

DOI:10.19651/j.cnki.emt.2212371

基于改进残差网络的泌尿系结石类型术前预测^{*}

刘琨^{1,3,4} 王向辉¹ 崔振宇² 杨昆^{1,3}

(1. 河北大学质量技术监督学院 保定 071002; 2. 河北大学附属医院泌尿外科 保定 071000;
3. 河北省新能源汽车动力系统轻量化技术创新中心 保定 071002; 4. 河北大学光学工程博士后流动站 保定 071002)

摘要: 为解决临幊上无法在术前预测泌尿系结石类型的问题,提出一种基于患者CT影像来术前预测结石类型的方法,并开发了基于改进残差网络的泌尿系结石类型术前预测辅助系统,实现了结石类型的术前预测。具体工作包括:首先,以Resnet34作为基础网络,改进了池化层、残差块结构和损失函数,并加入了密集连接结构,从而解决了结石误识别的问题;其次,设计了一种双分支多头自注意力模块,增加了结石区域的特征权重,大大提高了模型性能;最后,通过回顾式研究,建立了包含5709张结石CT影像数据集,按照3:1:1的比例随机分为训练集、验证集和测试集,用以对模型进行训练和性能验证。经实验证,提出的改进残差网络在测试集上准确度达到了72.90%,相对于原网络准确度提升了6.38%,F1分數提高了10%。结果表明,该模型能够有效提高泌尿系结石的术前预测精度并具有潜在的临床应用价值。

关键词: 泌尿系结石;术前预测;残差网络;图像分类

中图分类号: TP391.41 文献标识码: A 国家标准学科分类代码: 520.60

Preoperative prediction of urological stone types based on improved residual network

Liu Kun^{1,3,4} Wang Xianghui¹ Cui Zhenyu² Yang Kun^{1,3}

(1. College of Quality and Technical Supervision, Hebei University, Baoding 071002, China;
2. Department of Urology, Affiliated Hospital of Hebei University, Baoding 071000, China;
3. Hebei Technology Innovation Center for Lightweight of New Energy Vehicle Power System, Baoding 071002, China;
4. Postdoctoral Research Station of Optical Engineering, Hebei University, Baoding 071002, China)

Abstract: To solve the problem of clinical inability to predict urinary stone types preoperatively, we propose a method for preoperative prediction of stone types based on CT images, and develop a preoperative prediction aid system for urinary stone types based on improved residual network. This enables preoperative prediction of stone types. The main tasks includes: firstly, Resnet34 is used as the base network with improved pooling layer, residual block structure and loss function, and a dense connection structure is added. Thus, the problem of stone misidentification is solved. Secondly, a two-branch multi-headed self-attentive module was designed to increase the feature weights of the stone region, which greatly improved the model performance. Finally, through a retrospective study, a dataset containing 5709 CT images of stones was created and randomly divided into a training set, a validation set and a test set in the ratio of 3:1:1, which was used for training and performance validation of the model. The proposed improved residual network was experimentally verified to be 72.90% accurate on the test set, with a 6.38% improvement in accuracy and a 10% increase in F1 score. The results showed that the model can effectively improve the accuracy of preoperative prediction of urinary stones and has potential clinical application.

Keywords: urological stone; preoperative prediction; residual network; image classification

0 引言

泌尿系结石病简称尿石病,是最常见的泌尿外科疾病

之一,据统计一般人群发病率达5%~10%^[1],并呈逐年升高的趋势且治疗后易复发^[2-3]。尿石病若不能及时处理,将会引发肾绞痛及继发性病发症,更有甚者可能造成肾功能

收稿日期:2022-12-12

*基金项目:河北省高层次人才资助项目(B2019030010)、河北省自然科学基金(H2019201378)、河北大学校长基金(XZJJ201917)、河北大学医学学科培育项目(2021X07)资助

丧失和尿毒症。因此,对尿石病的精确诊断、治疗及预后具有重要的临床价值。

尿石病存在多种类型,不同种类的尿石病采用的治疗方法存在显著差异^[4]。根据结石化学成分,可分为草酸钙结石、磷酸钙结石、磷酸镁铵结石、胱氨酸结石、尿酸结石,其中草酸钙结石最为常见^[5]。草酸钙结石呈棕褐色,质地坚硬,粗糙,边缘不规则;磷酸钙结石呈灰白色,鹿角形,有明显的层状纹;磷酸镁铵结石表面较为光滑;胱氨酸结石呈淡黄色,六角形,质地较软;尿酸结石呈棕红色,颗粒状。尿酸和胱氨酸结石可选择碱化尿液药物溶解治疗,无需手术取石^[6];草酸钙结石硬度较大,宜采用经皮肾镜取石术治疗^[7];而磷酸镁铵结石为感染性结石,需要先进行抗感染处理,再采用外冲击波碎石术治疗^[8]。错误地选择治疗方案将导致患者承受更多的治疗痛苦和风险,所以如果医生能在治疗前掌握结石类型信息将对治疗过程提供很大指导价值^[9-10]。

目前临幊上缺少一种可靠的检测手段,实现体内结石类型的术前诊断。红外光谱分析法^[11]是临幊上常用的结石类型分析技术,但是其耗时长且局限于体外。医学影像数据例如计算机断层扫描(computed tomography, CT)为医生提供了无创的检测途径,Assmy 等^[12]尝试了用 CT 值预测结石类型,虽然准确度较低但为体内结石类型的术前诊断提供了可借鉴的思路。

近年来,人工智能技术在医学图像处理领域得到广泛发展^[13-15],通过将人工智能和医学图像处理技术相结合提升了对尿石病的精准诊断能力。Groe 等^[16]根据双能 CT 图像,利用机器学习方法预测了 200 个离体肾结石的主要类型,准确度为 91.1%;Kriegshauser 等^[17]用人工神经网络、支持向量机、决策树、随机树、朴素贝叶斯树 5 种模型对 32 个离体肾结石区分尿酸和非尿酸结石,最高准确度为 97%。但这些研究均采用了机器学习方法,严重依赖手动特征提取和特征筛选,操作复杂且容易忽略有效特征,而且仅用于离体结石的处理,无法术前预测结石类型。

卷积神经网络(convolutional neural networks, CNN)是人工智能技术的一类分支,目前已应用于泌尿系结石领域,其能够自动学习、提取各类数据中的特征,在图像处理中具有独特优势。Parakh 等^[18]根据患者 CT 影像构建了一种 CNN 模型,诊断患者是否患尿石病,准确度达到了 95%;Estrade 等^[19]利用 CNN 模型根据离体肾结石内窥镜影像预测结石类型,平均准确率均高于 87%;Black 等^[20]根据 63 例离体肾结石的数字照片,利用 Resnet101 网络构建了自动检测肾结石类型模型,召回率和平均精度分别为 85% 和 82.11%。但上述文献都是对离体结石的类型预测,无法起到术前指导的作用。对于结石的术前预测,Kim 等^[21]通过内窥镜图像构建 CNN 模型用来术前预测结石类型,取得了 90% 以上的准确度。高亚明^[22]基于影像组学方法预测体内草酸钙结石和尿酸结石类型,分类精度达

81.75%。Rudenko 等^[23]利用双能 CT 术前预测 5 种单纯性结石类型,准确度达到 85% 以上。但上述研究仍存在几点不足:1)内窥镜检查是一种微创检查,并且操作相对复杂;2)临幊中除了 5 种单纯型结石,还存在混合型结石的情况;3)网络对图像特征的利用率较低,若能够提高特征利用率则能有效提升网络预测结石类型的精度;4)忽略了数据不平衡问题对结果的影响,由于每种结石发病率不同,因此结石的数据集是存在类别不平衡问题的。

因此,针对上述问题,本文主要工作如下:1)开发了一种改进残差网络模型,利用模型提取尿石病患者的 CT 影像数据特征以达到术前预测多种结石类型的目的;2)对残差网络模型进行了改进,提出了一种残差融合模块并加入了密集连接结构,同时提出了一种双分支多头自注意力模块,从而增加了网络对特征的利用率;3)通过焦点损失函数对分类损失函数添加权重系数,从而减小数据不平衡问题对结果的影响。同时,本研究以术后结石的红外光谱检测结果为金标准,通过实验验证模型的性能。从而进行术前结石种类分类,指导临幊医生做出更科学的、个体化的治疗方案,防止结石患者术后复发。

1 算法改进

1.1 焦点损失函数

网络模型的性能与数据集分布有一定的关系,若数据集存在数据不平衡现象,模型的预测结果则会偏向于数据较多的一类,从而严重影响模型分类性能。为了解决这一问题,Facebook 团队在 2018 年提出了一种新的损失函数——焦点损失函数(Focal loss)^[24],并在 COCO 数据集上得到了验证。因此针对本文实验数据不平衡问题,本文利用 Focal loss 替代了交叉熵损失函数,定义分别如式(1)、(2)所示。Focal loss 在交叉熵损失函数的基础上增加了权重因子,通过对每类的损失添加权重,减小多类损失所占比重,增大少类损失所占比重,从而减小数据不平衡带来的影响。每类损失的权重系数为其样本数的反比,如本文数据集样本数 class 1 : class 2 : class 3 : class 4 = 15 : 5 : 1 : 8,则每类损失权重系数 class 1 : class 2 : class 3 : class 4 = 1 : 3 : 15 : 2。

$$CE(p_t) = -\log(p_t) \quad (1)$$

$$FL(p_t) = -\alpha_t(1-p_t)^\gamma \log(p_t) \quad (2)$$

式(1)、(2)中,CE 表示交叉熵损失,FL 表示焦点损失, p_t 表示每类的概率, γ 表示聚焦系数,本文中 γ 设置为 2, α_t 表示每类的权重系数。

1.2 残差融合模块

残差网络是一种典型的分类网络,跳跃连接结构解决了梯度消失和爆炸问题,从而能够使网络提取图像更深层的特征信息,本文选择 Resnet34 作为基础框架,在其基础上进行改进。Resnet34 网络主要由 stage0~4 模块和全局平均池化层(golbal average pooling, GAP)及全连接层

(fully connected layer, FC)组成,其中stage0包含1个 7×7 卷积层和1个 3×3 最大池化层,Stage1~4模块分别包含3、4、6、3个残差块,每个残差块由2个 3×3 卷积层和跳跃连接构成。残差块的结构如图1所示。

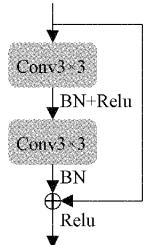


图1 Resnet34 残差块结构

为了能够更加充分地利用每层卷积提取出的特征,本文提出了一种残差融合模块,其结构如图2所示,相比于残差块结构,残差融合模块增加了1个通道拼接和1个 1×1 卷积层,从而将残差块中2个 3×3 卷积提取出的特征图在通道维度进行拼接融合,之后通过 1×1 卷积层压缩通道数,使融合后的特征图大小变为与原输入相同尺寸,并通过跳跃连接使两者相加。假设残差融合模块的输入为特征图 $x \in R^{W \times H \times C}$,其中W、H、C分别表示特征图的宽、高和通道数,则残差融合模块的输出为:

$$y = K_3([K_1(x), K_2(K_1(x))]) + x \quad (3)$$

式(3)中, $K_1(\cdot)$ 、 $K_2(\cdot)$ 分别表示2个 3×3 卷积, $K_3(\cdot)$ 表示 1×1 卷积。

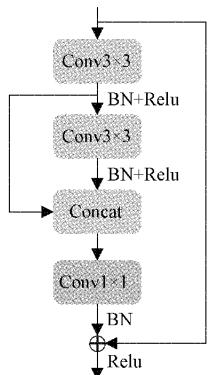


图2 残差融合模块结构

1.3 软池化

CNN通常需要池化操作来减小特征图的尺寸大小,如Resnet34网络,输入图片经过1个 7×7 卷积后,会通过最大池化层(Max Pooling)对特征图进行下采样,其定义如式(4)所示,Max Pooling是对核邻域内像素点去最大值,因此Max Pooling忽略了图像的背景信息,可能造成有效信息特征的损失,从而影响网络预测的准确度。因此,本文利用一种新的池化方法——软池化(Soft Pooling)^[25]对特征图进行下采样,Soft Pooling与Max Pooling不同,它通过对核邻域内像素点指数加权的方式,能够更好地保留信息

特征,从而提高网络模型的分类性能。Soft Pooling的定义如式(5)所示。

$$MP = \max_{i \in R} a_i \quad (4)$$

$$SP = \sum_{i \in R} \frac{e^{a_i}}{\sum_{j \in R} e^{a_j}} \quad (5)$$

式(4)、(5)中,MP表示Max Pooling输出,SP表示Soft Pooling的输出, a_i 表示核邻域内的像素值。

1.4 密集连接

通常图像的浅层特征具有丰富的细节信息,但是语义信息较弱;图像的深层特征细节信息较少,但语义信息较强。虽然Resnet34网络通过跳跃连接在一定程度上将浅层特征与深层特征相联系,但并没有将浅层特征与深层特征充分融合利用,在对结石进行分类时,容易造成误诊等情况。因此本文对Resnet34网络进行改进,加入了密集连接结构,如图3所示,即每个层都会与前面所有层在通道维度上连接在一起,并作为下一层的输入,但要确保各层特征能够拼接在一起,还必须保证每层特征图的尺寸大小相等。因此本实验利用上文提出的Soft Pooling最大程度的保留特征信息,通过 2×2 、 4×4 、 8×8 池化分别对各层特征图进行下采样,统一各阶段特征图尺寸,然后将其在通道维度进行拼接,之后再经过一个 1×1 卷积压缩通道,从而将结石CT影像的浅层特征和深层特征融合形成新特征图,实现了特征重用,提高了模型对结石的分类性能。假设网络第*i*阶段的输出为 x_i ,则传统的Resnet34网络和改进后的网络输出表达式分别如式(6)、(7)所示。

$$x_i = H_i(x_{i-1}) \quad (6)$$

$$x_i = H_i([x_0, x_1, \dots, x_{i-1}]) \quad (7)$$

式(6)、(7)中, $H_i(\cdot)$ 代表第*i*阶段一系列的BN,ReLU,Pooling及Conv的组合操作。

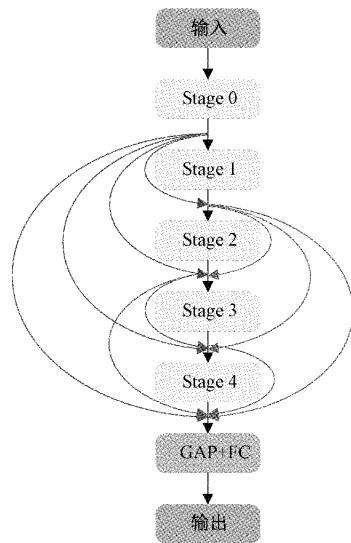


图3 密集连接结构

1.5 双分支多头自注意力模块

随着 transformer^[26]在自然语言处理领域的兴起,对自注意力机制的研究也越来越多,并将其逐渐应用于视觉图像处理领域。自注意力机制是注意力机制的改进,其减少了对外部信息的依赖,能够更大程度的获取图像的全局信息,从而更有利联系特征之间的相关性。而多头自注意力机制(Multi-head self-attention, MHSA)则是在自注意力的基础上,对特征图进行分组分别操作,从而获取图像更多不同空间的特征,其结构如图 4 所示。

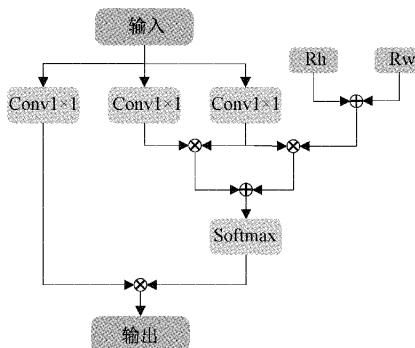


图 4 MHSA 结构

为了进一步获得更多的表征信息,提升注意力权值的有效性,本文提出了一种双分支多头自注意力模块(double-branch multi-head self-attention, DMHSA),同时该模块借鉴了残差网络的思想,结构如图 5 所示。加入了跳跃连接结构。当输入一个特征图后,先经过 1×1 卷积将通道扩展,之后通过两个并行的 MHSA 对输入特征图进行加权,然后将两个分支各自计算的加权特征图对应位置相加,再通过 1×1 卷积压缩通道,最后经过跳跃连接将压缩通道后的特征图与输入特征图作为输出,如式(8)所示。

$$y = K_2(f_1(K_1(x)) + f_2(K_1(x))) + x \quad (8)$$

式(8)中, x 表示 DMHSA 的输入, y 表示 DMHSA 的输出, $f_1(\cdot)$ 、 $f_2(\cdot)$ 表示两分支的 MHSA 操作, $K_1(\cdot)$ 、 $K_2(\cdot)$ 分别表示 2 个 1×1 卷积。

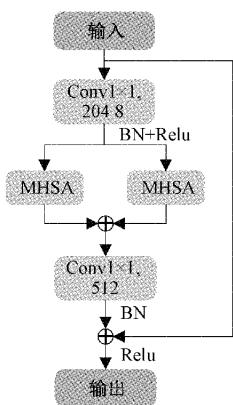


图 5 DMHSA 结构

1.6 网络模型

本文提出的改进 Resnet34 网络模型如图 6 所示,其主要由 Stage 0~4、密集连接、DMHSA 模块、GAP 和 FC 构成。在 Stage 0 中,本文利用 Soft Pooling 代替了 Max Pooling,从而在对图像下采样过程中保留更多的特征信息。Stage 1~4 则分别由 3、4、6、3 个本文提出的残差融合模块组成,残差融合模块在残差块的基础上添加了一个 Concat 操作和 1 个 1×1 卷积层,从而将残差块中 2 个卷积层提取出的特征拼接在一起。之后通过密集连接结构,将 Stage 0~4 提取的特征图进行融合,充分利用了图像的浅层特征和深层特征。然后利用本文设计的 DMHSA 模块,对特征图进行加权操作,从而使模型关注结石的主要特征,增加结石重要特征的权重,减少其他区域特征权重。最后将加权后的特征图经过 GAP 和 FC 层输出分类结果。

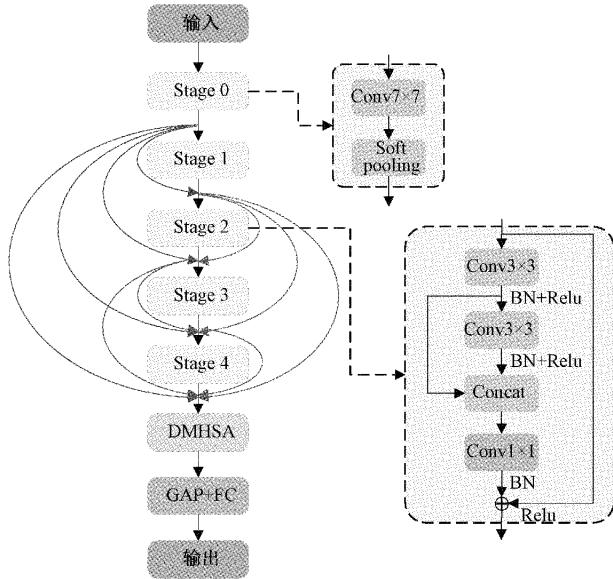


图 6 改进 Resnet34 结构

2 实验

2.1 数据收集

本实验数据来源于河北大学附属医院泌尿外科,收集了 2018 年 1 月~2021 年 4 月期间所有泌尿系结石患者 CT 影像,以及与其对应的红外光谱检测报告,共获得 698 例泌尿系结石患者影像数据,根据排除标准进行筛选:1)结石最大直径小于 2 mm;2)结石 CT 影像不清晰或存在伪影;3)结石 CT 影像无对应的红外光谱检测报告;4)混合性结石的组成成分占比均小于 60%。最终得到 392 例泌尿系结石患者的 5709 张 CT 影像,之后将 CT 影像分为 4 类,具体如表 1 所示。

2.2 数据预处理

首先通过 RadiAnt DICOM Viewer 软件将 DICOM 格式的 CT 影像数据转换为日常使用的 JPG 格式的影像数据,再进一步对影像进行图像命名匿名化和图像信息匿名

表1 每类数据样本量

类别名	结石类型	病例数	CT数
Class 1	草酸钙	255	2 994
Class 2	尿酸	41	1 028
Class 3	磷酸钙、磷酸镁铵和胱氨酸	10	196
Class 4	混合型	86	1 491

化。由于结石在 CT 影像中较小,因此将数据由经验丰富的专业泌尿外科医生利用 LabelImg 标注工具分别对数据集中的每张 CT 影像标注结石所在位置,并按照对应的报告予以结石种类标签,生成 XML 格式标注文件,接着根据标注文件剪切出结石区域并将其尺寸 Resize 为 64×64 像素。之后将数据按照 3:1:1 的比例随机划分为训练集、验证集和测试集,由于各类之间存在数据不平衡现象,因此对训练集进行数据扩充,扩充方式包括水平、垂直翻转、旋转($\pm 15^\circ$ 、 $\pm 30^\circ$ 、 $\pm 45^\circ$ 、 $\pm 60^\circ$ 、 $\pm 90^\circ$),从而使训练集中每一类的样本数保持大体一致,在一定程度上减弱数据不平衡的影响,制作完成的数据集如表 2 所示。

表2 数据集样本分布情况

类别	训练集	验证集	测试集
Class 1	1 796	599	599
Class 2	1848	206	206
Class 3	1 521	39	40
Class 4	1 788	298	299

2.3 实验设置

在 Ubuntu18.04 系统上搭建实验环境,实验在 Python3.7、Pytorch1.6、Cuda10.1 环境下进行, GPU 为 NVIDIA GeForce RTX 2070,IDE 工具采用 Pycharm,结石 CT 影像为 JPG 格式,尺寸均为 64×64 像素。将制作好的数据集输入到本文提出的分类网络中开始训练,使用梯度下降优化模型参数,批大小设为 16,训练初始阶段学习率为 0.001,权重衰减系数设置为 0.000 5,动量设置为 0.9,进行了 100 个周期(epoch)的训练。

3 结果与分析

3.1 评价指标

本文通过准确度(Accuracy)、精确度(Precision)、召回率(Recall)、特异性(Specificity)对模型的性能进行评估,上述指标是表征模型分类性能的不同维度的度量,准确度表示在所有样本中预测正确概率,精确度表示在所有预测为正样本中实际为正样本的概率,召回率表示在所有正样本中预测为正样本的概率;特异性表示在所有负样本中预测为负样本的概率,同时,本文又引入了 F1 分数(F1 Score)对模型的性能进行评估,定义分别如式(9)~(13)所示。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

$$P = \frac{TP}{TP + FP} \quad (10)$$

$$R = \frac{TP}{TP + FN} \quad (11)$$

$$Specificity = \frac{TN}{TN + FP} \quad (12)$$

$$F1\ Score = \frac{2PR}{P + R} \quad (13)$$

式(9)~(13)中,TP 表示真阳性样本量,TN 表示真阴性样本量,FP 表示假阳性样本量,FN 表示假阴性样本量;P 表示精确度;R 表示召回率。

3.2 对比实验结果

本文研究算法分别与 Resnet18、Resnet34、Vgg11、Shufflenet-v2、Efficientnet-v2 以及 Bot50 分类网络在构建的数据集上进行训练、测试,通过上述评价指标对比本文研究算法的性能,从而证明本文提出的改进残差网络模型相比于其他分类算法对结石的分类精度更高,实验结果如表 3 所示。

表3 不同网络实验结果对比 %

网络	准确率	精确度	召回率	特异性	F1 分数
Resnet18	66.26	59.18	58.85	86.20	58.68
Resnet34	66.52	57.95	55.98	85.98	56.42
Resnet50	69.40	61.90	61.28	87.78	61.50
Vgg11	68.62	60.05	63.73	87.88	61.30
Shufflenet-v2	61.45	54.55	57.30	84.68	55.59
Efficientnet-v2	62.67	55.33	55.50	85.43	55.32
Bot50	63.29	55.80	59.10	85.05	56.78
本文	72.90	68.35	65.23	88.80	66.42

由实验结果可知,原 Resnet34 网络对结石的分类准确度较低为 66.52%,经过改进后的网络对结石的分类准确度达到了 72.90%,相比于原网络提高了 6.38%,同时本文算法在 Precision、Recall、Specificity 和 F1 Score 指标上也都高于原网络,分别提高了 10.40%、9.25%、2.82%、10.00%。另外,本文提出的改进残差网络模型与其他分类算法相对,在各个评价指标上也均高于其他分类算法,尤其是在 Precision 和 F1 Score 上,高出其他分类算法 5%以上。

另外,为了更加全面的评估改进残差网络算法对结石分类的性能,本文绘制了改进前后算法和其他分类算法的 ROC 曲线图并计算出了各网络的 ROC 曲线下面积(the area under the ROC curve, AUC),以对比各个网络模型的性能,如图 7 所示。从图中可以看出本文提出的改进残差网络模型对各类结石分类的 AUC 均高于其他分类算法,与原 Resnet34 网络相比,本文算法对各类结石分类的 AUC 分别提高了 3.42%、3.25%、4.20%、4.33%。由此表明,本文提出的改进残差网络模型能够更加准确对结石进行分类。

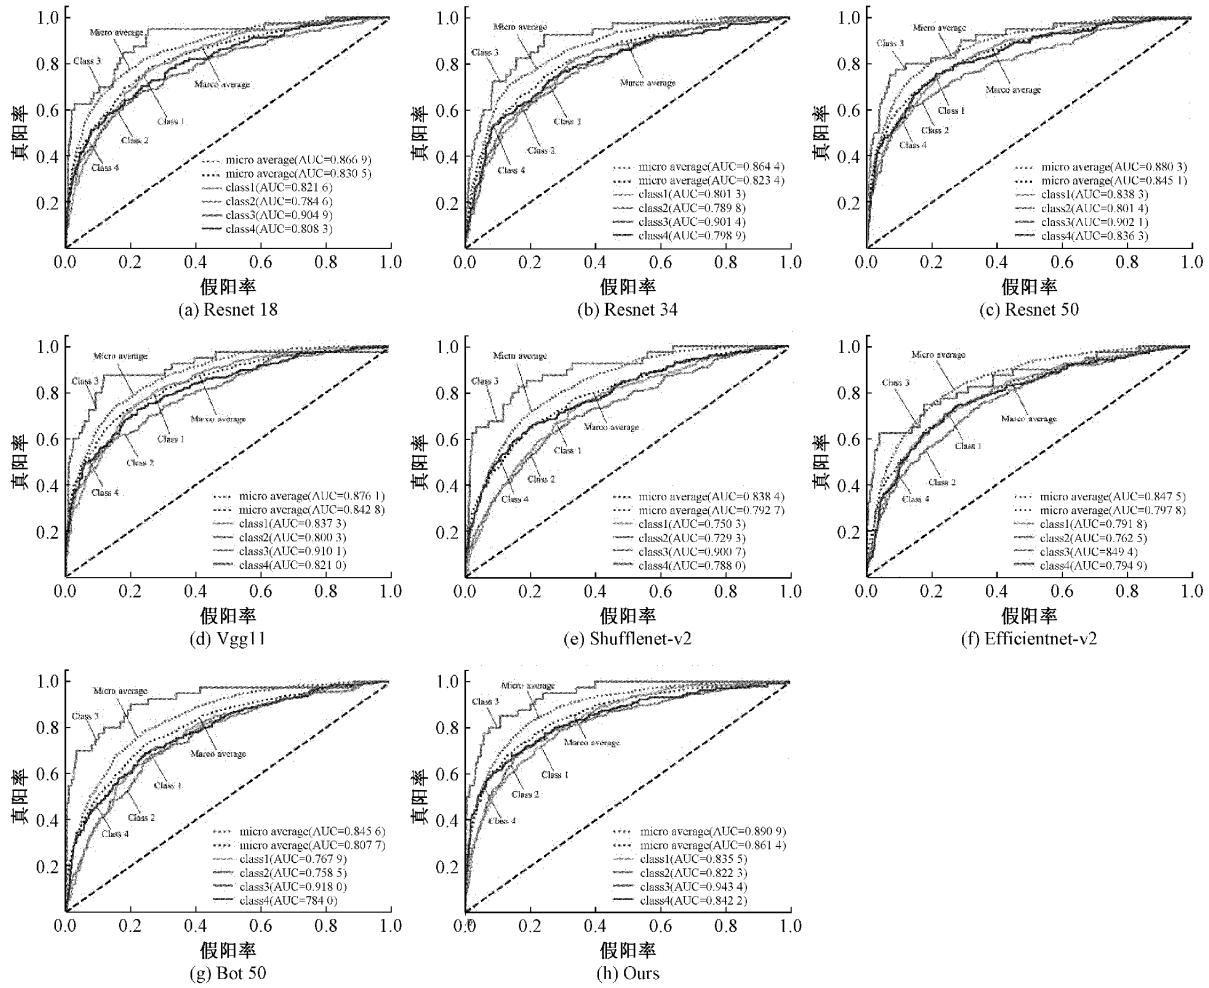


图 7 不同网络的 ROC 曲线

3.3 消融实验结果

本文对 Resnet34 网络进行了 5 个方面的改进,包括 Focal loss、Soft Pooling、密集连接、双分支多头自注意力模块和残差融合模块,分别以 S1、S2、S3、S4、S5 表示。为了

验证这 5 个模块对网络性能的改进效果,在 Resnet34 网络上依次添加 S1、S2、S3、S4、S5,并在本文数据集上进行训练、测试,从而证明各个模块的有效性,结果如表 4 所示。

表 4 消融实验结果对比

网络	准确率	精确度	召回率	特异性	F1 分数	%
Resnet34	66.52	57.95	55.98	85.98	56.42	
Resnet34+S1	68.88	60.35	63.50	87.83	61.48	
Resnet34+S1+S2	68.88	64.05	63.30	87.38	63.53	
Resnet34+S1+S2+S3	69.23	66.95	65.68	87.95	65.49	
Resnet34+S1+S2+S3+S4	71.50	65.98	66.15	88.48	65.65	
Resnet34+S1+S2+S3+S4+S5	72.90	68.35	65.23	88.80	66.42	

实验结果表明,将交叉熵损失替换为 Focal loss 后,模型的各个指标均达到了 60% 以上,表明对损失函数加权能够在一定程度上减弱数据不平衡的影响。在加入 Soft Pooling 和密集连接层后,模型的性能又分别得到了进一步提升,从而表明 Soft Pooling 和密集连接结构能够提高网

络对特征的利用效率,充分利用图像的浅层特征和深层特征,而特征的充分利用有利于提高网络性能。之后通过加入双分支多头自注意力机制,模型对结石的分类准确度达到了 71.50%,相比于原网络提升了 4.98%,表明双分支多头自注意力模块对特征图加权后能够提高网络对结石的

性能。最后将5个模块都添加后,模型准确度、F1分数等指标相对原网络得到大幅提升,由此表明,本文对Resnet34网络改进的5个模块能够有效提高模型对结石的分类性能。

3.4 网络性能评估

为了验证本文方法的性能,在临幊上对每类结石各随机挑选1例CT影像数据,利用本文提出的系统预测结石类型,预测结果如表5所示。另外,每例CT影像数据的预测置信度如图8所示。由实验结果可知,本文方法能够根据每例CT影像准确预测出4例结石的类型,但Case3与Case4的置信度低于Case1和Case2,这是因为用于训练模型的其他型结石数据量较少,而混合型结石是由多种成分组合而成,因此模型对于这两种结石的预测置信度低于草酸钙结石和尿酸结石。综上所述,本文方法能够达到术前预测结石类型的目的。

表5 每例CT预测结果

病例	真实值	预测结果
Case1	草酸钙结石	草酸钙结石
Case2	尿酸结石	尿酸结石
Case3	其他型结石	其他型结石
Case4	混合型结石	混合型结石

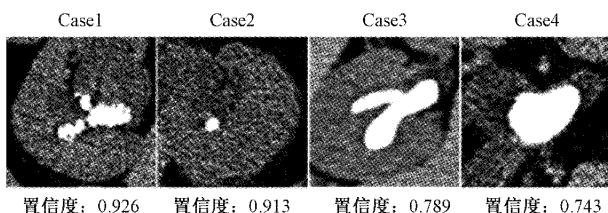


图8 每例CT预测置信度

3.5 对比研究

我们将所提出的方法与本领域已有的研究进行了横向对比,结果如表6所示。

表6 与已有研究对比结果

	图像类型	结石类型	技术方法
文献[21]	内窥镜	单纯型结石+	CNN
		混合型结石	
文献[22]	CT	草酸钙结石+	影像组学
		尿酸结石	
文献[23]	CT	单纯型结石	双能CT指数分析
		单纯型结石+	
本文方法	CT	混合型结石	改进残差网络

从表6中可以发现,本文方法与现有研究存在3点主要区别:1)本文方法基于CT术前预测结石类型,为无创性检查,而文献[21]采用的内窥镜图像,内窥镜检查是微创

性检查。2)文献[22]和[23]只考虑了草酸钙结石或尿酸结石等单纯性型结石,但在临幊中还存在大部分的混合型结石病例,而本研究针对多种结石类型,除了能够对单纯性结石分类外,还可以识别混合型结石,相比于文献[22]和[23]具有更大的临幊价值。3)本文提出的改进残差网络能够提取图像更加丰富的特征,同时本文方法能够减弱数据不平衡带来的影响,具有更好的应用价值。

4 结论

本文提出了一种基于CT影像术前预测结石类型的方法,并开发了基于改进残差网络的结石类型术前预测辅助系统。以Resnet34作为基础框架,设计了一种残差融合模块,并利用Soft Pooling代替了Max Pooling进行下采样,从而保留图像更多的特征信息。同时,利用Focal loss减弱了数据不平衡带来的影响,并加入了密集连接结构,通过密集连接融合图像的浅层特征和深层特征,使得结石误识别问题得到改善。另外,设计了一种双分支多头自注意力模块,使模型关注结石最具辨别的区域,提高了模型的分类性能,最终取得72.90%的准确度。从而表明,本研究能够在泌尿系结石患者进行手术前,准确的对其CT影像进行结石分类,有助于辅助医生选择合适的治疗方案并预防患者复发,减轻患者痛苦,具有潜在的临床应用价值。但本文提出的模型还存在一定的局限性,只利用了单中心的数据。因此,接下来将进一步从多个地区的医院收集数据,从而对本研究进一步探讨。

参考文献

- [1] SECKINER I,SECKINER S,SEN H,et al. A neural network-based algorithm for predicting stone-free status after ESWL therapy[J]. International Braz J Urol,2017,43(6):1110-1114.
- [2] MIERNIK A,HEIN S,WILHELM K,et al. Urinary stone analysis-what does the future hold in store? [J]. Aktuelle Urologie,2017,48(2):127-131.
- [3] FERRARO P M,CURHAN G C,D'ADESSI A,et al. Risk of recurrence of idiopathic calcium kidney stones: Analysis of data from the literature [J]. Journal of Nephrology,2017,30(2):227-233.
- [4] CUNNINGHAM P,NOBLE H,AL-MODHEFER A K,et al. Kidney stones: Pathophysiology, diagnosis and management[J]. British Journal of Nursing,2016,25(20):1112-1116.
- [5] FERRARO P M,MARANO R,PRIMIANO A,et al. Stone composition and vascular calcifications in patients with nephrolithiasis [J]. Journal of Nephrology,2019,32(4):589-594.
- [6] TZELVES L,MOURMOURIS P,SKOLARIKOS A,et al. Outcomes of dissolution therapy and monitoring

- for stone disease: Should we do better[J]. Current Opinion in Urology, 2021, 31(2): 102-108.
- [7] ULLAH A, KHAN M K, RAHMAN A U, et al. Percutaneous nephrolithotomy: A minimal invasive surgical option for the treatment of staghorn renal calculi[J]. Kmuj, 2012, 4(4): 156-160.
- [8] IQBAL M W, YOUSSEF R, NEISIUS A, et al. Contemporary management of struvite stones using combined endourological and medical treatment: Predictors of unfavorable clinical outcome[J]. Journal of Endourology, 2013, DOI: 10.1089/end.2013-0257.ecc13.
- [9] TALATI V M, SOARES R M O, KHAMBATI A, et al. Trends in urinary calculi composition from 2005 to 2015: A single tertiary center study [J]. Urolithiasis, 2020, 48(4): 305-311.
- [10] PEARLE M S, GOLDFARB D S, ASSIMOS D G, et al. Medical management of kidney stones: AUA guideline[J]. Journal of Urology, 2014, 192 (2): 316-324.
- [11] HERMIDA F J. Analysis of human urinary stones and gallstones by fourier transform infrared attenuated total reflectance spectroscopy[J]. Journal of Applied Spectroscopy, 2021, 88(1): 215-224.
- [12] ASSMY A, ABOU G M E, NAHAS A R, et al. Multidetector computed tomography: Role in determination of urinary stones composition and disintegration with extracorporeal shock wave lithotripsy an in vitro study[J]. Urology, 2011, 77(2): 286-290.
- [13] 何晓云, 许江淳, 陈文绪. 基于改进 U-Net 网络的眼底血管图像分割研究[J]. 电子测量与仪器学报, 2021, 35(10): 202-208.
- [14] 林桢哲, 王桂棠, 陈建强, 等. 基于残差网络深度学习的肺部 CT 图像结节良恶性分类模型[J]. 仪器仪表学报, 2020, 41(3): 248-256.
- [15] 喻殿智, 张欣, 迟杏. 基于 CA-DenseNet 的乳腺癌病理图像识别[J]. 国外电子测量技术, 2022, 41(5): 137-143.
- [16] GROE H N, LENNARTZ S, SALEM J, et al. Dose independent characterization of renal stones by means of dual energy computed tomography and machine learning: An ex-vivo study[J]. European Radiology, 2020, 30(3): 1397-1404.
- [17] KRIEGSHAUSER J S, SILVA A C, PADEN R G, et al. Ex vivo renal stone characterization with single-source dual-energy computed tomography: A multiparametric approach[J]. Academic Radiology, 2015, 23(8): 969-976.
- [18] PARAKH A, LEE H, LEE J H, et al. Urinary stone detection on CT images using deep convolutional neural networks: Evaluation of model performance and generalization[J]. Radiology: Artificial Intelligence, 2019, 1(4): e180066.
- [19] ESTRADE V, DAUDON M, RICHARD E, et al. Towards automatic recognition of pure and mixed stones using intra-operative endoscopic digital images[J]. BJU International, 2022, 129(2): 234-242.
- [20] BLACK K M, LAW H, ALDOUKHI A, et al. Deep learning computer vision algorithm for detecting kidney stone composition [J]. BJU International, 2020, 125(6): 920-924.
- [21] KIM U S, KWON H S, YANG W, et al. Prediction of the composition of urinary stones using deep learning [J]. Investig Clin Urol, 2022, 63: 441-447, DOI: 10.4111/ICU.20220062.
- [22] 高亚明. 基于影像组学的体内结石成分辅助诊断方法研究[D]. 扬州:扬州大学, 2020.
- [23] RUDENKO V, SEROVA N, KAPANADZE L, et al. Dual-energy computed tomography for stone type assessment: A pilot study of dual-energy computed tomography with five indices [J]. Journal of Endourology, 2020, 34(9): 893-899.
- [24] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2020, 42(2): 318-327.
- [25] STERGIOU A, POPPE R, KALLIATAKIS G. Refining activation downsampling with SoftPool[J]. Proceedings of the IEEE International Conference on Computer Vision, 2021, 10337-10346, DOI: 10.48550/arXiv.2101.00440.
- [26] VASWANI A, SHAZER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30: 5999-6009.

作者简介

刘琨,博士,讲师,硕士生导师,主要研究方向为人工智能医学图像处理。

E-mail: liukun15166@hbu.edu.cn

王向辉,硕士研究生,主要研究方向为人工智能医学图像处理。

E-mail: 1965452981@qq.com

崔振宇,博士研究生,副主任,主要研究方向为泌尿系结石、肿瘤、前列腺疾病的诊治。

E-mail: cuizhenyu615@163.com

杨昆(通信作者),博士,教授,博士生导师,主要研究方向为人工智能医学图像处理。

E-mail: hbu0126@163.com