

嵌入压缩采样的 腹部CT胰腺分割网络

徐强强¹ 张敏¹ 任冯刚² 吕毅² 冯筠³

摘要 针对全自动分割算法因胰腺器官解剖变异性较高而难以实现准确定位的问题,文中提出嵌入压缩采样的编码器解码器网络。通过分阶段训练网络的方式,分割网络可级联在预训练阶段,从标签空间中感知的胰腺位置先验知识实现对分割目标的精准定位,保证分割结果与标签形状的一致性。胰腺器官分割实验表明,文中网络分割性能较优。

关键词 医学图像, 胰腺分割, 编码器解码器网络, 压缩采样模型

引用格式 徐强强, 张敏, 任冯刚, 吕毅, 冯筠. 嵌入压缩采样的腹部CT胰腺分割网络. 模式识别与人工智能, 2021, 34(4): 300–310.

DOI 10.16451/j.cnki.issn1003-6059.202104002

中图法分类号 TP 391

Pancreas Segmentation Network for Abdominal CT Based on Compressive Sampling

XU Qiangqiang¹, ZHANG Min¹, REN Fenggang², LÜ Yi², FENG Jun³

ABSTRACT Due to the high anatomical variability of pancreas, it is difficult for automated segmentation algorithms to achieve accurate localization of the target. To solve this problem, an encoder-decoder network embedded with compressive sampling is proposed. By training the network in different stages, the segmentation network can cascade the prior knowledge of pancreas location perceived from the label space in the pre-trained stage. Thus, the precise positioning of the pancreas is realized and the consistency between the segmentation result and the label is ensured. The experimental results of pancreas segmentation show that the performance of the proposed network is better.

Key Words Medical Image, Pancreas Segmentation, Encoder-Decoder Network, Compressive Sampling Model

Citation XU Q Q, ZHANG M, REN F G, LÜ Y, FENG J. Pancreas Segmentation Network for Abdominal CT Based on Compressive Sampling. Pattern Recognition and Artificial Intelligence, 2021, 34(4): 300–310.

收稿日期:2020-06-15;录用日期:2020-12-10

Manuscript received June 15, 2020;

accepted December 10, 2020

国家自然科学基金重大科研仪器研制项目(No. 81727802)、
国家自然科学基金青年基金项目(No. 61701404)、陕西省自然
科学基金面上项目(No. 2020JM-438, 2019JM-494)、陕西省教
育厅专项科研基金项目(No. 17JK0769)资助

Supported by Major Program of National Natural Science Foundation of China(No. 81727802), Young Scientists Fund of National Natural Science Foundation of China (No. 61701404), Natural Science Foundation of Shaanxi Province of China (No. 2020JM-438, 2019JM-494), The Special Scientific Research Foun-

dation of Shaanxi Provincial Education Department of China (No. 17JK0769)

本文责任编辑 辛景民

Recommended by Associate Editor XIN Jingmin

1. 西北大学 数学学院 西安 710127
2. 西安交通大学 第一附属医院 肝胆外科 西安 710061
3. 西北大学 信息科学与技术学院 西安 710127
1. School of Mathematics, Northwest University, Xi'an 710127
2. Hepatobiliary Surgery, First Affiliated Hospital, Xi'an Jiaotong University, Xi'an 710061
3. School of Information Science and Technology, Northwest University, Xi'an 710127

医学图像分割技术在病理分析、临床诊断、手术动态规划等计算机辅助诊断方面具有广泛的研究意义和应用价值^[1-4]。随着数字医疗和深度学习等领域的发展,较大器官如心脏、肺、肾脏、肝脏等的分割技术已达到较高的精度^[5-11]。然而,由于电子计算机断层扫描(Computed Tomography, CT)影像的噪声、局部体效应和组织运动的影响等因素,胰腺器官周围存在大量紧密相连、密度相似的邻近组织,且胰腺本身具有解剖变异性较高、占比较小等特点^[4,8,12-22],因此,目前基于深度学习的腹部 CT 影像胰腺半自动分割算法和全自动分割算法的结果仍无法满足临床需求。

半自动的胰腺分割算法在训练网络时仅使用胰腺所在的最小图像块,进行胰腺分割时需依赖医生根据先验知识手工地从 CT 图像中勾画包含胰腺的最小矩形框^[15,20,22-23]。Liu 等^[24]提出将最小矩形区域送入 U 型网络(U Network, U-Net)的方法。U-Net 网络包含提取上下文信息的收缩路径和与收缩路径对称的扩张路径,能够用较短的训练时间得到较高的分割性能。Li 等^[20]基于残差的多尺度感受野网络,提出多尺度跨域的信息融合策略,有效解决过分割、欠分割及形状不一致等问题。Ning 等^[25]提出深度循环对抗网络(Deep Recurrent Adversarial Network, DRAN),在扩大网络感受野的基础上,建模相邻 CT 之间的上下文相关性,利用对抗模块提高网络的泛化性能。

全自动分割算法能从整幅原始 CT 切片图像中自动分割目标器官,摆脱对医生手工勾画的包含胰腺的最小矩形框的依赖,辅助临床医生,提高诊断效率。Roth 等^[12]提出将自底向上多层次卷积网络(Deep Convolutional Networks, ConvNets)方法,用于胰腺分割。Zhao 等^[17]提出两阶段训练的基于三维卷积神经网络(3D Convolutional Neural Network, 3D CNN)的胰腺分割网络,先在下采样后训练一个 3D U-Net 网络,得到候选区域,再在候选区域训练另一个 3D U-Net 网络并分割。Man 等^[19]基于可形变 U-Net 的深度 Q 学习网络,提取胰腺器官的各向异性特征,通过交互上下文信息准确分割胰腺。总之,全自动分割算法通常先找到目标感兴趣区(Region of Interest, ROI)后再进行细粒度的分割。相比半自动分割算法,全自动分割算法因对目标位置和网络初始化值具有敏感性,因此面临更大的难点和挑战^[26-29]。

本文提出嵌入压缩采样的编码器解码器网络,分两个阶段训练网络。第一阶段对编码器解码器网

络进行预训练,求解在压缩采样模型中定义的压缩矩阵和重建矩阵。在网络训练过程中,通过迭代优化使压缩矩阵能提取关于胰腺位置先验的稀疏性特征表示,网络能从标签空间中感知胰腺器官的位置先验知识。在第二阶段进行训练的分割主网络的解码器模块级联在第一个阶段求得的重建矩阵上。重建矩阵能从特征图中选择关于分割目标位置信息的稀疏性特征表示,在胰腺的分割预测概率图重构过程中实现对胰腺器官的精准定位,并从中恢复与原始输入图像保持相同分辨率的分割预测概率图。

1 嵌入压缩采样的编码器解码器网络

针对腹部 CT 胰腺器官全自动分割任务,本文提出嵌入压缩采样的编码器解码器网络。网络主要由编码器模块、解码器模块、压缩采样模块和特征聚合模块构成。

1.1 编码器模块和解码器模块

编码器模块提取关于图像的信息特征和抽象知识表示,编码器以 ResNet-50 为骨干网络,提取图像的语义特征,添加更多的卷积层,构成卷积块和瓶颈块,用于增强编码器在深层提取特征的稀疏性。图像的纹理、对比度等空间局部特征包含在浅层特征图中,深层包含图像的上下文信息和语义的表示。解码器模块通过对特征图进行上采样,将特征空间映射到像素空间,对特征进行重构,恢复至与原始输入图像保持相同的分辨率,得到胰腺的分割预测概率图。将浅层的空间局部特征与深层的语义特征进行融合^[30-35],可减少分割目标的细粒度信息的丢失,保留器官的形态结构,在胰腺边缘区域保证分割结果与标签的一致性。

将分辨率大小为 512×512 的原始 CT 切片作为编码器模块的输入,使用 2 层卷积核大小为 3×3,步长为 2×2 的卷积层提取图像特征,经过批量归一化层(Batch Normalization, BN)和整流线性单元(Rectified Linear Unit, ReLU)非线性激活层对每个卷积层的输出特征图进行变换,得到大小为 128×128 的高分辨率浅层特征图。卷积块中的瓶颈块交替使用的卷积核的大小为 1×1 或 3×3,步长为 1×1 或 2×2,后接 BN 和 ReLU 非线性激活层对特征进行变换,利用最大池化层进行下采样。相比单个卷积层,瓶颈块的使用能避免冗余卷积层的堆叠,具有压缩特征表示的作用,同时在网络训练过程中能有效减少参

数量.

在解码器模块中, 使用大小为 1×1 、步长为 1×1 的卷积核对深层语义特征图进行变换, 实现跨通道知识交融, 对网络特征图进行通道数降维和升维的控制, 减少卷积核参数和运算复杂度. 在解码器模块中嵌入压缩采样模块, 实现对胰腺位置的感知, 并将特征图恢复至与原始输入图像保持相同的分辨率, 得到胰腺的分割预测概率图. 为了保留胰腺的空间形状和结构信息, 在编码器模块与解码器模块之间添加特征聚合模块, 进行跨尺度的特征整合, 提高编码器解码器网络的表达能力和分割性能.

1.2 压缩采样模块

在解码器网络最后一层嵌入压缩采样模块, 如图 1 所示. 压缩采样模块能从标签空间包含的冗余信息中感知胰腺器官的位置先验知识, 在将特征图进行恢复重构胰腺的分割预测概率图的过程中实现对分割目标的精准定位, 从而减弱网络对分割目标位置和权重初始值的敏感性, 保证分割结果与标签的形状一致性.

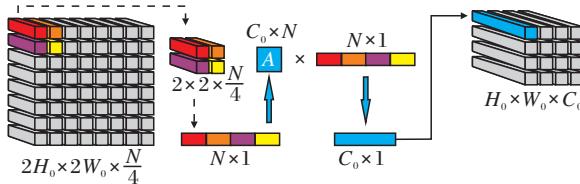


图 1 压缩采样块框图

Fig. 1 Flow chart of compressive sampling module

胰腺的位置先验知识包含在标签空间所含的冗余信息中, 采用独热编码方式对标签编码, 得到

$$\mathbf{G} \in \{0, 1, 2, \dots, C\}^{H \times W},$$

记为 $\mathbf{G} \in \{0, 1\}^{H \times W \times C}$, 其中, H, W 分别表示标签图的高和宽, C 表示所有分割类别. 由于胰腺分割任务只判定每个像素点属于胰腺区域或背景区域, 因此 C 的值为 2.

编码器最后一层输出的特征 $\mathbf{O} \in \mathbf{R}^{\tilde{H} \times \tilde{W} \times \tilde{C}}$, 其中, \tilde{H}, \tilde{W} 分别表示特征图的高和宽, \tilde{C} 表示通道数. 特征图 \mathbf{O} 各通道中坐标为 (i, j) 的像素点对应的值按照通道堆叠顺序构成观测向量, 记为 $\mathbf{o}_{ij} \in \mathbf{R}^{\tilde{C} \times 1}$, $\forall i = 1, 2, \dots, \tilde{H}, \forall j = 1, 2, \dots, \tilde{W}$, 从特征图 $\mathbf{O} \in \mathbf{R}^{\tilde{H} \times \tilde{W} \times \tilde{C}}$ 中可得到观测向量 \mathbf{o}_{ij} 的个数为 $\tilde{H} \times \tilde{W}$. 从 $\tilde{H} \times \tilde{W}$ 个观测向量中得到标签 \mathbf{G} 的分割预测概率图 $\hat{\mathbf{G}} \in \{0, 1\}^{H \times W \times C}$, 转化为对特征空间 \mathbf{O} 中的所有观测向量 \mathbf{o}_{ij} 进行恢复重建的问题. 观测向量 \mathbf{o}_{ij} 经过重建, 得到原始信号 $\mathbf{v}_{ij} \in \{0, 1\}^{N \times 1}$, 其中

$$N = r \times r \times C, r = \left\lceil \frac{\tilde{H}}{H} \right\rceil = \left\lceil \frac{\tilde{W}}{W} \right\rceil.$$

在训练网络时, H/r 或 W/r 若不是整数, 可通过双线性插值方式适当缩放原始图像和标签图像. 将信号 \mathbf{v}_{ij} 按照先水平后竖直的方向铺展, 构成标签预测概率图 $\hat{\mathbf{G}}$ 中的子图像块 $\hat{\mathbf{G}}_{ij} \in \{0, 1\}^{r \times r \times C}$, 则标签预测概率图 $\hat{\mathbf{G}}$ 共有 $\tilde{H} \times \tilde{W}$ 个子图像块.

现做如下假设: 若分割目标区域在图像中占比较小, 即 \mathbf{G}_{ij} 的多数项目为 0, 则重建的原始信号 \mathbf{v}_{ij} 是稀疏的. 通常情况下 $\tilde{C} < N$, 基于上述假设, 构建压缩采样模型

$$\mathbf{A}\mathbf{v}_{ij} = \mathbf{o}_{ij}.$$

如图 2 所示, 压缩矩阵 $\mathbf{A} \in \mathbf{R}^{\tilde{C} \times N}$. 建立从稀疏信号 \mathbf{v}_{ij} 中提取语义知识特征表示的线性系统, 记为 f . 重建系统 f^{-1} 对观测向量 \mathbf{o}_{ij} 进行变换, 得到原始信号的预测值

$$\hat{\mathbf{v}}_{ij} = f^{-1}(\mathbf{o}_{ij}) = f^{-1}(\mathbf{A}\mathbf{v}_{ij}) = \mathbf{B}\mathbf{A}\mathbf{v}_{ij},$$

即将重建矩阵 $\mathbf{B} \in \mathbf{R}^{N \times \tilde{C}}$ 定义为压缩矩阵 $\mathbf{A} \in \mathbf{R}^{\tilde{C} \times N}$ 的逆矩阵, 观测向量 \mathbf{o}_{ij} 经过重建矩阵 \mathbf{B} 的变換作用, 得到原始信号的预测值. 在第一阶段预训练中使用 ResNet-50 作为编码器骨干网络, 在解码器中嵌入构建的压缩采样模型, 采用端对端的训练方式, 迭代优化网络参数. 使用 l_2 范数作为损失函数, 使重建信号 $\hat{\mathbf{v}}_{ij}$ 与原始信号 \mathbf{v}_{ij} 的相似程度最大化, 则压缩采样模型中 \mathbf{A} 和 \mathbf{B} 的最优解为

$$\begin{aligned} \arg \min_{\mathbf{A}, \mathbf{B}} & \frac{1}{\tilde{H} \tilde{W}} \sum_{i=1}^{\tilde{H}} \sum_{j=1}^{\tilde{W}} \| \mathbf{B}\mathbf{A}\mathbf{v}_{ij} - \mathbf{v}_{ij} \|_2, \\ \text{s. t. } & \| \mathbf{o}_{ij} - \mathbf{A}\mathbf{v}_{ij} \|_2 \leq \varepsilon. \end{aligned}$$

当原始信号 \mathbf{v}_{ij} 不完全是稀疏的或观测向量 \mathbf{o}_{ij} 数据存在一定偏差时, 样本空间中数据带有噪声 e 的干扰, 其中:

$$\mathbf{o}_{ij} = \mathbf{A}\mathbf{v}_{ij} + \mathbf{e}, \mathbf{e} = [e_1, e_2, \dots, e_N]^T \in \mathbf{R}^{N \times 1},$$

噪声 \mathbf{e} 服从正态分布 $\mathbf{e} \sim N(0, \delta^2)$ 且令其满足边界条件 $\| \mathbf{e} \|_2 \leq \varepsilon$, 从而保证压缩采样重建的稳定性.

1.3 特征聚合模块

为了减少图像空间信息和结构特征的丢失, 保留并融合胰腺器官的形状、轮廓和大小特征, 在编码器模块与解码器模块之间添加特征聚合模块. 使用双线性插值方式, 对编码器模块中的浅层卷积块提

取的特征图不断进行下采样,将特征图的分辨率缩至与深层语义特征图保持相同,实现跨卷积块的信息交互和特征融合。可在对任意瓶颈块中的任意卷积层提取特征进行下采样后,与特征图 O 进行拼接串联融合。上述跨层级、跨通道、跨尺度的特征聚合策略,能保留输入图像的全局结构信息,并使之与分割目标的知识语义信息融合,进一步提高编码器解码器网络的表达能力和性能。

如图1所示,在第2阶段训练的分割主网络的编码器使用ResNet-50作为骨干网络,加入更多卷积层,增强网络的特征提取能力。以服从 $N(0, 0.1^2)$ 高斯分布对其进行初始化,使用第一阶段求解的重建矩阵 B 对使用特征聚合策略得到的特征图 O 进行上采样,恢复至与原始输入图像保持相同分辨率,得到

预测概率图。第2阶段在对编码器解码器主网络进行迭代训练时,采用交叉熵损失 $L(\varphi(X), G)$ 优化网络参数 W ,其中, G 表示标签图像,映射函数 φ 表示从原始输入图像 X 中推理得到胰腺器官的预测概率图 $\hat{G} = \varphi(X; W)$ 的非线性变换。假设空间 Φ 定义为

$$\Phi = \left\{ \varphi \mid \hat{G} = \varphi(X; W) \right\},$$

优化风险函数可表示为最小化关于假设空间中的映射函数 φ 平均意义下的交叉熵损失 $L(\varphi(X), G)$,即

$$\min_{\varphi \in \Phi} R(\varphi) = E[L(\varphi(X), G)].$$

由此得到嵌入压缩采样的编码器解码器网络框图,如图2所示。

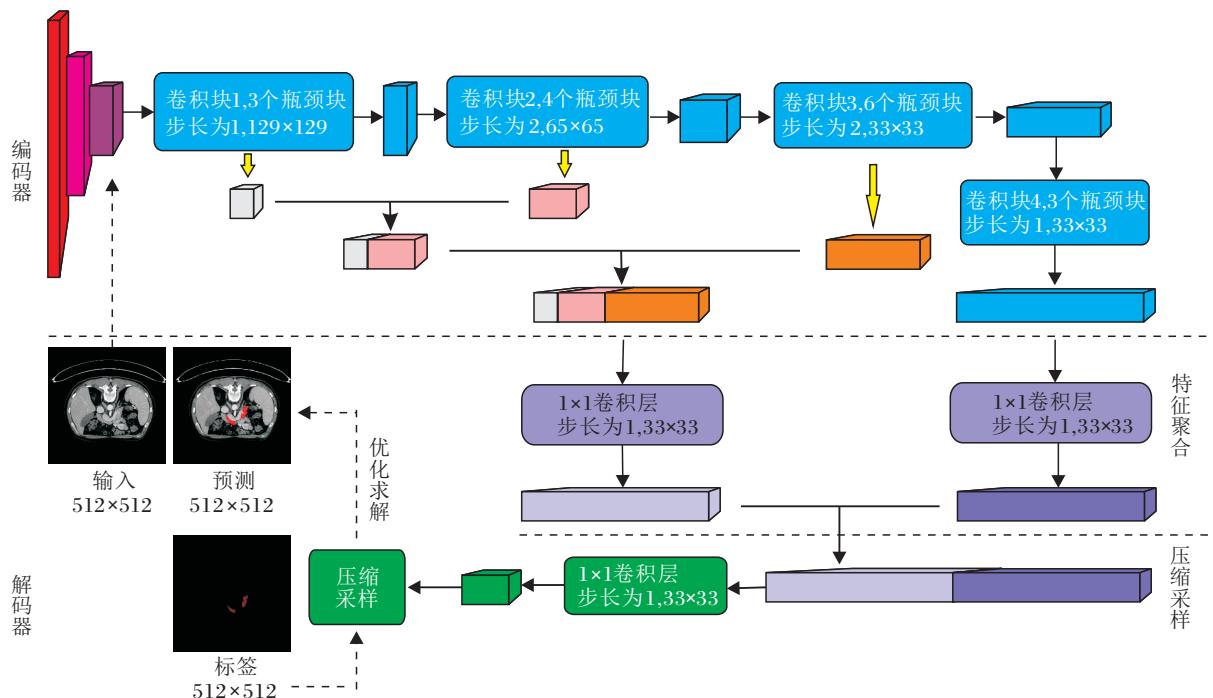


图2 本文网络框图

Fig. 2 Flow chart of the proposed network

2 实验及结果分析

2.1 实验环境

在公开NIH数据集^[12]和ISBI 2015 VISCERAL挑战赛数据集^[3]上进行实验。NIH数据集包含82套人体CT扫描增强数据,每个人体的CT扫描体素的维度为 $512 \times 512 \times L$,其中 $L \in [181, 466]$,为沿着人体长轴方向的轴状面切片数目,2D切片的分辨率大小为 512×512 。ISBI 2015 VISCERAL挑战赛数据集用于基准化多器官(肝脏、脾脏、肾脏、胰腺、胆

囊、左右肾上腺等)分割,本文仅应用其中18套有效的胰腺器官注释的人体CT扫描增强数据集,每套CT扫描体素的维度为 $512 \times 512 \times L$,其中 $L \in [194, 477]$ 。CT切片窗宽窗位范围调整为 $-100 \sim 240$ Hu以适用于胰腺分割,本文将含有胰腺器官的腹部CT切片作为有效数据集,用于训练或验证。

网络训练主要分为2个级联的阶段:第1阶段求解压缩采样模型,第2阶段训练胰腺分割主网络。为了求解压缩采样模型,第1阶段以标准的ResNet-50为编码器骨干网络,使用在ImageNet上的预训练权

重进行初始化,批量大小为 4,在训练集上经过 2 期的训练,求解压缩采样模块中的压缩矩阵 A 和重建矩阵 B . 在第 2 阶段训练嵌入压缩采样模块的编码器解码器分割主网络时,解码器除以 ResNet-50 骨干网络,添加更多卷积层并令其参数初始化时服从 $N(0, 0.1^2)$ 的高斯分布,初始化学习效率为 0.007,动量设置为 0.9,衰减权重为 0.000 1,批量大小为 4,采用随机梯度下降(Stochastic Gradient Descent, SGD)优化器最小化交叉熵损失. 在批量预处理过程中,对原始腹部 CT 切片图像采用随机水平翻转的数据增强策略. 分割主网络在较大的 NIH 数据集上训练 300 期,学习率衰减呈指数下降趋势,而在相对较小的 ISBI 2015 VISCERAL 挑战赛数据集的训练集上训练 1 000 期,学习率衰减采用多项式策略,衰减权重为 0.000 1.

2.2 评价指标

采用四折交叉验证的方式训练和测试本文网络,以平均准确率(mean Accuracy, mA)、平均交并比(mean Intersection over Union, mIoU)和平均 Dice 分数(Dice's Similarity Coefficient, DSC)作为分割性能评价指标. mA 衡量分割算法处理类别不平衡的有效性,mIoU 用于评估在训练过程中对分割目标进行定位的性能. 令 n_{ij} 为将属于第 i 类的像素分为第 j 类的像素数目, n_c 表示总类别数目,属于第 i 类像素的总数目 $t_i = \sum_j n_{ij}$,mA 和 mIoU 计算如下:

$$mA = \frac{1}{n_c} \sum_i \left(\frac{n_{ii}}{t_i} \right),$$

$$mIoU = \frac{1}{n_c} \sum_i \left(\frac{n_{ii}}{t_i + \sum_j n_{ji} - n_{ii}} \right).$$

X 表示测试数据集,假设 $f(x_i)$ 表示像素点 x_i 的预测值, $g(x_i)$ 表示该像素点相应的真实值,则

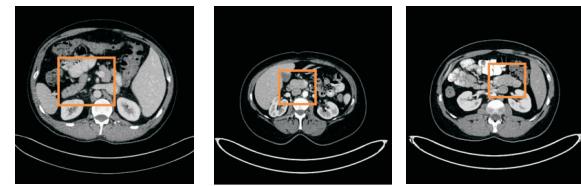
$$DSC(f(X), g(X)) = \frac{2 \sum_{x_i \in X} f(x_i) g(x_i)}{\sum_{x_i \in X} f(x_i) + \sum_{x_i \in G} g(x_i)}.$$

DSC 用于衡量图像预测值 $f(X)$ 与真实值 $g(X)$ 之间的相似性,量化胰腺器官的分割精度.

2.3 实验结果

图 3 为本文网络随机可视化部分 CT 数据 2D 切片的胰腺分割示例.(a) 中橘色矩形框是胰腺器官所在区域,(b) 为胰腺所在区域的放大图像,(c) 中红色区域为医生勾画的胰腺标签,(d) ~ (g) 中蓝色区域分别表示本文网络训练到第 1、5、18、102 期时分割胰腺器官的结果.由(d)可见,本文网络利用

压缩采样模块从标签空间中感知胰腺的位置先验,只需经过 1 期的训练,就完成对胰腺器官的精准定位,减弱网络对分割目标位置和权重初始值的敏感性,解决胰腺全自动分割算法难以对较小分割目标进行定位的问题.



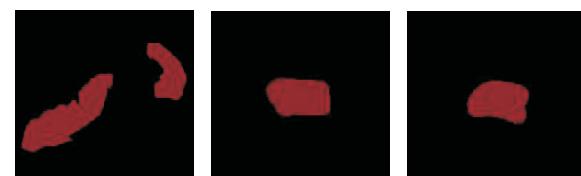
(a) 原始切片

(a) Original slices



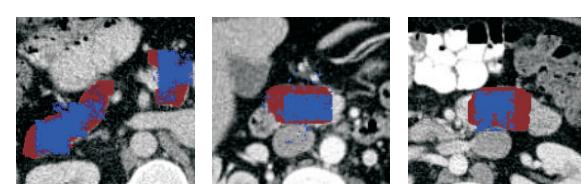
(b) 放大图像

(b) Enlarged images



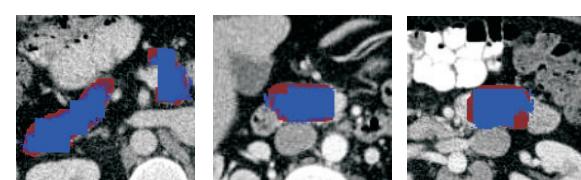
(c) 胰腺标签

(c) Ground-truth of pancreas



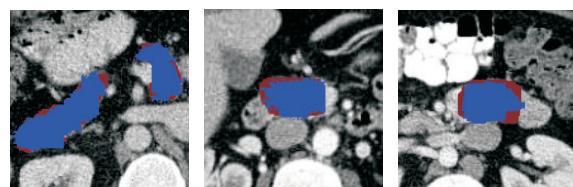
(d) 第 1 期分割结果

(d) Segmentation results of the 1st epoch



(e) 第 5 期分割结果

(e) Segmentation results of the 5th epoch



(f) 第 18 期分割结果

(f) Segmentation results of the 18th epoch



(g) 第 102 期分割结果

(g) Segmentation results of the 102nd epoch

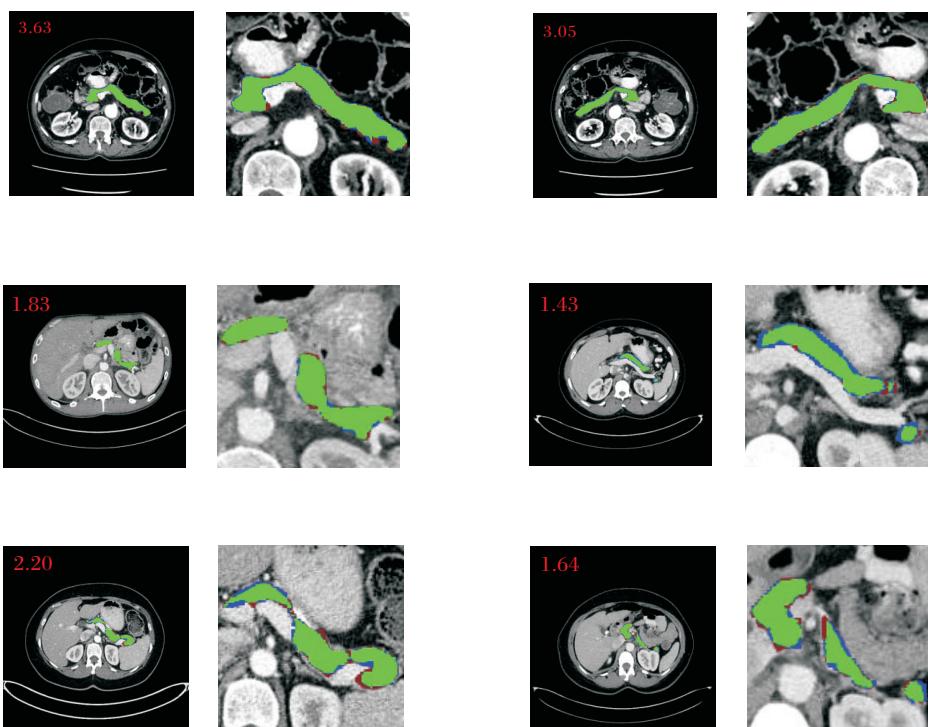
图 3 本文网络感知胰腺位置的可视化示意图

Fig. 3 Visualization of pancreas location-aware by the proposed network

在 NIH 数据集上对本文网络进行训练并接近收敛时,图4随机展示部分2D切片的分割结果,第1列和第3列表示标签与预测值在整幅CT切片中的重叠区域(绿色区域),左上角的红色数字表示胰腺的占比大小,第2列和第4列为相应区域的放大图。由图可看出,即使胰腺的位置和大小不固定、解剖变异性较高,利用跨层级、跨通道、跨尺度的特征聚合策略,仍能在胰腺边缘区域促使分割结果与标签趋于吻合。

本文网络在 NIH 数据集上的收敛趋势对比如图5所示。由图可知,在 NIH 数据集上,损失函数随迭代次数的增加迅速并趋于稳定收敛。经过前 50 期的训练之后,本文网络对目标定位、对不平衡数据处理及对胰腺分割的性能达到稳定。

多期数的训练是为了更新网络参数,使其在胰腺器官边缘区域出现的欠分割和过分割现象在可控范围内,让近似解更逼近真实解,进一步提高网络的鲁棒性和稳定性。



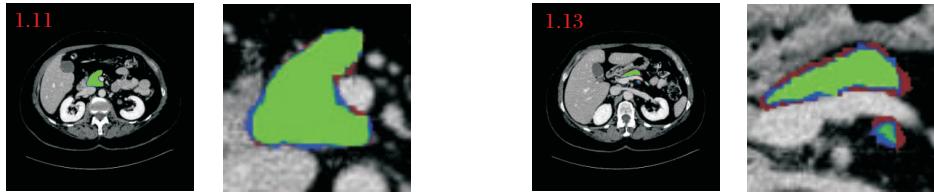


图4 本文网络在 NIH 数据集上的胰腺分割结果

Fig. 4 Pancreas segmentation results of the proposed network on NIH dataset

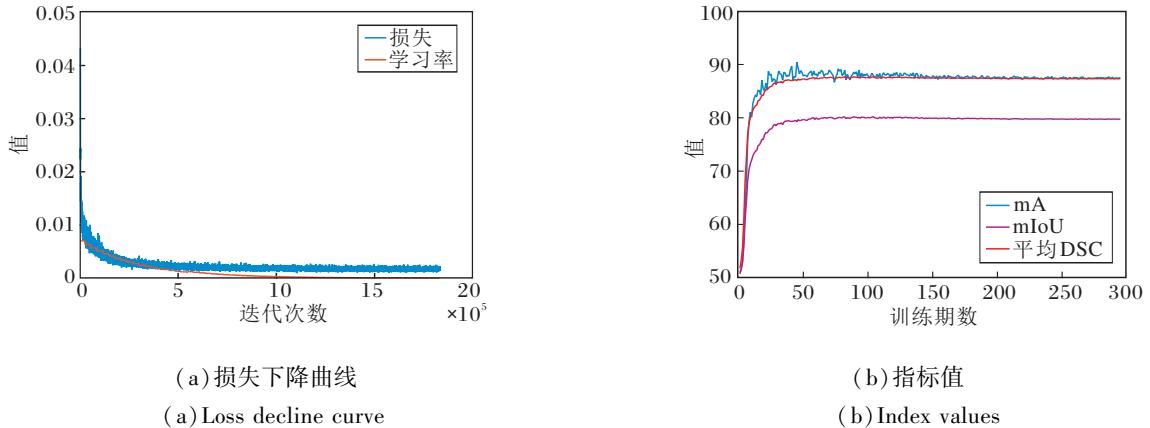


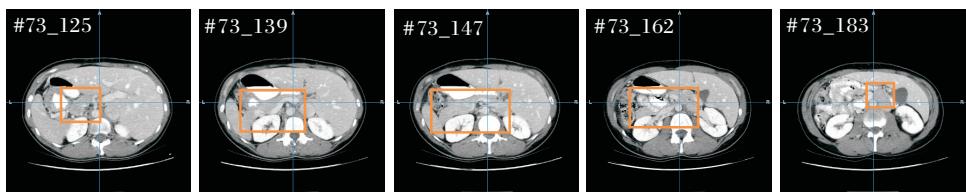
图5 本文网络在 NIH 数据集上的收敛趋势

Fig. 5 Convergence trend of the proposed network on NIH dataset

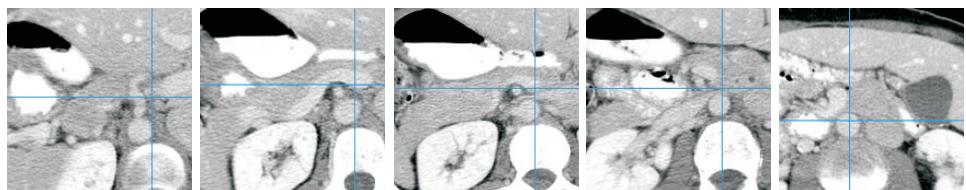
图6为本文网络在 NIH 数据集上第 73 号 CT 胰腺的分割结果。(a) 为当网络参数训练到最优时第 73 号病人 CT 的第 125、139、147、162 和 183 张 CT 切片,由图可见,本文网络在病人 CT 切片上的分割结

果与标签的形状具有一致性.

图7为本文网络在 NIH 数据集上的胰腺 3D 重建结果,(b) 中蓝色数字为 DSC. 由图可见,本文网络能保留器官的 3D 基本几何结构和特征.



(a) 病人 CT 切片
(a) Examples of CT slices of patients



(b) 放大图像
(b) Enlarged images

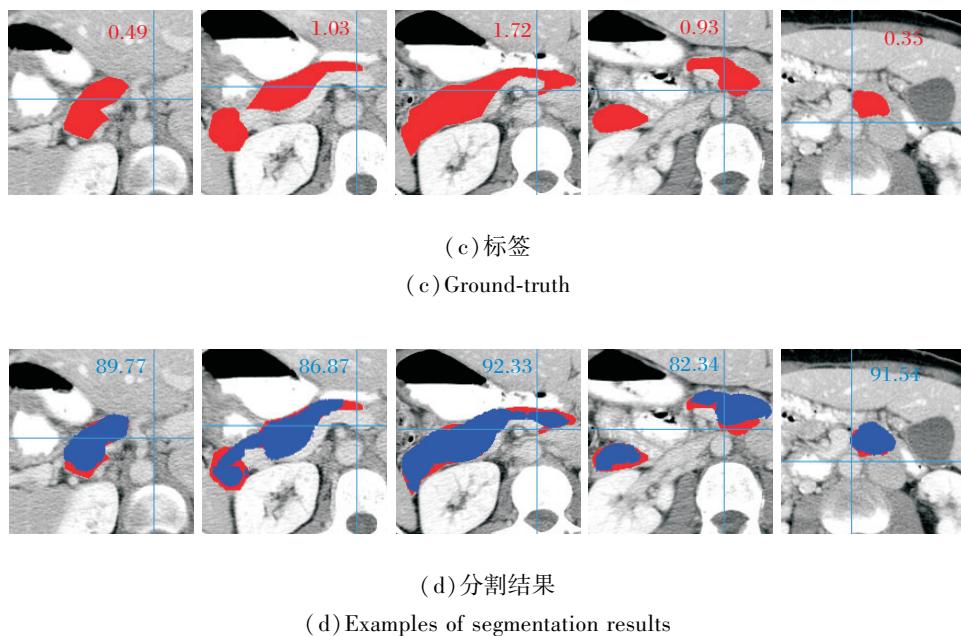


图 6 本文网络在 NIH 数据集上第 73 号 CT 胰腺的分割结果

Fig. 6 No. 73 CT pancreas segmentation results of the proposed network on NIH dataset

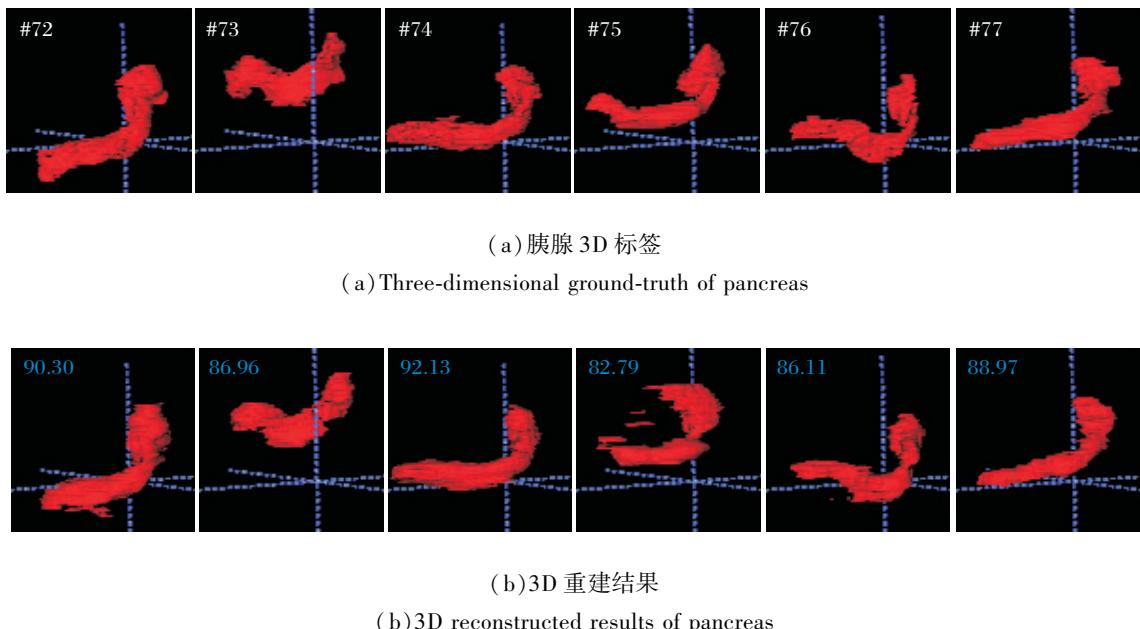


图 7 本文网络在 NIH 数据集上的胰腺 3D 重建结果

Fig. 7 Three-dimensional ground-truth and 3D reconstructed results of pancreas on NIH dataset

选择如下方法进行对比:文献[3]方法、文献[5]方法、固定点模型(Fixed-Point)^[6]、文献[7]方法、双阶段的三维卷积神经网络(Two-Stage 3D CNN)^[8]和文献[22]方法。各方法在 NIH 数据集上

的实验结果如表 1 所示。由表可见,本文网络平均值最高,DSC 最小值有较大幅度的提升,这为网络应用于临床时的安全性提供依据,标准差降至 4.00% 以下,进一步保证网络的稳定性。

表1 不同方法在 NIH 数据集上的实验结果对比

Table 1 Experimental results comparison of different methods on NIH dataset

方法	最小值	最大值	方差	平均值	%
文献[3] 方法	34.11	88.65	8.20	78.01	
文献[5] 方法	50.69	88.96	6.27	81.27	
Fixed-Point	63.02	90.85	5.47	82.65	
文献[7] 方法	71.04	91.47	4.19	85.32	
Two-Stage 3D CNN	57.20	91.20	4.51	85.99	
文献[22] 方法	69.62	91.45	4.86	84.59	
本文网络	82.79	92.13	3.18	87.69	

相关的胰腺分割方法在数据量相对较少的ISBI 2015 VISCERAL 挑战赛数据集上的平均 DSC 如下: U-Net^[12] 为 33.6%, 优势点森林 (Vantage Point Forests, VPF)^[4] 为 52.1%, 联合标签融合的多阿特拉斯方法 (Multi-altas Segmentation with Joint Label Fusion, MAS-JLF)^[13] 为 40.7%, 多数表决的多阿特拉斯方法 (Multi-altas Segmentation with Majority Voting, MAS-MV)^[13] 为 31.1%, 知识辅助卷积神经网络 (Knowledge-Aided Convolutional Neural Network, KaCNN)^[13] 为 58.8%, 本文网络为 72.17%。由此可见本文网络的平均 DSC 有较大幅度提升。

3 结束语

本文针对腹部CT胰腺全自动分割任务,提出嵌入压缩采样的编码器解码器网络,将依靠数据驱动的分割网络与基于先验知识构建的压缩采样相结合,通过两阶段级联的方式使分割网络具备器官的位置先验感知功能。本文网络能实现对分割目标的精准定位,减弱网络对分割目标位置和权重初始值的敏感性,保证胰腺分割结果与标签的形状一致性。在 NIH、ISBI 2015 VISCERAL 数据集上的实验表明,本文网络的性能较优。今后考虑将本文网络推广应用到腹部 CT 多个小器官的全自动分割中。

参 考 文 献

- [1] 张荣国,姚晓玲,赵建,等.融入局部几何特征的流行谱聚类图像分割.模式识别与人工智能,2020,33(4):313-324.
(ZHANG R G, YAO X L, ZHAO J, et al. Manifold Spectral Clustering Image Segmentation Algorithm Based on Local Geometry Features. Pattern Recognition and Artificial Intelligence, 2020, 33(4) : 313-324.)
- [2] 张大明,张学勇,李璐,等.利用广义信息熵谱选择的图像分割.

模式识别与人工智能,2019,32(3):225-236.

(ZHANG D M, ZHANG X Y, LI L, et al. Image Segmentation Using Generalized Information Entropy for Eigenvector Selection. Pattern Recognition and Artificial Intelligence, 2019, 32(3) : 225-236.)

- [3] JIMENEZ-DEL-TORO O, MÜLLER H, KRENN M, et al. Cloud-Based Evaluation of Anatomical Structure Segmentation and Landmark Detection Algorithms: Visceral Anatomy Benchmarks. IEEE Transaction on Medical Imaging, 2016, 35(11) : 2459-2475.
- [4] FARAG A, LU L, TURKBAY E, et al. A Bottom-Up Approach for Automatic Pancreas Segmentation in Abdominal CT Scans // Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2014: 103-113.
- [5] ZHENG Q, DELINGETTE H, DUCHATEAU N, et al. 3-D Consistent and Robust Segmentation of Cardiac Images by Deep Learning with Spatial Propagation. IEEE Transactions on Medical Imaging, 2018, 37(9) : 2137-2148.
- [6] ZHAO T Y, GAO D H, WANG J, et al. Lung Segmentation in CT Images Using a Fully Convolutional Neural Network with Multi-instance and Conditional Adversary Loss // Proc of the 15th International Symposium on Biomedical Imaging. Washington, USA: IEEE, 2018: 505-509.
- [7] MANSOOR A, BAGCI U, XU Z Y, et al. A Generic Approach to Pathological Lung Segmentation. IEEE Transactions on Medical Imaging, 2014, 33(12) : 2293-2310.
- [8] HEINRICH M P, BLENDOWSKI M. Multi-organ Segmentation Using Vantage Point Forests and Binary Context Features // Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2016: 598 - 606.
- [9] CUINGNET R, PREVOST R, LESAGE D, et al. Automatic Detection and Segmentation of Kidneys in 3D CT Images Using Random Forests // Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2012: 66-74.
- [10] WOLZ R, CHU C W, MISAWA K, et al. Automated Abdominal Multi-organ Segmentation with Subject-Specific Atlas Generation. IEEE Transactions on Medical Imaging, 2013, 32 (9) : 1723 - 1730.
- [11] CHRIST P F, ELSAER M E A, ETTLINGER F, et al. Automatic Liver and Lesion Segmentation in CT Using Cascaded Fully Convolutional Neural Networks and 3d Conditional Random Fields // Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2016: 415-423.
- [12] ROTH H R, LU L, FARAG A, et al. DeepOrgan: Multi-level Deep Convolutional Networks for Automated Pancreas Segmentation // Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2015: 556-564.
- [13] ROTH H R, LU L, FARAG A, et al. Spatial Aggregation of Holistically-Nested Networks for Automated Pancreas Segmentation //

- Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2016: 451–459.
- [14] ROTH H R, LU L, LAY N, et al. Spatial Aggregation of Holistically-Nested Convolutional Neural Networks for Automated Pancreas Localization and Segmentation. *Medical Image Analysis*, 2018, 45: 94–107.
- [15] ZHOU Y Y, XIE L X, SHEN W, et al. A Fixed-Point Model for Pancreas Segmentation in Abdominal CT Scans // Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2017: 693–701.
- [16] MA J T, LIN F, WESARG S, et al. A Novel Bayesian Model Incorporating Deep Neural Network and Statistical Shape Model for Pancreas Segmentation // Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2018: 480–487.
- [17] ZHAO N N, TONG N, RUAN D, et al. Fully Automated Pancreas Segmentation with Two-Stage 3D Convolutional Neural Networks // Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2019: 201–209.
- [18] FANG C W, LI G B, PAN C W, et al. Globally Guided Progressive Fusion Network for 3D Pancreas Segmentation // Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2019: 210–218.
- [19] MAN Y Z, HUANG Y S B, FENG J Y, et al. Deep Q Learning Driven CT Pancreas Segmentation with Geometry-Aware U-Net. *IEEE Transactions on Medical Imaging*, 2019, 38(8): 1971–1980.
- [20] LI F Y, LI W S, SHU Y C, et al. Multiscale Receptive Field Based on Residual Network for Pancreas Segmentation in CT Images. *Biomedical Signal Processing and Control*, 2020, 57. DOI: 10.1016/j.bspc.2019.101828.
- [21] ZHAO Y, LI H W, WAN S H, et al. Knowledge-Aided Convolutional Neural Network for Small Organ Segmentation. *IEEE Journal of Biomedical and Health Informatics*, 2019, 23(4): 1363–1373.
- [22] YANG Z Z, ZHANG L, ZHANG M, et al. Pancreas Segmentation in Abdominal CT Scans Using Inter-/Intra-Slice Contextual Information with a Cascade Neural Network // Proc of the 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Washington, USA: IEEE, 2019: 5937–5940.
- [23] ZHU Z T, XIA Y D, SHEN W, et al. A 3D Deep Coarse-to-Fine Framework for Volumetric Medical Image Segmentation // Proc of the International Conference on 3D Vision. Washington, USA: IEEE, 2018: 682–690.
- [24] LIU Y J, LIU S. U-Net for Pancreas Segmentation in Abdominal CT Scans [C/OL]. [2020-05-13]. http://perfectroc.com/publication/Yijun_ISBI181page_final.pdf.
- [25] NING Y, HAN Z Y, ZHONG L, et al. DRAN: Deep Recurrent Adversarial Network for Automated Pancreas Segmentation. *IET Image Process*, 2020, 14(6): 1091–1100.
- [26] GAO H Y, YUAN H, WANG Z Y, et al. Pixel Transposed Convolutional Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(5): 1218–1227.
- [27] ZEILER M D, KRISHNAN D, TAYLOR G W, et al. Deconvolutional networks // Proc of the IEEE Conference on Computer Vision and Pattern Recognition. Washington, USA: IEEE, 2010: 2528–2535.
- [28] ZEILER M D, TAYLOR G W, FERGUS R. Adaptive Deconvolutional Networks for Mid and High Level Feature Learning // Proc of the IEEE International Conference on Computer Vision. Washington, USA: IEEE, 2011: 2018–2025.
- [29] NOH H, HONG S, HAN B. Learning Deconvolution Network for Semantic Segmentation // Proc of the IEEE International Conference on Computer Vision. Washington, USA: IEEE, 2015: 1520–1528.
- [30] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation // Proc of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin, Germany: Springer, 2015: 234–241.
- [31] YU Q H, XIE L X, WANG Y, et al. Recurrent Saliency Transformation Network: Incorporating Multi-stage Visual Cues for Small Organ Segmentation // Proc of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Washington, USA: IEEE, 2018: 8280–8289.
- [32] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation // Proc of the European Conference on Computer Vision. Berlin, Germany: Springer, 2018: 833–851.
- [33] DING H H, JIANG X D, LIU A Q, et al. Boundary-Aware Feature Propagation for Scene Segmentation // Proc of the IEEE/CVF International Conference on Computer Vision. Washington, USA: IEEE, 2019: 6818–6828.
- [34] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834–848.
- [35] TIAN Z, HE T, SHEN C H, et al. Decoders Matter for Semantic Segmentation: Data-Dependent Decoding Enables Flexible Feature Aggregation // Proc of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Washington, USA: IEEE, 2019: 3121–3130.

作者简介



徐强强,硕士研究生,主要研究方向为机器学习、医学图像分割。E-mail: qiangqiangxu@126.com。

(**XU Qiangqiang**, master student. His research interests include machine learning and medical image segmentation.)



张敏(通信作者),博士,副教授,主要研究方向为人工智能、计算机视觉、医学图像处理. E-mail:dr.zhangmin@nwu.edu.cn.
(ZHANG Min (Corresponding author), Ph. D., associate professor. Her research interests include artificial intelligence, computer vision and medical image processing.)



任冯刚,博士研究生,主要研究方向为医工结合外科技术创新、肿瘤电磁物理消融技术. E-mail:resmak521@126.com.
(REN Fenggang, Ph. D. candidate. His research interests include medical engineering combined with surgical technology innovation and tumor electromagnetic physical ablation technology.)



吕毅,博士,教授,主要研究方向为肝胆胰肿瘤外科治疗. E-mail:luyi169@126.com.
(LÜ Yi, Ph. D., professor. His research interests include surgical treatment of hepatobiliary-pancreatic tumor.)



冯筠,博士,教授,主要研究方向为医学影像处理、人工智能、模式识别、多媒体系统. E-mail:fengjun@nwu.edu.cn.
(FENG Jun, Ph. D., professor. Her research interests include medical image processing, artificial intelligence, pattern recognition and multimedia system.)

2021 中国自动化大会征文通知

中国自动化大会是由中国自动化学会主办的国内最高层次的自动化领域大型综合性学术会议,2021 中国自动化大会主题为“中国自动化学会六十周年会庆暨钱学森诞辰 110 周年”,将于 2021 年 10 月 22 日至 24 日在北京召开,此次自动化大会多地并举、云端同步,续写自动化大会新未来。

2021 中国自动化大会将为全球自动化、信息与智能科学领域的专家学者和产业界的同仁提供展示创新成果、展望未来发展的高端学术平台,加强不同学科领域的交叉融合,引领自动化、信息与智能科学与技术的发展。

本次大会设多个特色论坛,征文领域 30 余种。热忱欢迎全国各高等院校、科研院所和企事业单位中从事相关领域研究的科技工作者积极投稿,特别希望征集能反映各单位研究特色的学术论文。

一、大会内容

- | | |
|----------|----------|
| 1、多地分会场 | 2、学术专题论坛 |
| 3、产业发展论坛 | 4、科技奖励论坛 |
| 5、青年人才论坛 | 6、纪念专题论坛 |
| 7、教育专题论坛 | 8、展览展示 |