

# 控制与决策

Control and Decision

## 周围神经MicroCT图像中神经束轮廓获取算法的改进

钟映春, 祝玉杰, 蚁晓虹, 李芳, 朱爽, 戚剑

引用本文:

钟映春, 祝玉杰, 蚁晓虹, 等. 周围神经MicroCT图像中神经束轮廓获取算法的改进[J]. *控制与决策*, 2021, 36(7): 1601–1610.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1664>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 基于改进DenseNet网络的人体姿态估计

Improved DenseNet network for human pose estimation

*控制与决策*. 2021, 36(5): 1206–1212 <https://doi.org/10.13195/j.kzyjc.2019.1218>

### 基于卷积神经网络的云雾遮挡舰船目标识别

Obscured ship target recognition based on convolutional neural network

*控制与决策*. 2021, 36(3): 661–668 <https://doi.org/10.13195/j.kzyjc.2019.0781>

### 复杂背景下全景视频运动小目标检测算法

Panoramic video motion small target detection algorithm in complex background

*控制与决策*. 2021, 36(1): 249–256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

### 基于强化学习的倒立摆分数阶梯度下降RBF控制

Reinforcement learning based fractional gradient descent RBF neural network control of inverted pendulum

*控制与决策*. 2021, 36(1): 125–134 <https://doi.org/10.13195/j.kzyjc.2019.0816>

### 基于改进堆叠自动编码器的循环冷却水系统工艺介质温度预测控制方法

Predictive control method of process medium temperature in circulating cooling water system based on improved stacked auto encoders

*控制与决策*. 2020, 35(12): 2835–2844 <https://doi.org/10.13195/j.kzyjc.2019.0694>

## 周围神经 MicroCT 图像中神经束轮廓获取算法的改进

钟映春<sup>1†</sup>, 祝玉杰<sup>1</sup>, 蚁晓虹<sup>1</sup>, 李芳<sup>2</sup>, 朱爽<sup>3</sup>, 戚剑<sup>4</sup>

(1. 广东工业大学 自动化学院, 广州 510006; 2. 广东财经大学 信息学院, 广州 510320;  
3. 南方医科大学珠江医院 骨科, 广州 510630; 4. 中山大学附属第一医院 显微外科, 广州 510080)

**摘要:** 采用原始的蒙皮区域卷积神经网络 (Mask R-CNN) 获取周围神经 MicroCT 图像中的神经束轮廓时存在收敛慢、精度低等问题. 首先构建两个数据集, 然后提出一种密集连接型网络结构, 提取神经束区域特征. 此外, 改进目标检测部分候选框的得分评价规则, 并结合迁移学习策略改进原始算法的训练方式. 采用准确率和交并比指标评价算法的准确度, 精细度阈值指标评价轮廓获取的精度, 并确定了精细度阈值的最佳值. 实验结果表明, 改进后算法在两个数据集中的准确率和交并比均在 83% 和 87% 以上. 在精细度阈值为 0.85 时, 获得的神经束轮廓最佳. 由此可见, 改进后算法能够良好地实现从周围神经 MicroCT 图像中获取神经束轮廓的目标, 为周围神经内部结构的三维可视化奠定基础.

**关键词:** 周围神经; 神经束轮廓获取; Mask R-CNN; MicroCT 图像; 卷积神经网络; 深度学习

中图分类号: TP391

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1664

开放科学(资源服务)标识码(OSID):



**引用格式:** 钟映春, 祝玉杰, 蚁晓虹, 等. 周围神经 MicroCT 图像中神经束轮廓获取算法的改进 [J]. 控制与决策, 2021, 36(7): 1601-1610.

## An improved approach to obtain contours of fascicular groups from MicroCT images of peripheral nerve

ZHONG Ying-chun<sup>1†</sup>, ZHU Yu-jie<sup>1</sup>, YI Xiao-hong<sup>1</sup>, LI Fang<sup>2</sup>, ZHU Shuang<sup>3</sup>, QI Jian<sup>4</sup>

(1. School of Automation, Guangdong University of Technology, Guangzhou 510006, China; 2. School of Information, Guangdong University of Finance & Economics, Guangzhou 510320, China; 3. Department of Bone and Joint Surgery, Zhujiang Hospital of Southern Medical University, Guangzhou 510630, China; 4. Department of Orthopedics Trauma and Microsurgery, The First Affiliated Hospital of Sun Yat-sen University, Guangzhou 510080, China)

**Abstract:** An improved mask region-convolutional neural network (Mask R-CNN) algorithm is proposed to conquer the shortcoming such as the slow convergence rate, low accuracy in the original Mask R-CNN algorithm to obtain contours of fascicular groups from MicroCT images of peripheral nerve. Firstly, the dataset of images is constructed and divided into two subsets. Then, the network architecture with dense connection is proposed to abstract the feature of fascicular groups. Furthermore, the regulation of proposal box scores in object detection part is improved, the transfer learning strategy is combined with the Mask R-CNN in training process. The average precision (AP) and the intersection over union (IoU) are adopted as evaluation indices of algorithm accurate, and the precision threshold is adopted as the evaluation index of algorithm precision, and the best value of the precision threshold is identified. Experiment results show that the AP and the IoU of the improved approach exceed 83% and 87% in the two peripheral nerve MicroCT image subsets. The improved algorithm has the best contours of fascicular groups at the threshold of 0.85. Experiments show that the improved algorithm can extract the contours of fascicular groups exactly and lay the foundation for the three dimensional visualization of the internal structure of peripheral nerve.

**Keywords:** peripheral nerves; acquisition contours of fascicular groups; mask region convolution neural network (Mask R-CNN); MicroCT images; convolution neural network; deep learning

收稿日期: 2019-11-27; 修回日期: 2020-03-13.

基金项目: 广东省自然科学基金项目 (2018A0303130137); 广东省高性能计算重点实验室开放项目 (TH1528); 广东省哲学社会科学规划学科共建项目 (GD18XJY05); 国家自然科学基金项目 (61975248).

责任编辑: 刘德荣.

<sup>†</sup>通讯作者. E-mail: gdut\_zyc@qq.com.

## 0 引言

周围神经损伤是外科临床上的常见疾病<sup>[1-2]</sup>. 在周围神经损伤修复术中, 三维可视化技术可辅助实现具有相同类型的神经束对接<sup>[3-4]</sup>, 使恢复神经的传导和控制功能成为可能. 神经束三维可视化所需要的信息主要来自于神经束轮廓, 因此获取神经束的轮廓信息是神经束三维可视化的关键步骤之一, 周围神经中神经束轮廓的精度将直接影响三维可视化的结果<sup>[5-6]</sup>. 神经束轮廓获取, 对于外科临床的神经修复手术而言, 主要是在手术的准备阶段, 提供一个神经束在空间的三维模型与受损部位进行对照, 进而可以精确度量神经束间距, 判断神经束延伸趋势, 协助医生进行精确的神经束修复<sup>[7]</sup>.

在周围神经图像中的神经束轮廓提取方面, 文献[8]针对乙酰胆碱酯酶染色后的二维全景图像, 采用改进的 *K*-means 聚类方法及像素点“蚕食”的方法获取神经束边界, 但需要人工干预来保证其准确性. 文献[9]针对周围神经CT图像提出一种交互式的神经束轮廓分割算法, 利用像素灰度和邻域位置信息切割图形, 可有效地抑制图像中的噪声, 但该分割算法是对人工选定的区域和粗糙的边缘进行校正, 不能实现全自动分割. 文献[10]提出基于贝叶斯的分层聚类方法, 该方法虽不需要任何先验信息, 但在一些形状不规则的神经结构中, 该算法会失效. 文献[11]采用深度学习中的稀疏自动编码器方法, 可自动地对每一副图像进行特征提取后训练神经网络模型, 该方法无需人工提取神经束轮廓特征, 但需要人工标注一副图像的轮廓信息作为迭代的开始, 属于半交互式方法.

在对原始的蒙皮区域卷积神经网络 (mask region-based convolutional neural network, Mask R-CNN) 进行改进方面, 文献[12]删除了 mask 分支, 引入 Light-Head RCNN, 并且调整了 RPN 网络中锚点框的比例. 改进后的算法极大地提高了目标检测的速度, 检测时间减少两倍以上, 但是没有提高算法的准确率. 文献[13]使用 PrRoIPooling 代替 RoiAlign, 可将目标检测的准确率提高至 90% 以上, 但轮廓分割准确率仅为 70%. 文献[14]将 Mask R-CNN 算法与均值移位跟踪器相结合进行改进, 实现动态手势的实时分割.

针对 Mask R-CNN 算法在周围神经 MicroCT 图像中神经束轮廓获取时存在的收敛慢、精度低等问题, 对其进行改进, 使其在收敛速度、准确率 (average precision, AP)、交并比 (intersection over union, IoU) 等方面取得优势. 本文在阈值概念的基础上, 提出了分割精细度阈值的评价指标, 并首次确定了周围神经 MicroCT 图像中获取神经束轮廓过程中精细度阈值的最佳取值.

首先, 设计了基于 Mask R-CNN 算法的周围神经 MicroCT 图像中神经束轮廓获取的总体架构; 其次, 针对不同染色方式获取的神经图像, 构建图像数据集; 然后, 提出密集连接型的网络结构进行特征提取, 并从目标检测部分候选框的得分规则以及模型的训练方式等方面改进原始算法; 最后, 将改进前后算法应用于周围神经 MicroCT 图像中进行对比、评估.

## 1 总体架构设计

本文设计的周围神经 MicroCT 图像中神经束轮廓获取算法的改进方法总体架构如图 1 所示.

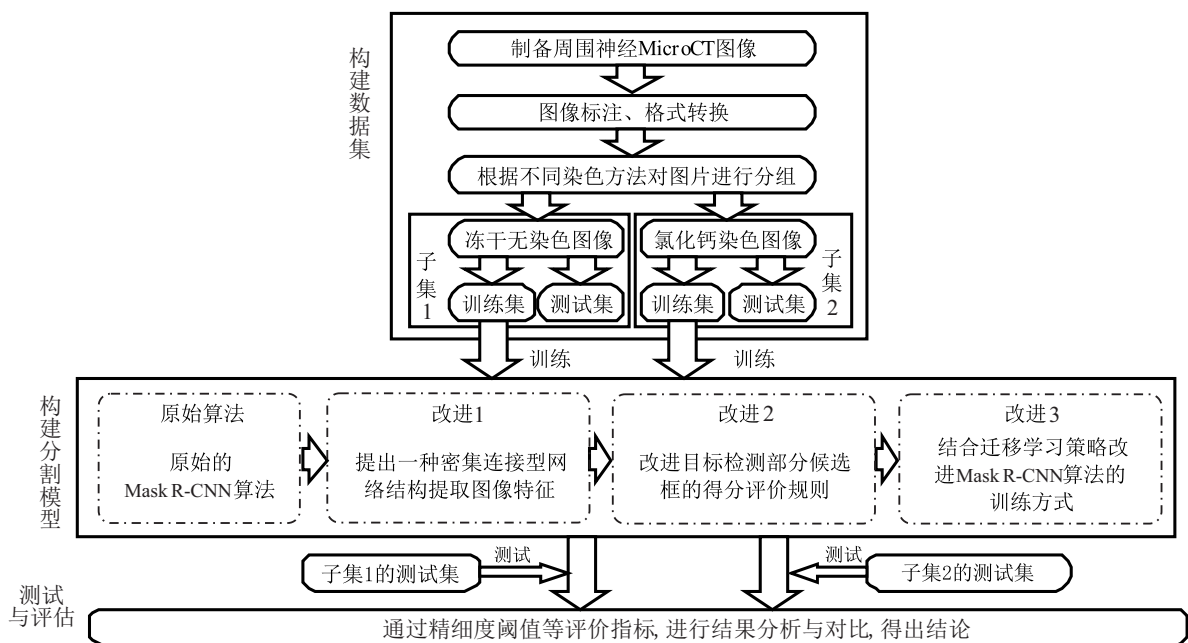


图1 周围神经MicroCT图像中神经束轮廓获取算法的改进方法总体架构

由图1可见,周围神经MicroCT图像中神经束轮廓获取算法的改进方法的总体架构包括构建数据集、构建分割模型、测试与评估3大过程。

构建数据集包括图像制备、图像标注和分组过程。分组过程是指将一个数据集中的所有图像随机地分为训练集和测试集。训练集用于神经网络模型的训练,寻找模型的最优参数,构建最佳的神经网络模型。然后,使用测试集中的原始图像对网络模型进行测试,其对应的标注后的图像作为一个基准,用于评估模型的分割效果。

构建分割模型阶段,针对原始的Mask R-CNN算法进行3个方面改进:1)提出一种密集连接型网络结构,用于提取图像中的神经束区域特征;2)改进原始算法中目标检测部分候选框的得分评价规则;3)将迁移学习策略结合到Mask R-CNN算法的训练过程中。

测试与评估过程,主要使用训练阶段的损失函数曲线、测试阶段的准确率、交并比、精细度阈值等数据,对改进前后的算法进行对比评估。

## 2 构建图像数据集

### 2.1 图像的制备

受限于当前的技术手段,暂时无法获得活体的周围神经束断面图像。在获取标本的神经束断面图像过程中,主要是对标本进行冻干无染色和饱和氯化钙染色处理。标本经过冻干无染色处理后扫描获得的图像<sup>[15]</sup>,神经束轮廓比较清晰,神经束内部像素特征与外部特征差异性比较明显,但是神经束的外形有一定的变形,没有呈现饱满的类圆形。标本经过饱和氯化钙染色处理后扫描获得的图像<sup>[11]</sup>,神经束轮廓有一定的模糊,神经束内部像素特征与外部特征差异性明显,神经束的外形呈现为饱满的类圆形。为了提高本文算法针对不同染色方法获取图像的通用性,本文以冻干无染色和饱和氯化钙染色的标本所获取的MicroCT图像为案例,研究如何改进深度学习算法,期望用一种算法即可获取任意染色标本的精确的神经束轮廓,解决染色方法选择问题。这对于外科临床手术具有重要意义。

首先,采集5 cm左右的周围神经段,在 $-80^{\circ}\text{C}$ 的环境下冷冻后使用冰冻切割机切割为长度3 mm的小段;然后采用无染色、饱和氯化钙染色两种方式对其进行染色;最后,将制备好的周围神经标本通过MicroCT设备扫描,得到周围神经的断层MicroCT图像(DICOM图像)。两种染色方式得到的周围神经图像如图2(a)和图2(b)所示。

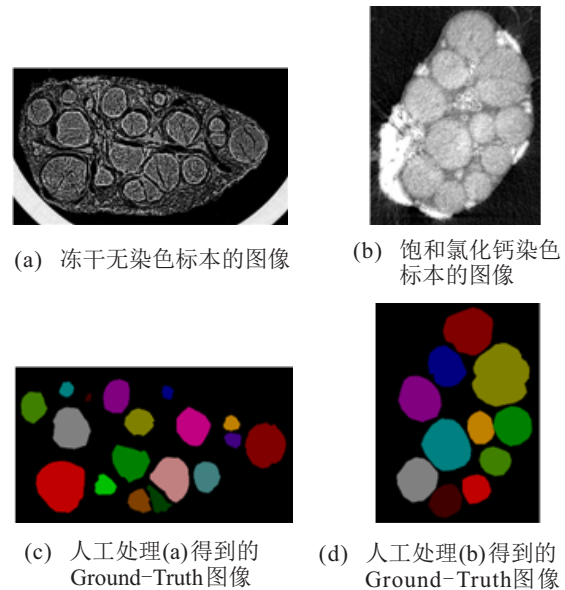


图2 不同染色方式的周围神经MicroCT图像

### 2.2 图像标注

使用Labelme工具对每一张周围神经MicroCT图像进行人工轮廓获取、标注标签。因为图像中只有神经束轮廓这一种待提取的目标,故标注的目标物只有背景和神经束两类。Mask R-CNN算法是一种实例分割算法,每个神经束后面需加上不同的阿拉伯数字,同一张图像中数字从1开始递增,不同图像中数字可重复。由于MicroCT设备扫描获得的DICOM图像无法直接被计算机处理,对标注完成后的图像进行格式转换,得到真实图像(Ground-Truth图像)如图2(c)和图2(d)所示。

Ground-Truth图像不仅用于训练Mask R-CNN算法,而且作为评价的基准,用于评估算法的轮廓获取效果。

### 2.3 训练集与测试集构建

图2(a)为冻干无染色标本的MicroCT图像,图像尺寸为 $1024 \sim 1024$  pixels。图2(b)为饱和氯化钙染色标本的MicroCT图像,图像尺寸为 $890 \times 1024$  pixels。由于经过不同染色方式所得到的图像特征具有较大差异且尺寸不同,将所有图像分为两个子数据集:冻干无染色数据集和氯化钙染色数据集,且将所有图像归一化为 $704 \times 704$  pixels。

子集1(冻干无染色数据集):通过冻干无染色脱水处理方式得到的MicroCT图像及其对应的Ground-Truth图像。

子集2(氯化钙染色数据集):通过饱和氯化钙染色方式得到的MicroCT图像及其对应的Ground-Truth图像。

每个子集按照3:1的比例再细分为训练集与测

试集,训练集与测试集之间的数据互不交叉。

### 3 Mask R-CNN算法的改进

#### 3.1 原始算法

原始的Mask R-CNN算法<sup>[16]</sup>在Faster R-CNN算法的基础上进行了一些改进,包括增加了实现掩码分割的Mask分支,使用ROI Align以解决特征图与原图缩放后候选框位置的像素偏差问题,即不匹配问题(misalignment)。且将Resnet101网络<sup>[17]</sup>与特征金字塔网络<sup>[18]</sup>结合,共同作为特征提取器,使Mask R-CNN网络可避免随着网络层数增加训练集准确率下降的缺点,这也是深度学习中较普遍存在的网络退化问题<sup>[19]</sup>。因此,Mask R-CNN成为目前为止最优秀的图像分割算法之一,可良好地实现实例分割任务<sup>[20-21]</sup>。

#### 3.2 Mask R-CNN算法的改进

##### 3.2.1 密集连接型的特征提取网络结构(改进1)

原始的Mask R-CNN算法采取特征金字塔结构,实现高级与低级特征的互相结合,提升了特征提取的性能。但是其只对上下两层的特征进行融合,对于多层特征图的利用并不充分。

针对上述不足,本文提出密集型连接的特征提取网络结构。将低层特征的高分辨率和高层特征的高语义信息通过上采样技术进行融合,将多个尺度检测的特征层上采样相应倍数后进行密集相连,使每一层的输入都包含了所有较早层的特征图,强化了特征的传递,可更充分地复用提取到的特征。

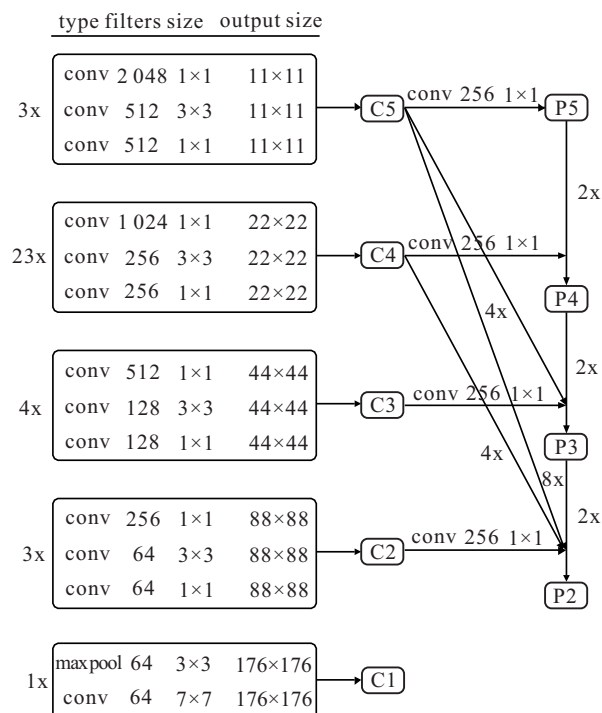


图3 密集连接型的特征提取网络结构

本文所使用的密集连接型特征提取网络结构如图3所示,输入图像尺寸为704×704 pixels,经过5个卷积块后提取的特征图C1、C2、C3、C4、C5分别为176×176、88×88、44×44、22×22、11×11pixels。横向连接为1×1的卷积操作,其在不改变特征图尺寸的前提下,统一将特征图转换为256通道,为不同层之间的融合提供基础。P4是由P5经过2倍上采样后与C4经过横向连接后相融合得到的特征图,故P4的输入包含了所有较早层的特征图。P3、P2同理。

##### 3.2.2 目标检测算法中得分评价规则的改进(改进2)

原始的Mask R-CNN算法采用非极大值抑制算法去除重复框<sup>[22]</sup>。其基本思想为:将与得分最大的候选框的交并比大于某个精细度阈值的候选框直接舍弃。该方法虽可去除重复框,但在两个目标距离很近,两个候选框的交并比大于设定的精细度阈值时,得分规则会直接将得分较低的候选框舍弃,这将会出现漏检现象。

研究表明,Soft-NMS算法在检测距离较近的两个目标时准确率更高<sup>[23]</sup>。因此,根据Soft-NMS算法思想,对目标检测算法中的得分评价规则进行改进。

改进后的候选框得分评价规则为:将交并比的值作为输入,并遵循交并比的值越大候选框得分越低的原则(交并比的值越大,越有可能是对同一目标的重复候选框),再与其候选框本身的得分相乘作为该候选框的最终得分。

改进后的候选框得分公式为

$$s_i = \begin{cases} s_i, & \text{IoU}(M, b_i) < N_t; \\ s_i(1 - \text{IoU}(M, b_i)), & \text{IoU}(M, b_i) \geq N_t. \end{cases} \quad (1)$$

其中: $s_i$ 为该候选框的得分; $M$ 为得分最高的候选框; $b_i$ 为第*i*个候选框;IoU( $M, b_i$ )为两个候选框的交并比; $N_t$ 为设定的精细度阈值,其大小决定获取到的候选框的精细程度。

式(1)是不连续的,因此最终的得分公式为

$$s_i = s_i \exp\left(-\frac{\text{IoU}(M, b_i)^2}{N_t}\right), \forall b_i \notin D, \quad (2)$$

其中 $D$ 是最终候选框的集合。

改进后的候选框得分评价规则不是简单地删除候选框,而是降低其置信度,因此可一定程度上降低漏检。

##### 3.2.3 结合迁移学习策略改进Mask R-CNN算法的训练方式(改进3)

深度学习依赖于大量标注数据,但周围神经MicroCT图像的获取相对比较困难,因此图像数量较少。引入迁移学习可降低算法对数据量的要

求<sup>[24]</sup>。Girshick等<sup>[25]</sup>提出,对卷积神经网络进行预训练,而后进行模型参数迁移,可以有效提高模型的泛化能力和准确度,并显著减少训练的时间。

COCO数据集<sup>[26]</sup>是一个大型的、丰富的数据集,专为图像检测、语义分割、实例分割任务而设计,可以用于Mask R-CNN算法的预训练。因此结合迁移学习的策略中,使用COCO数据集对神经网络模型进行预训练。

## 4 实验过程与结果分析

### 4.1 实验环境配置

实验硬件平台: CPU为i7-6700K, 32 G内存, GPU为英伟达公司的GTX1070显卡, 8 G显存, 硬盘1T, 1 920个CUDA核心, 内存带宽256 GB/s。

实验软件平台: Linux操作系统, 深度学习专用编程框架CUDA9.0以及cuDNN7.0, 高层神经网络API库Keras、TensorFlow和Python 3.6。

### 4.2 实验设计

为了避免训练阶段中配置信息不同带来的轮廓获取误差, 本文均采用相同的迭代次数与学习率调整方式, 共进行100轮迭代训练(每进行100次训练, 记为一“轮”迭代), 学习率为0.001。

在构建好的两个数据子集上对改进前后的算法进行了测试, 主要对比了4种算法:

- 1) 原始的Mask R-CNN算法;
- 2) 原始的Mask R-CNN算法+密集连接型网络结构, 简称为改进1算法;
- 3) 原始的Mask R-CNN算法+密集连接型网络结构+候选框得分评价规则的改进, 简称为改进2算法;
- 4) 原始的Mask R-CNN算法+密集连接型网络结构+候选框得分评价规则的改进+结合迁移学习策略的训练方式, 简称为改进3算法。

为了评估改进后算法的效果, 分别对子集1、子集2进行如下实验:

- 1) 采用数据子集中的训练集对4种算法分别进行训练, 记录训练过程的损失函数曲线;
- 2) 使用数据子集中的测试集对收敛后的4种算法进行分别测试, 在不同的精细度阈值下记录4种算法的交并比、准确率等数据;
- 3) 对比评估4种算法在训练阶段与测试阶段的数据结果。

为了使交并比、准确率、精细度阈值3个评价指标均达到较优水平, 实现神经束轮廓获取具有较高的精细度的同时, 也具有较好的交并比和准确率, 进行

了精细度阈值的选取实验。以改进3算法为例, 在相同的精细度阈值区间下进行分析, 探究精细度阈值的最佳选取。

### 4.3 评价指标

采用交并比<sup>[27-28]</sup>、准确率<sup>[29-30]</sup>和精细度阈值<sup>[23]</sup>对改进前后的算法性能进行比较。

交并比为真实值(ground-truth)和预测值(predicted segmentation)的交并比, 即

$$F_{IoU} = \frac{S_a \cap S_g}{S_a \cup S_g}. \quad (3)$$

其中:  $S_a$ 为产生的候选框(proposal box);  $S_g$ 为原标记框(ground-truth box);  $F_{IoU}$ 为它们的交叠率, 即它们的交集与并集的比值。最理想情况是完全重叠, 即 $F_{IoU}$ 为1。

准确率为检测模型在测试集上的平均准确率, 它由精确度(precision)与召回率(recall)共同来决定, 如下所示:

$$p = \frac{TP}{TP + FP}, \quad (4)$$

$$r = \frac{TP}{TP + FN}, \quad (5)$$

$$AP = \int_0^1 p(r) dr. \quad (6)$$

其中: TP为正确预测正样本数; FP为错误预测为正类的负样本数; FN为错误预测为负类的正样本数。AP值为在0到1之间所有召回值的精确平均值, 即P-R曲线(precision-recall curves)下的面积。AP值越接近1, 说明算法的效果越好。


精细度阈值是在轮廓获取中满足精细度分割要求的最低值。该值设定的越高, 测试过程中的预测框精度越高, 轮廓获取结果越精细。

精细度阈值的取值范围为[0.5, 0.95]<sup>[31]</sup>, 步长为0.05。当精细度阈值为0.5时,  $F_{IoU}$ 至少为0.5, 否则为负。AP值中, 预测为正样本的概率大于等于0.5时判定为正样本, 否则为负, 负样本同理。


## 4.4 实验结果与分析

### 4.4.1 子集1的实验结果

子集1中共包含图像1 046张, 其中训练集784张, 测试集262张。在训练阶段, 4种算法分别使用子集1中的训练集进行训练, 得到的损失函数曲线如图4所示。由图4(a)、4(b)可看出, 原始的Mask R-CNN算法、改进1算法和改进2算法起始的损失函数值分别为21、31和24, 具有一定差异, 因为改进1算法与改进2算法均增加了网络的复杂度, 所以起始的损失函数值比原始的Mask R-CNN算法高。最终3条曲线几乎稳定于同一个值0.7, 即训练过程达到收敛。



(a) 改进前后算法的损失函数曲线




(b) 图(a)的局部放大


图4 子集1中训练阶段的损失函数曲线

经过4轮迭代训练,改进1算法和改进2算法的平均斜率大约为0.06和0.05,比原始的Mask R-CNN算法的平均斜率0.04,分别增大了50%和25%。此后,3条曲线斜率变化较小,直至收敛。

改进3算法不仅起始的损失函数值很低,约为2.3,收敛速度也明显加快,在第1轮迭代时趋于稳定,并且最终收敛的损失函数值也更低,约为0.38。说明本文所提出的改进方法,能显著提高算法的收敛速度和训练效果。在测试阶段,4种算法分别在子集1的测试集中进行测试,在不同精细度阈值下得到的准确率曲线和交并比曲线如图5所示。



(a) 不同精细度阈值下的准确率曲线



(b) 不同精细度阈值下的交并比曲线


图5 子集1中测试阶段的准确率曲线和交并比曲线

由图5(a)和5(b)可看出,在相同的精细度阈值下,随着对原始Mask R-CNN算法的逐步改进:1)准确率和交并比在逐渐提高,且改进3算法的准确率和交并比最高,分割效果最好;2)曲线间的距离有所不同,改进3算法与改进2算法的曲线间距离最大,其次是改进2算法与改进1算法、改进1算法与原始的Mask R-CNN算法。这说明随着算法的逐步改进,对准确率和交并比的提升效果在逐步增加,且改进3算法的提升效果最显著。


随着精细度阈值的增加,图5(a)中4条曲线都呈现下降趋势,说明精细度阈值设定越高,满足精细度阈值条件的分割结果越少,故准确率开始下降。但改进3算法始终比原始的Mask R-CNN算法、改进1算法和改进2算法的准确率值高,说明其改进3算法在轮廓获取方面的性能更好。图5(b)中4条曲线都呈现出上升的趋势,说明随着精细度阈值的增加,对预测框的精度要求越高,最终留下来的真实框与预测框的交并比越大。

#### 4.4.2 子集2的实验结果

子集2中共包含图像456张,其中训练集342张,测试集114张。在训练阶段,4种算法分别使用子集2中的训练集进行训练,得到的损失函数曲线如图6所示。



(a) 改进前后算法的损失函数曲线



(b) 图(a)的局部放大

图6 子集2中训练阶段的损失函数曲线

由图6可看出:4种算法起始的损失函数值有较大差异,大约为11、10.7、15和2,但是原始的Mask R-CNN算法、改进1算法和改进2算法几乎收敛于同一个值,约为0.6,即3个算法收敛。改进3算法不仅起始

的损失函数值最低,收敛速度最快,在6轮迭代时基本趋于稳定,并且最终收敛到的损失函数值也更低,约为0.3. 说明本文所提出的改进方法,在子集2中也能显著提高算法的收敛速度和训练效果.

在测试阶段,4种算法分别在子集2的测试集中进行测试,在不同精细度阈值下得到的准确率曲线和交并比曲线如图7所示.




图7 子集2中测试阶段的准确率曲线和交并比曲线

由图7可以看出,在精细度阈值小于0.8时,4条曲线没有发生变化,准确率均为100%,交并比均在90%以上. 说明4种算法在子集2中都表现良好,且对于精细度阈值的变化具有一定的稳定性.

精细度阈值大于0.85时,改进1算法的准确率和交并比高于改进2算法和改进3算法. 因为子集2中的神经束不存在相互重叠的现象,所以在目标检测算法中,改进后的得分评价规则不如原始的得分评价规则对其适用性强.

在图7(a)中,准确率最高的曲线为原始的Mask R-CNN算法,因为子集2的训练集数量较少,难以满足训练复杂度较高的改进1算法,并且图像中神经束的轮廓具有一定的规律性,因此不使用迁移学习的效果更佳. 图7(b)中改进1算法的交并比最高,说明密集型、连接型的网络结构可提高特征的提取效果,因此候选框与真实框的比例最大. 改进3算法的交并比曲线在精细度阈值大于0.875后快速上升,超过了原始的Mask R-CNN算法曲线,说明本文提出的改进方法,在精细度阈值较高时,具有较好的分割精细度.

#### 4.4.3 精细度阈值的选取实验

由上述实验可以看出,不同的精细度阈值对交并比和准确率有较大影响,且随着精细度阈值的增加,4种算法的交并比与准确率之间为负相关的关系如图5、图7所示. 当精细度阈值较大时,预测框与真实框的交并比越大,轮廓获取的精细度越大,但是准确率将会减少. 因此,需要根据交并比和准确率进行综合考虑,选择一个在周围神经MicoCT图像中获取神经束轮廓任务中最佳的精细度阈值.

以改进3算法为例,探究在周围神经MicroCT图像中获取神经束轮廓的最佳精细度阈值. 由图5和图7可知,改进3算法在子集1中的准确率为0%~90%,交并比为87%~93%. 在子集2中的准确率为0%~100%,交并比为91%~93%. 同一数据集中的准确率与交并比范围差距较大. 因此,对两个子集中的准确率和交并比进行归一化处理,并放入同一坐标系中,如图8所示.

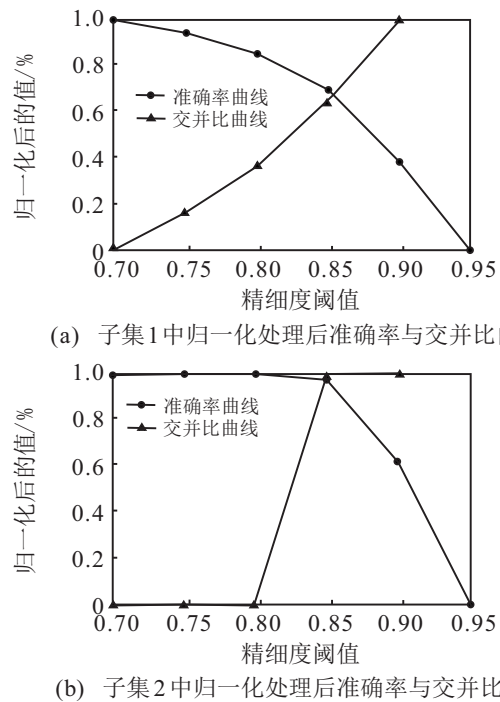


图8 不同精细度阈值下的交并比与准确率曲线

如图8所示,改进3算法在两个子数据集中的准确率曲线与交并比曲线均在精细度阈值大约为0.85时相交. 此时,准确率与交并比两个指标达到均衡. 因此,选择精细度阈值为0.85时,可以较好地平衡准确率与交并比两个成反比的指标,使轮廓获取的准确率达到较好的同时具有较高的交并比值. 对周围神经MicroCT图像中获取最佳的神经束轮廓具有重要意义.

## 5 讨论

由训练阶段中两个子集的损失函数曲线图可知,改进3算法不仅初始的损失函数值最低,收敛速度最快,而且最终收敛到的损失函数值也更低.本文提出的改进方法对于两种染色方式获取的周围神经MicroCT图像,都可提高算法的训练效果.

测试阶段共获得了多个精细度阈值下的准确率和交并比,选取精细度阈值0.7和0.75作为参考,汇总实验所得数据,结果如表1所示(加粗字体为最优结果).

表1 算法改进前后的对比结果

数据集	算法	%			
		AP70	AP75	IoU70	IoU75
子集1	原始的Mask R-CNN算法	75.1	67.4	85.8	86.9
	改进1算法	75.6	69.0	86.3	87.3
	改进2算法	76.3	69.5	86.9	87.8
	改进3算法	<b>88.0</b>	<b>83.4</b>	<b>87.8</b>	<b>88.5</b>
子集2	原始的Mask R-CNN算法	<b>100</b>	<b>100</b>	<b>91.3</b>	<b>91.3</b>
	改进1算法	<b>100</b>	<b>100</b>	<b>91.3</b>	<b>91.3</b>
	改进2算法	<b>100</b>	<b>100</b>	90.4	90.4
	改进3算法	<b>100</b>	<b>100</b>	91.1	91.1

AP50和AP75指的是精细度阈值设定为0.5和0.75时的准确率, IoU50和IoU75指的是精细度阈值设定为0.5和0.75时的交并比.

表1的汇总结果表明在子集1中:

1) 改进3算法的准确率与交并比最高.

2) 在相同的精细度阈值下,原始的Mask R-CNN算法、改进1算法、改进2算法、改进3算法的准确率和交并比的增长幅度逐渐增大.改进3算法相比于原始的Mask R-CNN算法AP70和AP75分别提高了12.9%和16.0%, IoU70和IoU75分别提高了2.0%和1.6%.

说明对于无染色方式获取的周围神经MicroCT图像,本文提出的改进方法可显著提高神经束轮廓获取的效果.

在子集2中:

1) 4种算法的准确率都为100%,交并比都在90%以上,并且在每一种算法中,AP70的值与AP75的值相同, IoU70与IoU75的值相同,说明4种算法在子集2中都表现良好,且准确率与交并比对于精细度阈值的变化具有一定稳定性.

2) 原始的Mask R-CNN算法与改进1算法的交并比的值相同且为最高.因为子集2中的神经束不存在相互重叠的现象,所以改进后的得分评价规则不如原始的得分评价规则对其适用性强,故改进2算法与改进3算法的交并比较低.

3) 改进3算法的交并比值比改进2算法的高,因为改进3算法虽然增加了网络的复杂度,但是结合了迁移学习的策略,一定程度上提高了网络的训练效果.

在精细度阈值的选取实验中,改进3算法经过归一化处理后的交并比与准确率曲线,在两个子集中均在精细度阈值为0.85时相交.因此,在精细度阈值为0.85时,可以较好地平衡准确率与交并比两个成负相关关系的指标,可以较好地获取周围神经MicroCT图像中的神经束轮廓.

## 6 结论

本文研究了基于Mask R-CNN算法的周围神经MicroCT图像中获取神经束轮廓的方法.本文的主要贡献有:

1) 提出了一种密集连接型网络提取图像中的神经束区域特征,在训练样本数量不变的情况下,使算法可以更好地挖掘和复用图像中的特征.

2) 在1)的基础上,改进了目标检测部分候选框的得分评价规则,提高目标检测的精度.

3) 在2)的基础上,结合迁移学习策略改进Mask R-CNN算法的训练方式,解决医学图像训练集不充足导致的模型不收敛、过拟合等问题.

4) 在阈值概念的基础上,提出了分割精细度阈值的评价指标,并首次确定了在周围神经MicroCT图像中获取神经束轮廓任务时的最佳取值.

实验结果表明:

1) 本文提出的改进方法对于两种染色方式获取的周围神经MicroCT图像中的神经束轮廓提取都有较好的效果,准确率均在83%以上,交并比均高于87%.

2) 在图像特征较为复杂的子集1中,3种改进措施可逐步提高算法的准确率和交并比,且本文所提出的改进3算法的提高效果最显著,具有收敛速度快、训练效果好、准确率高的特点,最适合于由无染色方式获取的周围神经MicroCT图像中神经束轮廓的获取任务.

3) 在训练集图像数量较少且神经束轮廓具有一

定规律的子集2中,4种算法的准确率和交并比均在90%以上,且对于精细度阈值的改变具有一定的稳定性.其中改进2算法在精细度阈值较高时交并比最高,具有更好的轮廓获取精细度.

4)在精细度阈值的选取实验中,改进3算法在两个子集中均在精细度阈值为0.85时相交.此时,可以较好地平衡准确率与交并比两个成负相关的指标.该发现尚属首次.该发现对于评价基于CNN的图像分割、图像中目标识别等任务的完成效果具有重要价值.

在分析实验结果的过程中可以发现,对于图像特征较为复杂的子集1,虽然改进后的网络模型对分割的准确率和交并比有了显著的提升,但是仍在90%以下.因此,这将是今后的工作中要解决的主要问题之一.

#### 参考文献(References)

- [1] Zhong Y C, Wang L P, Dong J H, et al. Three-dimensional reconstruction of peripheral nerve internal fascicular groups[J]. *Scientific Reports*, 2015, 5: 17168.
- [2] 睦涛,曹晓建.周围神经损伤修复术中运动束与感觉束鉴别的现状及展望[J].*中华实验外科杂志*, 2016, 33(11): 2438-2441.  
(Sui T, Cao X J. Identification of motor and sensory fiber during surgical repair of peripheral nerve injury: The situation and prospect[J]. *Chinese Journal of Experimental Surgery*, 2016, 33(11): 2438-2441.)
- [3] 钟映春,戚剑,刘小林,等.从图像中提取离散点状神经功能束边缘的研究[J].*系统仿真学报*, 2011, 23(7): 1414-1418.  
(Zhong Y C, Qi J, Liu X L, et al. Study on discrete nerve fascicular groups edge extraction from slice image[J]. *Journal of System Simulation*, 2011, 23(7): 1414-1418.)
- [4] Kagemann L, Ishikawa H, Wollstein G, et al. Visualization of 3-D high speed ultrahigh resolution optical coherence tomographic data identifies structures visible in 2D frames[J]. *Optics Express*, 2009, 17(5): 4208-4220.
- [5] 钟映春,罗鹏.从神经切片图像中识别功能束类型的研究[J].*中国图象图形学报*, 2012, 17(1): 82-89.  
(Zhong Y C, Luo P. Type recognition of fascicular groups from nerve slice image[J]. *Journal of Image and Graphics*, 2012, 17(1): 82-89.)
- [6] 任高宏,裴国献.周围神经三维重建与可视化研究进展[J].*中国修复重建外科杂志*, 2009, 23(2): 239-244.  
(Ren G H, Pei G X. Research progress on three-dimensional reconstruction and visualization of peripheral nerve[J]. *Chinese Journal of Reparative and Reconstructive Surgery*, 2009, 23(2): 239-244.)
- [7] 胡智魁.生物医学图像计算机智能识别关键技术研究[D].广州:广东工业大学,2012.  
(Hu Z K. The research of biologic medical image based on computer intelligent identify key technology[D]. Guangzhou: Guangdong University of Technology, 2012.)
- [8] Qi J, Wang W Y, Zhong Y C, et al. Three-dimensional visualization of the functional fascicular groups of a long-segment peripheral nerve[J]. *Neural Regeneration Research*, 2018, 13(8): 1465-1470.
- [9] Zhou X L, Liu B. A study on peripheral nerve image segmentation algorithm[C]. 2016 IEEE Information Technology, Networking, Electronic and Automation Control Conference. Chongqing: IEEE, 2016: 864-868.
- [10] Giraldo J J, Álvarez M A, Orozco Á A. Peripheral nerve segmentation using nonparametric Bayesian hierarchical clustering[C]. The 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Milan: IEEE, 2015: 3101-3104.
- [11] 李芳,钟映春,戚剑,等.周围神经MicroCT图像中神经束区域的自动分离[J].*应用科学学报*, 2019, 37(3): 359-368.  
(Li F, Zhong Y C, Qi J, et al. Automatic extraction of regions of peripheral nerve internal fascicular groups from MicroCT images[J]. *Journal of Applied Sciences*, 2019, 37(3): 359-368.)
- [12] Shi J, Zhou Y L, Xia W J, et al. Target detection based on improved mask rcnn in service robot[C]. 2019 Chinese Control Conference (CCC). Guangzhou, 2019.
- [13] He P L, Zuo L, Zhang C H, et al. A value recognition algorithm for pointer meter based on improved Mask-RCNN[C]. The 9th International Conference on Information Science and Technology (ICIST). Hulunbuir, 2019: 108-113.
- [14] Nguyen D H, Le T H, Tran T H, et al. Hand segmentation under different viewpoints by combination of Mask R-CNN with tracking[C]. The 5th Asian Conference on Defense Technology (ACDT). Hanoi, 2018: 14-20.
- [15] Zhu S, Zhu Q, Liu X, et al. Three-dimensional reconstruction of the microstructure of human acellular nerve allograft[J]. *Scientific Reports*, 2016, 6: 30694.
- [16] He K M, Gkioxari G, Dollár P, et al. Mask R-CNN[C]. 2017 IEEE International Conference on Computer Vision. Venice, 2017: 2980-2988.
- [17] 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. Las Vegas, 2016: 770-778.

- [18] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[J]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 936-944.
- [19] 田娟秀, 刘国才, 谷珊珊, 等. 医学图像分析深度学习研究方法研究与挑战[J]. 自动化学报, 2018, 44(3): 401-424.  
(Tian J X, Liu G C, Gu S S, et al. Deep learning in medical image analysis and its challenges[J]. Acta Automatica Sinica, 2018, 44(3): 401-424.)
- [20] 张泽苗, 霍欢, 赵逢禹. 深层卷积神经网络的目标检测算法综述[J]. 小型微型计算机系统, 2019, 40(9): 1825-1831.  
(Zhang Z M, Huo H, Zhao F Y. Survey of object detection algorithm based on deep convolutional neural networks[J]. Journal of Chinese Computer Systems, 2019, 40(9): 1825-1831.)
- [21] 回天, 哈力旦·阿布都热依木, 杜晗. 结合 Faster R-CNN 的多类型火焰检测[J]. 中国图象图形学报, 2019, 24(1): 73-83.  
(Hui T, Halidan·Abudureyimu, Du H. Multi-type flame detection combined with Faster R-CNN[J]. Journal of Image and Graphics, 2019, 24(1): 73-83.)
- [22] Neubeck A, Van Gool L. Efficient non-maximum suppression[C]. The 18th International Conference on Pattern Recognition (ICPR'06). Hong Kong, 2006: 850-855.
- [23] Bodla N, Singh B, Chellappa R, et al. Soft-NMS—Improving object detection with one line of code[C]. 2017 IEEE International Conference on Computer Vision (ICCV). Venice, 2017: 5562-5570.
- [24] 王银瑞, 彭敦陆, 陈章, 等. Trans-NER: 一种迁移学习支持下的中文命名实体识别模型[J]. 小型微型计算机系统, 2019, 40(8): 1622-1626.  
(Wang Y R, Peng D L, Chen Z, et al. Trans-NER: A Chinese named entity recognition model supported by transfer learning[J]. Journal of Chinese Computer Systems, 2019, 40(8): 1622-1626.)
- [25] Girshick R, Donahue J, Darrell T, et al. Region-based convolutional networks for accurate object detection and segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(1): 142-158.
- [26] Chen X L, Fang H, Lin T, et al. Microsoft COCO captions: Data collection and evaluation server[J]. 2015, arXiv:1504.00325.
- [27] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. 2017 IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 99: 2999-3007.
- [28] Zhao G L, Gutierrez-Osuna R. Using phonetic posteriorgram based frame pairing for segmental accent conversion[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2019, 27(10): 1649-1660.
- [29] W.Johnson J. Adapting Mask-RCNN for automatic nucleus segmentation[C]. Proceedings of the 2019 Computer Vision Conference. Las Vegas, 2018, 3(2): 7.
- [30] Zhu X Z, Dai J F, Yuan L, et al. Towards high performance video object detection[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 7210-7218.
- [31] 任之俊, 蔺素珍, 李大威, 等. 基于改进特征金字塔的 Mask R-CNN 目标检测方法[J]. 激光与光电子学进展, 2019, 56(4): 174-179.  
(Ren Z J, Lin S Z, Li D W, et al. Mask R-CNN object detection method based on improved feature pyramid[J]. Laser & Optoelectronics Progress, 2019, 56(4): 174-179.)

### 作者简介

钟映春(1973—), 男, 副教授, 从事神经信息学、图像理解等研究, E-mail: gdut\_zyc@qq.com;

祝玉杰(1994—), 女, 硕士生, 从事深度学习、图像处理的研究, E-mail: 1764568189@qq.com;

蚁晓虹(1997—), 女, 硕士生, 从事图像处理、人工智能的研究, E-mail: 844670646@qq.com;

李芳(1976—), 女, 副教授, 从事计算机工程与应用等研究, E-mail: lifang0609@126.com;

朱爽(1989—), 男, 主治医师, 博士, 从事计算机工程与应用等研究, E-mail: 38625267@qq.com;

戚剑(1974—), 男, 副教授, 博士, 从事显微外科方面的研究, E-mail: 2440109868@qq.com.

(责任编辑: 孙艺红)