

基于U-Net++的医学细胞核图像分割方法研究

龚梓坤

(南京邮电大学通达学院, 江苏 扬州 225127)

摘要: 针对传统方法提取医学细胞核轮廓不清晰、识别目标准确率不高的问题, 提出一种基于U-Net++的医学细胞核图像分割方法, 并引入降噪层对分割图像进行降噪处理。首先, 对医学细胞核图像进行合并掩码、调整图像大小的处理, 形成数据集; 然后, 将数据集输入U-Net++进行训练, 并在模型收敛后, 通过剪枝操作去除冗余的参数, 得到医学细胞核图像分割模型; 最后, 将该模型应用到医学细胞核, 得到总体精度更高、分割效果更稳定的细胞核分割结果。在验证集训练中, 该方法的总体精度达到84%, 相比U-Net提升了19.1%, 较Feedback U-Net提高了6.7%。实验结果表明, U-Net++在细胞核图像分割任务中表现出色, 不仅在分割精度上明显优于其他方法, 还展现出良好的泛化能力和强大的特征提取能力。

关键词: U-Net++; 医学细胞核; 图像分割; 特征融合; 卷积神经网络

DOI: 10.11907/rjtk.251053

扫描二维码阅读全文:



中图分类号: TP391.9

文献标识码: A

文章编号: 1672-7800(2026)004-0155-07

Research on Segmentation Method of Medical Nuclear Image based on U-Net++

GONG Zikun

(Tongda College of Nanjing University of Posts and Telecommunications, Yangzhou 225127, China)

Abstract: Aiming at the problems that the traditional methods of extracting medical nuclear outline are not clear and the accuracy of target recognition is not high, a U-net ++ based medical nuclear image segmentation method is proposed and noise reduction layer is introduced to reduce the segmentation image. Firstly, the medical nuclear images are processed by merging mask and adjusting image size to form a data set. Then, the data set was input into U-NET ++ for training until convergence, and redundant parameters were removed by pruning operation to obtain a medical nuclear image segmentation model. Finally, the model is applied to medical nuclei, and the results of nuclear segmentation with higher overall precision and more stable segmentation effect are obtained. After verification set training, the overall accuracy of the proposed method can reach 84%, about 19.1% higher than U-Net, and about 6.7% higher than Feedback U-Net. The experimental results show that U-NET ++ has higher segmentation accuracy and better generalization ability than other methods in nuclear image processing, showing a strong ability to extract nuclear image features.

Key Words: U-Net++; medical cell nucleus; image segmentation; feature fusion; convolution neural network

0 引言

手术导航对手术具有重要的指导作用, 能显著提高手术的精确性、安全性和成功率。其中, 医学细胞图像分割是手术导航中的关键环节。通过图像分割技术, 可以将图像中的目标区域(如细胞、器官或病变区域)从背景中提取出来, 为后续分析提供基础数据。这种技术能够帮助医护人员进一步诊断疾病, 或对其进行深入研究, 展现出广阔的应用前景。

然而, 手术导航领域的研究对医学细胞核图像分割的精确度要求较高, 这也是该技术的关键和难点所在。因此, 越来越多的学者提出具有不同特点的分割网络模型, 旨在提高图像分割结果的精度和计算效率。

Simonyan等^[1]提出了基于深度学习的网络框架VGG-Net, 构建了16~19层深度卷积神经网络, 有效地提取了图像的特征。同时, 该方法迁移到其它图片数据上的泛化性也较好, 但网络性能较低, 计算量较大。He等^[2]提出了一种神经网络框架ResNet, 引入恒等映射, 较准确地将梯度反馈到前面的网络层, 但该算法搭建的网络层数较多, 训

收稿日期: 2025-03-04

基金项目: 南京邮电大学通达学院大学生创新创业训练计划项目(202413989021Y)

作者简介: 龚梓坤(2004-), 女, 南京邮电大学通达学院计算机工程学院学生, 研究方向为计算生物、图像识别。

练时间较长。Long等^[3]提出了一种全卷积神经网络框架FCN,能够对任意大小的图像进行像素级别的预测和分割,但该网络在上采样过程中可能导致信息丢失,使得小目标分割的效果不佳。Ronneberger等^[4]提出了一种深度学习框架U-Net,可以自动学习图像特征,并实现高精度的分割结果,但网络获取的上下文信息较少,可能会出现边界模糊或者分割错误的情况。Zhou等^[5]提出了U-Net++网络,通过引入密集跳跃连接和深度监督,确保模型在不同场景、不同尺度下都能够很好地捕捉信息。同时,该网络在训练过程中能更好地监督网络的学习,从而提升分割精度。

针对医学细胞核图像目标众多且难以有效捕捉图像信息,导致分割精度较低的问题,本文提出一种基于U-Net++网络的医学细胞核图像分割算法,同时引入降噪层对图像进行进一步优化。

1 算法框架及原理

医学图像分割在手术导航中起着关键作用,其目的是将医学图像中的不同区域或组织(例如细胞)自动分割出来。这一技术在医学影像后续分析中为医生提供了重要支持。本文所提的U-Net++算法的系统框架如图1所示,共分为3个部分:

(1)特征提取。U-Net++网络中采用编码器部分完成图像的特征提取^[6]。

(2)特征融合。通过跳跃连接,将低层特征直接传递到相应的解码层进行元素拼接,以帮助恢复图像的细节^[7]。特征图通过多个额外的卷积层处理,以提取更高层次的特征,从而对特征图进行更精细的处理,最终产生分割结果。

(3)优化预测结果。对U-Net++网络中各个中间层和最终层的输出进行损失计算,使模型不仅关注最终的预测结果,还能够根据每一层的输出信息进行自我调整。同时,在深监督输出之前加入降噪层,通过3×3卷积平滑特征图,减少噪声干扰,进一步提升分割精度和模型的泛化能力。




Fig. 1 Block diagram of the image system

图1 图像系统框图

1.1 编码器特征提取

编码器结构大致分为3个部分:卷积层^[8]、池化层^[8]和激活函数^[9],如图2所示。首先,编码器接受W/96×H/96×670的张量信息作为输入。接着,在输入数据上应用卷积核进行运算:利用3×3的卷积核,逐步在图像的不同位置移动^[10]。同时,在输入特征图的四周补充1个像素,以防止因卷积操作引起的特征图的尺寸缩小。卷积核每次在其覆盖的局部区域内进行加权求和运算。其中,输入特征图X从(i,j)位置开始,取(m,n)的局部像素值,X(i+m,j+n)用来定位滑动窗口中卷积核覆盖的区域。K(m,n)表示卷积核K(一个3×3的小矩阵)在(m,n)位置的权重。卷积核K中的每个元素与K对应的输入区域X(i+m,j+n)进行乘积,并对运算结果进行累加,得到(i,j)位置的输出值Y(i,j),表达式如公式(1)所示:

$$Y(i,j)=\sum_{m=0}^{k-1}\sum_{n=0}^{k-1}X(i+m,j+n)\times K(m,n) \quad (1)$$




Fig. 2 Encoder structure

图2 编码器结构图

得到特征图的输出后,接着应用激活函数ReLU,对输出结果引入非线性特性,使得网络在进行特征学习时更加稀疏,从而有助于提高模型的表达能力^[11]。其中,该函数判断卷积层的输出x,若x大于0,f(x)即输出为原值;若x小于0,f(x)=0。表达式如公式(2)所示:

$$f(x)=\max(x,0) \quad (2)$$

最后,采用最大池化操作:在特征图上取2×2的区域,随后从中选取最大值,使得特征图的尺寸减少至原特征图的1/2^[12]。池化操作共进行4次,最终特征图的尺寸大小

为6×6。经过池化操作,在保留图片重要特征的前提下,减少了图片的尺寸,大大降低了计算量。

1.2 U-Net++特征融合

U-Net++网络是一种专门用于图像分割的网络,其核心在于改进的特征融合机制。通过这一机制,网络能够在复杂场景下更好地处理多尺度物体,并有效解决边界模糊问题。该模型具体实现特征融合任务的过程如下:

(1)采用上采样操作^[13](双线性插值算法^[14]),将解码器中深层的低分辨率特征图扩大到与浅层特征图一致的

分辨率。

(2)通过跳跃连接,将编码器中每一层的特征图传递给解码器中完成上采样的相应层,两者沿着通道维度进行拼接,拼接后的特征图包含了来自编码器的浅层空间信息和解码器的深层语义信息^[15]。

(3)将拼接后的特征图输入卷积层,融合来自不同来源的特征,生成新的特征图。U-Net++网络结构如图3所示。




Fig. 3 U-Net++ network structure

图3 U-Net++网络结构

1.2.1 像素的匹配

本文运用双线性插值算法,通过计算输入像素周围4个最近邻像素的加权平均值来估计新位置的像素值^[14]。其中,输入像素点P周围4个像素点为Q11、Q12、Q21、Q22,它们的值分别对应 $f(Q11)$ 、 $f(Q12)$ 、 $f(Q21)$ 、 $f(Q22)$,算法具体实现步骤如下:

首先,沿着水平方向对Q11、Q12和Q21、Q22进行水平插值,估计新像素点在水平方向上的值。 dx_1 和 dx_2 分别指新像素点相对于Q11、Q12和Q21、Q22的水平位置的差异。以Q11、Q12为例, dx_1 和 $1-dx_1$ 为Q11、Q12赋予的权重。若P更靠近Q11(即 dx_1 减小),则权重应该更倾向Q11,同时Q12的权重应该减小。因此,为Q11赋权重 $1-dx_1$,以增大Q11对水平插值结果的贡献;为Q12赋权重 dx_1 ,以减小Q12对水平插值结果的贡献。相反,若P更靠近Q12(dx_1 增大),这时 dx_1 会赋予Q12更大的权重,而Q11的权重会变小。通过这种加权方式,实现了在P位置附近对2个相邻像素值平滑过渡的目标。对Q21、Q22的赋权以此类推,经过水平插值,得到2个中间的插值结果(R1对应Q11、Q12的水平插值结果;R2对应Q21、Q22的水平插值结果)。

其次,将中间插值结果进行垂直方向上的插值, dy_1 、 dy_2 指P相对于R1和R2的垂直位置的差异。根据插值点在垂直方向上的坐标,对R1和R2进行加权求和(R1、R2由 dy_1 、 dy_2 控制权重),Y为新位置的像素值。表达式如公式

(3)所示:

$$Y = (1 - dy_1) \times [(1 - dx_1) \times Q11 + dx_1 \times Q12] + dy_1 \times [(1 - dx_2) \times Q21 + dx_2 \times Q22] \quad (3)$$

然后,将这些计算得出的新像素值填充到目标图像的相应位置。填充后的特征图为原特征图的2倍,填充操作进行4次,使高层次的特征图放大至与低层次的特征图相同的分辨率。

最后,将输入特征图的角点与输出特征图的角点对齐,确保填充后图像的几何特性整体保持一致,避免图像边界出现不一致的情况。

1.2.2 特征图的拼接

特征图的拼接是图像分割网络的核心部分之一。在U-Net网络中,特征图的拼接处理方式是简单地将编码器层的特征直接复制到解码器的对应层,而不进行额外处理。因此,许多分割网络针对此提出了改进。其中,RU-Net采用循环连接进行特征图的拼接处理,即特征图的每个像素的特征在每一层内部循环更新,使得每个像素的特征随着时间步不断优化,最终收敛到稳定状态^[16]。然而,这会导致每个像素需要在多个时间步内反复计算,若时间步过多,甚至会出现梯度消失或爆炸的问题,大大降低计算效率。

为了解决计算重复率过高的问题,Feedback U-Net采用解码器端的反馈优化机制,即特征图的特征反馈发生在解码器的多个层之间。这意味着Feedback U-Net无需在每个层内重复计算多次,从而显著降低了计算重复率。然而,由于Feedback U-Net需要依赖多次反馈迭代,并且特征层之间的连接并非固定,这使得模型训练成本增加,不利于实际应用。为了解决这一问题,本文采用U-Net++网络中固定且高效的跳跃连接进行特征图的拼接。

首先,该算法将编码器的每一层的特征图直接传递到解码器的相应层,确保在编码器的深层过程中没有丢失浅层的重要特征。接着,将编码器中的特征图和解码器中的特征图在通道维度上合并,形成新的特征图。

跳跃连接是U-Net++网络最具优势的设计部分。它帮助网络传递更细粒度的特征,避免信息丢失,同时也确保了在编码器的深层过程中没有丢失浅层的重要特征。位置 (i, j) 的特征图的像素值 $Y_{i,j}$ 的计算,结合了来自前一层或相邻像素点的信息,表达式如公式(4)所示:

$$Y_{i,j} = o(W_{i,j} \times [Y_{i-1,j}, Y_{i,j-1}] + b_{i,j}) \quad (4)$$

其中, $W_{i,j}$ 为权重矩阵,表示用于当前层卷积操作的卷积核。该矩阵为前一层同一列的特征图值($Y_{i-1,j}$)和同一层前一列位置的特征图值($Y_{i,j-1}$)加权赋值。 $b_{i,j}$ 是偏置项,用于微调卷积运算的结果。通过激活函数 $o(f(x))$ 的非线性变换,将加权后的特征值激活为新特征图的输出值 $Y_{i,j}$ 。同时,在将编码器特征图与解码器特征图进行通道维度拼接之前,需先判断二者的空间尺寸是否一

致。若不一致,可以通过上采样方式,将解码器特征图的大小调整至与编码器特征图的大小相同。

最终,将编码器输出的特征图与解码器输出的特征图在第三通道维度进行合并,使得网络在解码阶段能够同时利用高层语义信息和低层空间细节信息。

1.2.3 特征信息的整合

为了提取更有效的特征信息,对拼接后的特征图进行卷积操作,以生成更精确的特征表示,从而提高网络的预测精度。

本研究使用一个二维的 3×3 的矩阵 $i1$,其包含了一组需要学习的权重参数。接着,卷积核以 1 步幅从图像 $i2$ 左上角开始,逐步在图像上移动。每次卷积核都会覆盖图像中的一小部分区域。需要说明的是,为了在进行卷积操作后避免输出特征图尺寸明显减小,在卷积操作前需要对输入图像的边缘进行 0 填充。卷积核每次的移动都会对图像 $i2$ 的对应区域 $c12$ 进行加权求和,从而得到一个新的输出特征图。由于输入图像的通道为 3 通道,因此需要对每一个通道使用一个卷积核。最终,累加所有通道的加权结果,输出特征图像。卷积运算的加权求和的表达式,如公式(5)所示:

$$h(t) = \int f(T)g(t-T)dT \quad (5)$$

其中, $f(T)$ 为输入信号, $g(t-T)$ 代表卷积核在时间 $t-T$ 上滑动, $h(t)$ 是通过卷积操作产生的输出。在位置 T 上,即两者重叠部分, $f(T)$ 与卷积核 $g(t-T)$ 所代表的权重一一对应相乘,并对相乘结果进行积分,达到对每个位置的结果进行累加的目标。

通过对拼接后的图像进行卷积操作,减少了特征融合中产生的不相关信息和噪声,从而增强了网络的鲁棒性^[16]。该操作使模型能够更关注重要的局部特征,同时保留了全局信息。

1.3 预测结果的优化

由于医学细胞通常仅占病理图像的一小部分,这导致了严重的类别不平衡问题,并且缺乏有效评估模型预测误差的功能。为此,本文采用一种 $BCEDiceLoss$ 的复合损失函数,以解决上述问题^[17]。

首先,将解码器输出的概率图(表示每个像素属于前景或背景的概率)与真实的标签图进行对比,计算 BCE 损失,衡量每个像素的分类误差。

其次,计算 $Dice$ 损失,衡量预测区域与真实分割区域的重叠情况。将 BCE 损失和 $Dice$ 损失加权求和,得到最终的 $BCEDiceLoss$ 值。通过 $BCEDiceLoss$ 函数的梯度,进行反向传播,更新 U-Net++ 网络中的参数,以减少预测误差。 BCE 损失的表达式如公式(6)所示:

$$L_{BCE}(y, \hat{y}) = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (6)$$

其中, $\hat{y}_i$ 代表第 i 个样本的真实标签(0代表前景、1代表背景), $\hat{y}_i$ 代表第 i 个样本的预测概率。如果真实标签 $y_i=1$,则希望模型输出的预测概率 $\hat{y}_i$ 越接近 1 越好,这时的损

失是 $-\log(\hat{y}_i)$ 。如果真实标签 $y_i=0$,则希望模型输出的预测概率 $\hat{y}_i$ 越接近 0 越好,这时的损失是 $-\log(1-\hat{y}_i)$ 。通过 BCE 函数,计算真实标签和预测概率之间的对数差异,鼓励模型生成更准确的二分类概率。 $Dice$ 损失的表达式如公式(7)所示:

$$L_{Dice}(p, g) = 1 - \frac{2 \cdot \sum p_i g_i}{\sum p_i + \sum g_i} \quad (7)$$

其中, p_i 表示第 i 个像素的预测值(0~1 的概率), g_i 表示第 i 个像素的真实标签(1代表前景,0代表背景)。通过对 $p_i g_i$ 的累加,衡量预测目标和真实标签在前景像素上的重叠程度。 $\sum p_i$ 和 $\sum g_i$ 分别代表模型预测的前景区域像素数和真实的前景区域像素数。通过对预测模型和真实结果的交集像素数与预测区域和真实区域的总像素数进行归一化处理,结果 $L_{Dice}(p, g)$ 表示为一个标准化的比例值($Dice$)。由于损失函数需满足损失值越小表示预测越准确的条件,因此采用 $1-Dice$ 来满足这一属性。

最后,将 BCE 损失和 $Dice$ 损失进行加权求和,得到最终的 $BCEDiceLoss$ 值。 $BCEDiceLoss$ 损失函数的表达式如公式(8)所示:

$$BCEDiceLoss(p, g) = \alpha \times L_{Dice}(p, g) + \beta \times L_{BCE}(p, g) \quad (8)$$

其中, L_{BCE} 代表 BCE 函数的损失值, L_{Dice} 代表 $Dice$ 函数的损失值, α 和 β 是调节 2 个损失部分的权重,它们的和为 1。通过加权求和,两者用来平衡 BCE 和 $Dice$ 的贡献。通过 BCE 损失与 $Dice$ 损失相结合的形式,网络兼顾了像素级分类的准确性和整体分割区域的重叠情况,从而解决了细胞在图像中因占比过小而导致的精度度较低的问题,也确保了每个像素的预测概率尽可能接近真实标签。在这 2 个函数的相互作用下,实现了优良的医学细胞核分割图像的目标。

此外,U-Net++网络的核心优势在于密集的跳跃连接,但这虽然提升了性能,却也导致了多尺度特征的融合,从而产生信息冗余并引入了不必要的噪声。为了解决这一问题,本文加入降噪层进行降噪处理^[18]。

对输入的特征图进行加权平均来平滑特征图。将输入特征图 X 进入降噪层,该特征图的格式为 $C_{in} \times H \times W$ 。其中, C_{in} 表示输入特征图中的通道数量, H 表示特征图的垂直尺寸, W 表示特征图的水平尺寸。采用卷积核 W_l 对 X 进行卷积平滑处理, W_l 的格式为 $C_{out} * C_{in} * 3 * 3$ 。其中, C_{in} 为输入通道数, C_{out} 为输出通道数。通过加权平均局部像素的信息来平滑图像,从而去除高频噪声,保留重要的低频特征。平滑处理的表达式如公式(9)所示:

$$Y = Conv(X, W_l) + b \quad (9)$$

其中, Y 为输出特征图, X 为输入特征图, W_l 为卷积核, b 是偏置项(格式为 C_{out})。为每个输出通道提供一个常数偏移,从而增强模型的表示能力。通过在输入特征图 X 上滑动卷积核 W_l ,对每个位置的局部区域进行加权求和,有助于去除输入特征图中的高频噪声。并将偏置 b 加入卷积

结果中,用于调整卷积后的输出。

传递输出的特征图 Y 到网络的后续特征图层。通过卷积平滑处理,输出的特征图相较于输入图像更加平滑,减少了噪声对特征学习的干扰,同时保留了主要的低频信息。

2 实验结果与分析

为了验证实验结果的可靠性和准确性,本文实验部分采用 U-Net++ 网络对医学细胞进行图像分割,并将实验结果与 U-Net^[19] 网络、RU-net^[20] 网络和 Feedback U-Net^[21] 网络的实验结果进行对比。

本次实验的硬件环境如下:CPU 型号为 13th Gen Intel (R) Core(TM) i7-13700H,具有 14 核的处理功能(6 个性能核心,8 个能效核心),GPU 型号为 NVIDIA GeForce RTX 4060 Laptop GPU,内存为 15.9GB,系统环境为 Window11 编译语言为 Python3.9。本次实验中,Batchsize 设置为 12,共训练 100 轮。

2.1 实验数据集

本实验中所使用的图像和标签数据来源于数据集 dsb2018_96,该数据集共包含 2 010 张图片以及其对应的 28 121 张标签。每一张图片中有多个医学细胞核,并且每一张图片对应多个仅含单个细胞核的标签。这种数据组织方式在一定程度上提升了深度学习模型的效率。此外,为确保实验结果的准确评估,将数据集按比例分为训练集和验证集,其中 80% 的数据用于训练,20% 的数据用于验证。

2.2 数据的分析

交并比(IoU)是通过预测细胞核和标记细胞核的交集与其并集的比值来提供一种综合评估分割性能的方法^[14]。这种方法不仅能够同时考虑精确度和召回率,而且计算速度较快,特别适用于大规模医学图像数据集的分析。基于以上优势,本实验主要选择 IoU 指标来评估预测结果的准确性。IoU 的表达式如公式(10)所示^[22]:

$$IoU = \frac{\text{预测细胞核} \cap \text{标记细胞核}}{\text{预测细胞核} \cup \text{标记细胞核}} \tag{10}$$

预测细胞 $\cap$ 标记细胞统计了预测的分割结果与真实标签的重叠部分的像素数量,预测细胞 $\cup$ 标记细胞统计了预测的分割结果和真实标签中所有像素的总数。通过比值的计算,评估了预测区域对于实际预测区域的重叠率。训练集和验证集的损失变化,如图 4 所示。

其中,单线曲线代表训练集的损失变化,双线曲线代表验证集的损失变化。通过观察可发现随着训练轮数的增加,两者的损失值逐渐减少。当训练轮数接近 40 轮时,模型的损失值逐渐稳定在训练集和验证集上,分别在 0.2 和 0.16 左右。随着训练轮数的增加,训练集和验证集的损失曲线逐渐收敛,表明该模型表现出良好的稳定性和泛化




Fig. 4 Loss variation in training and validation sets

图 4 训练集和验证集的损失变化

能力。训练集和验证集的交并比变化,如图 5 所示。




Fig. 5 Variation of intersection ratio in training and validation sets

图 5 训练集和验证集的交并比变化

其中,单线曲线代表训练集的交并比,双线曲线代表验证集的交并比。通过观察可以看出,随着训练轮次的增加,两者的交并比值逐步提升。当训练轮数接近 40 轮数时,交并比值逐渐趋于稳定,训练集和验证集的交并比分别稳定在 0.8 和 0.84。这表明模型在未见数据上的表现更优,并且有效地避免了过拟合问题。

综上所述,该模型在医学细胞核的分割任务中表现稳定,验证集上的 IoU 略高,模型泛化性能良好。为了进一步体现本文方法的优势,将本次实验的 U-Net++ 网络的平均精准度与 U-Net 网络、RU-net 网络以及 Feedback U-Net 网络进行对比,如表 1 所示。通过对表 1 的分析可知,本网络在分割精准度方面明显优于其他 3 种算法。

训练完成后,在测试集中随机抽取 2 组样本对模型进行检验,抽样的细胞识别效果如图 6 所示。其中,原始细

Table 1 Accuracy evaluation of different segmentation networks

表 1 不同分割网络的精准度评价

试验方法	平均交并比/%
U-Net	59.3
RU-Net	71.4
Feedback U-Net	71.7
U-Net++	78.4

胞核图像为图 6(a)和图 6(d)。图 6(c)和图 6(f)分别标注了原始细胞核图像图 6(a)和图 6(d)中实际细胞核的位置。图 6(b)是原始细胞核图像图 6(a)经过 U-Net++ 网络处理后的图像;图 6(e)是原始细胞核图像图 6(d)经过 U-Net++ 网络处理后的图像。将原始图像图 6(a)与通过 U-Net++ 网络输出的分割图像图 6(b)进行对比,以及将原始图像图 6(d)与应用 U-Net++ 网络输出的分割图像图 6(e)进行对比,可以看出分割图像中所标识的细胞核与原始图像的细胞核重合度较高。由此可知,通过 U-Net++ 网络分

割后,图像可以基本识别并清晰地分割出所有的医学细胞核。将 U-Net++ 网络的分割图像 6(b)与目标医学细胞核的分割图像图 6(c)进行对比,以及将 U-Net++ 网络的分割图像图 6(e)与目标医学细胞核分割图像图 6(f)进行对比,可以看出 U-Net++ 网络的分割图像中所标识的细胞核基本与目标图像中所标识的细胞核重合度较高且细胞核边缘清晰。综上所述,U-Net++ 网络在对医学细胞核的分割任务中表现良好。




Fig. 6 Segmentation effect of medical nucleus image

图 6 医学细胞核图像的分割效果

3 结语

针对传统方法对医学细胞核分割时容易混淆前景背景,以及对边缘处理的效果不好的问题,本文提出了基于 U-Net++ 网络的医学细胞核图像分割的算法^[23]。首先,应用编码器结构提取原图的特征;其次,采用跳跃连接,将提取的特征进行融合;最后,运用 BCEDiceLoss 复合损失函数,对 U-Net++ 网络中的参数进行更新,并在训练过程中不断优化结果。为了验证方法的可行性,采用公开数据集 dsb2018_96,对其精度进行评估。实验结果表明,本文采用的网络在面对目标较小且密集的复杂分割环境时,表现出较高的准确率,充分展示了该方法在泛化能力和分割精度方面的优越性。此外,相较于 U-Net、RU-Net 和 Feedback U-Net 网络,该方法表现出更优的精度,因此具备了一定的可行性。后续计划引入注意力机制,使网络专注于关键区域的小目标,提高对细胞核更多细节的关注度,从而帮助模型更好地学习图中的特征^[24]。

参考文献:

- [1] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]//San Diego: International Conference on Learning Representations, 2015.
- [2] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//Las Vegas: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [3] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]//Boston: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015.
- [4] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [C]//Munich: International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015.
- [5] ZHOU Z, SIDDIQUEE M M R, 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, 2019: 3-11.
- [6] HE H, CHEN S. Automatic PET tumor segmentation based on U-Net

- model of pre-trained encoder [J]. Journal of Image and Graphics, 2020, 25(1):171-179.
- 何慧,陈胜.改进预训练编码器U-Net模型的PET肿瘤自动分割[J].中国图象图形学报,2020,25(1):171-179.
- [7] ZHAO T, ZHAO Y, WANG S, et al. UNet++-based multi-channel speech dereverberation and distant speech recognition [C]//Hong Kong: 12th International Symposium on Chinese Spoken Language Processing, 2021.
- [8] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [9] NAIR V, HINTON G E. Rectified linear units improve restricted boltzmann machines [C]//Proceedings of the 27th International Conference on Machine Learning, 2010: 807-814.
- [10] ZHAO X, WANG L, ZHANG Y, et al. A review of convolutional neural networks in computer vision[J]. Artificial Intelligence Review, 2024, 57(4): 99.
- [11] ZHANG H M, WU F J, ZHENG C, et al. Two properties of nonlinear activation function relu on mnist dataset [J]. Journal of Hubei Normal University (Natural Science Edition), 2024, 44(3):1-7.
- 张华民,吴方婧,郑超,等.mnist数据集上非线性激活函数relu的两个性质[J].湖北师范大学学报(自然科学版),2024,44(3):1-7.
- [12] WALTER B. Analysis of convolutional neural network image classifiers in a hierarchical max-pooling model with additional local pooling [J]. Journal of Statistical Planning and Inference, 2023, 224: 109-126.
- [13] HECKBERT P S. Fundamentals of texture mapping and image warping [R]. Technical Report, No. UCB/CSD-89-516, 1989.
- [14] WANG S, YANG K J. Research and implementation of image scaling algorithm based on bilinear interpolation [J]. Automation technology and applications, 2008, 27(7): 44-45.
- 王森,杨克俭.基于双线性插值的图像缩放算法的研究与实现[J].自动化技术与应用,2008,27(7):44-45.
- [15] JIAO R H, CHU J J, LIU J J, et al. SC-Net: contextual information hopping linkage network for overlapping chromosome segmentation [J]. Journal of Image and Graphics, 2024, 29(9):2806-2824.
- 焦润海,褚佳杰,刘嘉骥,等.SC-Net:用于重叠染色体分割的上下文信息跳跃连接网络[J].中国图象图形学报,2024,29(9):2806-2824.
- [16] WANG H Y. Semantic segmentation and change detection of urban remote sensing image based on RU-Net and BiUnet-Dense models [D]. Chengdu: Chengdu University of Technology, 2023.
- 王海英.基于RU-Net和BiUnet-Dense模型的城市遥感影像语义分割及变化检测[D].成都:成都理工大学,2023.
- [17] ARTIME O, GRASSIA M, DE D M, et al. Robustness and resilience of complex networks[J]. Nature Reviews Physics, 2024, 6(2): 114-131.
- [18] HSU C, CHANG C, CHEN T W, et al. Brain tumor segmentation (BraTS) challenge short paper: Improving three-dimensional brain tumor segmentation using SegResNet and hybrid boundary-dice loss [C]//International MICCAI Brainlesion Workshop, 2021: 334-344.
- [19] SHIQIN G X, YANG C R, LIU X D, et al. Based on attention mechanism of qin video denoising algorithms [J/OL]. Journal of Northwest University (Natural Science Edition), 2025-01-20. <https://doi.org/10.16152/j.cnki.xdxbzr.2025-01-014>.
- 师秦高雪,杨超然,刘鑫达,等.基于注意力机制的秦腔视频去噪算法研究[J/OL].西北大学学报(自然科学版),2025-01-20. <https://doi.org/10.16152/j.cnki.xdxbzr.2025-01-014>.
- [20] PUNN N S, AGARWAL S. Modality specific U-Net variants for biomedical image segmentation: a survey [J]. Artificial Intelligence Review, 2022, 55: 5845-5889.
- [21] SHIBUYA E, HOTTA K. Cell image segmentation by using feedback and convolutional LSTM [J]. Visual Computer, 2022, 38: 3791-3801.
- [22] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: faster and better learning for bounding box regression [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020:12993-13000.
- [23] EISUKE S, KAZUHIRO H. Feedback U-net for cell image segmentation [DB/OL]. <https://arxiv.org/abs/2004.14581>.
- [24] QIN C, WU Y, LIAO W, et al. Improved U-Net3+ with stage residual for brain tumor segmentation[J]. BMC Medical Imaging, 2022, 22(1):14.

(责任编辑:陈维捷)