

基于 U-Net 的多尺度视网膜血管分割方法

喻鲁立¹, 陈黎^{1,2}

(1. 武汉科技大学 计算机科学与技术学院, 湖北 武汉 430065;
2. 智能信息处理与实时工业系统湖北省重点实验室, 湖北 武汉 430065)

摘要: 视网膜血管的形态和结构一直是高血压、冠心病、糖尿病等疾病的重要诊断指标之一, 其检测和分割具有十分重要的意义。为了解决视网膜血管分割中, 血管末梢缺失和细小血管断裂的问题, 提出了一种基于 U-Net 改进模型的多尺度分割方法, 通过在编码阶段和解码阶段之间采用增加卷积块的方式来保持对不同尺度下的特征提取, 同时对增加的卷积块采用密集连接的方式解决由于网络加深带来的浅层特征缺失和梯度消失问题, 从而增强模型的特征提取能力并提高分割性能。此外, 采用 Dice 损失函数解决数据集中正负样本不平衡的问题。实验采用 CHASE_DB1 和 DRIVE 两个数据集进行训练和测试, 通过与 U-net、Residual U-net、Ladder-Net 以及 R2U-Net 的对比表明, 由于保留了多尺度的细节信息, 该方法取得了更好的分割效果。实验证明, 该方法能够有效提取健康视网膜图像和病变视网膜图像中的血管网络, 能够较好地分割细小血管。

关键词: 视网膜血管; U-Net; 卷积神经网络; 图像分割; 密集连接; 多尺度策略

中图分类号: TP391

文献标识码: A

文章编号: 1673-629X(2022)04-0140-06

doi: 10.3969/j.issn.1673-629X.2022.04.024

Multi-scale Segmentation of Retinal Vessels Based on U-Net

YU Lu-li¹, CHEN Li^{1,2}

(1. School of Computer Science and Technology, Wuhan University of Science and Technology, Wuhan 430065, China;
2. Hubei Province Key Laboratory of Intelligent Information Processing and Real-time Industrial System,
Wuhan 430065, China)

Abstract: The morphology and structure of retinal vessels have always been one of the important diagnostic indicators of hypertension, coronary heart disease, diabetes and other diseases, and their detection and segmentation are of great significance. In order to solve the problems of loss of vascular endings and rupture of small vessels in the segmentation of retinal vessels, a multi-scale segmentation method based on the improved U-Net model is proposed, which maintains feature extraction at different scales by adding convolutional blocks between the encoding stage and the decoding stage. At the same time, the added convolution blocks are densely connected to solve the problems of shallow layer feature loss and gradient disappearance caused by the deepening of the network, so as to enhance the feature extraction ability of the model and improve the segmentation performance. In addition, Dice loss function is used to solve the problem of unbalanced positive and negative samples in the data set. Two data sets, CHASE_DB1 and Drive, were used for training and testing in the experiment. The comparison with U-Net, Residual U-Net, Ladder-Net and R2U-Net shows that the proposed method has achieved better segmentation effect due to the retention of multi-scale details. Experimental results show that the proposed method can effectively extract the vascular network from healthy and pathological retinal images, and can better segment small vessels.

Key words: retinal vessels; U-Net; convolutional neural network; image segmentation; dense connection; multiscale strategy

0 引言

视网膜血管的形态和结构一直是高血压、冠心病、糖尿病等疾病的重要诊断指标之一。视网膜血管作为人体内唯一可以无创观察到的清晰血管, 其检测与分析对于上述疾病的研究有着重要的意义。但是由于视网膜血管密集且复杂, 传统的形态提取方法是由医生

来进行手工分割, 耗时较多, 不能满足大量病患的诊断需求, 同时也容易受到分割者主观因素的影响导致手工分割的质量不高。因此视网膜血管分割任务成为了计算机图像处理领域的热点和难点。近年来, 深度学习发展逐渐成熟, 自 2012 年 AlexNet^[1] 刷新了 Imagenet^[2] 的最好结果之后, 深度卷积神经网络在计

收稿日期: 2021-04-11

修回日期: 2021-08-12

基金项目: 国家自然科学基金资助项目(61773297)

作者简介: 喻鲁立(1997-), 男, 硕士, 研究方向为图像处理; 陈黎, 教授, 研究方向为人工智能与计算机视觉。

计算机视觉的各个领域都取得了不错的成绩。FCN^[3]在PascalVOC分割任务中取得了卓越的成绩,U-Net^[4]在某些医学图像处理上取得了最高的精度。PSP-Net^[5]和DeepLab^[6]也在其他的语义分割的任务中取得了好的成绩。在这些神经网络结构中,Ronneberger等^[4]提出的结构在医学图像处理中是被应用的最广泛的一种。

目前,国内外研究人员提出了许多基于U-Net结构的视网膜血管分割方法,比如文献[7]提出了在U-Net中采用循环卷积块。文献[8-10]提出将注意力模块引入U-Net结构中使得网络能选择性地专注于显著部分,以便更好地捕捉视觉结构。文献[11-13]提出在U-Net结构中引入密集连接块(Dense Blocks)。文献[14-15]提出将U-Net结构中的卷积块替换成Inception模块增强网络对空间信息的提取能力。文献[16]提出基于U-Net的多路径网络,在U型结构中增加多个U型子网络。该文将基于U-Net进行改进,将多尺度策略和Gao Huang等^[17]提出的密集链接相结合以增强模型对图片进行特征提取时在不同分辨率下的信息提取能力,使模型在视网膜血管末梢以及分叉处取得更精细的分割结果。

1 相关工作

1.1 更深层的神经网络

随着神经网络的网络层加深,不同的模型之间的差异更加明显,这也驱使着研究人员开始重新审视以往的研究思路,并且开始探索网络层间不同的连接方式。Highway Networks^[18]是第一个能对一百层以上的端到端网络进行有效训练的网络结构,通过使用旁路和可学习的门限机制使得部分信息流在无衰减的情况下通过一些网络层。而这些跳过一些网络层的跳层链接被认为是减轻深层网络带来的梯度消失影响的关键,文献[3,19]证明了卷积神经网络的跳层链接是有效的。而ResNets^[20]的提出进一步证明这一观点。由此,Gao Huang等^[17]提出密集连接网络。在传统网络结构中,通常将第 L 层的输出结果作为第 $L+1$ 层的输入,从而有转换 $X_L = H_L(X_{L-1})$ 。而ResNets^[20]增加了一个跳层链接,通过公式(1)跳过了非线性转换。

$$X_L = H_L(X_L - 1) + X_L - 1 \quad (1)$$

ResNets^[20]的一个优点是梯度可以直接从后面的网络层传递到较早的网络层,但是这也可能会阻碍网络层之间的信息传递。而更密集的连接可以进一步改善层与层之间的信息传递。Gao Huang等^[17]提出了一种不同的连接方式,将每一层的输出都当成后续网络层的直接输入。也就是说网络中的第 L 层的输入是前面0至 $L-1$ 层的输出。

$$X_L = H_L([X_0, X_1, \dots, X_{L-2}, X_{L-1}]) \quad (2)$$

其中, $X_0, X_1, \dots, X_{L-2}, X_{L-1}$ 是 L 层以前的各个层生成的特征图的串联。这样的连接方式减轻了深层网络梯度传播对网络性能的影响。同时,Krizhevsky等^[1]提出的ReLU激活函数已经在主流神经网络结构中替代了sigmoid激活函数。使用ReLU激活函数被证明可以使加深的网络层更容易收敛,ReLU激活函数的公式如下:

$$\text{ReLU}(x) = \max(x, 0) \quad (3)$$

Batch Normalization^[21]作为一种可以学习的归一化层,可以在一定程度上减轻梯度消失和梯度爆炸给网络带来的负面影响,同时也不会消耗过多的算力。可以通过在网络中逐层进行归一化处理的方式来减小反向传播时较远层因梯度传递造成的负面影响。

1.2 多尺度策略

目前大多数语义分割网络都采用了编解码结构。由于在编码过程中降低了图像的分辨率,所以这种方法会忽略图像中的一些细节。为了解决这一问题,Ronneberger等人^[4]提出在编码器和解码器之间建立跃层连接,使得网络能更加有效地提取到不同层次的特征,从而取得更精确的分割结果,但对于目标信息仍然会有丢失。为了解决这一问题,文献[22-23]通过传统网络中引入多尺度学习策略来增强目标信息的特征提取从而提升任务精度。文献[6]证明可以通过引入较低级别的特征进一步加强细节信息的获取。随着多尺度策略的进一步研究,多尺度特征融合策略引入了上下文相关的组合,共同利用高级特征和低级特征的优势。文献[24-26]合并了多尺度特征以进行语义分割,并提升了分割结果的精度。同时,Sun Ke等^[27]提出的高分辨率网络,在整个过程中维护高分辨率的特征,逐步增加高分辨率到低分辨率的子网,形成更多的阶段并将多分辨率子网并行连接。这个方法在人体姿态任务中取得了良好的效果。因此多尺度策略可提升网络的性能。

1.3 损失函数

视网膜血管分割是一个像素二分类问题,视网膜血管区域定义为正样本,其他区域定义为负样本。而在数据集当中,正负样本的比例接近1:9,正负样本比例严重失衡,如果采用图像分割任务中常用的均方差损失函数或二分类交叉熵损失函数,网络则会更加关注样本多的类别,使模型的预测结果强烈地偏向负样本。因此,样本少的部分经常缺失或是只能被部分检测到。所以实验中,该文采用Fausto Milletari等^[28]提出的Dice损失函数来对模型进行参数更新。公式如下:

$$\text{Dice} = 1 - \frac{2 \sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2} \quad (4)$$

其中, N 表示模型需要预测的像素点总数; $p_i \in [0, 1]$ 表示每个样本的预测值; $g_i \in \{0, 1\}$ 表示每个像素的标签值。Dice 对每个像素点计算梯度的公式如下:

$$\frac{\partial D}{\partial p_j} = 2 \left[\frac{p_j \left(\sum_i^N p_i^2 + \sum_i^N g_i^2 \right) - 2 p_j \sum_i^N p_i g_i}{\left(\sum_i^N p_i^2 + \sum_i^N g_i^2 \right)^2} \right] \quad (5)$$

2 文中方法

文中提出的方法是基于 U-Net^[4] 改进的模型, 主要改进是在 U-Net 网络的编码阶段和解码阶段之间通过增加密集连接网络的方式维持了网络对编码阶段

每一层输出的特征图的学习。然后将密集连接网络输出的特征图输入到解码器的相应层中, 接着与其他各层的特征图进行融合。以此来提高网络的特征提取能力, 从而使网络学习到更多的细节信息。

提出的模型整体呈一个四层的倒梯形结构, 每一层都保持着该层对应分辨率下的特征表达。其网络结构如图 1 所示。网络中有三次下采样和三次上采样, 该文将保持编码阶段每次下采样之前得到的特征图的表达, 直到与解码阶段对应的上采样特征图融合进入该层对应的解码阶段, 并且通过 ReLU 激活函数来加强特征图的细节信息, 从而提高网络对特征图细节信息的提取能力, 在特征图融合的时候对不同尺度的特征图的尺度和通道进行融合, 然后将融合后的特征图输入到对应的解码阶段。




图 1 提出的网络结构

2.1 多尺度方法

为了保持不同分辨率下特征图的表达, 使网络能更好地学习到图像中所包含的信息, 该文在编码阶段和解码阶段的对应网络层中间增加了部分卷积块用来保持模型对不同尺度特征的学习。然后将经过这些增

加的卷积块进一步提取信息后输出的特征图输入到解码阶段对应的网络层中, 与低分辨率网络层经过上采样以后的特征图进行融合, 使网络尽可能地保留不同尺度的特征信息。方法如图 2 所示。




图 2 保持多尺度特征提取的结构

2.2 密集连接

由于该文在编码阶段和解码阶段中间增加了部分卷积块,导致网络变的更深,使得网络丧失了部分浅层的特征,同时产生了深层网络常有的梯度消失问题。所以在增加的卷积块之间使用密集连接,增强网络中的信息传递,解决梯度消失和浅层特征缺失的问题。以图3为例。特征图进入模型编码阶段后输出的结果




图3 密集连接

常规的 U-Net 采用的是编码器最后一层的输出作为解码器的输入,这一输入含有最丰富的语义信息,但是图像经过多重卷积和池化操作后会缺少一些细节信息,因而对于分割目标会出现过分割和欠分割的问题,所以该文选择保持不同分辨率下的特征表达,并使用密集连接的方式保证网络中的信息流通。最后将多尺度多层次的特征图输入到解码阶段对应的网络层中与其他尺度的特征图进行融合。从而使最终的特征图保留不同尺度下的细节信息。

3 实验结果及分析

实验在一个工作站上运行,操作系统为 ubuntu18.04,工作站配备 Intel(R) Xeon(R) CPU E5-2620 V4 处理器,主频为 2.10 GHz,内存 64G, GPU 由四个 TiTan XP 组成。

3.1 实验数据及其预处理

实验采用了 DRIVE 数据集和 CHASE_DB1 数据集。DRIVE 数据集中包含 40 张彩色视网膜图像以及视网膜图像标签,其中前 20 张图像及其标注图像作为实验的训练样本,后 20 张图像及其标注图像作为实验的测试样本;CHASE_DB1 数据集中包含 28 张彩色视网膜图像以及视网膜图像标签,在该数据集随机挑中 20 张图像及标注用于训练样本,其余的 8 张图像及标注用于测试样本。在只有少量样本用于实验的情况下,为了提升模型的分割效果,增强模型的鲁棒性,实验中对每个数据集进行如下操作:首先对每张图像以 48 为间隔裁剪成 256×256 的图像块,并且对每个图像块及其标注图像以 25% 的概率随机进行上下左右翻转。同时也对每个图像块随机进行图像增强操作。由于模型对图像进行了三次下采样,所以该实验需要将图片填充至长宽都为 8 的倍数,所以在测试前在图片周围填充一些值为 0 的像素点。

为 x_1 , x_1 经过归一化处理后作为该层后面每一个卷积块的输入, x_1 经过第一个卷积块后生成的特征图 x_2 再经过归一化处理后也作为该层后面每一个卷积块的输入,所以第二个卷积块的输入为 $y_2 = H([x_1, x_2])$ 。以此类推,解码阶段对应层的输入为 $y = H([x_1, x_2, x_3, x_4])$ 。

3.2 评价指标

在视网膜血管的分割中,若模型预测的结果与专家的标注图像相同则该像素点为真阳性 (TP),若相反,则该像素点为假阳性 (FP);对于图像背景,若预测图像像素点与标注图像相同则该像素点为真阴性 (TN),若相反则该像素点为假阴性 (FN)。

为了定量分析网络模型的分割结果并且更好地与其他方法进行对比,采用准确率 (ACC)、灵敏度 (SE)、特异性 (SP) 和 F1 分数 (F1-score) 这四个通用指标来客观评价模型对视网膜血管的分割效果。其中 F1 分数越高,表示模型的分割结果与标注图像越相似。以上指标计算公式如下:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

$$SE = \frac{TP}{TP + FN} \quad (7)$$

$$SP = \frac{TN}{TN + FP} \quad (8)$$

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

$$Recall = \frac{TP}{TP + FN} \quad (10)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (11)$$

3.3 参数设置及训练

该优化方法采用随即梯度下降算法 (stochastic gradient descent, SGD); 训练批次设置为 1 000; batchsize 设置为 8; 测试批次为 1; 学习率初始化为 0.001, 权重衰减设置为 0.9, 在训练中使用 poly 策略对学习率进行调整, 公式如下。

$$learning_rate = base_lr \left(1 - \frac{iter}{max_iter}\right)^{power} \quad (12)$$

3.4 实验结果与分析

为了证明密集连接的有效性和必要性,进行了是

否加入密集连接的对比实验。结果如表 1 所示。

表 1 是否增加密集连接的消融实验

有无密集连接	SE	SP	ACC	F1-score
有密集连接	0.841 8	0.970 7	0.983 0	0.823 2
无密集连接	0.804 7	0.975 1	0.970 3	0.806 3

经过实验发现,该模型的分割能力和损失函数的采用有关。为了取得更好的效果,使用分割中常用的交叉熵损失函数(BCE loss)和 Dice 损失函数进行了对比实验,结果如表 2 所示。实验结果表明,使用 Dice 损失函数得出的分割结果在灵敏度和 F1-score 上要大幅优于使用交叉熵损失函数得出的结果。这是由于在视网膜血管在图像上存在严重对类别不平衡,使用交叉熵损失函数训练网络容易导致模型受到样本占比较大的类别影响导致模型过拟合。而 Dice 损失函数可以解决样本分布不均衡的问题,并在训练过程中对难以学习的样本进行有针对性的优化。从而缓解样本分布不均衡带来的负面影响,提升模型的性能。

表 2 损失函数的消融实验

损失函数	SE	SP	ACC	F1-score
BCE loss	0.823 4	0.971 3	0.984 5	0.816 3
Dice loss	0.841 8	0.970 7	0.983 0	0.823 2

为了验证文中算法的模型分割性能,将文中算法与 U-Net^[4]、Residual U-Net^[29]、Ladder-Net^[30]、R2U-Net^[7] 四种分割网络进行对比实验。采用相同的网络训练参数,对以上五种网络分别进行训练,并利用验证集对训练好的模型性能进行测试。

文中算法与 U-Net^[4]、Residual U-Net^[29]、Ladder-Net^[30]、R2U-Net^[7] 在各项评价指标上的对比情况如

表 3 和表 4 所示。在 CHASE_DB1 数据集上,文中算法相比于其他四种分割网络的灵敏度、特异性、准确率和 F1-score 均有不同程度的提高;在 DRIVE 数据集上,文中算法相比其他四种分割网络的灵敏度、准确率和 F1-score 均有不同程度的提高。

表 3 在 CHASE_DB1 数据集上的分割性能对比

算法	SE	SP	ACC	F1-score
U-Net ^[4]	0.828 8	0.970 1	0.957 8	0.778 3
Residual U-Net ^[29]	0.772 6	0.982 0	0.955 3	0.780 0
Ladder-Net ^[30]	0.803 1	0.981 8	0.965 6	0.803 1
R2U-Net ^[8]	0.792 8	0.982 0	0.963 4	0.792 8
文中算法	0.834 8	0.988 5	0.978 3	0.811 6

表 4 在 DRIVE 数据集上的分割性能对比

算法	SE	SP	ACC	F1-score
U-Net ^[4]	0.753 7	0.982 0	0.953 1	0.814 2
Residual U-Net ^[29]	0.772 6	0.982 0	0.955 3	0.814 9
Ladder-Net ^[30]	0.785 6	0.981 0	0.956 1	0.820 2
R2U-Net ^[8]	0.779 2	0.981 3	0.955 6	0.817 1
文中算法	0.841 8	0.970 7	0.983 0	0.823 2

图 4 展示了文中算法的分割效果。由图 4 可以很直观地看出,对于 DRIVE 数据集,文中算法的分割结果相比于 U-Net 的分割结果,对于图像右侧和图像中部的细小血管保留更加完整,分割轮廓也更加清晰。对于 CHASE_DB1 数据集,文中算法的分割结果相比于 U-Net 的分割结果,在图像四周的细小血管末梢分割更为清晰,并且有效解决了细小血管断裂的问题,血管的连通程度更高。




图 4 分割结果对比

管分割断裂的问题,进一步提升模型的分割精度。

4 结束语

针对视网膜图像处理和医学影像的分割特点,传统的分割网络对于过分割和欠分割等问题,提出了一种通过在网络编解码结构中采用密集链接的方式增加卷积块的方法,增强了模型在不同尺度下对于图像细节的提取能力,确保最大程度地保留细节信息。从实验结果可以看出,该算法相比于其他算法有更好的分割效果。在后面的工作中,将着重于解决部分细小血

参考文献:

- [1] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25:1097-1105.
- [2] DENG J, DONG W, SOCHER R, et al. Imagenet: a large-scale hierarchical image database[C]//2009 IEEE conference on computer vision and pattern recognition. Miami,

- Florida, USA; IEEE, 2009: 248–255.
- [3] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Boston: IEEE, 2015: 3431–3440.
 - [4] 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. Munich, Germany: Springer, 2015: 234–241.
 - [5] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu, HI, USA; IEEE, 2017: 6230–6239.
 - [6] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834–848.
 - [7] ALOM M Z, HASAN M, YAKOPCIC C, et al. Recurrent residual convolutional neural network based on u-net (r2u-net) for medical image segmentation [J]. arXiv: 1802.06955, 2018.
 - [8] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention u-net: learning where to look for the pancreas [J]. arXiv: 1804.03999, 2018.
 - [9] 薛文渲, 刘建霞, 刘然, 等. 改进U型网络的眼底视网膜血管分割方法 [J]. 光学学报, 2020, 40(12): 1210001.
 - [10] 秦晓飞, 郑超阳, 陈浩胜, 等. 基于U型卷积网络的视网膜血管分割方法 [J]. 光学仪器, 2021, 43(2): 24–30.
 - [11] JÉGOU S, DROZDZAL M, VAZQUEZ D, et al. The one hundred layers tiramisu: Fully convolutional densenets for semantic segmentation [C]//Proceedings of the IEEE conference on computer vision and pattern recognition workshops. Honolulu, HI, USA; IEEE, 2017: 1175–1183.
 - [12] 梁礼明, 盛校棋, 郭凯, 等. 基于改进的U-Net眼底视网膜血管分割 [J]. 计算机应用研究, 2020, 37(4): 1247–1251.
 - [13] 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.
 - [14] 李大湘, 张振. 基于改进U-Net视网膜血管图像分割算法 [J]. 光学学报, 2020, 40(10): 58–66.
 - [15] 杨丹, 刘国如, 任梦成, 等. 多尺度卷积核U-Net模型的视网膜血管分割方法 [J]. 东北大学学报: 自然科学版, 2021, 42(1): 7–14.
 - [16] 代洋洋, 王宽全. UU-Net: 基于U-Net的U形多路径网络的视网膜血管分割 [J]. 哈尔滨工程大学学报, 2020, 41(5): 718–723.
 - [17] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu, HI, USA; IEEE, 2017: 2261–2269.
 - [18] SRIVASTAVA R K, GREFF K, SCHMIDHUBER J. Training very deep networks [J]. arXiv: 1507.06228, 2015.
 - [19] HARIHARAN B, ARBELÁEZ P, GIRSHICK R, et al. Hypercolumns for object segmentation and fine-grained localization [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Boston, MA, USA; IEEE, 2015: 447–456.
 - [20] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas, USA; IEEE, 2016: 770–778.
 - [21] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [J]. arXiv: 1502.03167, 2015.
 - [22] LI Y, CHEN Y, WANG N, et al. Scale-aware trident networks for object detection [C]//Proceedings of the IEEE/CVF international conference on computer vision. Seoul, KR; IEEE, 2019: 6053–6062.
 - [23] GHIASI G, LIN T Y, LE Q V. Nas-fpn: learning scalable feature pyramid architecture for object detection [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Long Beach, CA; IEEE, 2019: 7036–7045.
 - [24] LIU J J, HOU Q, CHENG M M, et al. A simple pooling-based design for real-time salient object detection [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Long Beach, CA; IEEE, 2019: 3917–3926.
 - [25] WU H, ZHANG J, HUANG K, et al. Fastfcn: rethinking dilated convolution in the backbone for semantic segmentation [J]. arXiv: 1903.11816, 2019.
 - [26] ZHAO Q, SHENG T, WANG Y, et al. M2det: a single-shot object detector based on multi-level feature pyramid network [C]//Proceedings of the AAAI conference on artificial intelligence. Honolulu, HI, USA; AAAI, 2019: 9259–9266.
 - [27] SUN K, XIAO B, LIU D, et al. Deep high-resolution representation learning for human pose estimation [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Long Beach, CA; IEEE, 2019: 5693–5703.
 - [28] MILLETARI F, NAVAB N, AHMADI S A. V-net: fully convolutional neural networks for volumetric medical image segmentation [C]//2016 fourth international conference on 3D vision (3DV). Stanford, CA, USA; IEEE, 2016: 565–571.
 - [29] ZHANG Z, LIU Q, WANG Y. Road extraction by deep residual U-Net [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 15(5): 749–753.
 - [30] ZHUANG J. Laddernet: multi-path networks based on u-net for medical image segmentation [J]. arXiv: 1810.07810, 2018.