



基于 U-Dense-net 网络的 DSA 图像 冠状动脉血管分割

王卓英¹, 童基均¹, 蒋路茸¹, 潘哲毅²

(1. 浙江理工大学信息学院, 杭州 310018; 2. 武警海警总队医院信息科, 浙江嘉兴 314000)

摘要: 冠状动脉血管是研究心血管疾病的重要基础, 为准确分割 DSA(Digital subtraction angiography) 图像冠状动脉血管, 提高训练过程中血管特征的有效利用率, 提出了一种基于 U-Dense-net 网络的分割方法。该方法首先对数据集进行限制对比度直方图均衡化预处理; 然后对预处理结果进行图像粗分割, 基于 U-Dense-net 网络, 在解码器部分融合密集残差块和注意力机制实现深度神经网络模型, 加强特征映射, 充分提取局部特征, 实现血管与背景的分类; 最后利用形态学处理、阈值分割、基于多点区域生长的连通域分析进行图像细分割, 实现血管的提取。将测试结果和 3 位专家手工标注的标准图进行对比分析, 结果表明: 该数据集的分割结果精确率、召回率、 F_1 分数分别为 83.22%、89.81%、86.04%, 3 种特性曲线下的平均面积为 0.9923。与其他方法比较, 该方法提取到的血管信息较为完整, 为精确分割冠状动脉血管提供了一种解决方案。

关键词: 冠状动脉血管; 图像分割; U-Dense-net; 密集残差块; 注意力机制; 深度神经网络; DSA

中图分类号: TS391.4

文献标志码: A

文章编号: 1673-3851(2021)05-0390-10

Coronary artery segmentation of DSA images based on U-Dense-net network

WANG Zhuoying¹, TONG Jijun¹, JIANG Lurong¹, PAN Zheyi²

(1. School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China; 2. Information Office, Hospital of Coast Guard Corps of Chinese People's Armed Police Forces, Jiaxing 314000, China)

Abstract: Coronary artery is an important basis for the study of cardiovascular diseases. In order to segment coronary arteries accurately in DSA (digital subtraction angiography) image and improve the effective utilization of vascular features in the training process, this paper proposes a segmentation method based on U-Dense-net. Firstly, the data set is preprocessed by limiting contrast and equalizing histograms. Secondly, the preprocessed results are roughly segmented. Based on U-Dense-net, our study implements a deep neural network model by fusing the dense residual block and attention mechanism in the decoder to strengthen feature mapping, fully extract local features and realize the classification of blood vessels and backgrounds. In the end, morphological processing, threshold segmentation and connected component analysis based on multi-point region growth are used to segment the images finely and extract vessels. The test results are compared with the standard drawings annotated by three experts manually, and it is found that the accuracy rate, recall rate and F_1 score of the segmentation result of this data set are 83.22%, 89.81% and 86.04% respectively, and the mean area under three ROC curves is 0.9923. The comparison

收稿日期: 2020-09-02 网络出版日期: 2021-02-04

基金项目: 国家自然科学基金项目(61602417); 浙江理工大学基础研究项目(2019Q042); 浙江理工大学“521 人才培养计划”

作者简介: 王卓英(1996—), 女, 山西吕梁人, 硕士研究生, 主要从事智能医学图像处理方面的研究。

通信作者: 潘哲毅, E-mail: panzheyi@sina.com

with other methods shows that the proposed method can extract complete blood vessel information and provide an effective solution for the accurate segmentation of coronary arteries.

Key words: coronary artery segmentation; image segmentation; U-Dense-net; dense residual net; attention mechanism; deep neural network; DSA

0 引言

心血管疾病通常是由冠状动脉病变区域狭窄引起的^[1],对血管狭窄程度进行分析是辅助心血管疾病诊断和治疗评估的常用手段。冠状动脉造影(Coronary arteriography, CAG)是目前临床上对病灶冠脉狭窄的病例分析的唯一有效的“金标准”^[2],医生可以通过数字减影血管造影(Digital subtraction angiography, DSA)图像了解冠状动脉狭窄病变的位置、狭窄程度和具体范围等详细信息,对病人病情作出判断。在传统的临床诊断中,医生通常采用手动跟踪冠脉血管进行分析,这种凭经验诊断的方法,存在准确率低和客观性差等缺点^[3]。因此,对 DSA 图像进行精确的冠状动脉血管分割能够更好地满足临床需求。

现有的传统算法主要通过区域生长法、滤波法和图割法等实现冠状动脉血管分割。Kerkeni 等^[4]将多尺度区域生长方法用于 2D X 光血管造影图像中的冠状动脉分割,通过引入区域生长规则,结合血管选择性和方向信息,实现细血管的提取。Cervantes-Sanchez 等^[5]使用基于差分进化优化策略的 Gabor 滤波器的血管增强方法进行 X 光造影图像的分割,通过数值优化获得控制 Gabor 滤波器的最优参数,以便在降低训练阶段的计算成本时获得最佳血管检测率。Mabrouk 等^[6]引入自适应能量函数,结合局部和全局两个尺度的自适应,基于图割提出多尺度算法实现血管分割,其灵敏度优于其他方法。然而,传统分割冠状动脉算法无法对具有不同灰度特性的血管图做出精准分割。近年来,深度学习在医学图像分析表现出显著的优越性,有很大的应用价值和较好的发展前景^[7]。杨少戈^[8]基于全卷积神经网络(Fully convolutional networks, FCN)^[9],结合金字塔池化模块^[10],运用 PSPNet 网络对冠脉造影图进行分割,获取较好的多尺寸全局信息。Shen 等^[11]利用 3D FCN 学习冠状动脉三维语义特征,同时引入注意门机制增强血管,抑制无关区域。Huang 等^[12]使用 3D U-net 进行脉腔分割,通过选择和测试各种数据转换,以减少过度拟合的问题。Ronneberger 等^[13]提出了一种 U-net 网络结

构,在 FCN 网络结构基础上进行网络结构改进和扩展,利用上采样部分的特征通道将信息传播到高分辨率层,以更好地保留有效信息。该网络结构通过对少量数据样本进行弹性形变操作,使网络学习到不同形变特征,实现高精度分割。徐光柱等^[14]为有效解决梯度消失和过拟合的问题,结合 Dense-Net 网络中的稠密连接^[15],实现了血管的分割。Wang 等^[16]采用 Dense U-net 网络实现了眼底血管图像分割,结果表明 dense 密集块可以促进特征重用并缓解梯度消失的问题,在每个密集块中,各层直接连接到其所有先前的网络层,改善了分类性能。

为提高血管特征有效信息的利用率,本文提出了一种基于 U-Dense-net 网络的血管分割方法。首先,针对 DSA 图像清晰度低、对比度弱等问题,利用限制对比度直方图均衡化(Contrast limited adaptive histogram equalization, CLAHE)进行预处理,以增强对比度,提高细节显示度;然后,对预处理图像进行粗分割,本文在 U-Dense-net 网络基础上,提出了一种融合密集残差块和注意力机制的深度神经网络模型,对预处理结果图像训练和测试,得到图像粗分割结果。在网络中引入密集残差块传递原始特征,保证其利用率最大化,同时将注意力机制模块代替原始网络结构跳跃连接部分,将浅层信息融入深层,进一步提高特征利用率,突出血管相关区域,提高准确率;最后,对粗分割结果进行细分割,结合形态学处理实现断点连接,结合阈值分割获得血管二值图像,结合基于多点区域生长的连通域分析提取血管连通域,以实现血管提取。

1 本文方法

本文提出的方法主要包括图像预处理、图像粗分割、图像细分割 3 个步骤。图像预处理部分采用 CLAHE 方法,提高血管与背景的对比度;图像粗分割部分采用 U-Dense-net 网络,融合密集残差块和注意力机制的深度神经网络实现血管与背景的分类;图像细分割部分采用结合形态学处理、阈值分割及基于多点区域生长的连通域分析方法,实现血管的提取。经过 3 个步骤,实现 DSA 冠状动脉血管图像的精确分割。

1.1 图像预处理

在预处理阶段,对 DSA 图像进行血管增强处理,以提高其对比度并突出细节部分,为获取血管图像的有效信息奠定基础。利用 CLAHE 进行处理,可避免由于大量灰度级被合并导致的图像不自然现象,更好地增强图像中的局部细节^[17]。CLAHE 采用自适应直方图均衡化的方式,通过加入对比度限制直方图高度,达到抑制噪声和削弱对比度过度增强的目的^[18];同时,在分块处理阶段,通过对相邻区域进行双线性插值^[19]消除块状效应。参考文献[17]和[20],本文方法预处理部分中的 CLAHE 算法流程如图 1 所示,具体步骤为:

- a)将原始图像分为 $m \times n$ 个大小相等、相邻子块间连续但不重叠的子块区域。 m 、 n 分别表示子块的行数和列数。
- b)计算每个子块区域的直方图。
- c)计算图像限制对比度,根据剪切限制系数对子块进行直方图剪切。
- d)对剪切后每个子块的新直方图作均衡化处理。
- e)确定每个子块中心点,将其作为样本点,对相邻的子块区域进行双线性插值^[21],进而得到新的灰度值。

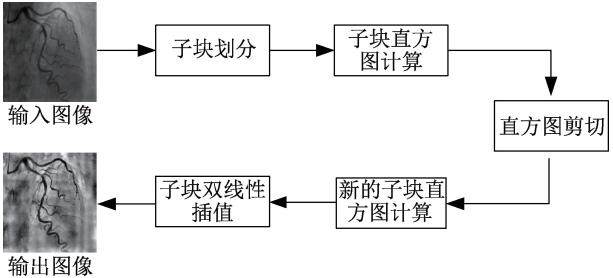


图 1 CLAHE 算法流程

1.2 图像粗分割

针对预处理结果图像,本文采用网络模型对增强后的图像训练和测试,将血管和背景进行分类,实现图像中血管的粗提取。深度神经网络通过梯度反向传播方式来更新优化权重,网络层数的加深会导致梯度更新信息呈指数衰减,从而出现梯度消失和过拟合的问题,而密集残差块可通过跳跃连接解决该问题,注意力机制可通过重点关注图像目标区域来获取细节信息,提高图像特征表达能力。因此,本文方法图像粗分割部分,在基于 U-Dense-net 网络基础上,提出了一种融合密集残差块和注意力机制的深度神经网络模型,实现预处理结果图像粗分割。

1.2.1 密集残差块

残差模块^[22]的特点是通过增加深度来提高网

络训练的准确率,使用跳跃连接缓解梯度消失的问题^[23];同时,在进行网络层信息传递时,直接将输入信息传递到网络模块输出位置,避免信息丢失。本文所采用的密集残差块结构如图 2 所示。密集残差块输入特征映射为 X ,将密集连接作为残差学习映射 $F(X)$,最后得到输出映射 $H(X)$ 。采用这种方法有利于提高模块输入特征利用率,一方面,将输入映射 X 通过恒等映射分支叠加到输出映射,使 $H(X) = F(X) + X$,有效保留原有特征;另一方面,通过残差学习分支 $F(X)$,将输入映射 X 叠加到残差模块,以解决梯度消失问题,同时又学习到新的特征,提高网络性能。模块包含批标准化(Batch normalization, BN)^[24],激活函数 ReLU^[25]以及 3×3 的卷积层,完成输入映射 X 的密集残差学习。

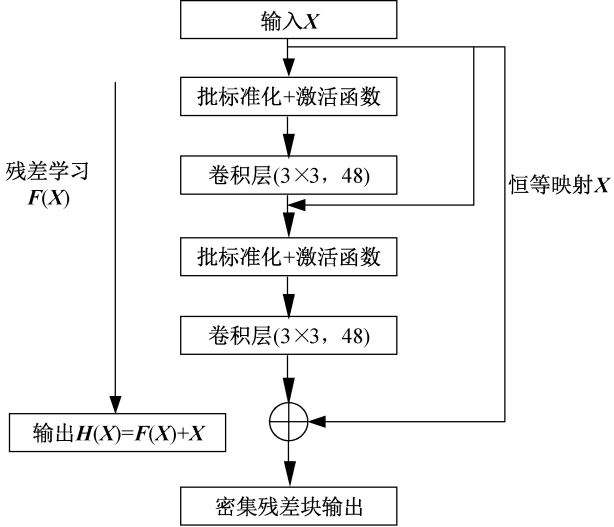


图 2 本文采用的密集残差块结构

1.2.2 注意力机制

注意力机制^[26]是指可自动学习聚焦不同形状和大小的目标结构,其通过注意门组成的模型,在训练过程中隐式地学习了如何对输入图像中与任务不相关区域进行抑制,突出有利于特定任务的显著特征。因此,为突出血管部分,抑制非血管部分,本文引入注意力机制模块,利用编码器低层特征映射,通过跳跃连接为解码器高层特征映射聚焦血管区域。本文注意力机制模块如图 3 所示。门信号 g 和特征图 x 均为网络编码器部分的特征映射,其中:门信号 g 为编码器部分网络层的特征映射,其包含上下文信息以修剪下层特征响应^[27],特征图 x 为门信号的上层特征映射,其有利于选择血管有效信息,过滤不重要的信息。门信号 g 和特征图 x 通过卷积层和转置层实现类型匹配;模块采用 ReLU 激活函

数进行门控处理, 1×1 的卷积层进行注意力表达, sigmoid 激活函数避免在输出端产生较稀疏的激活, 使 AG 的参数达到更好的收敛, 最后通过上采样扩

展尺寸, 获得与原始输入特征图 x 相同大小的输出特征图, 利用点积方式得到特征的自相关性, 对每个像素进行推理选择。





图 3 本文注意力机制模块

1. 2. 3 网络模型

为对图像预处理结果进行粗分割, 实现血管与背景的分类, 本文基于 U-Dense-net 网络, 提出了一种融合密集残差块和注意力机制的深度神经网络模型, 对图像预处理结果进行训练和测试, 实现冠状动脉血管图像的粗分割。基于 U-Dense-net 网络模型及算法流程如图 4 所示。该网络由编码器和解码器组成, 编码器部分输入层经过卷积、BN 提取基本信息, 使用 DB 块增加网络深度, 提高特征利用率, 利用块中的残差结构缓解梯度消失问题, 各层之间通过池化完成特征映射下采样。解码器部分和编码器部分在各层之间通过注意力机制完成低层特征映射的融合, 将激活部

分限制于待分割区域, 减小激活值来优化分割结果, 同时突出注意力机制跳跃连接传递的显著特征; 利用反卷积完成上采样操作, 同时到最后输出层使用卷积, 将特征向量映射到所属的网络输出层。

在基于 U-Dense-net 网络模型中, 卷积层的大小为 1×1 , 最大池化层的大小为 2×2 , 反卷积层的大小为 3×3 , 归一化层的动量因子均为 0.9, 用以将数据置于标注正态分布下, 缓解梯度消失问题。每次下采样之前的图像大小分别为 48×48 、 24×24 、 12×12 , 在反卷积过程中的图像大小则与下采样过程相同。网络运用 softmax 作为激活函数, 交叉熵 (Categorical crossentropy)^[28] 作为损失函数。



(a) 网络结构

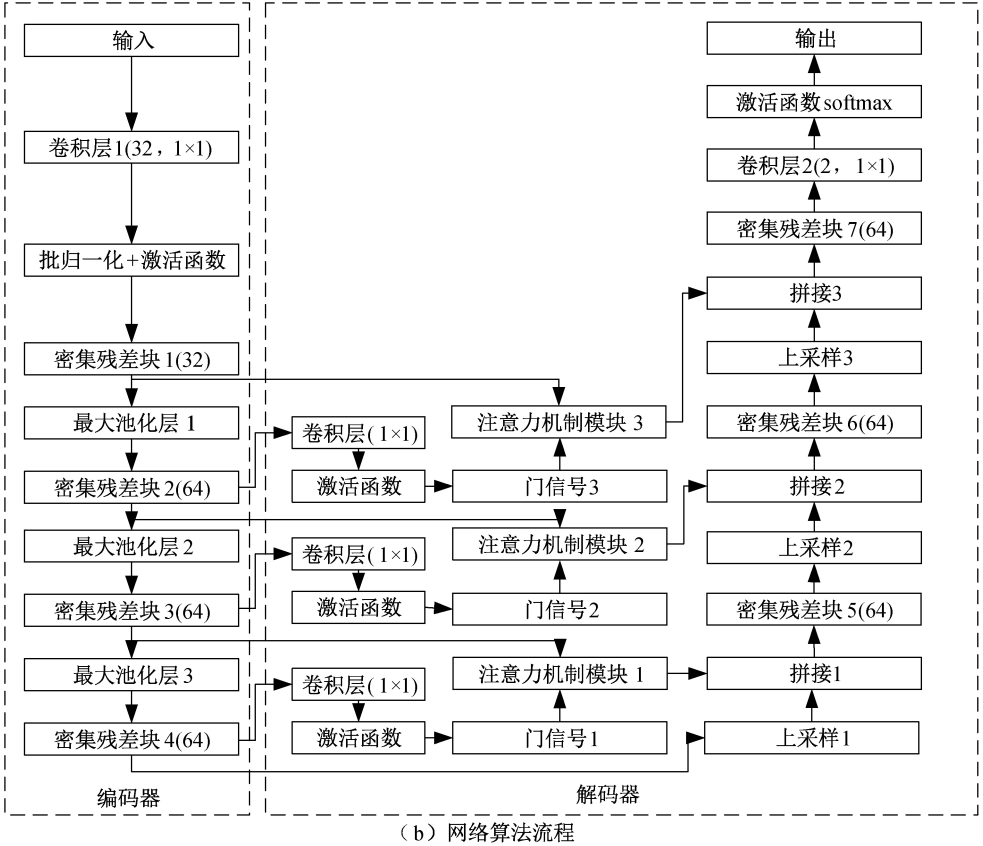


图4 U-Dense-net 网络模型及算法流程

1.3 图像细分割

由于图像粗分割结果存在背景干扰、空洞以及断点,故本文方法采用后处理实现血管图像细分割,其操作过程如下:

a)首先通过形态学腐蚀、膨胀操作将血管空洞以及断点作处理,腐蚀、膨胀具体运算可分别描述为:

$$A \ominus B = \{x, y \mid (B)_{xy} \subseteq A\}$$
 (1)

$$A \oplus B = \{x, y \mid (B)_{xy} \cap A \neq \emptyset\}$$
 (2)

其中: A、B 分别表示图像集合和结构元素, x、y 表示 A 中的像元。

b)其次通过调整阈值将血管灰度图像转为二值图像,设置阈值完成全局阈值分割。

c)最后基于多点区域生长进行连通域分析对二值图像提取血管,选取多个感兴趣血管区域种子点,根据相同像素值的准则进行生长,直至连通域生长停止,完成血管图像的分割。

1.4 评价指标

冠状动脉血管分割的结果一般通过 3 个指标进行评价,即准确率(Accuracy)、精确率(Precision)和召回率(Recall)指标进行评价,这 3 个指标的计算方法分别为:

$$A = \frac{P_T + N_T}{P_T + N_T + P_F + N_F}$$
 (3)

$$P = \frac{P_T}{P_T + P_F}$$
 (4)

$$R = \frac{P_T}{P_T + N_F}$$
 (5)

其中: A 表示准确率, P_T 表示实际正样本被预测为正样本的像素数, N_T 表示实际负样本被预测为负样本的像素数, P_F 表示实际负样本被预测为正样本的像素数, N_F 表示实际正样本被预测为负样本的像素数, P 表示精确率, R 表示召回率。

为了平衡精确率和召回率之间的差异,利用 F₁ 分数计算得到较为平均的估值, F₁ 分数值 F 的计算方式为:

$$F = \frac{2 \times P \times R}{P + R} = \frac{2P_T}{(P_T + P_F) + (P_T + N_F)}$$
 (6)

ROC (Receiver operating characteristic) 曲线是表征分类问题血管分割方法性能的重要曲线,以假阳性率为横坐标、真阳性率为纵坐标,利用曲线下方的面积大小 S_{AUC} (Area under curve, AUC) 进行评判,值越接近 1,血管分割方法性能越好。本文中

真阳性率用正确检测的血管像素数占原图血管像素数的比例表示,假阳性率用错误检测的血管像素数占原图非血管像素数的比例表示。

2 实验结果与分析

本文实验的计算机采用 Windows10 64 位操作系统,搭载 NVIDIA GeForce GTX 1080Ti GPU。训练平台为 python、开源深度学习框架 Tensorflow1.13.1。

2.1 数据集及实验参数设置

本文获取了冠状动脉 DSA 图像数据集,以及由 3 位医生专家手动进行动脉血管分割建立的 3 组标准集。数据集共包含 50 幅 512×512 像素大小的不同形态的血管图像,其中 25 幅为灰度级动态范围较宽的血管图像,25 幅为灰度级动态范围较窄的血管图像;3 组标准集分别包含 50 幅与数据集血管图像对应的二值血管图像。在训练过程中,从数据集两组不同的血管图像中分别选出 15 幅,进行 90° 旋转、左右及上下对称的数据增强操作,增至 120 幅,建立训练集;剩余 20 幅图像作为测试集。训练过程中,标准集采用专家 3 标注的冠状动脉血管分割图像;测试过程中,将测试数据集作为输入,同时,为避免医生由于主观因素影响对血管分割结果的判断,将得到的测试结果图像与 3 组标准集图像对比,同时可根据图像观察不同医生对血管主干及分支手动分割的结构相似性程度,以此评价分割方法。

实验过程中,在每幅预处理的冠状动脉血管图像上通过滑窗方式随机裁剪出 130000 个 48×48 的小块输入到训练网络,在每一轮的训练阶段,取 90% 用于训练,剩余的 10% 用于验证。网络训练过程使用 SGD(Stochastic gradient descent)优化,动

量因子设为 0.3,学习率设为 0.01。模型训练迭代次数为 200,训练块的大小设为 32×32 。

2.2 实验结果及性能分析

2.2.1 图像预处理结果分析

经过 CLAHE 预处理的结果如图 5 所示。从图 5 中可以看出,血管与背景对比度得到明显增强,由于光线造成的明暗差异得到适度均衡,使血管整体得以充分显现,将有利于后续的分割操作。

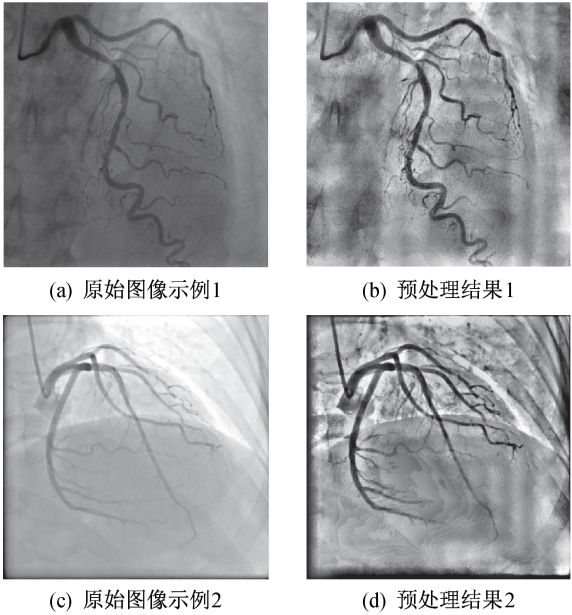


图 5 血管图像预处理结果

2.2.2 图像粗分割结果分析

随机选取的 patch 在网络层特征图变化如图 6 所示,根据网络层特征图变化,在下采样过程中,网络学习得到血管低层次特征,经过注意力机制以及密集残差块的融合,在上采样过程中,网络集中学习血管段部分,使有效信息得到充分利用,经过网络训练与测试实现图像粗分割,完成血管与背景的分类,其结果如图 7 所示。




图 6 随机选取的 patch 在网络层特征图变化

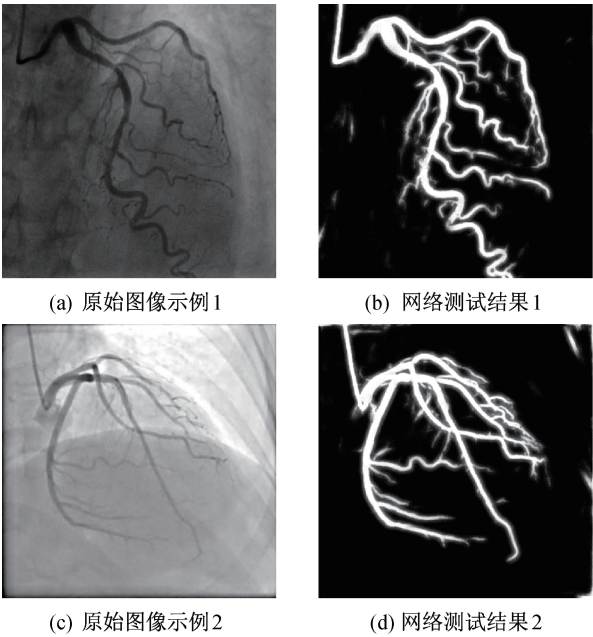


图7 图像粗分割结果




图8 原始图、金标准图与本文方法分割结果图像

表1 本文方法评价指标结果

标准图	$R/\%$	$P/\%$	$F/\%$	S_{AUC}
专家1	89.36	82.89	85.67	0.9939
专家2	88.55	84.02	85.88	0.9905
专家3	91.52	82.74	86.56	0.9926
平均值	89.81	83.22	86.04	0.9923

从图 10 可以看出：

基于 Hessian 矩阵^[29]进行分割的血管较为完整,该方法通过分析每个像素不同尺度的 Hessian 矩阵特征值来获得图像每个像素的血管值,从而获得完整的血管结构。

使用 CLAHE-阈值方法分割的血管断裂部分较多,实际上,图像分割部分直接采用阈值方法,设

2.3 本文方法分割结果分析

本文方法经过图像预处理、粗分割和细分割得到的血管分割结果与 3 位专家手动分割的标准图的对比如图 8 所示,从图中可以看出:3 位专家基本将血管主干部分分割出来,只在细血管及末梢血管部分稍有差异,经过精确分割可得到冠状动脉主干血管以及大部分旁支血管,末梢细血管也可得到一定程度的提取。

本文测试图数据集经过测试的评价指标结果如表 1 所示。测试结果分别与 3 位专家标注金标准图对比的 ROC 曲线如图 9 所示。

2.4 与其他方法分割结果对比分析

根据图 8 中的结果图对比以及表 1 中的评价指标结果分析,本文方法可以有效地分割出冠状动脉血管的主干部分,旁支血管以及部分细血管。为了说明本文方法的普适性,将结果与其他方法的分割结果做相关对比,各方法分割结果如图 10 所示。




图9 本文方法结果图与 3 位专家标准图对比的 ROC 曲线

置不同的阈值进行分割对像素值的影响不同,导致灰度不均匀的血管图像分割效果不同。

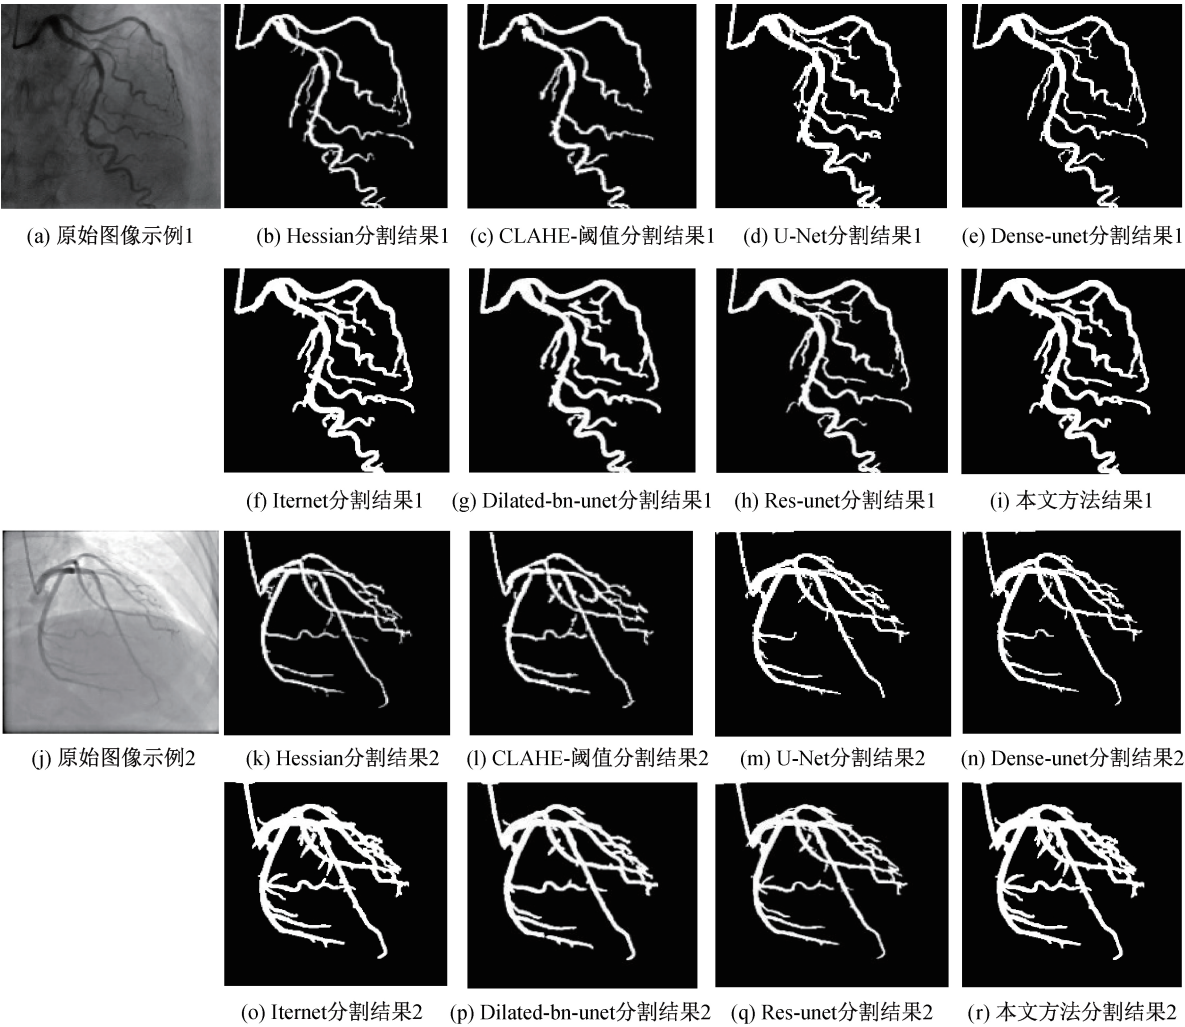


图 10 不同方法分割结果图像

使用 U-net 方法分割的血管对于细血管部分稍有欠缺。U-net 网络结构层的数量与本文方法相同,但是其卷积深度较浅,导致无法获取更多的图像信息。对于难以获取特征的位置(例如叉点和血管末端)的预测不足。

基于 Dense-unet 方法相对于本文方法,在网络跳跃连接部分通过直接连接将浅层信息融入深层,无法增强血管段部分的权重,使血管与背景部分以同等比重进行叠加,获得较少的有效信息。

基于 Iternet 方法通过设置迭代优化网络性能,其本质是在不改变原始 U-net 网络结构的前提下,在每次迭代过程中,对网络进行迭代内部的优化,提高网络训练精度,然而其在网络训练阶段,对特征图的信息并未进行更深层次的利用。

基于 Dilated-bn-unet 方法在基于 U-net 网络的基础上融合空洞卷积扩大感受野,使每层网络可得到输入特征图更大范围内的全局信息,减少信息

的损失,然而其对于原始特征得不到有效利用,并仍以直接跳跃连接进行对等层的信息融合。

基于 Res-unet 方法采用残差网络进行跳跃连接,即将每层网络的输出特征图通过残差网络连接的方式融入对等层信息中,在一定程度上提高了特征利用率,然而其无法提高该层网络输入特征图的利用率。

使用本文方法分割的血管可以增强原始图像的对比度,同时网络训练深度增加,密集残差模块通过恒等映射和残差学习提高原始特征的利用率并预测出更多的血管细节部分,注意力机制实现跳跃连接,完成浅层信息到深层的融合,通过分配比重突出血管段部分,使血管信息更加完整。

表 2 中列出了各种方法在平均精确率,平均召回率,平均 F_1 分数以及平均 S_{AUC} 这 4 种评价指标方面的对比,进一步说明了本文方法分割结果的有效性和普适性。

表 2 不同方法评价指标对比

方法	$R/\%$	$P/\%$	$F/\%$	S_{AUC}
Hessian	91.21	83.10	86.80	—
CLAHE-阈值	80.18	85.06	82.20	—
U-net	88.83	74.90	80.88	0.9781
Dense-unet	89.77	80.17	84.30	0.9917
Iternet	87.76	81.24	84.10	0.9937
Dilated-bn-unet	88.86	83.61	85.99	0.9944
Res-unet	91.84	79.49	84.99	0.9948
本文方法	89.81	83.22	86.04	0.9923

3 结 论

本文针对 DSA 冠脉血管图像,提出了一种基于 U-Dense-net 网络的血管分割方法。首先,对 DSA 血管图像进行 CLAHE 预处理,增强血管与背景的对比度;然后,采用基于 U-Dense-net 网络,融合密集残差块和注意力机制,对预处理图像进行粗分割,实现血管与背景的分类;最后结合形态学处理、阈值处理以及基于多点区域生长的连通域分析,对粗分割图像进行细分割,完成 DSA 冠脉血管的提取。实验结果表明:本文方法在预处理部分能够实现原始 DSA 冠脉血管图像对比度的提升;在图像粗分割及细分割部分能够提取较为完整的血管信息。

基于 U-Dense-net 网络模型用于图像粗分割存在细小血管分割不全的不足。在后续研究中,将针对图像粗分割部分细小血管的分割,从像素特性、血管结构的线性特性等不同角度提取血管图像特征,通过在各层引入残差模块,提高特征利用率,提升网络的训练性能,以实现更好的分割效果。

参考文献:

[1] Woodruffe S, Neubeck L, Clark R A, et al. Australian cardiovascular health and rehabilitation association (ACRA) core components of cardiovascular disease secondary prevention and cardiac rehabilitation 2014[J]. Heart, Lung and Circulation, 2015, 24(5): 430-441.

[2] Kirişli H A, Schaap M, Metz C T, et al. Standardized evaluation framework for evaluating coronary artery stenosis detection, stenosis quantification and lumen segmentation algorithms in computed tomography angiography[J]. Medical Image Analysis, 2013, 17(8): 859-876.

[3] 康文伟. 冠状动脉造影图像的分割方法研究[D]. 长春: 吉林大学, 2010: 11.

[4] Kerkeni A, Benabdallah A, Manzanera A, et al. A coronary artery segmentation method based on

multiscale analysis and region growing[J]. Computerized Medical Imaging and Graphics, 2016, 48: 49-61.

[5] Cervantes-Sanchez F, Cruz-Aceves I, Hernandez-Aguirre A, et al. Coronary artery segmentation in X-ray angiograms using Gabor filters and differential evolution [J]. Applied Radiation and Isotopes, 2018, 138: 18-24.

[6] Mabrouk S, Oueslati C, Ghorbel F. Multiscale graph cuts based method for coronary artery segmentation in angiograms[J]. Innovation and Research in BioMedical Engineering, 2017, 38(3): 167-175.

[7] Zhao B, Feng J S, Wu X, et al. A Survey on deep learning-based fine-grained object classification and semantic segmentation [J]. International Journal of Automation and Computing, 2017, 14(2): 119-135.

[8] 杨少戈. 基于深度学习的冠脉造影图像分割[D]. 北京: 北京邮电大学, 2019: 44-49.

[9] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.

[10] He K M, Zhang X Y, Ren S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.

[11] Shen Y, Fang Z J, Gao Y B, et al. Coronary arteries segmentation based on 3D FCN with attention gate and level set function[J]. IEEE Access, 2019, 7: 42826-42835.

[12] Huang W M, Huang L, Lin Z P, et al. Coronary artery segmentation by deep learning neural networks on computed tomographic coronary angiographic images [C]// 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Honolulu, HI, USA: IEEE, 2018: 608-611.

[13] 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. Switzerland: Springer, 2015: 234-241.

[14] 徐光柱, 胡松, 陈莎, 等. U-net 与 Dense-net 相结合的视网膜血管提取[J]. 中国图象图形学报, 2019, 24(9): 1569-1580.

[15] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 2261-2269.

- [16] Wang C, Zhao Z Y, Ren Q Q, et al. Dense U-net based on patch-based learning for retinal vessel segmentation[J]. Entropy, 2019, 21(2): 168.
- [17] 冯清枝, 王丹. 基于 LIP 模型和 CLAHE 的低照度图像增强算法[J]. 光电技术应用, 2018, 33(5): 31-36.
- [18] Pizer S M, Amburn E P, Austin J D, et al. Adaptive histogram equalization and its variations[J]. Computer Vision, Graphics, and Image Processing, 1987, 39(3): 355-368.
- [19] Sasi N M, Jayasree V K. Contrast limited adaptive histogram equalization for qualitative enhancement of myocardial perfusion images[J]. Engineering, 2013, 5(10): 326-331.
- [20] 马静云, 叶兵, 汪仕铭. 基于 CLAHE 和多尺度细节融合的静脉图像增强算法[J]. 半导体光电, 2020, 41(5): 738-742.
- [21] 刘巧玲, 李想, 明旭. 基于双线性插值的 CLAHE 算法研究与实现[J]. 成都大学学报(自然科学版), 2015, 34(2): 149-151.
- [22] 张娜, 陈春宇, 徐璐, 等. 基于深度残差网络与离散哈希的指静脉识别方法[J]. 浙江理工大学学报(自然科学版), 2020, 43(4): 549-556.
- [23] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV: IEEE, 2016: 770-778.
- [24] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[EB/OL]. (2015-02-13) [2020-09-02]. <https://arxiv.org/abs/1502.03167>.
- [25] Kim J, Kim S, Lee M. Convolutional neural network with biologically inspired ON/OFF ReLU[M]//Neural Information Processing. Cham: Springer International Publishing, 2015: 316-323.
- [26] Oktay O, Schlemper J, Folgoc L L, et al. Attention u-net: Learning where to look for the pancreas[EB/OL]. (2018-04-11) [2020-09-02]. <https://arXiv.org/abs/1804.03999>.
- [27] Wang F, Jiang M, Qian C, et al. Residual attention network for image classification[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Washington: IEEE Computer Society, 2017: 3156-3164.
- [28] De Boer P T, Kroese D P, Mannor S, et al. A tutorial on the cross-entropy method[J]. Annals of Operations Research, 2005, 134(1): 19-67.
- [29] Kerkeni A, Benabdallah A, Bedoui M H. Coronary artery multiscale enhancement methods: A comparative study [C]// ICIAR: International Conference on Image Analysis & Recognition. Berlin, Heidelberg: Springer, 2013: 510-520.

(责任编辑:康 锋)