91.9%。相比之下加入 DAE 模型并迭代处理得到的边界更加光滑,如图10E后续处理极好的纠正了法向量处理下的边界下半部的异常点, IoU

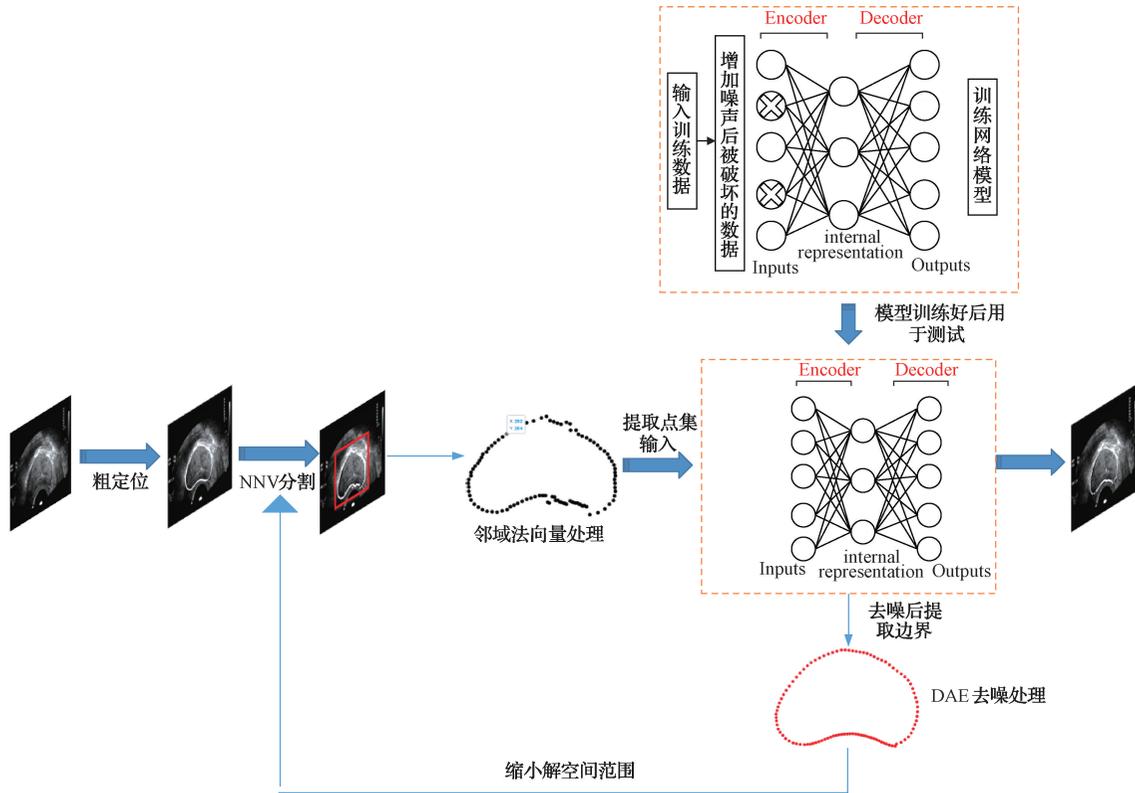
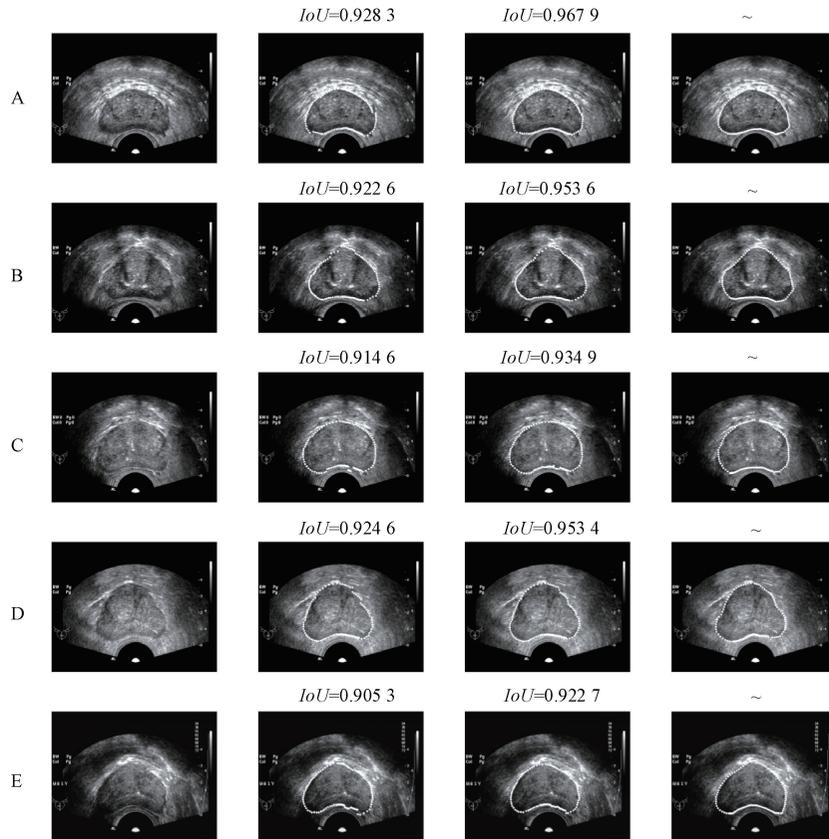


图9 分割流程



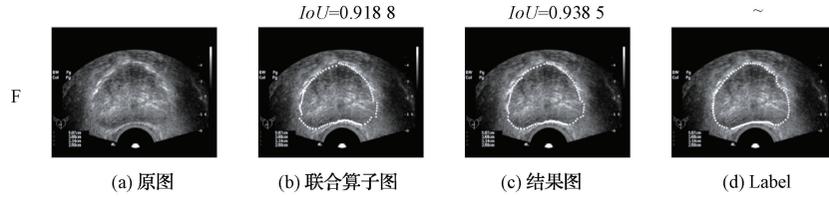


图 10 效果图

提高了 1.74%。最终结果 mIoU 提高了 2.48%。迭代算子的折中处理充分融合两类边界的特点,缩小了解的空间范围,得到前列腺边界不仅符合形状特征并且满足边缘灰度特征,更富有真实性。

为选取最佳的 DAE 训练模型,在此基础上本文对 DAE 的失活率(corruption level)参数作出调整,分别选取失活率为 0.1、0.15、0.2、0.25、0.3 做对照实验,并记录 5 个指标下对各张图片的分割精度。对应的箱线图如图 11 所示,精度表如表 1 所示。

图 11 和表 1 的数据表明,随着 corruption level 的逐步加大,DAE 对初分割边界的去噪效果也逐步提升,直到 corruption level=0.2 时,DAE 的优化效果达到最佳,平均

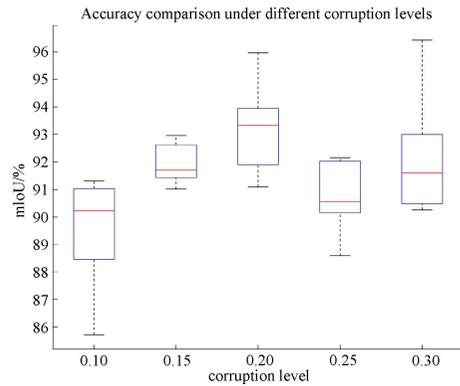


图 11 IoU 指标箱线图

表 1 对照实验

Corruption	0.10			0.15			0.20			0.25			0.30		
	IoU	Dice	Sensitivity												
图 10A	0.857 3	0.923 1	0.897 2	0.915 8	0.956 0	0.958 5	0.910 9	0.953 4	0.921 5	0.904 8	0.950 0	0.910 1	0.906 8	0.951 1	0.921 1
图 10B	0.908 9	0.952 3	0.933 2	0.910 2	0.953 0	0.925 4	0.930 5	0.964 0	0.943 3	0.885 9	0.939 5	0.899 5	0.902 6	0.948 8	0.918 7
图 10C	0.884 6	0.938 8	0.938 8	0.926 2	0.961 7	0.950 2	0.919 1	0.957 9	0.938 1	0.906 1	0.950 7	0.924 9	0.925 2	0.961 1	0.945 1
图 10D	0.895 6	0.944 9	0.929 1	0.929 6	0.963 5	0.948 4	0.939 5	0.968 8	0.946 7	0.920 3	0.958 5	0.933 1	0.904 8	0.950 0	0.932 7
图 10E	0.913 2	0.954 6	0.952 7	0.918 4	0.957 5	0.941 1	0.959 7	0.979 4	0.966 8	0.921 6	0.959 2	0.934 8	0.964 3	0.981 8	0.973 6
图 10F	0.910 4	0.953 1	0.946 5	0.914 3	0.955 3	0.936 5	0.936 1	0.967 0	0.945 8	0.901 5	0.948 2	0.913 7	0.929 9	0.963 7	0.947 8

IoU 达 93% 以上,往后效果逐渐下滑。这表明过低的失活率训练出来的模型面对受噪声污染严重的边界不好进行去噪处理,失活率过高的模型重构出来的边界可能会失去它原有的形态特征,降低了分割精度。因此采用失活率为 0.2 时训练的模型实现了最佳适中处理。

为衡量本文方法的准确性,将其与近年来的深度学习模型进行对比,用同样的数据集进行训练, batchsize 设为 4,分别对本次数据集迭代训练 10 000 轮,存储最终的模型进行测试,用于训练的 GPU 为 Tesla V100 32G,深度学习平台为 Paddlepaddle。另外本文方法在内的所有模型测试使用的 CPU 为 Intel(R) Core(TM) i5-10500 CPU @3.10GHz 3.10GHz。

为验证本方案的精确性和高效性,对比传统的 Hodge 检测算子、专用于分割的 BiseNet^[21]、经典的医学分割模型 U-net^[22]、SegNet^[23]以及近两年的 U²-net^[24]的效果图、精度以及每幅图的平均测试运行时间如表 2、3 所示。

传统机器学习算子的主要依据是前列腺边界周围显

著的灰度对比度,算子注重对边缘的探寻,推理速度十分迅捷,然而这类算子存在一些弊端。表 3 中 Hodge 算子分割形成的二值图 10C、E、F 明显存在一些缺口,平均 IoU 精度只有 87.92%。原因是过于单一的灰度信息不足以准确捕获边界,每根法向量上的算子都按照各自片面的灰度信息搜索单个边界点,这种方式受噪声影响很大,从而容易造成前后边界点在空间上差异较大,而前列腺的边界往往都是趋于完整平滑的,本文提出的联合法向量算子在一定程度上缓和了这一问题,增加法向量算子的邻域信息,使相邻的边界节点合理联系起来,形成更平滑的边界,但依旧存在不合理的异常边界,根源是算子的检索范围过大覆盖了伪影部位,导致其在滑动检索时形成误判,避开了真实边界,而本文加入 DAE 的核心在于学习前列腺边界的形态特征并有效拉回异常边界,压缩算子的检测范围,迭代算子本质是在压缩后的法向量范围进行再次检测,这种逐步求精的方式确保了前列腺各处边界的准确性。

表2 对比试验分割精度比较

方法	Hodge 算子	U-net	BiseNet	SegNet	U ² -net	本文	Mask
图 10A							
图 10B							
图 10C							
图 10D							
图 10E							
图 10F							
IoU	0.879 2	0.938 7	0.899 8	0.895 3	0.954 7	0.944 0	—
DSC	0.917 6	0.968 3	0.921 7	0.940 4	0.970 1	0.970 5	—

表3 分割效率与消耗

模型	每张图片的平均 预测时间/s	平均占用 内存/MB
Hodge 算子	0.9	87
BiseNet	3	169
U-net	5.3	2 083
SegNet	5.6	1 390
U ² -net	2	734
本文	1.6	421

卷积神经网络的监督学习在分割邻域取得了不小的成就,主要对图像逐个像素分类提取目标类来实现分割,精度好坏关键在于两点:数据集容量和算力。TRUS 图像不同于多通道图,机器设备和一些外来因素导致成像不够清晰、信噪比低,边界缺乏辨识度,因此网络需要更多的数据集来支持模型的优化,这也涉及到巨大的算力。例如本文用同样的数据集经过轻量级的双边分割网络(BiseNet)进行处理,该网络提出的特征融合模块和注意力模块非常

适合适用于图像的语义分割,注意力模块应用到的全局平均池化减少了计算代价,实验表明,该方法的确具有不错的推理速度,而且分割过程对内存的占用更少,然而训练收敛后 IoU 不到 90%,DSC 值也是所有实验模型中的最低,该语义信息体现的并不可靠,这表明在面对 TRUS 图像的大量的噪声干扰时,高精度的分割也需要足够参数数量的支撑;专用于医学图像领域分割的 U-net 和 SegNet 是主要由卷积层堆叠的对称的像素处理级网络,涉及到庞大的参数量与计算量,实验测得了不错的 DCS 精度分别为 96.83%和 94.04%,然而结合表 3 发现 U-net,对图 10B 的处理以及 SegNet 对图 10D 的处理图都出现了背景类被错误归为目标类的现象。其原因在于神经网络在处理分割问题时多数是对图像中的每个像素逐步分类,而 TRUS 图像的斑点噪声主要就集中在目标物外部,即便是以算力和时间作为代价,这两类网络也无法有效克服这一影响;U²-net 则是两层嵌套的 U 形结构,其中残差 U 形模块(Residual U-block,RSU)能从不同尺度获取更多上下文信息,而且这些模块使用了池化操作,即使网络加深依旧

不会加大计算量,性能优于 U-net,该模型获得所有方法中的最高精度,并在平均耗时和内存占用上明显占优。本文处理过程目标直指前列腺边界,注重学习前列腺的形态特征,以一种克服噪声和不规则形状的算子来生成符合实际情况的前列腺边界,相比于深度学习处理起来更加精简。再者这种方式参数量大大少于神经网络且回避了前列腺内外部大量噪声的干扰,因此必不会出现错误分类冗余信息现象,另外本方案加入的 DAE 是一种轻量级的 3 层神经网络,只针对输入的边界点进行加工,也简化了大量的计算成本,平均预测时间和内存占用都达到了最优,总的来说保证了精度与分割速度上的最佳折中处理。

4 结 论

医学超声图像存在不良的噪声污染,对比度低,边缘模糊不清且数据量欠缺,如何克服这些不良因素并提高分割的准确性和高效性具有不小的挑战。本文研究的核心在于对传统机器学习算子的改进以及在神经网络降噪自编码器的应用上的创新。改进后形成的联合法向量算子可获得更充分的边缘灰度信息,形成相对连贯平滑的初始化边界;为加强本研究的抗噪能力,引入 DAE,本文输入给 DAE 的并不是往常的整幅图片,而是边界的坐标点,通过对这些边界形态特征进行学习,然后对带有噪点的初始化边界进行去噪重构,最后本文研究的难点在于对前列腺各个部位的逐步精细化分割,当两类边界点重合,引入迭代算子对其存在争议的窄带部分(解的空间)进行逐步约束直至收敛,最后形成一个近乎完美匹配的真实边界。本文研究是基于机器学习算子和神经网络的混合模型,符合未来发展趋势,充分融合两类方法的优势实现了一种不依赖庞大数据集和机器设备并能克服噪声污染的前列腺分割算法。

参 考 文 献

- [1] 中国抗癌协会泌尿男生殖系统肿瘤专业委员会前列腺癌学组. 前列腺癌筛查中国专家共识(2021年版)[J]. 中国癌症杂志, 2021, 31(5): 435-440.
- [2] 黄建波, 蔡迪明, 罗燕. 基于特征学习框架的前列腺超声图像分割方法研究[J]. 生物医学工程与临床, 2018, 22(6): 610-616.
- [3] 许瑶瑶, 单剑锋. 基于密集连接和 Inception 模块的前列腺图像分割[J]. 电子测量技术, 2022, 45(15): 151-157.
- [4] 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.
- [5] 钟思华, 王梦璐, 郭兴明, 等. 基于改进 VNet 的肺结节分割方法研究[J]. 仪器仪表学报, 2020, 41(9): 206-215.
- [6] 纪秋浪, 王继红, 杨晨, 等. 多尺度双重注意力网络医学图像分割模型[J]. 国外电子测量技术, 2022, 41(6): 65-71.
- [7] YAN P, XU S, TURKBEBY B, et al. Discrete deformable model guided by partial active shape model for TRUS image segmentation[J]. IEEE Transactions on Biomedical Engineering, 2010, 57(5): 1158-1166.
- [8] WANG W, PAN B, YAN J, et al. Magnetic resonance imaging and transrectal ultrasound prostate image segmentation based on improved level set for robotic prostate biopsy navigation[J]. The International Journal of Medical Robotics and Computer Assisted Surgery, 2021, 17(1): 1-14.
- [9] HAMBARDE P, TALBAR S, MAHAJAN A, et al. Prostate lesion segmentation in MR images using radiomics based deeply supervised U-net[J]. Biocybernetics and Biomedical Engineering, 2020, 40(4): 1421-1435.
- [10] WANG Y, DENG Z, HU X, et al. Deep attentional features for prostate segmentation in ultrasound[C]. Medical Image Computing and Computer Assisted Intervention-MICCAI 2018: 21st International Conference. Springer, 2018: 523-530.
- [11] 陈洪涛, 高艳, 朴莹, 等. 双通道 Unet 模型对前列腺自动勾画的研究[J]. 中国医学装备, 2022, 19(7): 17-21.
- [12] JIANG J, GUO Y, BI Z, et al. Segmentation of prostate ultrasound images: The state of the art and the future directions of segmentation algorithms[J]. Artificial Intelligence Review, 2022, 56(1): 615-651.
- [13] YAN P, XU S, TURKBEBY B, et al. Optimal search guided by partial active shape model for prostate segmentation in TRUS images[C]. Medical Imaging 2009: Visualization, Image-Guided Procedures, and Modeling. SPIE, 2009, 7261: 478-488.
- [14] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11(12): 3371-3408.
- [15] CHAN T F, VESE L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277.
- [16] MICHELUCCI U. An introduction to autoencoders[J]. Applied Deep Learning with Tensor Flow 2, 2022: 257-283.
- [17] 代豪, 杨亚良, 岳献, 等. 基于模块化降噪自编码器的视网膜 OCT 图像降噪方法[J]. 光学学报, 2023, 43(1): 58-65.

- [18] WANG S H, CHEN Y. Fruit category classification via an eight-layer convolutional neural network with parametric rectified linear unit and dropout technique[J]. *Multimedia Tools and Applications*, 2020, 79(21): 15117-15133.
- [19] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2019:658-666.
- [20] FIDON L, LI W, GARCIA-PERAZA-HERRERA L C, et al. Generalised wasserstein dice score for imbalanced multi-class segmentation using holistic convolutional networks[C]. 3rd International Workshop on Brain-Lesion (BrainLes) held jointly at the Conference on Medical Image Computing for Computer Assisted Intervention (MICCAI), 2017.
- [21] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. *CoRR*, 2015.
- [22] YU C, WANG J, PENG C, et al. Bisenet: Bilateral segmentation network for real-time semantic segmentation[C]. *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018: 325-341.
- [23] 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.
- [24] QIN X, ZHANG Z, HUANG C, et al. U²-net: Going deeper with nested U-structure for salient object detection [J]. *Pattern Recognition*, 2020, 106: 107404.

作者简介

石勇涛, 博士, 副教授, 硕士生导师, 主要研究方向为模式识别、医学图像处理。

E-mail: ytshi@ctgu.edu.cn

尤一飞, 硕士研究生, 主要研究方向为深度学习、医学图像处理。

E-mail: 1667605520@qq.com

高超, 硕士研究生, 主要研究方向为深度学习、医学图像处理。

E-mail: 2631805696@qq.com

李伟, 硕士研究生, 主要研究方向为深度学习、医学图像处理。

E-mail: 1350137837@qq.com

雷帮军, 博士, 教授, 主要研究方向为图像处理。

E-mail: Bangjun.Lei@ieee.org

储志杰, 硕士研究生, 主要研究方向为深度学习、医学图像处理。

E-mail: 744130077@qq.com