

甲状腺结节超声自动诊断算法研究

章浩伟¹, 李占齐¹, 李 淼²

(1. 上海理工大学 医疗器械与食品学院, 上海 200082; 2. 郑州颐和医院, 河南 郑州 450000)

摘要: 甲状腺结节是临床常见疾病, 由其发展而成的甲状腺癌发病率逐年上升。甲状腺超声图像结构复杂、边缘不清晰、斑点噪声严重、对比度低, 给甲状腺疾病的诊断带来极大困难。使用Mask R-CNN算法, 结合迁移学习方式, 在ImageNet数据集上预训练网络ResNet50、SENet及SE-ResNet50, 得到预训练权重参数, 以此作为实验模型的初始化参数。采用优化损失函数的方法, 以融合残差注意力机制的SE-ResNet50为主干网络进行特征提取, 实现了精确率为0.936、召回率为0.851、特异性为0.948、mAP值为0.824的检测结果。该算法对于甲状腺疾病的超声辅助诊断具有一定参考价值。

关键词: Mask R-CNN; 迁移学习; 残差注意力机制; 优化损失函数; 医学影像

DOI: 10.11907/rjdk.211301

中图分类号: TP312

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2022)001-0090-06



Research on the Automatic Ultrasound Diagnosis Algorithm of Thyroid Nodules

ZHANG Hao-wei¹, LI Zhan-qi¹, LI Miao²

(1. School of Medical Instrument and Food Engineering, University of Shanghai for Science and Technology, Shanghai 200082, China;
2. YiHe Hospital of Zhengzhou, Zhengzhou 450000, China)

Abstract: Thyroid nodule is a common disease in clinical practice, the incidence of thyroid cancer caused by nodules has increased year by year. Thyroid ultrasound images have complex tissue structure, unclear edges, severe speckle noise, and low contrast, which brings great difficulties to doctors in diagnosing thyroid diseases. In this article, using the Mask R-CNN algorithm, combined with the migration learning method, pre-training the networks ResNet50, SENet and SE-ResNet50 on the ImageNet data set to obtain the pre-training weight parameters, which are used as the initialization parameters of the experimental model. And the optimized loss function is used in the method of fusion residual attention mechanism network SE-ResNet50 for feature extraction under the backbone network, the accuracy rate is 0.936, the recall rate is 0.851, the specificity is 0.948, the mAP is 0.824. The proposed method can assist doctors in diagnosing thyroid ultrasound diseases and has certain reference significance.

Key Words: Mask R-CNN; transfer learning; residual attention mechanism; optimized loss function; medical imaging

0 引言

近年来,甲状腺癌的发病率逐年上升。2019年,美国有52 070名成年人确诊甲状腺癌,甲状腺癌是20-34岁美国女性最常见的癌症之一^[1]。国内统计结果显示,2012年北京地区的甲状腺疾病发病率为10年前的4.9倍^[2]。部分甲状腺结节会发生恶变,导致甲状腺癌,因此对于甲状腺结节的观察与诊断十分重要,早期发现治疗可以在很大程度上降低甲状腺癌的发生率与死亡率。甲状腺结节的超

声诊断很大程度上受到医生主观经验的影响,自动化智能化的甲状腺结节检测可大幅度减少医生工作量,降低诊断时对临床经验的依赖程度,获得与穿刺活检相当的诊断精度。

卷积神经网络(Convolutional Neural Network, CNN)能端到端地进行训练,自动学习图像的高级与低级特征,在医学图像检测中具有重要应用。然而,由于甲状腺超声图像组织结构复杂、边界模糊、形状不规则,给检测识别工作带来很大挑战。目前,甲状腺结节的快速、准确诊断是一项亟待解决的难题。

收稿日期:2021-03-05

基金项目:国家自然科学基金项目(8207120087);上海市科委医学引导项目(12401907700)

作者简介:章浩伟(1970-),男,博士,上海理工大学医疗器械与食品学院副教授,硕士生导师,研究方向为医学影像、深度学习、生物力学。本文通讯作者:章浩伟。

1 相关研究

Wu 等^[3]针对甲状腺超声图像结节分割不准确的问题,设计联合上采样模块,融合具有不同扩展系数的普通标准卷积和扩展卷积的上下文信息,实现了 93.19% 的准确率和 0.8558 的 dice 值;邵蒙恩等^[4]结合 CV 模型与 RSF 模型,建立 CV-RSF 模型,实现了甲状腺结节超声图像的半自动分割;Wei 等^[5]提出一种具有注意力机制的双路径 U 型网络 Attention-DPU,采用微型双路径模块代替普通卷积层,利用注意力机制提高图像分割效率和准确率;Zhang 等^[6]提出一种端到端、多通道、无规则的 CNN 网络,旨在提取更多的语义信息用于超声图像的分割,与 U-Net、U-Net++、M-Net 和 Dilated U-Net 相比,该网络的性能分别提高了 6.59%、36.03%、23.64% 和 31.71%;吴迪^[7]利用集成学习(Boosting)算法将多个弱分类器组合为一个强分类器,在测试集上的恶性结节预测准确率达到 86%,召回率达到 96%;Singh 等^[8]基于灰度共生矩阵(GLCM)提取特征,然后利用 SVM 对甲状腺结节进行分类,最大分类精度为 84.62%;Yu 等^[9]建立了一个基于区域活动轮廓和纹理的特征提取框架,通过结合人工神经网络(ANN)与 SVM 分类器,实现了准确率为 92.00%,敏感性为 100%,特异性为 87.88% 的分类性能;Xiao 等^[10]对 3 个不同深度的网络模型 ResNet50、Xception、InceptionV3 进行特征提取,以简单级联的方式融合 3 种网络提取的特征,然后将特征输入到 ANN 分类器中,判别超声图像的良好性,最终实现了 85.13% 的准确率和 0.91 的 AUC 值。


以上文献多是针对甲状腺超声图像进行分类或分割的单一任务研究,不能对甲状腺结节进行整体诊断与评价。基于此,本文设计一种改进的 Mask R-CNN 算法,以 ResNet50、SENet 为基础主干网络,并融合残差注意力机制模块得到 SE-ResNet50 网络,改进多任务损失函数,实现了基于深度卷积神经网络(Deep Convolutional Neural Network, DCNN)的甲状腺超声结节检测、良恶性判别与分割三项任务于一体的研究。

2 实验方法


2.1 实验数据分析

2.1.1 甲状腺结节鉴别特点分析

图 1 为甲状腺超声图像示例。临床上,医生主要从形态特征、衰减特性、回声模式、钙化特性等方面对甲状腺结节进行诊断^[11]。具体来讲,良性甲状腺结节形态规则、边界清晰、结节后方呈回声增强或等回声,结节的纵横比一般小于 1,结节周围声晕规则,有完整包膜,内部无钙化或有粗大钙化^[12];恶性甲状腺结节形态不规则,边界欠清晰,结节后方回声衰减,结节纵横比通常大于 1,包膜不明显或无完整包膜,出现微小钙化、血流信号增强,常伴有颈部淋巴结转移性肿大^[13]。



(a)



(b)

Fig. 1 Thyroid ultrasound image example

图 1 甲状腺超声图像示例

2.1.2 实验数据采集与预处理

采集 2 934 幅甲状腺超声图像作为实验数据集,采集地点为徐州市某三甲医院,其中良性结节图像有 1 673 张,恶性结节图像有 1 261 张,图像为二维 JPG 格式,采集所用超声诊断仪类别不同,包括 Philips-123、SIEMENS、GE Voluson S8、ACCUVIX-gfg、TOSHIBA。

原始超声图像周边有较多对实验无用的信息,如医院名称、图像采集时间、设备名称、患者信息、超声探头的发射频率、探测深度等。为避免图像分辨率过大带来的计算负担,通过保持原始图像 ROI(Region of Interest)区域的长宽比例调整图像大小,得到甲状腺超声图像的 ROI 子图。对于一个尺寸为 $h \times w$ 的图像,裁剪其周边无用信息,按照尺寸 $\max\{h, w\}$ 进行零值填充,resize 成 512×512 大小,最后在医生的指导下制作成标准的 COCO 数据集形式。图 2 为 ROI 子图及其对应掩码。

2.2 实验平台

训练集和测试集的比例为 8:2,即训练集:测试集=2 347:587。实验模型部署在中科曙光的高级运算平台上,实验系统为 Linux 操作系统,编译环境为 Python 3.7.9,CUDA 版本 10.0,显卡为 Tesla V100-SXM2-32GB,使用 pytorch1.4.0 进行整体模型的搭建。




Fig. 2 Ultrasound image and corresponding mask image
图2 超声图像及其对应掩码图像

2.3 算法建立

2.3.1 Mask R-CNN 算法

基于 CNN 系列的目标检测算法,如 Fast R-CNN^[14]、Faster R-CNN^[15]和 Mask R-CNN^[16]等在目标检测领域均取得了巨大成功。相较于 Faster R-CNN 网络,Mask R-CNN 在其基础上添加了一个掩膜预测分支。图 3 为 Faster R-CNN 与 Mask R-CNN 的架构图,Mask R-CNN 将 Faster R-CNN 中的 RoIPooling 改进为 RoIAlign,在预测框提取过程中使用双线性插值法,改进了 RoIPooling 中量化偏差对后续回归定位产生的影响,因此 Mask R-CNN 的检测效果更胜一筹。Mask R-CNN 是一个两阶段检测模型:第一个阶段基于输入图像产生可能的目标候选建议框;第二个阶段预测目标类别,优化回归框,并基于第一阶段的输出生成目标区域像素级别的分割掩膜。

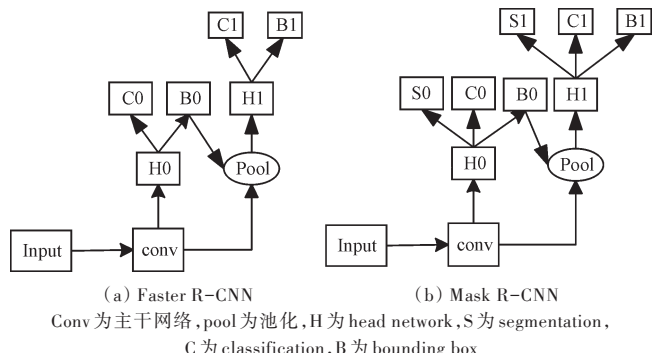


Fig. 3 Faster R-CNN and Mask R-CNN architecture

图3 Faster R-CNN 与 Mask R-CNN 架构

2.3.2 改进损失函数的 Mask R-CNN 算法

Mask R-CNN 的多任务损失函数包含定位损失、分类损失以及分割损失 3 个部分。如式(1)所示, L_{cls} 为分类损失,表示预测类别与实际类别的接近程度; L_{box} 为边框回归损失,表示模型的定位效果; L_{mask} 为分割掩码损失,以二进制交叉损失值作为分割损失函数。在多任务网络结构中,使用两个权重参数 α_1 和 α_2 控制检测与分割任务的优先等级。在以 ResNet50 为主干网络,以 Imagenet 数据集上预训练的权重为初始权重的 Mask R-CNN 模型中,通过改变 α_1 和 α_2 的大小,得到“3.2”项下表 2 的结果。根据表中结果显

示,在接下来的实验中,将 α_1 和 α_2 分别设置为 0.9 和 0.7。式(2)为分割分支的损失函数,其中 y 和 \hat{y} 分别为真实值与预测值。

$$L = L_{cls} + \alpha_1 L_{box} + \alpha_2 L_{mask} \quad (1)$$

$$L_{mask} = -\frac{1}{m^2} \sum_{1 \leq i, j \leq m} [y_{ij} \log \hat{y}_{ij}^k + (1 - y_{ij}) \log (1 - \hat{y}_{ij}^k)] \quad (2)$$

2.4 主干网络选择与算法模型构建

2.4.1 主干网络

ResNet 网络使用跳跃连接和拟合残差两种方式,利用残差映射模块结构,通过跳跃连接将各个阶段的输入信息跳跃连接至输出处,下层网络只需要在两者之间学习不同的地方,一定程度上避免了相同特征的重复学习,简化了学习目标,有效缓解了深层网络导致的梯度消失或梯度爆炸问题^[17]。SENet (Squeeze-and-Excitation Networks) 采用一种全新的特征重标定策略,通过学习的方式自动获取每个特征通道的重要程度,基于此提升有用的特征权重,抑制或减轻无用的特征权重,通过优化网络运行时间,减少参数计算量,使 SE 模块具有注意力机制特点^[18]。

采用残差网络 ResNet50 和 SENet 为基础主干网络,通过融合残差与注意力机制,将 SE 模块作为注意力门控单元嵌入到 ResNet 网络中,得到主干网络 SE-ResNet50。如图 4 所示,该网络首先降低输入特征维度,变为输入的 $1/r$,然后通过 ReLU 激活函数增加更多的非线性单元,有助于更好地拟合通道间复杂的相关性;接着通过一个 FC 全连接层恢复原始维度,再通过 Sigmoid 函数进行权重归一化;最后通过 Scale 将归一化后的权重加权到每个通道特征上^[18]。

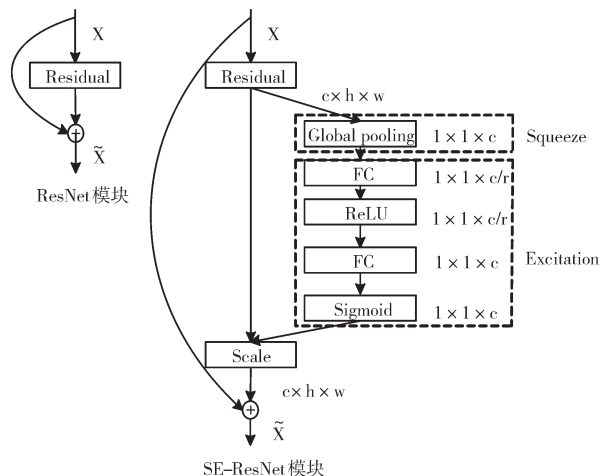


Fig. 4 SE-ResNet module

图4 SE-ResNet 模块

2.4.2 整体算法模型构建

设置 ResNet50、SENet、SE-ResNet50 为主干网络,使用 Mask R-CNN 模型的多任务功能实现甲状腺结节的定位、分割与良恶性分类等一体化自动诊断,通过改进多任务损失函数中的权重占比,实现模型优化。图 5 为本次实验构建的甲状腺超声结节定位、分割、良恶性判别模型。

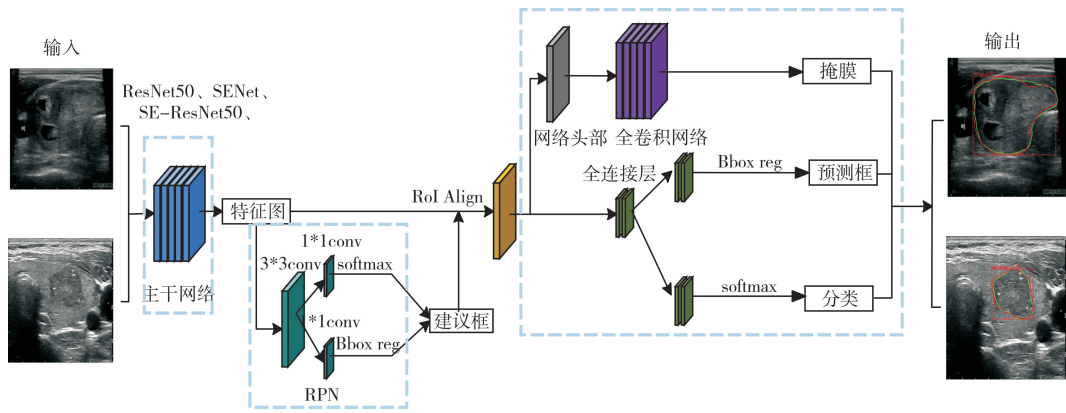


Fig. 5 Ultrasound thyroid nodule localization, segmentation, benign and malignant discrimination model

图 5 甲状腺超声结节定位、分割、良恶性判别模型

2.4.3 参数设置

在目标检测任务中, IoU 为交并比, 表示预测框与实际标注框的交叠率^[19]。IoU_{thr} 为类别置信度, 其值在 [0, 1] 之间。当 IoU=0 时, 预测框与真值框没有交集, 此时结果最差; 当 IoU=1 时, 预测框与真值框重合, 此时结果最好。当预测候选框与原标记框的交并比 IoU>IoU_{thr} 时, 视为正样本; 反之, 视为负样本^[20]。本实验的 IoU_{thr} 设置为 0.5, epoch 设置为 20, 在训练过程中采用优化策略, 等间距调整学习率, 初始学习率设置为 lr=0.002 5, 学习率采用 warmup^[21] 的方式, Learning momentum 设置为 0.9, Backbone stride 设置为 [4, 8, 16, 32, 64], RPN NMS threshold 设置为 0.7。采用迁移学习策略, 在 ImageNet 数据集上预训练 ResNet50、SENet 与 SE-ResNet50 网络得到权重参数, 作为实验模型的初始化参数^[22]。

3 实验结果与分析

3.1 实验评估指标

将恶性结节标注为 malignant, 设置为正样本; 良性结节标注为 benign, 设置为负样本。为定量评估分类性能, 结合临床应用, 设置以下 4 个指标: 真阳性 (True Positive, TP) 指恶性结节被正确判定为恶性; 假阳性 (False Positive, FP) 指良性结节被错误判定为恶性; 真阴性 (True Negative, TN) 指良性结节被正确判定为良性; 假阴性 (False Negative, FN) 指恶性结节被错误判定为良性。用于图像分类的几种评价指标定义如式 (3)、式 (4)、式 (5) 所示。其中, 精确率 (Precision) 也称为查准率, 用于衡量分类器检测出的阳性样本确为阳性样本的概率; 召回率 (Recall) 也称为敏感性 (Sensitivity)、查全率, 其值越高, 阳性样本被漏诊的概率越低; 特异性 (Specificity) 也称为真阴性识别率, 其值越高, 发生误诊的概率越低; mAP (Mean Average Precision) 为 AP 的平均值, 即平均精度均值。

$$\text{精确率 (precision)} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{敏感性 (Sensitivity)} = \frac{TP}{TP + FN} \quad (4)$$

$$\text{特异性 (Specificity)} = \frac{TN}{TN + FP} \quad (5)$$

根据预测分数值与 IoU_{thr} 的关系确定预测结果, 如表 1 所示, Y_{pred} 为网络预测分数, Y_{gt} 为实际的样本类别。

Table 1 Definition of prediction results

表 1 预测结果定义

大小比较	Y _{gt}	预测结果
$Y_{pred} \geq IoU_{thr}$	P	TP
$Y_{pred} < IoU_{thr}$	N	FP
$Y_{pred} \leq IoU_{thr}$	P	FN
$Y_{pred} > IoU_{thr}$	N	TN

3.2 实验结果评估

表 2 为以 ResNet50 为主干网络时, 不同损失函数权重参数下的检测效果。可以看出, 当 $\alpha_1 = 0.9, \alpha_2 = 0.7$ 时, mAP 值最高。因此, 以下结果展示与评估均在该设置下进行。

Table 2 Detection effect under different weight parameters of loss function

表 2 不同损失函数权重参数下的检测效果

α_1	α_2	mAP
1	1	0.734
1	0.9	0.740
1	0.8	0.737
0.9	0.9	0.768
0.9	0.8	0.774
0.9	0.7	0.786
0.9	0.6	0.770
0.9	0.5	0.763
0.8	0.9	0.729
0.8	0.8	0.748

表 3 为在 3 个主干网络下, Mask R-CNN 算法在实验数据集上的测试结果。从表中可以看出, 融合残差注意力机制的 SE-ResNet50 主干网络实现了精确率为 0.936, 召回率为 0.851, 特异性为 0.948, mAP 值为 0.824 的效果, 模型检测效果显著。

Table 3 Test results

表3 测试结果

网络模型	精确率	召回率	特异性	mAP
ResNet50	0.924	0.789	0.901	0.786
SE-Net	0.913	0.826	0.874	0.743
SE-ResNet50	0.936	0.851	0.948	0.824

实验的测试数据集有 587 例,图 6(彩图扫 OSID 码可见)为 SE-ResNet50 主干网络下的检测结果示例。其中,红色矩形虚线框为模型检测出来的甲状腺结节定位,矩形上方为良恶性判别预测及对应的预测分数,红色曲线为模型分割的掩膜边界,绿色曲线为在医生指导下标注的实际结

节范围的可视化展示,为实验参照的金标准。可以看出,本文算法对甲状腺结节的定位准确,分类效果良好,特别是能够较为准确地对恶性结节中的微钙化特点进行判别。对于结节分割问题,本文算法能够预测出结节的大致轮廓,但边缘分割还不够精准,这是由于甲状腺结节超声图像边缘模糊,即使是经验丰富的医生勾画出的轮廓也不一定准确。此外,本文模型有将同一个结节检测为两个、将周围器官检测为结节的情况。在超声图像中,甲状腺周围组织器官在形态上与甲状腺结节较难区分,这也是导致模型多检测或错误检测的原因之一。

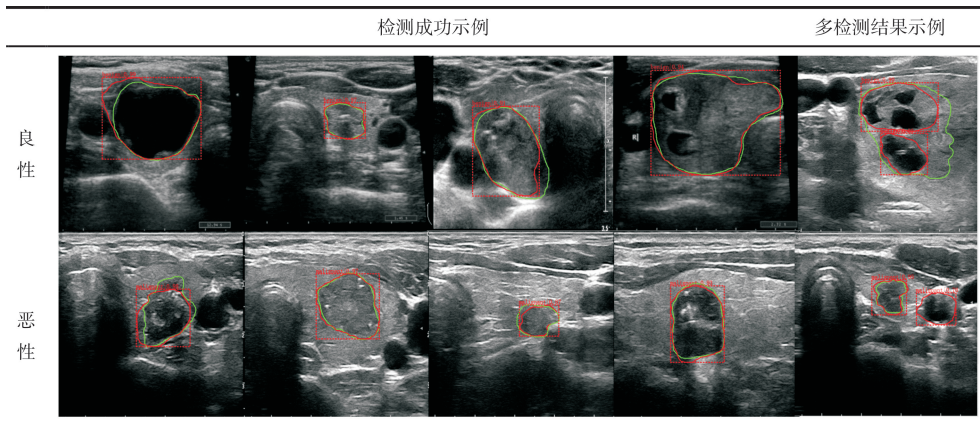


Fig. 6 Test result example

图6 检测结果示例

图 7 为 SE-ResNet50 主干网络下,本文算法在测试集上的准确率与损失率曲线。可以看出,本文算法准确率整体呈上升趋势且稳定收敛,损失率呈下降趋势且稳定收敛,说明其在实验数据集上性能良好。

4 结语

本文以甲状腺结节的超声自动化诊断为研究目标,以 Mask R-CNN 算法为模型,进行了主干网络和损失函数两方面的改进创新,具体表现在:①以 ResNet50、SENet 网络为基础主干网络,融合残差注意力机制构建 SE-ResNet50 主干网络;②对多任务损失函数进行加权优化,在优化损失函数的基础上,通过比较 ResNet50、SENet、SE-ResNet50 3 种不同主干网络的性能,发现融合残差注意力机制的 SE-ResNet50 网络在甲状腺结节的超声检测、分类、分割任务中表现最佳。其在实验数据集上实现了精确率为 0.936,召回率为 0.851,特异性为 0.948,mAP 值为 0.824 的检测效果。该算法能为甲状腺结节的超声诊断提供较为可靠的参考依据,在甲状腺疾病超声诊断自动化领域具有一定的工程意义。


然而,实验也具有一定局限性:首先是医学数据较难获取,本次实验数据量较小,后续可通过增加数据量提高实验结果的可靠性和鲁棒性;其次,甲状腺结节超声图像的边缘分割精度不高,仍需进一步改善。后续会进一步向超声科医生学习病理知识,应用于结节边缘与纹理特征的提取上,辅助自动化诊断。

参考文献:

[1] REBECCA L S, KIMBERLY D M, AHMEDIN J. Cancer statistics,



(a) Test set accuracy curve
(a) 测试集准确率曲线



(b) Test set loss curve
(b) 测试集损失率曲线

Fig. 7 Accuracy rate and loss rate curve of the test set

图7 测试集准确率、损失率曲线

- 2019[J]. CA: A Cancer Journal for Clinicians, 2019, 69(suppl12):7-34.
- [2] YANG L, SUN T T, YUAN Y N, et al. Analysis of the incidence trend and pathological characteristics of thyroid cancer in Beijing urban area from 1995 to 2010[J]. Chinese Journal of Preventive Medicine, 2013, 47(2):109-112.
杨雷, 孙婷婷, 袁延楠, 等. 1995-2010年北京城区甲状腺癌发病趋势及病理特征分析[J]. 中华预防医学杂志, 2013, 47(2):109-112.
- [3] WU J, ZHANG Z, ZHAO J, et al. Ultrasound image segmentation of thyroid nodules based on joint up-sampling[J]. Journal of Physics: Conference Series, 2020, 1651: 012157.
- [4] SHAO M E, YAN J Y, CUI X Y, et al. Ultrasound image segmentation algorithm of thyroid nodules based on CV-RSF model[J]. Journal of Biomedical Engineering Research, 2019, 38(3):336-340.
邵蒙恩, 严加勇, 崔靖尧, 等. 基于 CV-RSF 模型的甲状腺结节超声图像分割算法[J]. 生物医学工程研究, 2019, 38(3):336-340.
- [5] WEI P, TONG M. Attention-DPU: Dual-path UNet with an attention mechanism for ultrasound image segmentation[J]. Journal of Physics Conference Series, 2020, 1693:012155.
- [6] ZHANG L, ZHANG J, LI Z, et al. A multiple-channel and atrous convolution network for ultrasound image segmentation[J]. Medical Physics, 2020, 47(12): 6270-6285.
- [7] WU D. Research and implementation of diagnostic classification methods for thyroid nodules[D]. Shanghai: Donghua University, 2017.
吴迪. 甲状腺结节诊断分类方法的研究与实现[D]. 上海: 东华大学, 2017.
- [8] SINGH N, JINDAL A. Ultra sonogram images for thyroid segmentation and texture classification in diagnosis of malignant (cancerous) or benign (non-cancerous) nodules[J]. International Journal of Computer Applications, 2012, 50(11):43-49.
- [9] YU Q, JIANG T, ZHOU A, et al. Computer-aided diagnosis of malignant or benign thyroid nodes based on ultrasound images[J]. European Archives of Oto-Rhino-Laryngology, 2017, 274(7):2891-2897.
- [10] XIAO T, LIU L, LI K, et al. Comparison of transferred deep neural networks in ultrasonic breast masses discrimination[J]. BioMed Research International, 2018(3):1-9.
- [11] LIU T, GUO Q, LIAN C, et al. Automated detection and classification of thyroid nodules in ultrasound images using clinical-knowledge-guided convolutional neural networks[J]. Medical Image Analysis, 2019, 58:101555.
- [12] HORVATH E, MAJLIS S, ROSSI R, et al. An ultrasonogram reporting system for thyroid nodules stratifying cancer risk for clinical management[J]. The Journal of Clinical Endocrinology and Metabolism, 2009, 94(5):1748-1751.
- [13] NIBBER A, MISTRY R, SOORIYAMOORTHY T, et al. Ultrasound classification of thyroid nodules: a systematic review[J]. Cureus, 2020, 12(3):e7239.
- [14] ROSS G. Fast R-CNN[DB/OL]. <https://arxiv.org/abs/1504.08083>.
- [15] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [16] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2020, 42(2):386-397.
- [17] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Las Vegas: IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- [18] JIE H, LI S, GANG S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 40(8):2011-2023.
- [19] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [20] LI H, WENG J, SHI Y, et al. An improved deep learning approach for detection of thyroid papillary cancer in ultrasound images[J]. Scientific Reports, 2018, 8(1):1-12.
- [21] HUO Z, GU B, HUANG H. Large batch training does not need warmup[DB/OL]. <https://arxiv.org/abs/2002.01576>.
- [22] ZHUANG F Z, LUO P, HE Q, et al. Survey on transfer learning research[J]. Journal of Software, 2015, 26(1):26-39.
庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1):26-39.

(责任编辑:尹晨茹)