

基于改进U-Net模型的细胞图像分割

郭健邦, 陈昌奉, 罗伟铭

(吉首大学 计算机科学与工程学院, 湖南 吉首 416000)

摘要: 为了解决传统U-Net模型存在的非线性特征提取能力有限、细胞图像分割精度较低的问题, 提出一种基于改进的U-Net网络模型的细胞图像分割算法。首先, 在U-Net网络模型的基础上改进原有Conv_Block卷积块的结构, 设计了一种新的卷积结构Catch_Conv, 减少U-Net网络在卷积过程中重复提取patch中的冗余信息; 其次, 在特征融合过程中引入带有残差模块的SE-Attention注意力机制Res-SEAtt, 确保U-Net网络感受野不减小的情况下, 降低池化处理导致的信息损失。实验表明, 所提算法的分割准确率达到97.88%, DICE系数达到92.45%, 相较于其他模型在评价指标上具有更好的分割效果。

关键词: 图像分割; 卷积神经网络; U-Net; 注意力机制

DOI: 10.11907/rjdk.241586

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2026)002-0172-08

扫描二维码阅读全文:



Cell Image Segmentation Based on Improved U-Net Model

GUO Jianbang, CHEN Changfeng, LUO Weiming

(College of Compute Science and Engineering, Jishou University, Jishou 416000, China)

Abstract: In order to solve the problems of limited non-linear feature extraction ability and weak cell image segmentation accuracy in traditional U-Net models, a cell image segmentation algorithm based on an improved U-Net network model is proposed. Firstly, based on the U-Net network model, the structure of the original Conv_Slock convolution block was improved, and a new convolution structure Catch_Cnv was designed to reduce the redundant information repeatedly extracted from patches in the U-Net network during the convolution process; Secondly, in the process of feature fusion, the SE-Attention attention mechanism Res-SEAtt with residual modules is introduced to ensure that the receptive field of the U-Net network does not decrease and to reduce the information loss caused by pooling processing. The experiment shows that the segmentation accuracy of the proposed algorithm reaches 97.88%, and the DICE coefficient reaches 92.45%, which has better segmentation performance compared to other models in terms of evaluation indicators.

Key Words: image segmentation; convolutional neural network; U-Net; attention mechanism

0 引言

图像分割是计算机视觉领域一个重要的研究方向, 旨在将数字图像中的像素分成不同区域, 使每个区域都具有相似的视觉特征。图像分割在医学影像分析、自动驾驶、智能视频监控等领域中应用广泛, 医学影像分析是最具挑战性的应用之一, 原因为医学图像通常具有复杂的结构和纹理, 还存在噪声和伪影等问题^[1]。

在过去数十年中, 不少学者提出了阈值分割、区域增长、边缘检测、图论、机器学习等图像方法^[1-3]。随着深度学习发展, 基于神经网络的图像分割算法受到广泛关注, 特别是U-Net模型现已成为目前广泛使用的图像分割模型之一^[4]。具体地, U-Net模型采用编码器—解码器结构, 编码器通过卷积与池化操作将输入图像转换为一系列特征图, 解码器将特征图上采样与编码器中对应层的特征图进行拼接, 将低级别特征与高级别特征相结合^[5]。此外, U-Net模型还使用跳跃连接保留特征图之间的细节信息改

收稿日期: 2024-12-10

基金项目: 国家自然科学基金项目(62266019); 湖南省自然科学基金项目(2024JJ7412); 国家级大学生创新训练计划项目(202210531009)

作者简介: 郭健邦(2001-), 男, 吉首大学计算机科学与工程学院学生, 研究方向为自然语言处理; 陈昌奉(1993-), 男, 博士, CCF会员, 吉首大学计算机科学与工程学院讲师, 研究方向为自然语言处理、计算机辅助医学诊断、图神经网络; 罗伟铭(2002-), 男, 吉首大学计算机科学与工程学院学生, 研究方向为自然语言处理。本文通讯作者: 陈昌奉。

善分割结果,使模型在许多图像分割任务中表现更出色,尤其是在医学图像分割中的效果十分优秀。

Abdulkadir等^[6]通过增加U-Net模型的深度、注意力机制以进一步优化U-Net模型,并将其应用于三维图像分割领域,取得了较好的分割结果。Cheng等^[7]进一步改进U-Net模型,提出一种新的网络结构DCAN捕捉图像中的边界信息,相较于传统U-Net模型效果更好。Jégou等^[8]提出一种基于密集连接网络的全卷积神经网络,对高分辨率图像进行高效分割,在大规模数据集上取得了优异的性能。Zhou等^[9]提出一种基于U-Net模型的新型网络结构UNet++,通过增加跳跃连接与上采样模块的数量、深度,取得了更好的分割效果,特别是在医学图像领域中的效果较好。Huang等^[10]提出UNet 3+,利用全尺度跳跃连接与深度监督来充分利用不同尺度的特征,提升模型分割精度与计算效率。

然而,由于U-Net模型的非线性特征表达能力较弱,在卷积过程中容易造成特征损失,导致分割精度不理想。为此,本文在文献分析的基础上总结了U-Net图像分割的研究现状,提出一种基于改进U-Net细胞图像分割模型。首先,在U-Net网络模型的基础上改进Conv_Block卷积块的结构,设计了一种新的卷积结构Catch_Conv,以减少U-Net网络在卷积过程中重复提取patch中的冗余信息;其次,在特征融合的过程中引入带有残差模块的SE-Attention注意力机制Res-SEAtt,确保不减小U-Net网络感受野的情况下进一步提取图像特征,降低池化处理导致的信息损失。

1 相关工作

1.1 U-Net网络结构

U-Net网络继承了全卷积神经网络(Fully Convolutional Networks, FCN)的框架,是由编码器、解码器和特征层连接组成的拓扑结构,因网络结构对称,形似英文字母“U”而得名^[4]。首先,编码器对应图像的收缩路径,用于提取图像上下文信息,一共分为4层,每层都包含两次3×3Vaild卷积、ReLU和一次下采样操作,主要对细胞前景和背景进行分类^[11];其次,解码器对应扩展路径,用于还原图像尺寸、修复图像细节,也分为4层,每层都包含两次3×3Vaild卷积、ReLU和一次上采样操作,以准确定位细胞;最后,通过特征层连接方法结合细粒度层信息与粗粒度层信息,将同一层收缩路径的特征图裁剪到与扩展路径大小一致,并进行拼接操作,以还原下采样过程中的损失信息,从而得到更多的细胞细节信息^[12,13]。综上,该设计使U-Net可利用较少的训练集进行训练,以取得较好的分割结果。

虽然,经典的U-Net网络中包含2×2 Max Pool最大池化操作,但收缩路径与扩展路径特征图仅为单纯拼接,会导致模型学到细胞非线性特征不强。在细胞图像单一、平

铺、规整时拥有不错的图像分割精度,但对重叠、黏连、团簇、组织包裹等多干扰噪声细胞样本进行分割时会出现精度下降的情况。换言之,U-Net网络对数据集的要求较高,在面对多干扰噪声的细胞数据时泛化能力不足。经典的U-Net网络结构如图1所示。

1.2 扩张卷积

扩张卷积是深度学习领域中一种重要的卷积操作,旨在处理多尺度信息及扩大感受野,在图像分割、物体检测等任务中性能提升显著^[13]。扩张卷积在医学图像处理中应用广泛,例如病灶检测和分割,国内外研究者开展了众多基于扩张卷积的医学图像处理研究,以提升疾病诊断和医学影像分析的准确性^[1-3]。

1.3 残差网络

深度神经网络在计算机视觉、自然语言处理和其他领域取得了广泛应用。当网络层数增加时,传统神经网络在训练中容易出现梯度消失或梯度爆炸问题,限制了网络深度。为此,Wu等^[14]提出残差网络(ResNet),引入跳跃连接(Skip Connection, SC)和残差块,允许网络学习残差函数以训练非常深的神经网络,解决深度神经网络训练过程中的梯度消失问题。实验表明,ResNet的深层网络结构在图像分类、物体检测和语义分割等任务中取得了卓越的性能。自从ResNet提出以来,研究人员便开始改进残差模块以提升模型性能,并拓宽深度学习在不同领域广泛应用。例如,DenseNet引入密集连接增强信息传递;SENet引入注意力机制以动态调整特征图权重。

1.4 SE模块

SE(Squeeze-and-Excitation)模块是一种深度学习中的关键组件,旨在增强模型对重要特征的关注度,提升网络性能^[15]。SE模块的核心思想是通过两个步骤来优化特征图:①在挤压(Squeeze)阶段,通过全局平均池化操作降低每个通道的维度,生成一个全局特征描述子;②在激发(Excitation)阶段,使用全连接层将全局特征描述子映射为一个权重向量,对原始特征图中的每个通道进行加权,调整每个通道的重要性,使加权后的特征图包含网络认为最有用的信息。

近年来,研究人员对SE模块提出了许多改进和扩展,以适应不同任务和网络架构。例如,有一些变种的SE模块专用于目标检测、语义分割、文本分类等任务。此外,还有研究工作探讨了如何将SE模块与其他关注机制(如注意力机制)相结合,以提升模型性能。

2 CCRS-Unet模型框架

2.1 整体模型框架

基于Catch_Conv与ResNet改进的U-Net网络(Catch_Conv-ResNet-UNet, CCRS-UNet)模型,以U-Net网络为基本框架,由卷积、下采样、上采样和拼接操作所组




Fig. 1 Classic U-Net structure

图1 经典的U-Net结构

成的编码器—解码器构成,如图2所示(网络左半边为收缩路径,右半边为扩展路径)。




Fig. 2 CCRS-UNet structure

图2 CCRS-UNet结构

在收缩路径上,对输入图像进行4次卷积和下采样操作,逐层提取图像重要特征并降低图像分辨率。在扩展路径上,首先将收缩路径的输出结果逐层进行上采样操作;其次,将图像抽象特征解码还原到原图尺寸,以修复图像细节、定位细胞位置,保留更多图像特征;最后,将相同层

次的收缩路径特征图与上采样结果特征融合后进行卷积,以提取图像特征。

本文改进了U-Net网络的Conv_Block卷积块,在初始U-Net网络的两次3×3卷积基础上加入1×1卷积操作,并进行张量拼接操作以形成Catch_Conv卷积块。在特征融

合过程中,引入带有残差块的SE-Attention注意力机制Res-SEAtt,以增加特征重复利用率,使模型提取更多图像细节信息,尤其是低对比度区域的信息。

2.2 扩张Conv_Block卷积块

U-Net网络的卷积过程是两次 3×3 卷积的顺序级联。本文在此基础上采用创新的拼接结构(Catch_Conv, CC),添加 1×1 卷积操作、改变张量通道数并进行一次张量拼接,以最大程度保留上层的线性与非线性特征,如图3所示。




Fig. 3 Catch_Conv structure

图3 Catch_Conv结构

假设模型输入为一个 $[1, C, n, n]$ 大小的张量,1为批量大小, C 为通道数, n 为图像长度和宽度。U-Net卷积操作的计算量为:

$$L_1 = [n^2 \times C \times (3 \times 3) \times 2 \times C] \quad (1)$$

$$L_2 = [n^2 \times 2C \times (3 \times 3) \times 2 \times 2C] \quad (2)$$

$$L_{\text{总}} = [L_1 + L_2 = n^2 \times C^2 \times 54] \quad (3)$$

式中: L_1 、 L_2 分别为第一、第二次 3×3 卷积的计算量。

改进后的卷积块计算量为:

$$R_1 = [n^2 \times C \times (3 \times 3) \times C] + [n^2 \times C \times (1 \times 1) \times C] \quad (4)$$

$$R_2 = [n^2 \times C \times (3 \times 3) \times 2C] + [n^2 \times 2C \times (1 \times 1) \times C] \quad (5)$$

$$R_{\text{总}} = R_1 + R_2 = n^2 \times C^2 \times 30 \quad (6)$$

式中: R_1 、 R_2 分别为图3中改进卷积块的两个卷积路径。

实验表明,本文所改进的U-Net卷积操作的计算量为传统U-Net网络卷积操作的5/9,且计算量差距会随 n 的提升逐渐变大。

2.3 带残差块的SE-Attention注意力机制

在U-Net网络中,收缩路径与扩展路径通过跳跃连接方式相互连接,使模型可同时捕捉局部、全局特征,在图像分割任务中可获得更好的性能。本文在跳跃连接中引入带有残差块的SE-Attention注意力机制(Res-SEAtt),而非简单的连接,共分为GAP、Excitation、Scale和Residual等4

个步骤,如图4所示。




Fig. 4 Res-SEAtt structure

图4 Res-SEAtt结构

SE-Attention注意力机制将下采样过程的特征图(feature map)进行一次过滤,使分割模型自动获取每个特征通道的重要程度及更多非线性特征,利用特征重要程度提升特征优先级,抑制对当前任务不重要的特征,消除跳跃连接过程中的噪声与无关信息,减少模型计算开销,增强模型灵敏度、分割精度及对前景的学习能力,在应对多干扰噪声细胞样本的分割上泛化能力更强。

由于注意力机制在低对比度的区域中学习效果不佳,本文在SE-Attention机制外层加上残差块,以保留更多的下采样输出信息,缓解低对比度区域及微弱边缘处的欠分割问题^[16]。

Res-SEAtt模块的全局平均池化(Global Average Pooling, GAP)操作是将每个通道的二维特征($H \times W$)压缩成一个实数 $1 \times 1 \times C$ 。

$$Z_C = f_{\text{GAP}}(U_C) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U_C(i, j) \quad (7)$$

式中: Z_C 、 U_C 均为张量; H 、 W 为图像的长、宽; f_{GAP} 为GAP操作的函数变换,以改进U-Net网络非线性特征提取能力有限的问题。

Excitation步骤是为每个特征通道生成一个权重值,通过两级全连接层(Full connection, FC)组成一个Bottleneck结构,构建通道间的相关性,并逐步迭代优化模型,使其更好地学习每个通道应占有的权重值。Scale步骤是将学习到的不同通道权重加权到对应通道特征上,通过与对应通道值相乘以引入Attention机制。

3 实验与结果分析

3.1 实验环境与数据集

实验硬件配置为AMD Ryzen 7 4800H、Nvidia GeForce GTX 1650Ti,以Pytorch为基础框架来训练、测试网络模型。实验数据集为Booz Allen Hamilton公司联合Kaggle公司面向全球共同发起的Data Science Bowl Featured Prediction Competition中提供的各种细胞病理切片图像,如图5所示^[17]。

具体地,数据集中共包含670张在不同条件下获得的




Fig. 5 Cell data set sample types

图5 细胞数据集样本类型

各类细胞图像,细胞形态不同、图像放大倍率不同、成像方式也不同(包含荧光彩图与灰度图像),每张图片都有对应的 ImageId。同时,以二八比例分割数据集,将 538 张图片作为训练集,剩下的 132 张图片作为测试集。其中,训练集图片共有 9 种分辨率,且每张原图有多个 mask,即一张图含有多个细胞。

本文通过规整化操作,将图片分辨率统一为 256×256 大小的 png 格式图片,并将多个 mask 合并为一张带标签的蒙板真值图,合并过程如图 6 所示。




Fig. 6 Mask tag merging process

图6 Mask 标签组合并流程

3.2 图像预处理

针对细胞形态的多样性(细胞重叠、细胞黏连、密集分布等情况)问题,通过结合 Laplacian 算子、采用限制对比度自适应直方图均衡化方法(Contrast Limited Adaptive Histogram Equalization, CLAHE)来增强图像特征,如图 7 所示^[18,19]。其中,Laplacian 算子对原始进行滤波操作,通过锐化细胞边界将细胞目标前景从背景中突显出来。

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (8)$$




Fig. 7 CLAHE noise reduction method

图7 CLAHE 降噪法

$$g(i,j) = \sum_{r=-k}^k \sum_{s=-l}^l f(i-r, j-s) H(r,s) \quad (9)$$

$$H_1 = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad (10)$$

式中: $i, j=0, 1, 2, \dots, N-1; k=1, l=1, H(r,s)$ 。

CLAHE 降噪法能限制图像噪声,提升细胞边缘对比度,强化重叠密集黏连的细胞边缘,降低噪声对分割的影响^[19,20]。首先,将图像分为 $n \times n$ 个子区域,每个子区域大小相等,连续且不重叠;其次,计算每个子区域的直方图,用 $l(k)$ 表示;最后,计算裁剪幅值 δ 。

$$\delta = C_{\text{clip}} = \frac{N_x \cdot N_y}{M} \quad (11)$$

式中: N_x, N_y 分别为每个子区域在 x, y 方向上的像素个数; M 为对应子区域的灰度级数; C_{clip} 为裁剪系数。

基于幅值 δ 剪切每个子区域的直方图 $l(k)$,将超出幅值的像素平均分配到每个灰度级上,并计算超出幅值的像素点总数 N_{total} 及每个灰度级平均分配到的像素 N_{sub} 。

$$N_{\text{total}} = \sum_{k=0}^{M-1} \{ \max [l(k) - \delta] \} \quad (12)$$

$$N_{\text{sub}} = \frac{N_{\text{total}}}{M} \quad (13)$$

同时,利用 $l'(k)$ 表示重新分配后的直方图。

$$l'(k) = \begin{cases} \delta + N_{\text{sub}} & l(k) \geq \delta \\ l(k) + N_{\text{sub}} & l(k) \leq \delta \end{cases} \quad (14)$$

最后,依次对每个子区域的新直方图 $l'(k)$ 作均衡化处理,通过双线性插值得最终图像,如图 8 所示。

3.3 训练细节

目前,在二分类图像分割任务中,通常采用的损失函数为像素级的二进制交叉熵损失函数。为了解决图像中正负类别不平衡的问题,本文采用的损失函数如式(15)所示^[21]。TverskyLoss、CrossEntropyLoss 的计算公式分别如式(16)、式(17)所示。

$$L = \text{TverskyLoss} + (\alpha \times \text{CrossEntropyLoss}) \quad (15)$$




Fig. 8 Partial image preprocessing results

图8 部分图像预处理结果

$$T(\alpha, \beta) = \frac{\sum_{i=1}^N p_{0i} g_{0i}}{\sum_{i=1}^N p_{0i} g_{0i} + \alpha \sum_{i=1}^N p_{0i} g_{1i} + \beta \sum_{i=1}^N p_{1i} g_{0i}} \quad (16)$$

$$C = -\frac{1}{N} \sum_{i=1}^N [y_i \log p_i + (1 - y_i) \log (1 - p_i)] \quad (17)$$

式中: P_{0i} 为预测情况中第 i 个像素属于目标区域的概率; P_{1i} 为预测情况中第 i 个像素属于背景区域的概率; g_{0i} 为真实情况中第 i 个像素属于目标区域的概率; g_{1i} 为真实情况中第 i 个像素属于背景区域的概率; p_i 为预测值; y_i 为真实值。

在参数设置方面,本文采用 Adam 算法优化损失函数,初始学习率为 0.001,批量大小为 1,训练迭代为 100 次, $A=0.1$, TverskyLoss 的 α, β 分别为 0.3、0.7。

3.4 评估指标

本文采用交并比 (Intersection over Union, IoU)、骰子系数 (Dice Score, DICE)、准确度 (accuracy)、灵敏度 (sensitivity)、特异度 (specificity) 等 5 个指标测评分割性能^[22]。

$$R_{IoU} = \frac{TP}{TP + FP + FN} = \frac{|A \cap B|}{|A \cup B|} \quad (18)$$

$$S_{scroe} = \frac{2TP}{2TP + FP + FN} = \frac{2|A \cap B|}{|A| + |B|} \quad (19)$$

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (20)$$

$$sensitivity = \frac{TP}{TP + FN} \quad (21)$$

$$specificity = \frac{TN}{TN + FP} \quad (22)$$

式中: TP、TN、FP、FN 分别为细胞像素正确分类数目、背景像素正确分类数目、背景像素错误分类数目、细胞像素错误分类数目; A, B 分别为真实值和预测值; IoU 为语义分割的标准度量,是真实值和预测值的交集与并集比,值为 1 时表示两者完全相同; Dice Score 为医学图像分割的重要度量,表示真实值与预测值的相似度,值越大表示两者相似度越高; accuracy、sensitivity、specificity 是二分类任务中经典的分类指标,值越大越好。

3.5 实验结果

为了验证本文模型的有效性,将所提模型与 U-Net 模

型、Res-UNet、Seg-Net、R2U-net 进行比较,如表 1 所示^[23-25]。由此可知,CCRS-UNet 模型在 IOU、DICE 分数上表现最好,表明他对图像分割任务的像素级别匹配效果最佳。CCRS-UNet 相较于其他模型,重叠度、分割精度、准确率更优秀,对整体图像分割任务的分类性能最好,能正确分割出图像中的各个区域,与真实标签匹配更准确。在敏感性方面,CCRS-UNet 的性能略低于 U-Net、Res-UNet,表明模型在检测图像正例方面的表现良好。在特异性方面稍逊于 Seg-Net,表明模型在准确检测负例方面的表现良好,可避免将负例误分类为正例。

Table 1 Comparison results of CCRS-UNet with multiple network models

表 1 CCRS-UNet 与多个网络模型的比较结果

模型名称	指标				
	IOU	DICE	accuracy	sensitivity	specificity
CCRS-UNet	0.864 52	0.924 5	0.978 8	0.958 0	0.978 5
U-Net	0.843 07	0.912 5	0.974 0	0.958 9	0.974 4
Res-UNet	0.846 31	0.913 4	0.976 4	0.956 0	0.979 5
Seg-Net	0.817 35	0.895 4	0.970 7	0.934 2	0.976 0
R2U-Net	0.845 12	0.912 9	0.976 4	0.951 3	0.980 7

综上,CCRS-UNet 在多个指标上表现优异,特别在 IOU、DICE 和准确率方面更为突出,进一步证明了所提模型在图像分割任务中具有良好的性能和鲁棒性。

图 9 为 CCRS-UNet 在某张图片上的可视化结果。由此可见,CCRS-UNet 的分割效果相较于比较模型更优秀。




Fig. 9 Comparison of segmentation performance between CCRS-UNet and other models

图 9 CCRS-UNet 与其他模型分割效果比较

同时,本文进行消融实验以验证 CCRS-UNet 模型各模块对整体性能的影响,实验结果如图 10 所示。消融模型的样本分割笑容结果如图 11 所示。由此可见,相较于初始的 U-Net 网络模型,CCRS-UNet 在性能上得到了全面提升。当去除 SE-Attention 机制后性能下降,证明了带有残差块的 SE-Attention 注意力机制可降低池化处理导致的信息损失问题,提升了模型灵敏度与分割精度。CCRS-UNet 中未加入 Att 机制的性能仍然优于添加 Att 的 U-Net 网络模型,证明了 Att 机制在不同神经网络模型中的影响并非总是正向的,需要进行针对性分析。




Fig. 10 CCRS-UNet ablation experiment normalization results

图 10 CCRS-UNet消融实验归一化结果




Fig. 11 Ablation experiment results

图 11 消融实验结果

在总体运算耗时方面,将 CCRS-Unet 模型与 U-net 等模型进行比较,实验结果如表 2、图 12 所示。由此可知,CCRS-UNet 模型的图像分割耗时相较于 U-Net 模型耗时更短,证明了扩张 Catch_Conv 卷积块可减少 U-Net 网络在卷积过程中重复提取 patch 冗余信息,显著提升了模型分割效率。

Table 2 Comparison of the running results between CCRS-UNet and multiple network models

表 2 CCRS-UNet 与多个网络模型的运行结果比较

模型名称	比较指标	
	耗时/s	参数/MB
CCRS-UNet	63	71.1
U-Net	80	118
Res-Unet	105	49.8
Seg-Net	69	112
R2U-Net	221	149

4 结语

本文为了更准确地从细胞病理切片图像中分割细胞,提出一种基于改进 U-Net 网络模型的细胞图像分割算法




Fig. 12 Time consumption of CCRS-Net and other models under different numbers of images

图 12 不同图像数量下 CCRS-Net 与其他模型的耗时

CCRS-UNet。首先,对传统 U-Net 网络的卷积块进行改进,采用创新的张量拼接结构,引入 1×1 卷积形成 Catch_Conv 卷积块最大程度保留上层的线性与非线性特征;其次,减少 U-Net 网络在卷积过程中重复提取 patch 冗余信息,以降低计算资源消耗(相较于 U-Net 网络,耗时、参数分别降低 12.5%、39.75%);最后,采用 Res-SEAtt 机制加强细胞区域的权重,提取更多非线性特征,确保 U-Net 网络感受野不减小的情况下,降低池化处理所导致的信息损失,减缓图像亮度不均衡、对比度低对模型造成的干扰,提升模型在不同类型细胞分割中的分割精度。

实验表明,所提模型对细胞图像的分割精度为 97.88%,IoU 达到 86.452%。然而,本文研究仅在单一数据集下进行实验,后续将扩充实验数据集,增强 CCRS-UNet 的泛化能力,还将进一步优化网络结构,使其更好地捕获局部细节信息,提升模型分割精度。

参考文献:

- [1] CUI K, TIAN Q C, LIAN L. A review of medical image segmentation algorithms based on U-Net variants[J]. Computer Engineering and Applications, 2024, 60(11): 32-49.
崔珂,田启川,廉露. 基于 U-Net 变体的医学图像分割算法综述[J]. 计算机工程与应用, 2024, 60(11): 32-49.
- [2] PU Q M, YIN S, LI Z M, et al. A review of U-shaped convolutional networks in breast medical image segmentation[J]. Computer Science and Technology, 2024, 18(6): 1383-1403.
蒲秋梅,殷帅,李正茂,等. U 型卷积网络在乳腺医学图像分割中的研究综述[J]. 计算机科学与探索, 2024, 18(6): 1383-1403.
- [3] RAYHAN M A, IQBAL A M F, MUZAHIDUL A I, et al. DOLG-NeXt: convolutional neural network with deep orthogonal fusion of local and global features for biomedical image segmentation[J]. Neurocomputing, 2023, 546: 126362.
- [4] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]// Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.
- [5] XIA Y, LIU W, YANG D, et al. Early stage tumor segmentation in breast

- MRI using shape enhanced U-Net[J]. Biomedical Signal Processing and Control, 2024, 93:106198.
- [6] ÇİÇEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation[C]// Medical Image Computing and Computer-Assisted Intervention, 2016: 424–432.
- [7] CHENG J, LIU J, XU Y W, et al. Superpixel classification based optic disc and optic cup segmentation for glaucoma screening[J]. IEEE Transactions on Medical Imaging, 2013, 32(6):1019–1032.
- [8] 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, 2017: 11–19.
- [9] ZHOU Z, RAHMAN S M M, TAJBAKHS N, et al. UNet++: a nested U-Net architecture for medical image segmentation[C]// Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, 2018: 3–11.
- [10] HUANG H M, LIN L F, TONG R F, et al. UNet 3+: a full-scale connected UNet for medical image segmentation[C]// IEEE International Conference on Acoustics, Speech and Signal Processing, 2020: 1055–1059.
- [11] SØRENSEN K, CAMARA O, DE BACKER O, et al. NUDF: neural unsigned distance fields for high resolution 3D medical image segmentation[C]// IEEE 19th International Symposium on Biomedical Imaging, 2022: 1–5.
- [12] BRAHAM Y, ELLOUMI Y, AKIL M, et al. Parallel computation of watershed transform in weighted graphs on shared memory machines[J]. Journal of Real-Time Image Processing, 2018(1): 1–16.
- [13] LIN Y Y, LU D Y, BAO X Y, et al. Analysis of image salient object detection method integrating attention and multi-scale dilated convolution[J]. Electronic Technology, 2024, 53(5): 35–37.
林元元,鲁大营,包新月,等.融合注意力和多尺度扩张卷积的图像显著性目标检测方法分析[J].电子技术,2024,53(5):35–37.
- [14] WU Z F, SHEN C H, HENGEL A V D. Wider or deeper: revisiting the ResNet model for visual recognition[DB/OL]. <https://arxiv.org/abs/1611.10080>.
- [15] JIN X, XIE Y P, WEI X S, et al. Delving deep into spatial pooling for squeeze-and-excitation networks[J]. Pattern Recognition, 2022, 121: 108159.
- [16] OLIVIER P, THOME N, RAMBOUR C, et al. U-Net transformer: self and cross attention for medical image segmentation[C]// Machine Learning in Medical Imaging, 2021: 267–276.
- [17] CAICEDO J C, GOODMAN A, KARHOHS K W, et al. Nucleus segmentation across imaging experiments: the 2018 data science bowl[J]. Nat Methods, 2019, 16:1247–1253.
- [18] LI M H, GAO S S, HAN H J, et al. Image smoothing method combining L₀ optimization and Laplace operator[J]. Journal of Computer-Aided Design & Graphics, 2021, 33(7): 1000–1014.
李孟航,高珊珊,韩慧健,等.结合L₀优化与拉普拉斯算子的图像平滑方法[J].计算机辅助设计与图形学学报,2021,33(7):1000–1014.
- [19] CAI Z Z, TANG P, HU J B, et al. Retinal vessel segmentation based on PST and multi-scale Gaussian filter[J]. Application Research of Computers, 2019, 36(6):1893–1896.
蔡震震,唐鹏,胡建斌,等.基于PST和多尺度高斯滤波的视网膜血管的分割[J].计算机应用研究,2019,36(6):1893–1896.
- [20] TANG H Y, WANG Y, SONG C, et al. Breast cell image segmentation algorithm based on cavity U-Net network[J]. Journal of Optoelectronics · Laser, 2021, 32(5): 470–476.
唐浩漾,王燕,宋聪,等.基于空洞U-Net网络的乳腺细胞图像分割算法[J].光电子·激光,2021,32(5):470–476.
- [21] VALVERDE M J, SHATILLO A, TOHKA J. Sauron U-Net: simple automated redundancy elimination in medical image segmentation via filter pruning[J]. Neurocomputing, 2024, 594: 127817.
- [22] ZHOU T, DONG Y L, HUO B Q, et al. Review on the application of U-Net network medical image segmentation[J]. Journal of Image and Graphics, 2021, 26(9):2058–2077.
周涛,董雅丽,霍兵强,等.U-Net网络医学图像分割应用综述[J].中国图象图形学报,2021,26(9):2058–2077.
- [23] XIAO X, LIAN S, LUO Z M, et al. Weighted Res-UNet for high-quality retina vessel segmentation[C]// 9th International Conference on Information Technology in Medicine and Education, 2018:327–331.
- [24] RAJAKUMAR G, LEELA J R S, DARNEY P E, et al. Seg-Net: automatic lung infection segmentation of COVID-19 from CT images[C]// 5th International Conference on Trends in Electronics and Informatics, 2021: 739–744.
- [25] ALOM Z M, HASAN M, YAKOPCIC C, et al. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for Medical Image Segmentation[EB/OL]. <https://pubmed.ncbi.nlm.nih.gov/30944843/>.
(责任编辑:刘嘉文)