

# 基于 CT 图像的深度学习模型鉴别良恶性肾肿瘤

陈美容,周涛,陈炫幸,钟向阳,陈智慧,冯宝,陈业航,徐坤财

**【摘要】 目的:**探讨基于 CT 图像的深度学习模型对肾脏良、恶性肿瘤的鉴别诊断价值。**方法:**回顾性搜集 2008—2020 年经病理证实且符合本研究要求的 798 位患者(共 805 例肾肿瘤)的临床和三期(平扫、皮髓质期和实质期)腹部 CT 影像资料。其中,来自本院的 418 例肾癌和 78 例肾良性肿瘤的资料用于建立影像组学模型和内部验证,来自另外两个研究中心和一个公共数据库(癌症医学图像数据库 TCIA)的 262 例肾癌和 47 例肾良性肿瘤的资料作为独立外部验证集。使用 ITK-SNAP3.6.0 软件,在三期 CT 图像中选择肿瘤边缘显示较清楚的一期图像,选取肿瘤最大层面及其上、下相邻层面,沿病灶边缘手动勾画 ROI,再通过软件的空间调整技术,使另外两期 CT 图像上肿瘤的边缘与勾画的 ROI 的边缘最大程度地拟合。使用 ResNet50 网络中的卷积核作为特征提取器,分别提取 3 期图像上肾肿瘤的影像组学特征,并采用 Mann-Whitney *U* 检验进行特征的筛选。对于同一肾肿瘤,分别建立基于单期和 3 期 CT 图像的深度学习模型,并对各模型的预测效能进行外部验证。随后,将训练集中良、恶性肿瘤组的样本数按 3 种比例(1:1、1:2、1:3)进行设置,分别用于极限学习机(ELM)分类模型的训练,建立基于多期 CT 图像的 3 种深度学习模型,并对模型进行外部验证。采用 AUC 曲线评估深度学习模型对良恶性肾肿瘤的鉴别诊断效能,采用综合判别改善指数(IDI)评估模型预测能力的改善情况。**结果:**基于多期 CT 图像的预测模型预测恶性肿瘤的 AUC(0.84)大于基于单期(平扫、皮髓质期和实质期)图像的 3 个 AUC(0.78、0.79、0.77)。良性与恶性肿瘤的样本数比例分别为 1:1、1:2 和 1:3 时,基于多期图像的预测模型的 AUC 分别为 0.85、0.84 和 0.86。基于多期图像的预测模型与基于单期图像的 3 个预测模型比较,IDI 值分别为 0.1215、0.1209 和 0.0094(*P* 均>0.05)。**结论:**基于多期 CT 图像的深度学习模型对肾癌与肾良性肿瘤具有较好的鉴别诊断效能,改变训练集中肾良恶性肿瘤的样本比例对预测模型的诊断效能无显著影响。

**【关键词】** 肾肿瘤;深度学习;影像组学;体层摄影术,X 线计算机

**【中图分类号】** R814.42;R737.11 **【文献标识码】** A **【文章编号】** 1000-0313(2023)04-0468-06

DOI:10.13609/j.cnki.1000-0313.2023.04.016

开放科学(资源服务)标识码(OSID):



**CT-based deep learning model for differentiating renal cell carcinoma from benign renal tumor** CHEN Mei-rong, ZHOU Tao, CHEN Xuan-xing, et al. Department of Radiology, Jiangmen Central Hospital of Guangdong Province, Guangdong 529000, China

**【Abstract】 Objective:** To investigate the value of a CT-based deep learning model for the differentiation of renal carcinoma and benign renal tumor. **Methods:** Clinical and three-phase [(precontrast phase, PCP), (cortical medullary phase, CMP), (nephrographic phase, NP)] abdominal CT imaging data of 798 patients (a total of 805 renal tumors) with pathologically proven RCCs and benign renal tumors between 2008 and 2020 were retrospectively collected, including 418 RCCs and 78 benign tumors from our institution, as the training dataset for model development and internal validation. Patients from two independent institutions and a public database (the Cancer Imaging Archive, TCIA) were included as the external dataset for individual testing, including 262 RCCs and 47 benign tumors. Among the three phases, the phase in which the margin of the tumor was clearly showed was selected, and then on the slice of the tumor with maximum diameter the its upper and lower slices, regions of interest (ROIs) in the tumor was delineated using ITK-SNAP (Version 3.6.0) software, and then

作者单位:529000 广东江门,江门市中心医院放射科(陈美容、周涛、陈炫幸、钟向阳);529500 广东阳江,阳江市人民医院放射科(陈智慧);541000 广西桂林,桂林航天工业学院(冯宝、陈业航、徐坤财)

作者简介:陈美容(1978—),女,广东阳江人,副主任医师,主要从事腹部影像学诊断工作。

通讯作者:周涛, E-mail: zt18144851097@163.com

space adjustment technique of the software was used to maximize the fit of the CT images from other two phases with the delineated tumor region. The convolution kernel in ResNet50 network was used as the feature extractor to extract the features from the three phases CT images of renal tumor. The Mann-Whitney *U*-test was used for feature selection. Deep learning models based on single-phase and multi-phases CT images were built for the same renal tumor, respectively, and were validated with external data. Then, the sample numbers of benign and malignant tumor groups were set according to three ratios (1 : 1, 1 : 2, 1 : 3) respectively, which were used for the training of extreme learning machine (ELM) classification model. The three deep learning models based on three phases CT images were established, and the prediction models were externally validated. The AUC curve was used to evaluate the differential diagnosis efficiency of the deep learning model for benign and malignant renal tumors, and the Integrated Discrimination Improvement (IDI) was used to evaluate the improvement of the predictive ability of the model. **Results:** The prediction model based on the three phase CT images achieved a higher AUC of 0.84 than those based on single phase CT images (0.78, 0.79, 0.77). When the sample size ratio of benign and malignant tumors were 1 : 1, 1 : 2 and 1 : 3, the AUC of the prediction models based on the three phases CT images were 0.85, 0.84 and 0.86, respectively. Compared with the model based on multiphases CT images, the IDI values of the three models based on single phase CT images were 0.1215, 0.1209 and 0.0094, respectively, and there was no significant difference (all  $P > 0.05$ ). **Conclusion:** The deep learning model based on multi-phase CT images has better diagnostic performance for differentiating renal carcinoma from benign renal tumor. Changes of the proportion of benign and malignant renal tumor samples in the training dataset have no significant effect on the diagnostic performance of the prediction model.

**【Key words】** Renal neoplasms; Deep learning; Radiomics; Tomography, X-ray computed

近年来,随着 CT 检查的广泛临床应用,对肾脏肿瘤的检出率也不断提高<sup>[1-2]</sup>。但是,由于部分肾脏肿瘤的术前影像诊断不够准确,良性肾肿瘤患者接受不必要手术的人数也随之增加<sup>[3]</sup>。小肾肿瘤( $\leq 4$  cm)约占肾细胞癌的 85%,约占良性病变的 20%~40%,如血管平滑肌脂肪瘤和嗜酸细胞腺瘤<sup>[4]</sup>。在 CT 图像上,当发现病灶内有低密度的脂肪组织时,并不难做出诊断,但对乏脂型 AML 的准确诊断仍具有挑战性。对肾肿瘤的准确诊断是影响患者生存和治疗方式的最重要的预后因素。目前,所有无显微镜下脂肪的实性强化肾肿块,在其性质得到其它方法的证实之前,都被认为是恶性的,而且透明细胞肾细胞癌与嗜酸细胞腺瘤之间影像学特征存在重叠,单纯依靠影像学方法无法准确诊断肾肿瘤的良、恶性。通过穿刺活检或手术可取得组织的病理学信息,但穿刺活检为有创性检查,取材比较局限,而且存在发生肿瘤种植转移及出血等风险<sup>[5]</sup>。因此,采用可靠的无创性方法来诊断肾脏肿瘤对实现个体化精准医疗具有重要临床意义。影像组学作为一种新兴的诊断技术和肿瘤辅助检测手段,可以高通量的提取图像上的数字化结构特征,再基于大数据分析,提取有价值的特征<sup>[6]</sup>。目前,基于 CT 图像的影像组学研究已经在腹部病变中广泛开展<sup>[7]</sup>。本研究拟建立基于 CT 图像的深度学习(deep learning,

DL)模型,用于常见肾癌与肾良性肿瘤的鉴别,并探讨训练集中不同比例肾良、恶性肿瘤样本数对深度学习模型预测效能的影响。

## 材料与方 法

### 1. 一般资料

回顾性搜集 2008—2020 年本院及外院有病理结果的 854 例肾肿瘤患者的临床和影像学资料。纳入标准:①术前标准三期 CT 扫描资料完整且图像质量达到本研究要求;②经随访获得完整的病理和临床资料。排除标准:①肿瘤破裂出血,且瘤周有明显渗出;②CT 图像上可见肿瘤内有明确的脂肪成分;③CT 图像显示肿瘤完全由囊性成分组成;④伴有可能影响图像分析的其它肾疾病;⑤CT 检查前接受了放化疗等抗肿瘤治疗。

最终纳入符合研究要取得 798 例患者共 805 个肾肿瘤(其中 7 例患者有 2 个肾肿瘤病灶)。其中,本院有 491 例共 496 个病灶(肾癌 418 个;肾良性肿瘤 78 个),作为训练集;外院有 307 例共 309 个病灶(肾癌 262 个;肾良性肿瘤 47 个),作为外部验证集。肾癌的病理类型包括透明细胞癌、嫌色细胞癌和乳头状细胞癌;肾良性肿瘤的病理类型包括乏脂型血管平滑肌脂肪瘤和嗜酸细胞腺瘤。本研究经医学伦理委员会批

准,所有患者免签知情同意书。

## 2. 检查方法

CT 检查设备包括 Siemens Somatom sensation 16 螺旋 CT 机、Canon Aquilion 64 螺旋 CT 机和 Siemens Somatom Force 双源 CT 机,常规行平扫(pre-contrast phase, PCP)、皮髓质期(cortical medullary phase, CMP)和实质期(nephrographic phase, NP)增强扫描,扫描参数:120 kV, 200~350 mAs,层厚 3.0 mm,层间距 3.0 mm,矩阵 512×512。以高压注射器经静脉注入对比剂碘普罗胺,剂量 2.0 mL/kg,总量 70~100 mL,注射流率 3.0 mL/s。

## 3. 图像分割和预处理

所有 CT 图像以原始尺寸和分辨率的 DICOM 格式自 PACS 下载至 MRIcroGL 软件(<https://www.mccauslandcenter.sc.edu/mricrogl/>)中,将 DICOM 格式文件转换为 NIFTI 格式,然后使用 ITK-SNAP (Version 3.6.0)软件对肿瘤图像分割,并以 NIFTI 格式储存<sup>[8]</sup>。在 3 期 CT 图像中选择肿瘤边缘显示较清楚的一期图像,选取肿瘤最大层面及其上、下相邻层面,沿肿瘤边缘手动勾画 ROI,通过 ITK-SNAP 的空间调整技术,使另外两期 CT 图像上肿瘤的位置与勾画的 ROI 最大程度地拟合,使 3 期 CT 图像上的 ROI 相互匹配(图 1)。图像的 ROI 勾画过程由 3 位分别有 5、7 和 10 年腹部诊断经验的放射科医师独立完成。

为了提高图像质量及稳定性,本研究在训练模型之前对图像进行了预处理,包括归一化、像素重采样和

通道合并。规一化旨在管理数据权重的不一致性;像素重采样可以提高模态的精度和总体参数估计,包括上采样和下采样;在进行通道合并时,首先将 ITK-SNAP 软件中已完成肿瘤分割的图像导出为 .png 格式,计算病灶的中心点坐标,生成以整个病灶大小为单位的正方形框。然后,将框选好的病灶的坐标值应用到 PCP、CMP 和 NP 序列中,以该坐标选定 3 个序列的图片,同样得到以病灶大小为单位的正方体,并将其归一化为 224×224 大小的图片。最后,将归一化的图片进行重采样并将其灰度化为单通道,并将得到的单通道的图片以相邻的 3 张图片进行 3 通道合并,同时归一化到 224×224 大小。

## 4. DL 模型的建立

DL 模型的训练:使用 ResNet50 网络对平扫、皮髓质期和实质期各单期及三期 CT 图像分别进行 DL 模型的训练。模型训练参数:输入模型的 batch 为 32,学习率为 0.01,优化算法为随机梯度下降算法,优化器动量为 0.9,采用交叉熵损失函数来反映目标域期望值之间的损失,一共训练 150 轮次。

特征的提取:使用 ResNet50 网络中的卷积核作为特征提取器,分别提取平扫、皮髓质期和实质期三期图像上肾肿瘤的影像组学特征,每期图像共提取了 13632 个影像组学特征。为了降低特征冗余,采用 Mann-Whitney *U* 检验对良性与恶性病变进行特征筛选。

极限学习机分类模型的构建:极限学习机(ex-

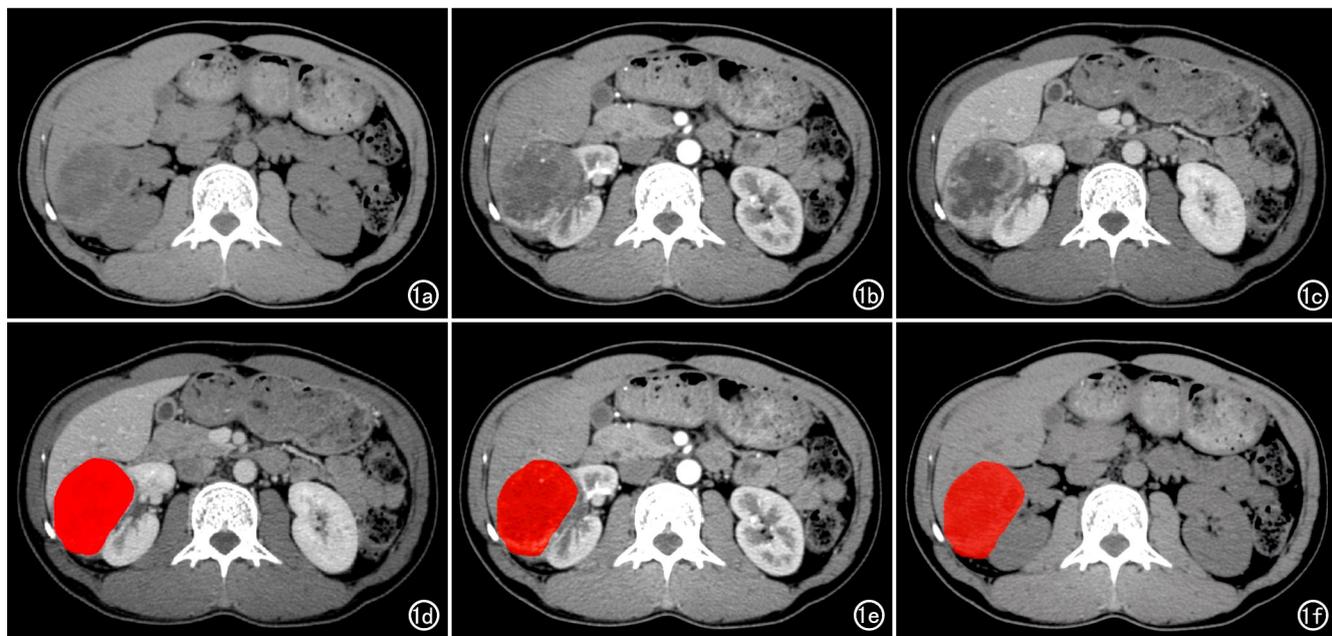


图 1 ccRCC 三期 CT 图像上勾画 ROI 示意图。a)平扫 CT 图像,右肾低密度肿块,密度不均匀;b)增强皮髓质期图像,右肾肿块呈不均匀强化,瘤内坏死区无明显强化;c)增强实质期图像,显示右肾肿块强化减退;d)勾画 ROI 后的实质期图像;e)将图 d 上勾画的 ROI 复制到皮髓质期图像上;f)将图 d 上勾画的 ROI 复制到平扫图像上。

trema learning machine, ELM) 或超限学习机, 是一类基于前馈神经网络 (feed-forward neuron network, FNN) 构建的机器学习系统或方法。传统的 ELM 具有单隐含层, 对比其它的浅层学习系统, 如支持向量机 (Support Vector Machine, SVM) 和单层感知机 (single layer perceptron), 在学习速率和泛化能力方面, 具有一定的优势<sup>[9]</sup>。本研究中的总样本由 125 个肾良性肿瘤和 680 个肾癌组成, 训练集中肾良性肿瘤 78 个、肾癌 418 个, 肾恶性肿瘤占比较大。为了探讨训练集中不同比例肾良、恶性肿瘤对深度学习模型预测效能的影响, 在极限学习机分类模型的构建时, 将训练组中的肾良性肿瘤与肾癌的数量按 1:1、1:2、1:3 的不同比例分别用于分类模型的训练, 并对模型进行外部验证。

### 5. 数据统计分析

本研究中的数据统计分析采用 Python 3.6 和 R 语言 3.4.0, 以  $P < 0.05$  为差异有统计学意义。采用两独立样本  $t$  检验或秩和检验对良、恶性肾肿瘤组的一般临床资料进行比较。模型评估指标包括特异度、敏感度、阳性预测值 (PPV)、阴性预测值 (NPV)、符合率、受试者操作特征曲线下面积 (AUC)、综合判别改善指数 (integrated discrimination improvement, IDI) 和净重新分类指数 (net reclassification improvement, NRI)。

## 结果

### 1. 一般临床资料

入组患者的一般临床资料见表 1。在训练集和验证集中, 肾癌组患者的平均年龄均大于肾良性肿瘤组 ( $P < 0.05$ ), 而良、恶性组之间性别构成的差异均无统计学意义 ( $P > 0.05$ )。

### 2. 深度学习预测模型的诊断效能

基于各单期 (平扫、皮髓质期和实质期) 及联合 3 期 CT 图像分别建立预测肾肿瘤性质的 DL 模型, 在外部验证集中进行验证, 各个 DL 预测模型的诊断效能指标值见表 2。结果显示, 基于三期 CT 图像的 DL 预测模型的 AUC 值 (0.84) 和特异度 (0.80) 最高。对各模型的 AUC 进行比较, DeLong 检验结果显示, 4 个模型的 AUC 之间差异无统计学意义 ( $P$  值为 0.227~0.900)。

与基于单期 CT 图像的 3 个 DL 预测模型相比,

基于三期 CT 图像的 DL 预测模型的 IDI 和 NRI 值均大于 0 (表 3), 表明基于三期图像的预测模型的预测能力较单期有所改善。

表 2 基于不同期相 CT 图像建立的 DL 模型预测肾良恶性肿瘤的效能

CT 扫描期相	AUC	敏感度	特异度	符合率	PPV	NPV
肾皮髓质期	0.78	0.77	0.53	0.73	0.90	0.29
肾实质期	0.79	0.79	0.70	0.78	0.93	0.38
平扫	0.77	0.65	0.74	0.66	0.93	0.27
三期联合	0.84	0.75	0.80	0.76	0.95	0.36

表 3 基于三期分别与基于各单期 CT 图像的预测模型性能的比较

组间比较	IDI	$P$ 值	NRI	$P$ 值
三期 vs. PCP	0.1215	0.0009	0.2613	0.0065
三期 vs. CMP	0.1209	0.0012	0.1860	0.0218
三期 vs. NP	0.0913	0.0094	0.1626	0.0476

### 3. 不同比例肾良恶性肿瘤样本数的预测模型的效能

分别按 1:1、1:2、1:3 训练 DL 模型, 并进行独立外部验证, 各个 DL 预测模型的诊断效能指标值见表 4~7。结果显示, 当样本中良性肾肿瘤数与肾癌数的比例是 1:3 时, DL 模型预测恶性肿瘤的 AUC 值 (=0.86) 最大, 符合率为 0.80。与训练集原有样本 (不改变样本比例) 基于三期 CT 图像的模型比较, 改变良恶性样本数比例的这 3 个模型的 IDI 分别为 0.013、-0.015 和 0.028, 其中 2 个模型的整体鉴别效能稍有提高, 但差异均无统计学意义 ( $P > 0.05$ )。

表 4 肾良、恶性肿瘤数的比例为 1:1 时 DL 模型预测恶性肿瘤的效能

CT 扫描期相	AUC	敏感度	特异度	符合率	PPV	NPV
肾皮髓质期	0.79	0.64	0.76	0.66	0.93	0.28
肾实质期	0.78	0.63	0.80	0.66	0.94	0.28
平扫	0.78	0.51	0.85	0.56	0.95	0.23
三期联合	0.85	0.80	0.74	0.79	0.94	0.41

表 5 肾良、恶性肿瘤数的比例为 1:2 时 DL 模型预测恶性肿瘤的效能

CT 扫描期相	AUC	敏感度	特异度	符合率	PPV	NPV
肾皮髓质期	0.77	0.63	0.78	0.66	0.94	0.28
肾实质期	0.80	0.62	0.82	0.65	0.95	0.28
平扫	0.80	0.63	0.78	0.66	0.94	0.28
三期联合	0.84	0.73	0.78	0.74	0.95	0.34

表 6 肾良、恶性肿瘤数的比例为 1:3 时 DL 模型预测恶性肿瘤的效能

CT 扫描期相	AUC	敏感度	特异度	符合率	PPV	NPV
肾皮髓质期	0.81	0.79	0.63	0.77	0.92	0.35
肾实质期	0.83	0.70	0.87	0.73	0.96	0.35
平扫	0.82	0.70	0.74	0.71	0.93	0.31
三期	0.86	0.82	0.72	0.80	0.94	0.41

表 1 入组患者的一般临床资料

指标	训练集				验证集			
	良性肿瘤组 (77 例)	肾癌组 (414 例)	$t/\chi^2$ 值	$P$ 值	良性肿瘤组 (46 例)	肾癌组 (216 例)	$t/\chi^2$ 值	$P$ 值
年龄/岁	50.77±13.21	54.45±11.98	2.439	0.015	50.52±13.60	57.37±12.22	3.444	0.001
性别比(男/女)	16/61	82/332	0.038	0.845	10/36	52/209	0.080	0.777

表 7 改变训练集中肾良、恶性肿瘤比例时 DL 模型的 IDI 和 NRI

比例 <sup>#</sup>	IDI(95%CI)	P 值	NRI(95%CI)	P 值
1 : 1	0.013(-0.086~0.087)	0.989	0.076(-0.233~0.385)	0.612
1 : 2	-0.015(-0.088~0.058)	0.690	0.087(-0.223~0.396)	0.583
1 : 3	0.028(-0.056~0.113)	0.500	0.210(-0.097~0.517)	0.181

注：<sup>#</sup>肾良、恶性肿瘤样本数的比例。

## 讨 论

由于目前影像诊断方法仍存在局限性,在肾肿瘤的术前诊断中仍存在很大概率的误判,约 30% 的良性肾肿瘤患者接受了不必要的部分或根治性肾切除术<sup>[10]</sup>,对患者身心及经济造成很大影响。因此,寻找一种准确可靠的术前鉴别肾恶性肿瘤的方法具有重要的临床意义。既往研究已证实影像组学分析鉴别肾脏良恶性肿瘤的可行性,如王平等<sup>[11]</sup>发现基于 CT 增强图像的影像组学模型在鉴别肾透明细胞癌与非透明细胞癌方面具有良好的诊断效能;Lee 等<sup>[12]</sup>采用深度学习(AlexNet)对肾细胞癌和肾血管平滑肌脂肪瘤进行分类,符合率可达 76.6%。基于深度学习的特征分析与手工提取的特征分析进行比较,前者更优秀。

在本研究中,基于多期 CT 图像的深度学习模型鉴别肾癌与良性肾肿瘤的效能优于基于单期 CT 图像的模型,AUC 值为 0.84。在既往研究中,Cui 等<sup>[13]</sup>分别基于肾肿瘤的 2D(单层)/3D(整个肿瘤多层)ROI 及 CT 平扫、肾皮髓质期、肾实质期及三期图像建立了支持向量机分类器,发现基于肿瘤 3D-ROI 的多期图像建立的预测模型对区分乏脂型的肾血管平滑肌脂肪瘤与肾癌具有更好的效能,在区分乏脂型血管平滑肌脂肪瘤与肾透明细胞癌时 AUC 为 0.97,在区分乏脂型血管平滑肌脂肪瘤与全部肾癌时 AUC 为 0.96,与本研究结果基本一致。究其原因,可能是肿瘤多期 CT 图像比单期 CT 图像为影像组学模型提供更准确和更全面的肿瘤信息,在仅分析单期或单层 CT 图像特征时,模型可能会错过部分肿瘤特征,如微量脂肪、出血、钙化及肿瘤的血供情况等。因此,基于多期 CT 图像的深度学习模型诊断效能稳定性及准确度更高。但也有部分学者,如鲍远照等<sup>[14]</sup>发现 CT 单期模型如皮髓质期、实质期及排泄期与整合模型相比较,对肾嫌色细胞癌与嗜酸细胞腺瘤鉴别的预测性能差异无统计学意义。

自然发病率下,肾癌发病率高于良性肾肿瘤,肾癌比良性肾肿瘤更易出现内部囊变、坏死和出血,样本中良恶性肿瘤的分布不均可能会对深度学习模型的诊断效能产生影响。本研究通过不同比例的良恶性肾肿瘤样本分别建立深度学习模型,探讨此因素对模型诊断效能稳定性的影响。当训练组中肾良恶性肿瘤比例为

1 : 3 时,在外部验证集中,预测模型的 AUC 为 0.86,符合率为 0.80,整体鉴别能力稍有提高,IDI 为 0.028,与自然发病率下肾良恶性肿瘤的比例(入组训练集良恶性肿瘤 78 : 418)无显著差异。综合分析各模型的预测效能,IDI 值的差距不大( $P > 0.05$ ),说明样本中肾良恶性肿瘤的比例变化并不会引起深度学习算法的偏向性,模型效能具有良好的稳定性,可适用于放射科医师的日常诊断工作。

相较于机器学习,深度学习在某些方面具有一定优势。机器学习是通过输入数据映射到目标,而这一过程是通过观察许多输入和目标的示例来完成的,最终的结果将会受到输入数据质量的影响;另外,也可能有过度拟合训练集数据的风险<sup>[15]</sup>。深度学习是应用神经网络架构构建的算法,卷积神经网络(convolutional neural network,CNN)是一类包含卷积计算且具有深度结构的前馈神经网络,是深度学习的代表算法之一。CNN 可以自动学习大量高维度特征信息,而这些在传统图像分析是无法识别的,这在建立医学影像及其解析间的复杂关系模型中有着非常重要的作用<sup>[16]</sup>,也已经在多项相关研究中取得重大进展<sup>[16-20]</sup>。本研究使用 ResNet50,是 CNN 的一种,其包含了 49 个卷积层和一个全连接层,可以解决深层网络中梯度弥散和精度下降的问题,使网络能够越来越深,从而保证精度,并进一步控制速度。在各种医疗领域的数据库中,影像学的数据占比较高,具有易获取和格式标准的特点,是筛查肿瘤、诊断肿瘤、预测疗效及评价预后的主要依据之一<sup>[21]</sup>,而影像学与人工智能的结合在以上方面具有较好的前景。

本研究中的深度学习模型对鉴别肾癌与肾良性肿瘤有良好的诊断效能,对帮助肾肿瘤患者选择合理的临床诊疗方案提供一定价值。但本研究也存在一些局限性:首先,研究对象中肿瘤的病理类型的范围较大,尚未能实现对肿瘤亚型的分类;其次,由于测试集的样本量较少,未来我们还需要多中心和大样本地验证本研究中模型的效能。

## 参考文献:

- [1] Laguna MP, Algaba F, Cadeddu J, et al. Current patterns of presentation and treatment of renal masses: a clinical research office of the endourological society prospective study[J/OL]. J Endourol, 2014, 7: e861-e870. DOI: 10.1089/end.2013.0724.
- [2] Ljungberg B, Bensalah K, Canfield S, et al. EAU guidelines on re-

- nal cell carcinoma: 2014 update[J/OL]. *Eur Urol*, 2015, 67(5): e913-e924. DOI: 10.1016/J.EURURO.2015.01.005.
- [3] Murphy AM, Buck AM, Benson MC, et al. Increasing detection rate of benign renal tumors: evaluation of factors predicting for benign tumor histologic features during past two decades[J/OL]. *Urology*, 2009, 73(6): e1293-e1299. DOI: 10.1016/j.urology.2008.12.072.
- [4] Ball MW, Bezerra SM, Gorin MA, et al. Grade heterogeneity in small renal masses: potential implications for renal mass biopsy[J/OL]. *J Urol*, 2015, 193(1): e36-e40. DOI: 10.1016/j.juro.2014.06.067.
- [5] 曹新玥, 朱美霖, 印隆林, 等. CT 影像组学预测肾透明细胞癌病理分级: Meta 分析[J]. *中国医学影像技术*, 2022, 38(8): 1197-1202.
- [6] 刘再毅, 梁长虹. 促进影像组学的转化研究[J]. *中国医学影像技术*, 2017, 33(12): 1765-1767.
- [7] 彭洋, 杨阳, 孟晓岩, 等. RSNA2020 腹部影像学[J]. *放射学实践*, 2021, 36(3): 310-315.
- [8] 赵宝连, 萧毅. 肾癌影像组学研究现状及展望[J]. *放射学实践*, 2020, 35(8): 1068-1072.
- [9] Huang GB, Zhu QY, Siew CK. Extreme learning machine: theory and applications[J]. *Neurocomputing*, 2005, 70(1-3): 489-501.
- [10] Baghdadi A, Aldhaam NA, Elsayed AS, et al. Automated differentiation of benign renal oncocytoma and chromophobe renal cell carcinoma on computed tomography using deep learning[J]. *BJU Int*, 2020, 125(4): 553-560.
- [11] 王平, 裴旭, 殷小平, 等. 基于增强 CT 影像组学模型鉴别肾透明细胞癌与非透明细胞癌[J]. *中国医学影技术*, 2019, 35(11): 1689-1692.
- [12] Li ZC, Zhai G, Zhang J, et al. Differentiation of clear cell and non-clear cell renal cell carcinomas by all-relevant radiomics features from multiphase CT: a VHL mutation perspective[J]. *Eur Radiol*, 2019, 29(8): 3996-4007.
- [13] Cui EM, Lin F, Li Q, et al. Differentiation of renal angiomyolipoma without visible fat from renal cell carcinoma by machine learning based on whole-tumor computed tomography texture features[J]. *Acta Radiol*, 2019, 60(11): 1543-1552.
- [14] 鲍远照, 葛亚琼, 程琦, 等. 基于增强 CT 影像组学在鉴别肾嫌色细胞癌与肾嗜酸细胞腺瘤中的应用价值[J]. *放射学实践*, 2021, 36(2): 211-215.
- [15] Currie G, Hawk KE, Rohren E, et al. Machine learning and deep learning in medical imaging: intelligent imaging[J]. *J Med Imaging Radiat Sci*, 2019, 50(4): 477-487.
- [16] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [17] Esteva A, Kuprel B, Novoa RA, et al. Dermatologist level classification of skin cancer with deep neural networks[J]. *Nature*, 2017, 542(7639): 115-118.
- [18] Ardila D, Kiraly AP, Bharadwa JS, et al. Author correction: end-to-end lung screening with three dimensional deep learning on low-dose chest computed tomography[J/OL]. *Nat Med*, 2019, 25(8): e954-e961. DOI: 10.1038/s41591-019-0536-x.
- [19] Xu Y, Hosny A, Zeleznik R, et al. Deep learning predicts lung cancer treatment response from serial medical imaging[J]. *Clin Cancer Res*, 2019, 25(11): 3266-3275.
- [20] Liu K, Li Q, Ma J, et al. Evaluating a fully automated pulmonary nodule detection approach and its impact on radiologist performance[J/OL]. *Radio Artif Intell*, 2019, 1(3): e180084. DOI: 10.1148/ryai.2019180084.
- [21] 辛仲宏, 雷军强, 郭城, 等. 深度学习用于宫颈癌诊疗研究进展[J]. *中国医学影像技术*, 2022, 38(5): 779-782.

(收稿日期: 2022-12-12 修回日期: 2023-03-14)