

DOI:10.3969/j.issn.1005-202X.2024.07.017

医学人工智能

基于少样本学习算法的结直肠粘膜下肿瘤和息肉内镜图像分类系统

伍亚辉^{1,2}, 朱世祺¹, 吴宇东³, 张儒发⁴, 朱锦舟¹

1. 苏州大学附属第一医院消化内科, 江苏 苏州 215006; 2. 同济大学附属东方医院儿内科, 上海 200120; 3. 苏州市相城区阳澄湖人民医院内科, 江苏 苏州 215138; 4. 苏州大学附属常熟医院消化内科, 江苏 苏州 215500

【摘要】目的:为解决难以收集足够结直肠粘膜下肿瘤样本训练深度学习模型的问题,基于少样本学习算法构建了粘膜下肿瘤和息肉内镜图像分类模型。**方法:**收集多中心来源的结直肠粘膜下肿瘤内镜图像共172张,包括结直肠脂肪瘤(CRLs)、神经内分泌肿瘤(NETs)、锯齿状病变及息肉、传统腺瘤各43张。基于这些内镜图像构建支持集和查询集,在ImageNet和食管内镜图像上二次预训练的ResNet50提取图像特征,计算欧氏距离,使用K近邻算法进行分类。与原始模型和低、高年资内镜医师进行对比,评估少样本学习模型的性能。**结果:**提出的少样本学习模型分类准确率、宏曲线下面积和Macro F1值分别为0.831、0.925和0.831,诊断CRLs的准确率和F1值分别为0.925和0.850,诊断NETs的准确率和F1值分别为0.906和0.805。同时,该模型具有较好的分类一致性(Kappa=0.775)和可解释性。**结论:**构建的少样本学习模型在区分CRLs、NETs、锯齿状病变及息肉、传统腺瘤内镜图像上表现出优异性能,可用于辅助内镜下识别结直肠粘膜下肿瘤。

【关键词】少样本学习; 结直肠粘膜下肿瘤; 结直肠息肉; 消化内镜图像; 深度学习

【中图分类号】R318; R574

【文献标志码】A

【文章编号】1005-202X(2024)07-0897-08

Development of a few-shot learning based model for the classification of colorectal submucosal tumors and polyps on endoscopic images

WU Yahui^{1,2}, ZHU Shiqi¹, WU Yudong³, ZHANG Rufa⁴, ZHU Jinzhou¹

1. Department of Gastroenterology, the First Affiliated Hospital of Soochow University, Suzhou 215006, China; 2. Department of Pediatric Internal Medicine, Shanghai East Hospital, Tongji University, Shanghai 200120, China; 3. Department of Internal Medicine, Suzhou Xiangcheng District Yangcheng Lake People's Hospital, Suzhou 215138, China; 4. Department of Gastroenterology, Changshu Hospital Affiliated to Soochow University, Suzhou 215500, China

Abstract: Objective To address the difficulty in collecting sufficient endoscopic images of colorectal submucosal tumors for traditional deep learning model training, a few-shot learning based model (FSL model) is proposed for classifying colorectal submucosal tumors and polyps on endoscopic images. **Methods** A total of 172 endoscopic images of colorectal submucosal tumors were collected from different centers, including 43 each of colorectal lipomas (CRLs), neuroendocrine tumors (NETs), serrated lesions and polyps (SLPs), and traditional adenomas. A support set and a query set were constructed using these endoscopic images. ResNet50 which was pre-trained on ImageNet and esophageal endoscopic images was used to extract image features. Subsequently, K-nearest neighbors algorithm was used for classification based on the calculated Euclidean distance. The classification performance of FSL model was evaluated through the comparison with the original model and endoscopists. **Results** FSL model had a 4-class classification accuracy of 0.831, Macro AUC of 0.925, Macro F1-score of 0.831; moreover, the proposed model achieved diagnostic accuracies of 0.925 and 0.906 for CRLs and NETs, with F1 score of 0.850 and 0.805. Additionally, the proposed model exhibited high classification consistency (Kappa=0.775) and interpretability. **Conclusion** The established FSL model performs well in distinguishing CRLs, NETs, SLPs and traditional adenomas on endoscopic images, indicating its potential utility in assisting the identification of colorectal submucosal tumors under endoscopy.

Keywords: few-shot learning; colorectal submucosal tumor; colorectal polyp; endoscopic image; deep learning

【收稿日期】2024-04-10

【基金项目】国家自然科学基金(82000540); 肝脾外科教育部重点实验室开放基金(GPKF202304); 苏州市科教兴卫项目(KJXW2019001); 苏州大学医学部学生课外科研项目(2021YXBKWKY050)

【作者简介】伍亚辉, 硕士研究生, 主任医师, 研究方向: 人工智能在消化病、儿内科中的应用, E-mail: wuyahui8@163.com

【通信作者】朱锦舟, 博士, 副主任医师, 硕士生导师, 研究方向: 人工智能在消化病中的应用, E-mail: jzzhu@zju.edu.cn

前言

胃肠道粘膜下肿瘤(Submucosal Tumor, SMT)是源于胃肠道黏膜肌层、黏膜下层或固有肌层的隆起性病变,包括胃肠道间质瘤、平滑肌瘤神经鞘瘤、神经内分泌肿瘤(Neuroendocrine Tumors, NETs)、脂肪瘤和异位胰腺^[1]。相比于胃肠道息肉,SMT多数情况下没有明显临床症状,发病率和检出率较低,平均每300例内镜检查中才能发现1例SMT^[2]。近年来,随着早癌筛查,内镜检查的普及和超声内镜技术的广泛开展,SMT的检出率也在不断上升^[3]。SMT在消化道各部位的类型不均衡,在下消化道SMT中,以结直肠脂肪瘤(Colorectal Lipomas, CRLs)和NETs为主^[4-5]。NETs是起源于神经内分泌细胞的高分化神经内分泌肿瘤,大多数为G1期肿瘤,内镜下表现为小的、半球状或结节状的粘膜下隆起,表面光滑呈黄白色,可见清晰的毛细血管^[6]。CRLs是一种由成熟脂肪细胞组成的良性肿瘤,内镜下表现与NETs相似,可出现“枕头征”^[7]。而作为结肠镜检查中最常见的息肉,其在内镜下表现为与周围粘膜清晰的边界,有腺管开口,不同的息肉分型有着不同的镜下特征。内镜下的初步判断对于后续检查和治疗方式的选择至关重要,可指导内镜医师开展进一步的超声内镜检查或者活检明确病变性质。然而,对于直径小于1 cm,边界清晰,呈息肉样隆起的结直肠SMT,在内镜下难以与息肉进行鉴别。同时,随着结肠镜检查数量的增加和阅片时间的减少,大量的内镜图像使内镜医师疲惫不堪,导致SMT的误诊率逐步升高。

因此,有必要提供一种客观的诊断技术来区分SMT和息肉。

深度学习在医学图像分析中表现出色,已广泛应用于消化内镜图像的识别、分类和分割任务^[8]。但是对于传统的深度学习,识别结直肠SMT的内镜图像是一件具有挑战性的任务,例如CRLs和NETs的发病率较低,缺乏足够的标记数据用于训练,导致模型欠拟合。此外,CRLs、NETs组内存在差异,与息肉组间相似度高,增加了传统深度学习模型学习和提取特征的难度。为了解决上述问题,笔者采用了少样本学习算法。与传统的深度学习不同,少样本学习能够基于先前经验中的知识快速适应,从少量观察中学习新的概念,并实现对未知样本的识别和分类^[9]。同时,为了减少组内差异和组间相似对分类性能的影响,在少样本学习的框架中融合度量学习和迁移学习算法^[10-11]。本研究提出了一种基于迁移学习和度量学习的小样本学习模型,用于CRLs、NETs、传统腺瘤(Adenomas)和锯齿状病变及息肉(Serrated lesions and polyps, SLPs)的四分类任务,实现对结直肠SMT和息肉的分类。

1 资料与方法

研究的具体流程如图1所示,包括内镜图像的收集,基于迁移学习、度量学习的少样本模型的建立,模型四分类性能评价和模型可视化解释。少样本模型的建立和可视化解释基于Python 3.9版本的开源TensorFlow 2.8框架实现;分类性能通过R语言4.2版本计算。

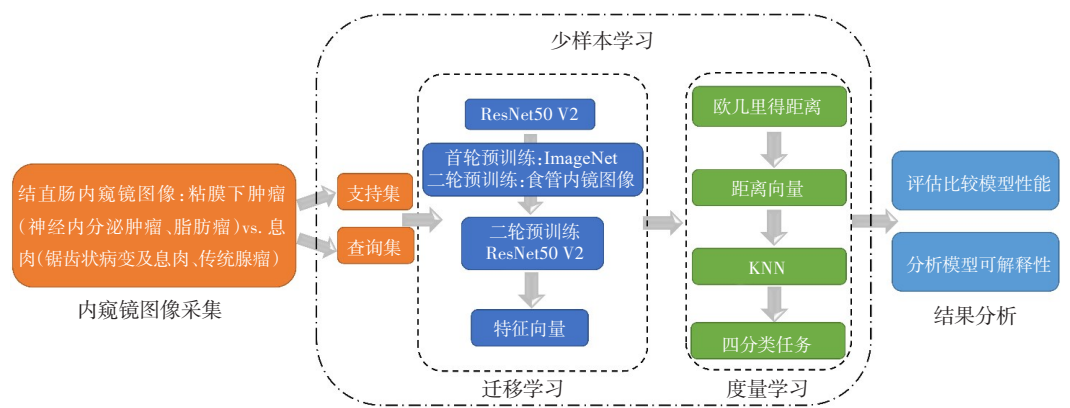


图1 四分类少样本学习的研究流程图
Figure 1 Flowchart of the few-shot learning for 4-class classification

1.1 一般资料

本研究是一项多中心回顾性研究,共纳入苏州大学附属第一医院、常熟市第一医院和阳澄湖人民

医院内镜中心的172张结肠镜白光图像。其中,CRLs、NETs、传统腺瘤和SLPs内镜图像各43张。此外,还纳入苏州大学附属第一医院内镜中心1512张

食管内镜白光图像,包括429张正常食管图像,489张早期食管癌图像和594张进展期食管癌图像。这些食管内镜图像以8:2的比例被随机划分为训练集和测试集,用于二次预训练。

1.2 图像预处理

由两名高年资内镜医师和一名高年资病理医师对172张内镜图像明确诊断,其中NETs、传统腺瘤和SLPs的诊断均由病理结果获得,CRLs的诊断由超声内镜或病理结果获得。所有结肠镜图像统一缩放至331 mm×331 mm大小,并以RGB三通道格式保存。

1.3 少样本学习模型的建立

1.3.1 支持集和查询集的建立

少样本学习模型是一

种有监督的深度学习模型,由用于训练的支持集(Support Set)和用于测试的查询集(Query Set)构成。支持集包括N个基类,每个基类含有K个标记样本,即N-way K-shot。查询集由未标记的样本构成,确保支持集和查询集中样本无重复。该模型通过学习预训练模型提供的先验知识,根据支持集中已标记样本将查询集中的未标记样本进行分类^[12]。

本研究中,支持集包括4个基类(CRLs、NETs、传统腺瘤和SLPs),每个基类包含3张内镜图像,因此被命名为4-way 3-shot的少样本学习模型。查询集由剩余的160张图像构成。食管内镜图像的收集划分、支持集和查询集的建立如图2所示。

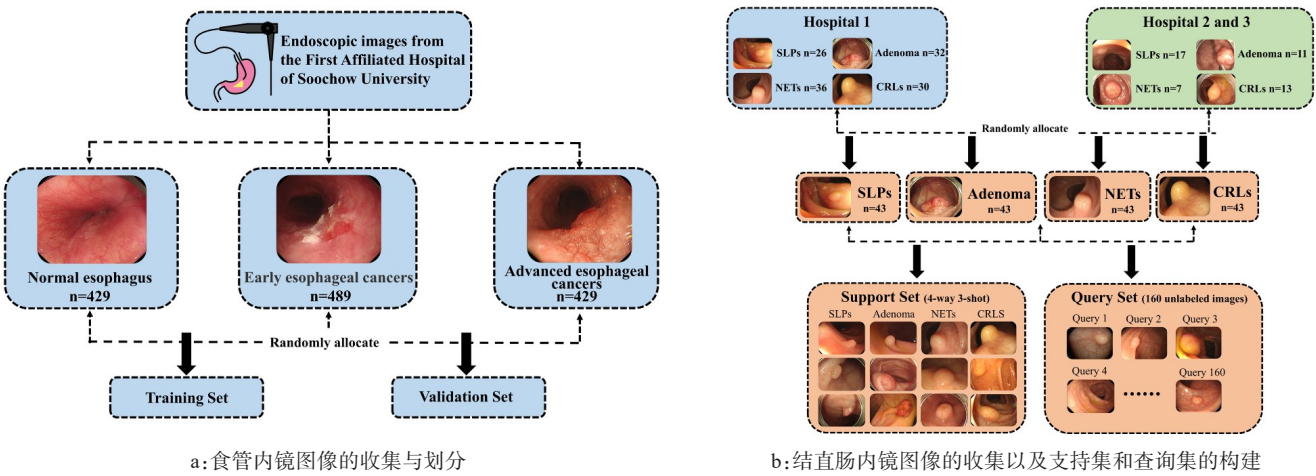


图2 内窥镜图像数据集的收集
Figure 2 Establishment of endoscopic image datasets

1.3.2 特征提取器 -ResNet50 V2 本研究选择ResNet50 V2作为图像特征提取器。ResNet被称为残差神经网络,通过引入计算机视觉领域的残差表征概念,改善因神经网络层数过多而出现模型退化的问题,减少过拟合现象的发生。ResNet50 V2通过调整ReLU和BN层的位置,结合3个残差模块,以捕获更多更复杂的特征^[13]。

1.3.3 迁移学习 目前医学领域的数据集样本量小,不适合从头训练深度学习模型,因此出现了迁移学习这一训练技术。模型在大的源数据集上进行预训练,学习特征提取的能力,然后迁移到目标数据集上使用。虽然迁移学习具有较好的性能,其在训练过程中也需要一定数量的参考样本进行权重微调,这在某些罕见的疾病中无法得到满足^[14-15],因此本研究创新性地采用了二次预训练。

(1) 首次和二次预训练。在ImageNet上对

ResNet50 V2进行首次预训练,获得用于提取特征的初始激活权重。考虑到本研究需要提取内镜图像的特征,对首次预训练模型的全连接层和输出层进行重塑,替换原有的全连接层为新的全连接层($n=3$,第一层节点数为1 024,第二层节点数为256,第三层节点数为64),替换原有的输出层($n=1\,000$)为新的输出层($n=3$),采用Softmax为激活函数。新的全连接层和输出层权重通过1 512张食管内镜图像的三分类任务进行二次预训练。预训练后的模型保留了首次预训练和二次预训练学习得到的模型框架和权重,能够更好地识别和提取内镜图像。

(2) 提取支持集和查询集中图像的特征。将二次预训练得到的ResNet50 V2迁移到支持集和查询集进行特征提取。锁定模型特征提取层和全连接层权重,移除输出层,将输出的64个特征合并为一个1×64的特征向量模型,采取Adam优化算法,学习率

为 0.000 1, batch size 设置为 32。支持集中的每张图像通过二次预训练的模型输出 1×64 的特征向量。12 张支持集图像命名为 $S_1 \sim S_{12}$, 对应的特征向量命名为 $R_{S_1} \sim R_{S_{12}}$ 。160 张查询集图像命名为 $Q_1 \sim Q_{160}$, 对应的特征向量命名为 $R_{Q_1} \sim R_{Q_{160}}$ 。迁移学习示意图如图 3 所示。

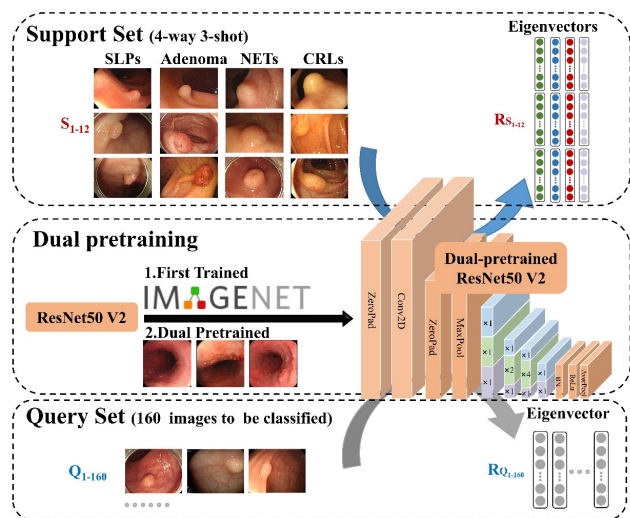


图3 运用迁移学习提取内镜图像的特征向量
Figure 3 Utilizing transfer learning to extract eigenvectors from endoscopic images

1.3.4 度量学习 度量学习旨在通过度量样本间的相似性实现分类任务, 它将输入图像的特征向量投射到具有距离信息的度量空间中, 使得组内样本间距离近, 组间样本距离远, 利用距离衡量相似性, 并最终通过相似性实现分类^[16]。欧式距离是最常见的度量单位, 可直观地体现样本间的绝对距离。K 近邻 (K-Nearest Neighbor, KNN) 算法作为一种非参数算法, 通过与未知样本近邻的 K 个已知样本类别判别该未知样本的种类^[17]。度量学习示意图见图 4。本研究采用欧氏距离度量支持集和查询集图像间的绝对距离, 对于每张查询集图像, 计算其与支持集图像间的 12 个距离, 提取这 12 个距离为该查询集图像的距离向量, 输入到 KNN 分类器中进行分类。

1.4 模型评价

根据查询集中 160 张内镜图像的分类结果评估少样本学习模型的分类能力。同时, 运用传统的 ResNet50 V2 模型、一名低年资内镜医师 (≤ 5 年内镜诊疗经验) 和一名高年资内镜医师 (≥ 15 年内镜诊疗经验) 分别对查询集图像进行分类, 以进一步评估少样本模型的分类能力。采用混淆矩阵呈现图像的分类结果; 采用准确率 (Accuracy, ACC)、召回率 (Recall)、特异性 (Specificity)、精确性 (Precision) 和 F1 值 (F1-score) 评估每个类别的分类性能; 采用

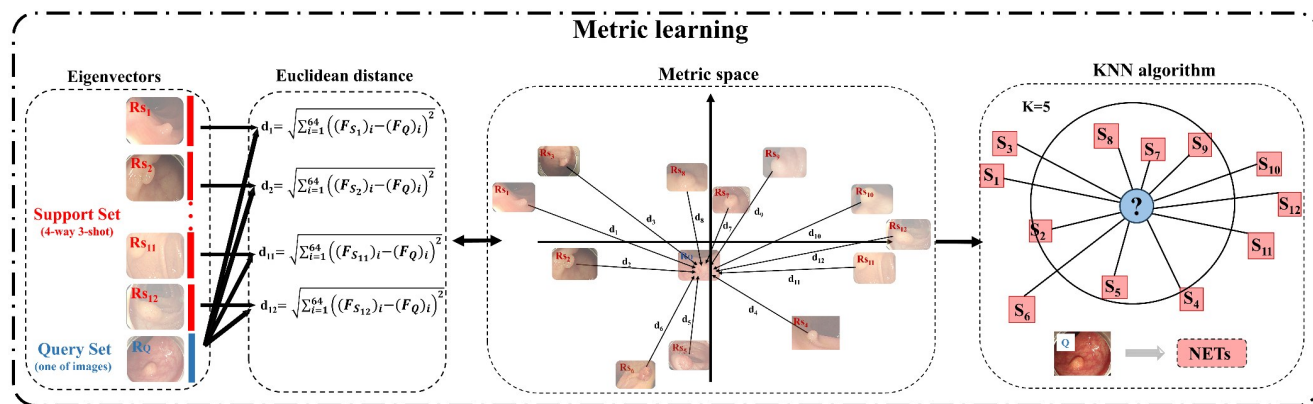


图4 运用度量学习对查询集中图像进行分类
Figure 4 Utilizing metric learning to classify endoscopic images on query set

ACC、宏曲线下面积 (Macro-Area Under the Curve, Macro-AUC), Macro F1 值和卡帕系数 (Kappa) 综合评估四分类任务性能。另外, 使用梯度加权的类激活热映射 (Gradient-weighted Class Activation Mapping, Grad-CAM) 算法, 利用输出与输入间的梯度差, 以热力图的形式实现可视化解释^[18]。

2 结果

2.1 少样本学习模型分类性能的评价与比较

图 5 混淆矩阵中展示了少样本学习模型、原始 ResNet50 V2 以及低、高年资内镜医师对查询集中 160 张内镜图像的分类表现。在四分类方面, 少样本学习模型达到了最高的分类 ACC (0.831), Macro-AUC (0.925) 和 Macro F1 值 (0.831), 均优于高年资内镜医师 (ACC 0.794, Macro-AUC 0.906, Macro F1 值 0.795), 如图 6 所示。

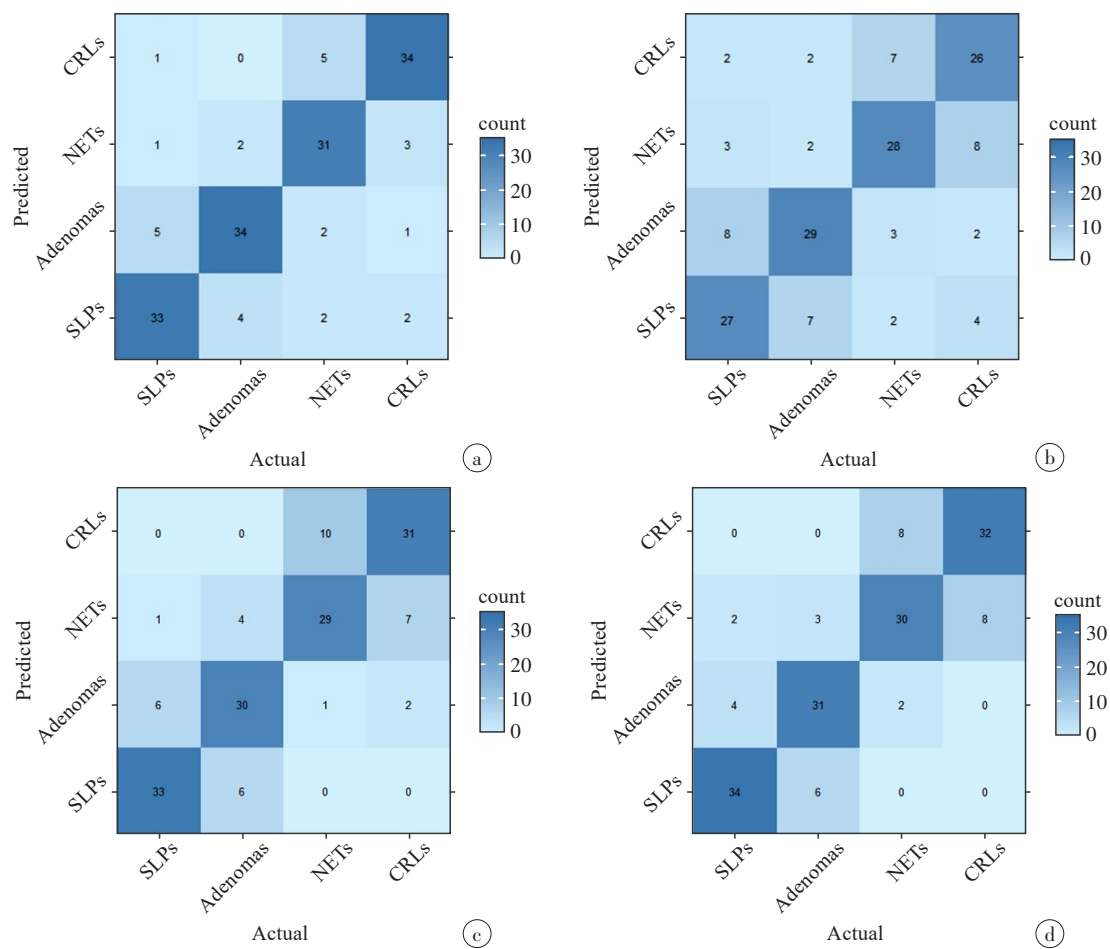


图5 少样本学习模型(a)、原始模型(b)与低(c)、高(d)年资内镜医师分类结果的混淆矩阵

Figure 5 Confusion matrix on classification results of few-shot learning (FSL) model (a), original model (b), junior (c) and senior (d) endoscopists

CRLs:结直肠脂肪瘤;NETs:神经内分泌肿瘤;Adenomas:传统腺瘤;SLPs:锯齿状病变及息肉

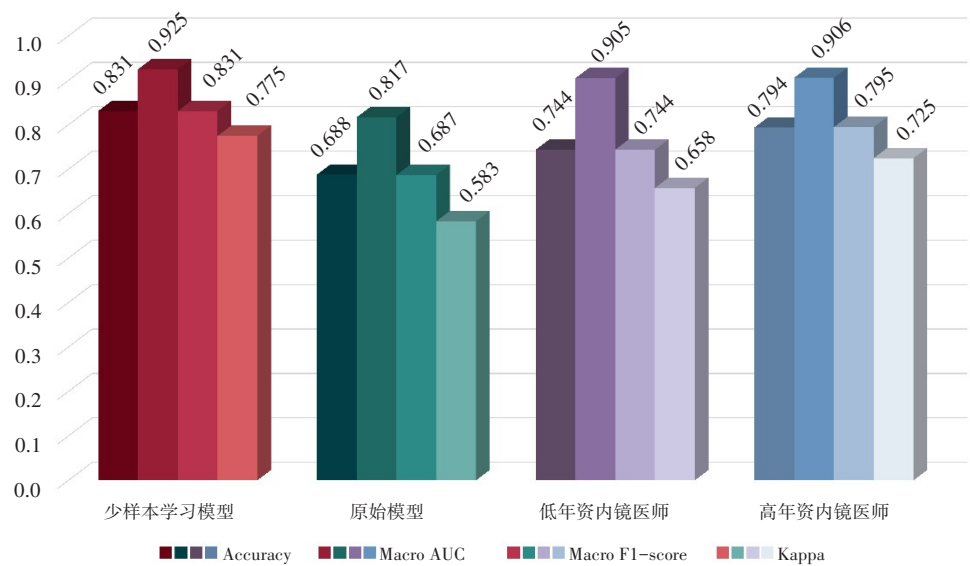


图6 少样本学习模型、原始模型与低、高年资内镜医师四分类任务指标

Figure 6 Four-class task metrics of FSL model, original model, junior and senior endoscopists

每个类别的分类指标见表1。具体来说,在识别结直肠 SMT 方面,少样本学习模型表现出优异的分

类性能,超过了原始模型和内镜医师。对于CRLs的分类,模型 ACC 达 0.925,F1 值达 0.850;对于NETs的

分类,ACC达0.906,F1值达0.805。对于传统腺瘤的分类,少样本学习模型的分类能力与高年资内镜医师相当(ACC:0.919 vs 0.906,F1值:0.840 vs 0.805);而在SLPs的分类中,少样本学习模型的分类能力略次于高年资医师(ACC:0.913 vs 0.925,F1值:0.829 vs 0.850)。一致性结果显示,少样本学习模型的Kappa达0.775,表明其分类结果与实际结果间有较强的一致性。

表1 少样本学习模型、原始模型与低、高年资内镜医师在各个类别上的分类性能
Table 1 Classification performance of FSL model, original model, junior and senior endoscopists for each category

模型	类别	准确率	召回率	特异性	精确性	F1值
少样本学习模型	SLPs	0.913	0.850	0.933	0.810	0.829
	Adenomas	0.919	0.850	0.942	0.829	0.840
	NETs	0.906	0.775	0.950	0.838	0.805
	CRLs	0.925	0.850	0.950	0.850	0.850
原始模型	SLPs	0.838	0.675	0.892	0.675	0.675
	Adenomas	0.850	0.725	0.892	0.690	0.707
	NETs	0.844	0.700	0.892	0.683	0.691
	CRLs	0.844	0.650	0.908	0.703	0.675
低年资内镜医师	SLPs	0.919	0.825	0.950	0.846	0.835
	Adenomas	0.869	0.750	0.908	0.732	0.741
	NETs	0.831	0.675	0.883	0.659	0.667
	CRLs	0.869	0.725	0.917	0.744	0.734
高年资内镜医师	SLPs	0.925	0.850	0.950	0.850	0.850
	Adenomas	0.906	0.775	0.950	0.838	0.805
	NETs	0.856	0.750	0.892	0.698	0.723
	CRLs	0.900	0.800	0.933	0.800	0.800

2.2 少样本学习模型的可视化解释

图7展示了少样本学习模型的可视化解释,在热力图中,高亮部分代表模型分类决策过程中权重较高的区域,即模型预测的病变区域,颜色越浅表示权重越低,对应正常区。这种可视化解释展示了模型较准确地定位病变区域,突显了模型强大的决策和特征提取能力。

3 讨论

本研究纳入了CRLs和NETs两种粘膜下肿瘤,一方面,相较于其他的结直肠SMT,CRLs和NETs的内镜检出率相对较高,能够收集到一定数量的内镜图片用于构建支持集和查询集,另一方面,某些情况下CRLs、NETs和息肉有着相似的内镜表现,难以依靠肉眼鉴别。同时,考虑病理学依据是诊断粘膜下肿瘤和息肉的金标准,笔者根据2019年WHO消化系统肿瘤的病理分类将结直肠息肉分为SLPs和传统腺瘤^[19]。术前活检和内镜下切除是治疗息肉的首选方法。对于不同大小的息肉,治疗方式也存在差异。

直径小于10 mm的息肉,可采用内镜下行冷活检钳切除或冷圈套器切除术;直径大于10 mm的息肉,建议先行术前活检,明确病理类型和良恶性程度,再行内镜粘膜切除术;而对直径大于20 mm或活检怀疑恶性病变的息肉,可考虑内镜粘膜下剥离术,以获得较高的整块切除率和较低的复发率^[20-22]。而与息肉的管理不同,粘膜下肿瘤的治疗与管理依赖于正确的诊断和良恶性程度的判断。由于术前活检具有侵入性,可能造成粘膜损伤或粘连,增加穿孔出血、肿瘤散播等风险,从而增加治疗难度,因此不建议直接采用粘膜活检进行诊断,而应依赖放射学和超声内镜的结合诊断。超声内镜能够明确肿瘤的内部回声和来源,初步判断病变的良恶性程度^[23],进而确定后续的治疗方案。以CRLs和NETs为例,Seo等^[24]发现使用超声内镜诊断CRLs的诊断敏感性和特异性可达90%以上。CRLs属于无恶性潜能的良性病变,对于无症状的CRLs,明确诊断后无需切除或随访^[1]。NETs是一种胃肠道惰性肿瘤,部分可表现侵袭性和转移性,贸然进行活检和切除会增加肿瘤转移和穿

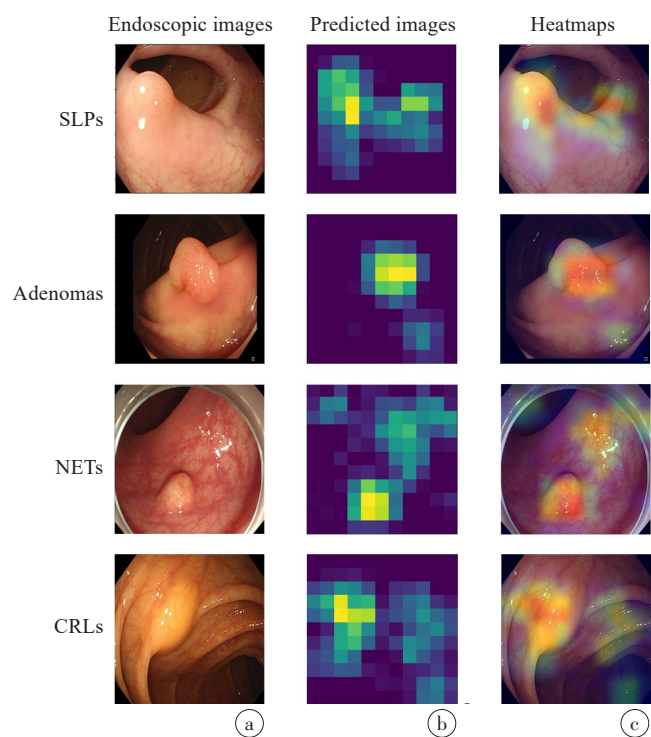


图7 少样本学习模型的可视化解释

Figure 7 Visual interpretation of FSL model

a:原始内镜图像;b:模型预测的病变区域图像;c:原始图像与病变预测区域相重合的热力图

孔出血的风险。因此,需要在治疗前评估病灶大小,粘膜下深度和是否存在转移灶。内镜下怀疑为NETs,建议行超声内镜明确其浸润深度和转移情况。若侵入肌层或存在转移,建议外科手术切除而非内镜切除。同时,结直肠NETs的治疗需要根据超声下的病灶大小确定。直径小于5 mm的NETs可采取单纯内镜粘膜切除术或器械辅助的粘膜切除术;直径为5~20 mm的病灶可考虑内镜粘膜下剥离术。对于直径大于20 mm的结直肠NETs,其转移风险较高,通常需要追加核磁共振等放射学检查,并采取外科治疗^[25]。因此,及时明确内镜下初步诊断对粘膜下肿瘤和息肉的后续管理和治疗至关重要。

随着深度学习技术的发展,计算机辅助诊断在胃肠道粘膜下肿瘤中得到广泛引用。Liu等^[26]的综述总结了深度学习辅助超声内镜在区分各类粘膜下肿瘤中的优势。但是在进展超声内镜前的白光内镜阶段,尚未有研究使用深度学习来区分诊断粘膜下肿瘤。一方面随着超声内镜结合细针穿刺活检、免疫组化染色及新型成像技术的出现^[7],诊断粘膜下肿瘤的技术不断进步,单纯依靠内镜下判断病变容易被忽视;另一方面,传统的深度学习模型需要大量标记图像进行训练,以学习目标图像的细微特征,而粘膜下肿瘤的发生率低,难以收集足够数量的内镜图

像用于训练,导致相关研究成果较少。

少样本学习作为深度学习的一种方法,用于解决样本数量稀少和邻域泛化的问题,逐渐被应用于医学领域。Suganya等^[27]使用少样本学习算法,基于COVID-19患者的胸部CT图像,成功预测了各类肺部并发症,ACC达0.954,AUC达0.933。Yin等^[28]使用少样本学习,对胃印戒细胞癌、胃腺癌和胃溃疡的内镜图像进行区分,达到了79.4%的分类准确性,优于高年资内镜医师。

本研究构建了一种少样本学习分类模型,用于区分结直肠粘膜下肿瘤和息肉,模型融合了迁移学习和度量学习,利用二次预训练的ResNet50 V2模型提取图像特征,并使用KNN分类器对SLPs、传统腺瘤、NETs和CRLs进行分类。结果显示,该模型分类性能优秀,对粘膜下肿瘤的诊断准确率高,优于传统的深度学习模型和低、高年资内镜医师,证明了少样本学习在分类结直肠粘膜下肿瘤和息肉内镜图像的优越性。此外,针对本研究的少样本学习任务,本文还创新性地采用了双重预训练的方法,由于ImageNet数据库中自然生活图像与内镜图像存在较大差距,直接迁移在自然生活图像上预训练的模型可能无法准确识别内镜图像中的病灶。故首先在1 512张食管内镜图像上进行简单的有监督的三分类任务,对模型进行了一定的参数调整,增强了模型对内镜相关图像识别的能力,提高了模型对内镜下病灶的敏感性,进一步提高了模型的分类性能,再将其运用于结直肠粘膜下肿瘤和息肉图像的分类任务中。

可视化的Grad-CAM热力图证明了模型能够较准确地识别内镜病灶区域,并根据病灶区域提取特征,实现分类。这是少样本学习模型在结肠镜图像处理的首次应用,也是将深度学习用于分类粘膜下肿瘤与息肉内镜图像的首次尝试。本研究也存在一些不足之处。首先本研究为回顾性研究,存在选择偏倚。其次,本研究仅对SLPs、传统腺瘤、NETs和CRLs进行了四分类,而并未分类更多的亚型。最后,需要在实际临床应用中探索少样本模型实时监测的效果。

综上,本研究构建的少样本学习模型在分类结直肠粘膜下肿瘤和息肉内镜图像方面有着优异表现,在诊断胃肠道疾病上有着巨大潜力。一方面,可协助内镜医师在直接切除、内镜活检或超声内镜检查中进行选择。另一方面,少样本学习模型在诊断结直肠粘膜下肿瘤的优异性能,为未来人工智能辅助诊断少见疾病提供思路。此外,需要进一步将该模型部署在实际临床应用中。

【参考文献】

- [1] 中华医学会消化内镜分会NOTES、外科学组, 中国医师协会内镜医师分会消化内镜专业委员会, 中华医学会外科学分会胃肠外科学组. 中国消化道黏膜下肿瘤内镜诊治专家共识(2023版)[J]. 中国实用外科杂志, 2023, 43(3): 241-251.
NOTES and Endoscopic Surgery Group, Chinese Society of Digestive Endoscopy, Chinese Medical Association, Digestive Endoscopy Special Committee, Endoscopic Physicians Branch of Chinese Medical Doctor Association, Chinese Society of Gastrointestinal Surgery, Chinese Society of Surgery, Chinese Medical Association. Chinese consensus on endoscopic diagnosis and management of gastrointestinal submucosal tumors(version 2023)[J]. Chinese Journal of Practical Surgery, 2023, 43(3): 241-251.
- [2] Sharzei K, Sethi A, Savides T. A clinical practice update on management of subepithelial lesions encountered during routine endoscopy: expert review[J]. Clin Gastroenterol Hepatol, 2022, 20(11): 2435-2443.e4.
- [3] 中华医学会消化内镜学分会外科学组, 中国医师协会内镜医师分会消化内镜专业委员会, 中华医学会外科学分会胃肠外科学组. 中国消化道黏膜下肿瘤内镜诊治专家共识(2018版)[J]. 中国实用外科杂志, 2018, 38(8): 840-850.
Endoscopic Surgery Group, Chinese Society of Digestive Endoscopy, Chinese Medical Association, Digestive Endoscopy Special Committee, Endoscopic Physicians Branch of Chinese Medical Doctor Association, Chinese Society of Gastrointestinal Surgery, Chinese Society of Surgery, Chinese Medical Association. Chinese consensus on endoscopic diagnosis and management of gastrointestinal submucosal tumors (version 2018)[J]. Chinese Journal of Practical Surgery, 2018, 38(8): 840-850.
- [4] 齐志鹏, 钟芸诗, 周平红, 等. 内镜切除结肠黏膜下肿瘤临床病理学特征分析(附559例报告)[J]. 中国实用外科杂志, 2016, 36(1): 115-118.
Qi ZP, Zhong YS, Zhou PH, et al. Clinicopathological analysis of colorectal submucosal tumors: a report of 559 cases resected under endoscopic[J]. Chinese Journal of Practical Surgery, 2016, 36(1): 115-118.
- [5] Modlin IM, Lye KD, Kidd M. A 5-decade analysis of 13,715 carcinoid tumors[J]. Cancer, 2003, 97(4): 934-959.
- [6] Jung YS, Yun KE, Chang Y, et al. Risk factors associated with rectal neuroendocrine tumors: a cross-sectional study[J]. Cancer Epidemiol Biomarkers Prev, 2014, 23(7): 1406-1413.
- [7] Alkhatib AA, Faigel DO. Endoscopic ultrasonography-guided diagnosis of subepithelial tumors[J]. Gastrointest Endosc Clin N Am, 2012, 22(2): 187-205.
- [8] Zhuang HM, Zhang JX, Liao F. A systematic review on application of deep learning in digestive system image processing[J]. Vis Comput, 2023, 39(6): 2207-2222.
- [9] Vella D, Ebejer JP. Few-shot learning for low-data drug discovery[J]. J Chem Inf Model, 2023, 63(1): 27-42.
- [10] Snell J, Swersky K, Zemel R. Prototypical networks for few-shot learning[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017: 4080-4090.
- [11] Hosna A, Merry E, Gyalmo J, et al. Transfer learning: a friendly introduction[J]. J Big Data, 2022, 9(1): 102.
- [12] Wang YQ, Yao QM, Kwok JT, et al. Generalizing from a few examples: a survey on few-shot learning[J]. ACM Computing Surveys, 2020, 53(3): 63.
- [13] He KM, Zhang XY, Ren SQ, et al. Identity mappings in deep residual networks [C]//Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 630-645.
- [14] Deepak S, Ameer PM. Brain tumor classification using deep CNN features via transfer learning[J]. Comput Biol Med, 2019, 111: 103345.
- [15] Shi F, Chen BJ, Cao QQ, et al. Semi-supervised deep transfer learning for benign-malignant diagnosis of pulmonary nodules in chest CT images[J]. IEEE Trans Med Imaging, 2022, 41(4): 771-781.
- [16] Yoshida T, Takeuchi I, Karasuyama M. Distance metric learning for graph structured data[J]. Mach Learn, 2021, 110(7): 1765-1811.
- [17] Yu JS, Wang XQ, Chen XD, et al. Automatic premature ventricular contraction detection using deep metric learning and KNN [J]. Biosensors (Basel), 2021, 11(3): 69.
- [18] Selvaraju RR, Cogswell M, Das A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[J]. Int J Comput Vis, 2020, 128(2): 336-359.
- [19] Nagtegaal ID, Odze RD, Klimstra D, et al. The 2019 WHO classification of tumours of the digestive system[J]. Histopathology, 2020, 76(2): 182-188.
- [20] 覃弦, 宋军, 侯晓华. 结肠息肉内镜下诊断及治疗进展[J]. 中华消化内镜杂志, 2021, 38(12): 1040-1046.
Qin X, Song J, Hou XH. Progress in endoscopic diagnosis and treatment for colorectal polyps [J]. Chinese Journal of Digestive Endoscopy, 2021, 38(12): 1040-1046.
- [21] He XS, Hang D, Wu KN, et al. Long-term risk of colorectal cancer after removal of conventional adenomas and serrated polyps [J]. Gastroenterology, 2020, 158(4): 852-861.e4.
- [22] Murakami T, Kurosawa T, Fukushima H, et al. Sessile serrated lesions: Clinicopathological characteristics, endoscopic diagnosis, and management[J]. Dig Endosc, 2022, 34(6): 1096-1109.
- [23] Faulx AL, Kothari S, Acosta RD, et al. The role of endoscopy in subepithelial lesions of the GI tract[J]. Gastrointest Endosc, 2017, 85(6): 1117-1132.
- [24] Seo SW, Hong SJ, Han JP, et al. Accuracy of a scoring system for the differential diagnosis of common gastric subepithelial tumors based on endoscopic ultrasonography[J]. J Dig Dis, 2013, 14(12): 647-653.
- [25] Pavel M, Öberg K, Falconi M, et al. Gastroenteropancreatic neuroendocrine neoplasms: ESMO clinical practice guidelines for diagnosis, treatment and follow-up [J]. Ann Oncol, 2020, 31(7): 844-860.
- [26] Liu XY, Song W, Mao T, et al. Application of artificial intelligence in the diagnosis of subepithelial lesions using endoscopic ultrasonography: a systematic review and meta-analysis[J]. Front Oncol, 2022, 12: 915481.
- [27] Suganya D, Kalpana R. Prognosticating various acute covid lung disorders from COVID-19 patient using chest CT Images[J]. Eng Appl Artif Intell, 2023, 119: 105820.
- [28] Yin MY, Zhang RF, Lin JX, et al. Identification of gastric signet ring cell carcinoma based on endoscopic images using few-shot learning [J]. Dig Liver Dis, 2023, 55(12): 1725-1734.

(编辑:薛泽玲)