

深度学习在宫腔镜图像分析中的应用

宋阳¹, 王冉冉², 周金婷²

1. 武汉科技大学医学部医学院, 湖北 武汉 430000; 2. 湖北文理学院附属襄阳市中心医院妇产科, 湖北 襄阳 441100

【摘要】宫腔镜检查是子宫内膜病变诊疗过程中不可或缺的技术。近年来,随着人工智能的迅速发展,深度学习技术凭借着其出色的特征提取能力和对大规模数据的高效学习能力,为宫腔镜图像的深入剖析提供新的途径。本研究通过关键词检索、文献筛选、质量评估及主题归纳的方法系统地回顾和分析深度学习技术(CNN、DNN、U-Net、YOLO、Transformer等)在宫腔镜图像中的应用情况,包括子宫内膜癌、子宫内膜息肉、子宫内膜炎疾病的检测分类,子宫肌瘤的治疗及子宫粘连综合征术后生育能力的预测等,并提出存在的不足,对基于宫腔镜图像的深度学习技术的发展趋势进行展望,期待能推动该领域研究的进一步发展。

【关键词】深度学习;宫腔镜;子宫内膜病变;综述

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2025)12-1675-06

Review of applications of deep learning in hysteroscopic image analysis

SONG Yang¹, WANG Ranran², ZHOU Jinting²

1. School of Medicine, Wuhan University of Science and Technology, Wuhan 430000, China; 2. Department of Obstetrics and Gynecology, Xiangyang Central Hospital, Hubei University of Arts and Science, Xiangyang 441100, China

Abstract: Hysteroscopy is an indispensable technique in the diagnosis and treatment of endometrial lesions. In recent years, with the rapid development of artificial intelligence, deep learning technology has emerged as a novel approach for the in-depth analysis of hysteroscopic images, owing to its outstanding feature extraction capabilities and efficient learning performance on large-scale data. Through keyword retrieval, literature screening, quality assessment, and topic induction, this study systematically summarizes the applications of deep learning techniques such as CNN, DNN, U-Net, YOLO, and Transformer in hysteroscopic image analysis, encompassing the detection and classification of endometrial cancer, endometrial polyps, and endometritis, the therapeutic management of uterine fibroids, and the prediction of fertility outcomes following surgery for uterine adhesions. Additionally, the existing limitations and a prospect of the development trends regarding deep learning-based hysteroscopic image analysis are provided, expecting to promote the further advancement in relevant research.

Keywords: deep learning; hysteroscopy; endometrial disease; review

前言

妇科疾病是女性面临的主要威胁之一,这些疾病包括但不局限于子宫内膜癌(Endometrial Carcinoma, CE)^[1]、子宫内膜息肉(Endometrial Polyps, EP)^[2]、子宫肌瘤^[3]等,这些疾病不仅危害女性的身体健康,还会在心理层面给女性带来负面影响,极大影响其生活质量。

目前,子宫内膜病变的诊断主要依赖宫腔镜检查加子宫内膜活检^[4],但病检结果往往需要一定的时间才能获得,准确及时的诊断对于疾病的治疗和预后至关重要。通过宫腔镜图像,医生能直观地观察子宫腔内的情况,方便做出初步诊断;然而这有赖于妇科医生丰富的临床经验,诊断医师带有一定的主观性,可能有误诊的风险^[5-6]。近年来,基于宫腔镜图像的深度学习技术逐渐成为研究的新兴领域,有望提高妇科医生初步诊断的效率和准确性。

【收稿日期】2025-03-15

【基金项目】湖北省自然科学基金(2024AFB1071)

【作者简介】宋阳,硕士研究生,住院医师,研究方向:普通妇科, E-mail: 1627034356@qq.com

【通信作者】周金婷,博士,副主任医师,研究方向:盆底疾病, E-mail: 409484199@qq.com

1 宫腔镜检查 and 深度学习

1.1 宫腔镜检查

宫腔镜检查是一种微创诊疗技术,将宫腔镜插

入患者阴道,经宫颈管进入子宫腔后利用气体或液体介质使子宫膨胀起来。相对于传统的检查方法,宫腔镜具有直观观察、定位准确等优势,并且有助于疾病的早期诊断,继而影响疾病的预后。通过宫腔镜可以查看宫颈管、宫颈内口、宫腔及输卵管开口等是否正常以及子宫内膜是否可能发生病变,可以通过宫腔镜下活检了解子宫内膜的功能状态,以便妇科医生做出更准确的初步判断,然后向患者解释病情并及时确定治疗方案。此外还可以直接在宫腔镜下进行手术治疗^[7-8]。

1.2 深度学习技术

深度学习是机器学习的一个重要分支^[9],机器学习是实现人工智能的核心技术。深度学习的概念源于人工神经网络的研究,含多个隐藏层的多层感知器是一种深度学习结构,具有自动特征提取和学习数据等特征,该技术通过端到端学习的方式,利用梯度下降算法和反向传播机制,自动地从大规模数据中提取从低级到高级的复杂特征,从而免除繁琐的特征工程。根据训练数据集是否存在标签,深度学习大致可分为监督式、无监督式和半监督式学习^[10]。深度学习技术是一类模式分析方法的统称,主要涉及3类方法:卷积神经网络(Convolutional Neural Network, CNN)、循环神经网络、深度置信网络^[11]。深度学习模型通常由输入层、隐藏层和输出层3部分组成,不同层之间通过模拟神经元连接^[12]。利用这一结构,深度学习可以通过逐层组合低层特征逐步构建出更高层次的抽象特征,从而揭示数据的潜在结构。深度学习在医学领域的优势在于可以整合多种数据模式来提升对复杂信息的理解与决策能力,在物体检测、语义分割和图像分类等任务中达到专家级的精度^[13-16]。在医学领域,深度学习技术擅长观察图像中的隐藏模式,并帮助临床医生实现诊断。深度学习革新了医学图像分析,在注册、分割、特征提取和分类等图像处理任务中取得优异成果。深度学习技术已被证明是器官分割、癌症检测、疾病分类和计算机辅助诊断最有效的方法^[17]。例如,深度学习技术应用于早期胃癌识别,Zhang等^[18]提出一种由5种GAM-EfficientNet模型组成的深度学习方法,该方法平均准确率、特异性、精确度、召回率和F1分数分别为78.70%、91.92%、80.23%、78.70%和78.00%,高于所有内窥镜医师的平均评分。Wang等^[19]采用基于分割的深度学习架构,利用深度解码网络来整合先前的特征,并建立能区分正常和病理变化的语义分割模型;此外,采用迁移学习来创建为阴道镜图像量身定制的特征提取器。该模型实现了高灵敏度

(96.38%)、特异性(95.84%)、精确度(97.56%)和F1分数(96.96%)。深度学习在膀胱镜的应用中也有研究,Guo等^[20]利用卷积神经网络中的U-Net算法开发一个深度学习模型。在验证集上,U-Net算法对肿瘤的认识准确率达到98%,与泌尿外科医生相比,具有更高的准确性和更快的检测速度。近年来,深度学习在宫腔镜图像分析中的研究也收获了显著进展。

2 基于宫腔镜图像的深度学习在疾病检测和分类中的应用

2.1 深度学习模型CE检测中的应用

CE是发生于子宫内膜的一种上皮性恶性肿瘤,是女性生殖道三大恶性肿瘤之一。CE近年来发病率在世界范围内呈上升趋势,CE的发病年龄越来越年轻化,肥胖、糖尿病等危险因素可能与CE相关,许多CE I型患者比较年轻,往往有生育需求^[21-23]。因此,临床医生不断探索各种方法对其早期诊断,以期改善CE患者的预后,降低死亡率。目前诊断CE主要有影像学检查、宫腔镜检查、病理学诊断等方法^[24]。宫腔镜检查可以直接观察到子宫内膜是否发生病变,以便妇科医生做出初步的诊断,但是早期癌症病灶不明显,容易漏诊。近年来随着宫腔镜技术和深度学习的发展,通过深度学习提取宫腔镜图像中病变部位的特征,可为CE的早期诊断带来新的曙光。有研究表明深度学习模型在辅助CE诊断方面表现出良好的性能。Takahashi等^[25]公开一种自动宫腔镜图像分析CNN系统,该系统可以从正常的子宫内膜组织中识别CE病变,其采用基于3种流行的深度神经网络模型Xception、MobileNetV2和EfficientNetB0,开发一种连续性分析方法以提高癌症诊断的准确性。结果表明使用标准方法时,诊断准确率为80%,当采用所提出的连续性分析和组合3个神经网络时,诊断准确率分别提高到89%和90.29%,这些发现表明,所提出的方法能促进CE的及时诊断。见表1^[25-34]。

2.2 深度学习模型在EP检测中的应用

EP是妇科常见疾病,是由于炎症导致子宫内膜增生形成凸向宫腔的息肉状赘生物。虽然大多数息肉是良性的,但多达12.9%的患者被发现患有癌前息肉或恶性息肉^[35]。宫腔镜下准确识别息肉并摘除是降低CE的关键。Zhao等^[26]提出一种基于YOLOX的深度学习模型自动检测EP,并且在YOLOX中提出组归一化方法来提高模型实时检测EP病变的性能,在后续处理阶段应用Volumetric Adversarial Frequency Attack(VAFA)算法有效解决原始YOLOX

表1 深度学习在宫腔镜图像中的应用

Table 1 Application of deep learning in hysteroscopic image analysis

作者	数据规模	算法	任务	准确率	F1分数	AUC
Takahashi等 ^[25]	411 800张	CNN	检测	0.80	0.78	-
Zhao等 ^[26]	11 839张	YOLOX+GN+VAFA	检测	MCH:0.91	0.94	-
				TJH:0.88	0.83	-
Kitaya等 ^[27]	8 443张	VGGNet-16	检测	0.93	0.91	0.93
Zhang等 ^[28]	1 851张	VGGNet-16	分类	0.81	0.87	0.94
Raimondo等 ^[29]	1 500张	ResNet50	分类	0.87	0.80	-
曹明亮等 ^[30]	4 781张	EfficientNet-B0	分类	0.93	-	0.98
		ResNet18		0.84	-	0.98
Török等 ^[31]	6 288张	FCNN	分割	0.86	-	-
Wang等 ^[32]	1 385张	U-Net	分割	0.86	-	-
		InceptionV3+DeepSurv				
Li等 ^[33]	4 922张	InceptionV2+DeepSurv	预测	-	-	0.95
		ResNet50+DeepSurv				
Li等 ^[34]	4 922张	比例风险CNN	预测	-	-	0.99

模型对EP检测的不稳定性问题,同时进行模型泛化性验证。此模型是利用323例EP患者的11 839张图像数据集进行训练,然后运用另外2家机构的2个数据集(MCH测试集、TJH测试集)进行验证。结果表明,YOLOX+GN+VAFA算法对于MCH测试集的敏感性、特异性、准确性、精确度和F1分数分别为100%、88.52%、90.91%、69.57%和93.91%。在TJH测试集中,YOLOX+GN+VAFA算法的等效结果分别为92.0%、76.0%、88.0%、92.0%和83.24%,表明改进后的模型可以有效地应用于宫腔镜检查来降低EP漏诊、误诊的风险。

2.3 深度学习模型在子宫内膜炎检测中的应用

子宫内膜炎是一种子宫内膜的炎症病理状况,其特征是CD138(+)的浆细胞的异常浸润。子宫内膜炎的诊断传统上依赖于子宫内膜活检和子宫内膜基质浆细胞的组织病理学/免疫组织化学检测。然而,子宫内膜活检对受试者来说是痛苦的过程,并且有限的子宫内膜活检样本可能会错过隐藏在其他粘膜位置的标志性细胞。Kitaya等^[27]使用深度学习模型将宫腔镜图像与免疫组化结果联系起来,建立计算机辅助检测系统检测子宫内膜炎。VGGNet-16被用作图像分析的核心CNN架构。研究结果表明CNN模型的准确性、F1分数和曲线下面积(Area Under Curve, AUC)分别为92.8%、90.7%和0.93。

2.4 深度学习模型在妇科疾病分类中的应用

基于宫腔镜图像的深度学习在妇科疾病分类方

面取得不错的进展,甚至能超越经验丰富的妇科医生。Zhang等^[28]开发第一个基于CNN的计算机辅助设计系统,以VGGNet作为深度学习模型的主要结构,并对其调整实现迁移学习和子宫内膜病变分类,诊断结果以两种方式呈现:五分类(无异型性的子宫内膜增生、非典型增生、CE、EP和黏膜下肌瘤)和两分类(恶性/癌前或良性病变)。研究结果显示,VGGNet-16模型在子宫内膜病变分类方面的总体准确率为80.8%。对无异型性子宫内膜增生、非典型增生、CE、EP和黏膜下肌瘤的敏感度分别为84.0%、68.0%、78.0%、94.0%和80.0%;对于这些诊断,模型的特异性分别为92.5%、95.5%、96.5%、95.0%和96.5%。在将病变分类为良性或癌前/恶性时,VGGNet-16模型的准确性、敏感性和特异性分别为90.8%、83.0%和96.0%。VGGNet-16模型的诊断表现在两项分类任务中略优于妇科医生。通过应用VGGNet-16模型,有望提升诊断子宫内膜病变的整体准确率,从而及时为患者提供更精确的治疗方案。

Raimondo等^[29]开发一种深度学习模型(ResNet50)结合临床因素(年龄、绝经状态、宫内节育器、激素治疗和他莫昔芬的使用)和宫腔镜图像用于子宫内膜病变的检测和分类。在分类任务中,模型结合临床因素的总体准确率为86.74%,特异性90.06%,F1分数80.11%。通过融合临床因素和宫腔镜图像,深度学习模型获得最佳性能。

在深度学习领域,可视化技术梯度加权类激活

热力图 (Gradient-weighted Class Activation Mapping, Grad-CAM) 是用于可视化与理解 CNN 决策的技术, 其核心原理在于对流入 CNN 最后一个卷积层的特征进行分析, 突出显示图像的关键区域, 并在原图像进行标记, 最终实现 CNN 诊断过程的颜色可视化^[36]。曹明亮等^[30]将数据集划分为训练集和测试集, 训练集用于模型学习与训练后, 采用 ResNet18 和 EfficientNet-B0 两种模型架构对测试集分别采用五类 (无异型性的子宫内膜增生、非典型增生、CE、EP 和黏膜下肌瘤) 和二类分类任务 (恶性/癌前或良性病变) 进行模型验证, 并将 Grad-CAM 层嵌入最优模型中。结果显示, 在五类分类任务中, EfficientNet-B0 模型的准确度 (93.23%) 高于 ResNet18 模型 (84.23%); 两种 CNN 模型的 AUC 均在 96.00% 以上。在二分类任务准确度和特异度的评估中, 两种模型相似, 均在 93.00% 以上, 而 EfficientNet-B0 模型敏感度 (91.14%) 明显优于 ResNet18 模型 (77.22%)。EfficientNet-B0 模型联合 Grad-CAM 算法可识别出图像中异常区域, 经病理检查证实, 模型输出热力图中标记区域约 95% 为病灶区域, 表明 EfficientNet-B0 模型联合 Grad-CAM 研发的宫腔镜诊断模型具有较高的诊断准确度、敏感度和特异度, 在诊断子宫内膜病变方面具有应用价值。

3 基于宫腔镜图像的深度学习在疾病治疗中的应用

3.1 深度学习有助于宫腔镜子宫肌瘤切除术

黏膜下肌瘤是子宫肌瘤的一种, 肌瘤不仅凸于宫腔会影响子宫收缩, 并且受挤压可能会脱出到阴道内, 引起异常子宫出血^[37]。目前, 针对该疾病的治疗主要是宫腔镜下子宫肌瘤切除术, 影响手术疗效的因素主要是在明确病变切除范围的基础上精准切除肌瘤和避免子宫穿孔现象的发生^[38]。为确定深度学习模型识别肌瘤和正常子宫肌层之间平面的准确性, Török 等^[31]首次报道全连接 CNN 模型在宫腔镜手术中识别完整子宫肌层和子宫黏膜下肌瘤病变之间的边界。该研究从背景中提取肌瘤的方法是基于全卷积神经网络 (Fully Convolutional Neural Network, FCNN), 对视频帧进行自动分割, 确定肌瘤的区域, 应用不同的过滤器和程序来识别先前注释的结构。手动注释的图像用于训练 FCNN, 然后这个预先训练的网络用于在看不见的视频帧中自动分割正常子宫肌层, 分割准确率达到 86.19%, 结果表明使用深度学习技术分析宫腔镜视频的过程有助于在进行宫腔镜手术时实时识别结构。

3.2 深度学习降低宫腔镜手术中气体栓塞发病率

气体栓塞是宫腔镜手术的一种潜在严重并发症, 虽然罕见但是非常危险, 严重时甚至可能导致患者死亡。静脉气体栓塞 (Venous Gas Embolism, VGE) 的发生率为 10%~50%, 其表现可能从临床上难以察觉到需要复苏不等。自十年前液体膨胀介质引入以来, VGE 的发生率已显著降低, 然而仍有 0.03% 的严重 VGE 风险可能导致死亡。同时, 手术宫腔镜检查中亚临床 VGE 事件的发生率常被显著低估^[39]。这种灾难性的医源性并发症使原本相对简单的手术变得相当危险, 充分的监测对于早期发现气体栓塞和避免致命后果至关重要。U-net 是一种图像分割技术, 广泛用于主要图像模式, 包括 X 射线照相、计算机断层扫描、磁共振成像和显微镜。Wang 等^[32]提出一种融合深度边缘感知网络与标记控制分水岭算法的检测框架, 用于从宫腔镜图像中提取气泡参数。该边缘感知网络采用编码器-解码器架构进行气泡分割, 并通过边缘损失函数进行监督学习。基于标记控制分水岭算法的后处理方法可进一步分离气泡实例并计算尺寸分布。大量实验表明, 所提模型性能优于传统分割方法。实验数据显示, 该边缘感知网络的准确率、灵敏度、精确度、Dice 分数及平均交并比分别为 85.9%、86.8%、95.5%、86.2% 和 75.8%。因此, 边缘感知网络模型具有在宫腔镜手术中开发自动气泡去除装置的潜力。近年来应用于宫腔镜图像的深度学习模型演进及任务扩展见图 1。




图 1 2018~2024 年应用于宫腔镜图像的深度学习模型演进及任务扩展
Figure 1 Evolution and task expansion of deep learning models applied to hysteroscopic image analysis from 2018 to 2024

4 基于宫腔镜图像的深度学习在生育能力预测中的应用

子宫粘连综合征是由于子宫内膜损伤导致宫腔部分或全部闭塞的一种疾病, 临床可表现为月经异常、不孕、反复流产等不良妊娠结局^[40]。宫腔镜粘连分离术是目前治疗子宫粘连综合征的主要方法, 虽然通过手术能恢复子宫正常的形态, 但手术可能会造成子宫内

膜发生二次损伤从而影响患者后续受孕^[41]。预测宫腔粘连患者术后的妊娠情况,及时为不同的患者提供个性化治疗能提高妊娠率和活产率。迁移学习模型(Transformer)的出现,充分展现基于注意力模型所蕴含的巨大潜力。Yang等^[42]率先针对Transformer的可迁移性展开研究,结果发现它的可迁移能力不逊色于CNN。Transformer运用全局自注意机制对整幅图像的特征以及特征间的长期依赖关系进行模拟,着重学习特征之间的相对关系,以此提升对不同分布数据的泛化能力。另外,Transformer中的交叉注意力在对不同分布甚至是来自不同模态的分布时表现也很出色。Li等^[33]使用DeepSurv架构构建4个迁移学习模型用于预测宫腔镜粘连松解术后的生育结果,采用3种CNN架构进行宫腔镜图像分类:InceptionV3、ResNet50和InceptionResNetV2。InceptionV3利用多个不同大小的卷积滤波器来提取不同尺度的特征,提供更宽的感受野;ResNet50结合残差连接,以缓解梯度消失问题并提高训练稳定性;InceptionResNetV2结合Inception和ResNet的优势,为图像识别提供更深入、更高效的架构。结果表明,InceptionV3+DeepSurv在训练集和验证集的AUC为0.96和0.89。InceptionResNetV2+DeepSurv的训练集和验证集的AUC为0.97和0.97。ResNet50+DeepSurv在预测1年内自然受孕时,训练集和验证集的AUC为0.95和0.83。模型在测试集上进行外部验证对于1年内自然受孕预测,InceptionV3+DeepSurv、InceptionResNetV2+DeepSurv、ResNet50+DeepSurv的AUC为0.94、0.95、0.93。使用DeepSurv架构增强的模型在预测不同时间点受孕的概率方面明显优于单独执行分类的迁移学习模型,该模型显示出预测宫腔镜粘连松解术后患者生育结果的潜力,有助于妇科医生在宫腔镜粘连松解术后对患者进行个性化治疗。Li等^[34]比较比例风险CNN和InceptionV3,其中,比例风险CNN结合卷积神经网络和比例风险模型,使其能学习和预测生育结果如何随时间变化,这使得它特别适用于生育力评估。利用Grad-CAM为比例风险CNN开发可视化面板,可以突出宫内病变,该研究使用无监督学习算法对宫内病变进行定量分析,使用Pearson方法,在编码矩阵中对具有高相关性的代码进行聚类;然后将聚类网络与代码高度相关的临床特征相连接。比例风险CNN系统准确预测受孕,在3个随机分配的数据集中AUC分别为0.982、0.992和0.990,优于InceptionV3框架(AUC为0.917、0.779、0.885)。基于比例风险方法的CNN可准确评估术后生育能力。

5 总结与展望

妇科疾病长期以来一直是女性健康领域的一大难题。基于这个难题,深度学习模型从CNN到Transformer,在妇科疾病的诊断与检测、治疗、预后方面都表现出巨大的潜力,但目前仍面临许多挑战。(1)深度学习模型在图像分析中的性能高度依赖训练数据的数量和质量。深度学习是典型的数据驱动方法,模型通过从数据中自动学习特征和模式来完成的任务,与依赖人工设计规则的传统方法不同,模型需要海量数据,避免欠拟合、噪声、标注错误或偏差导致模型学到错误模式。一般来说,深度学习技术应用于图像识别问题需要收集100 000~1 000 000张图像才能构成一个可行的训练数据集。然而,在医疗领域,部分妇科疾病,如罕见的CE亚型等样本数量不足,导致模型难以学习全面特征。(2)尽管实验室研究显示深度学习模型在妇科疾病中的诊断准确率可达90%以上,但其临床转化仍是一大问题,大部分模型还未应用于临床实践。不同医院的宫腔镜设备有多种型号,图像格式及分辨率都存在一定差异,模型需要针对性适配,增加部署成本。(3)尽管深度学习模型在特定数据集上显示出卓越的性能,但这些数据集多来自单一机构,缺乏不同设备、人群和成像条件的覆盖,所以在不同设备、人群、机构中的泛化能力仍存在质疑。未来深度学习在宫腔镜中的应用可以进一步发展:(1)利用弱监督学习解决标注数据稀缺问题^[43]。通过弱监督学习减少模型对数据的依赖,节约人力、时间和成本;并且应采集多中心收集数据,以获得性能更好的模型。(2)未来的工作要着力于模型的实际应用,探索模型应用到临床宫腔镜中的可行性,以提高疾病检测的效率和准确性。(3)在深度学习模型构建之后,模型应该经过外部验证和改进。(4)当深度学习模型性能较高时,纳入其他更罕见宫内病变(如苗勒管畸形、非典型息肉样腺瘤、门大动脉瘤、肉瘤、滋养细胞疾病、受孕产物滞留)等疾病。(5)利用深度学习技术实时手术导航,结合增强现实技术实现术中病灶实时分割与风险预警^[44-45]。(6)建立纵向预后模型,整合多时间点宫腔镜图像与生化指标(如CA125)预测CE复发风险。将深度学习技术和宫腔镜技术相结合,建立有效的深度学习模型,不仅能提高妇科医生在诊断过程中的准确性和及时性,还能为临床治疗提供更及时和精准的指导。尽管目前在这一领域还存在一些挑战和问题,但通过有效的数据管理和临床应用的广泛推广,有望促进该领域的进一步发展。

【参考文献】

- [1] Renaud LI, St-Laurent E, Compare C, et al. Endometrial cancer: from clinical reality to molecular treatment[J]. *Discov Oncol*, 2025, 16(1): 1874.
- [2] Weigel GM, Baisson GN, Mihalov L, et al. Prevalence of and risk factors for endometrial polyps among asymptomatic postmenopausal women with uterovaginal prolapse[J]. *Am J Obstet Gynecol*, 2025, 232(2): 196.e1-196.e6.
- [3] Marsh EE, Wegienka G, Williams DR. Uterine fibroids[J]. *JAMA*, 2024, 331(17): 1492-1493.
- [4] Di Spiezio Sardo A, Iorio GG, Guerra S, et al. The role of hysteroscopy in patients with adenomyosis and infertility: bringing out the submerged[J]. *Fertil Steril*, 2025, 123(6): 1140-1142.
- [5] Luzarraga Aznar A, Canton R, Loren G, et al. Current challenges and emerging tools in endometrial cancer diagnosis[J]. *Int J Gynecol Cancer*, 2025, 35(4): 100056.
- [6] Rullo S, Sorrenti G, Marziali M, et al. Office hysteroscopy: comparison of 2.7- and 4-mm hysteroscopes for acceptability, feasibility and diagnostic accuracy[J]. *J Reprod Med*, 2005, 50(1): 45-48.
- [7] Anon. ACOG technology assessment No.13 summary: hysteroscopy [J]. *Obstet Gynecol*, 2018, 131(5): 1.
- [8] Moore JF, Carugno J. Hysteroscopy[M]//StatPearls[Internet]. Treasure Island (FL): StatPearls Publishing, 2025.
- [9] Varghese C, Harrison EM, O'Grady G, et al. Artificial intelligence in surgery[J]. *Nat Med*, 2024, 30(5): 1257-1268.
- [10] Chen X, Wang X, Zhang K, et al. Recent advances and clinical applications of deep learning in medical image analysis[J]. *Med Image Anal*, 2022, 79: 102444.
- [11] Tran KA, Kondrashova O, Bradley A, et al. Deep learning in cancer diagnosis, prognosis and treatment selection[J]. *Genome Med*, 2021, 13(1): 152.
- [12] Rai R. Deep learning in image segmentation for cancer[J]. *J Med Radiat Sci*, 2024, 71(4): 505-508.
- [13] Zhou T, Cheng Q, Lu H, et al. Deep learning methods for medical image fusion: a review[J]. *Comput Biol Med*, 2023, 160: 106959.
- [14] Nakamura Y, Higaki T, Tatsugami F, et al. Possibility of deep learning in medical imaging focusing improvement of computed tomography image quality[J]. *J Comput Assist Tomogr*, 2020, 44(2): 161-167.
- [15] Dang C, Qi Z, Xu T, et al. Deep learning-powered whole slide image analysis in cancer pathology[J]. *Lab Invest*, 2025, 105(7): 104186.
- [16] Yue T, Wang Y, Zhang L, et al. Deep learning for genomics: from early neural nets to modern large language models[J]. *Int J Mol Sci*, 2023, 24(21): 15858.
- [17] Sistaninejad B, Rasi H, Nayeri P. A review paper about deep learning for medical image analysis[J]. *Comput Math Methods Med*, 2023, 2023: 7091301.
- [18] Zhang KZ, Wang HB, Cheng YR, et al. Early gastric cancer detection and lesion segmentation based on deep learning and gastroscopic images[J]. *Sci Rep*, 2024, 14(1): 7847.
- [19] Wang L, Chen RY, Weng JJ, et al. Detecting and localizing cervical lesions in colposcopic images with deep semantic feature mining[J]. *Front Oncol*, 2024, 14: 1423782.
- [20] Guo YS, Li CB, Zhang SH, et al. U-net-based assistive identification of bladder cancer: a promising approach for improved diagnosis[J]. *Urol Int*, 2024, 108(2): 100-107.
- [21] Peeri NC, Bertrand KA, Na RH, et al. Understanding risk factors for endometrial cancer in young women[J]. *J Natl Cancer Inst*, 2025, 117(1): 76-88.
- [22] Corr BR, Erickson BK, Barber EL, et al. Advances in the management of endometrial cancer[J]. *BMJ*, 2025, 388: e080978.
- [23] Agusti N, Kanbergs A, Nitecki R. Potential of molecular classification to guide fertility-sparing management among young patients with endometrial cancer[J]. *Gynecol Oncol*, 2024, 185: 121-127.
- [24] PDQ Screening and Prevention Editorial Board. Endometrial Cancer Screening (PDQ®): Health Professional Version. 2025 Apr 10. In: PDQ Cancer Information Summaries[EB]. Bethesda (MD): National Cancer Institute (US), 2002.
- [25] Takahashi Y, Sone K, Noda K, et al. Automated system for diagnosing endometrial cancer by adopting deep-learning technology in hysteroscopy[J]. *PLoS One*, 2021, 16(3): e0248526.
- [26] Zhao AH, Du X, Yuan SZ, et al. Automated detection of endometrial polyps from hysteroscopic videos using deep learning[J]. *Diagnostics (Basel)*, 2023, 13(8): 1409.
- [27] Kitaya K, Yasuo T, Yamaguchi T. Bridging the diagnostic gap between histopathologic and hysteroscopic chronic endometritis with deep learning models[J]. *Medicina (Kaunas)*, 2024, 60(6): 972.
- [28] Zhang YZ, Wang ZH, Zhang J, et al. Deep learning model for classifying endometrial lesions[J]. *J Transl Med*, 2021, 19(1): 10.
- [29] Raimondo D, Raffone A, Salucci P, et al. Detection and classification of hysteroscopic images using deep learning[J]. *Cancers (Basel)*, 2024, 16(7): 1315.
- [30] 曹明亮, 尹蜜, 王庆彬, 等. 基于深度学习算法联合 Grad-CAM 的宫腔镜子宫内膜病变诊断模型研究[J]. *实用妇产科杂志*, 2024, 40(5): 409-413.
- [30] Cao ML, Yin M, Wang QB, et al. Research on diagnosis model of endometrial lesions by hysteroscopy based on deep learning algorithm combined with Grad-CAM[J]. *Journal of Practical Obstetrics and Gynecology*, 2024, 40(5): 409-413.
- [31] Török P, Harangi B. Digital image analysis with fully connected convolutional neural network to facilitate hysteroscopic fibroid resection[J]. *Gynecol Obstet Invest*, 2018, 83(6): 615-619.
- [32] Wang D, Dai W, Tang D, et al. Deep learning approach for bubble segmentation from hysteroscopic images[J]. *Med Biol Eng Comput*, 2022, 60(6): 1613-1626.
- [33] Li BH, Chen H, Duan H. Artificial intelligence-driven prognostic system for conception prediction and management in intrauterine adhesions following hysteroscopic adhesiolysis: a diagnostic study using hysteroscopic images[J]. *Front Bioeng Biotechnol*, 2024, 12: 1327207.
- [34] Li BH, Chen H, Duan H. Visualized hysteroscopic artificial intelligence fertility assessment system for endometrial injury: an image-deep-learning study[J]. *Ann Med*, 2025, 57(1): 2478473.
- [35] Lim JW, Simpson A, Shirreff L. Endometrial polyps[J]. *CMAJ*, 2024, 196(8): E265.
- [36] 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.
- [37] Carey-Love A, Bradley L, Kho RM. Diagnostic considerations and surgical techniques for a large prolapsing submucosal myoma[J]. *Fertil Steril*, 2023, 120(4): 920-921.
- [38] 全培青. 宫腔镜手术治疗粘膜下子宫肌瘤患者的临床疗效及并发症发生率分析[J]. *中国医疗器械信息*, 2023, 29(6): 127-129.
- [38] Quan PQ. Clinical efficacy analysis of hysteroscopic surgery for patients with mucosal uterine fibroids and complications[J]. *China Medical Device Information*, 2023, 29(6): 127-129.
- [39] Xu R, Zhou XF, Wang LF, et al. Gas embolism during surgical hysteroscopy leading to cardiac arrest and refractory hypokalemia: a case report and review of literature[J]. *Medicine (Baltimore)*, 2023, 102(37): e35227.
- [40] Liu TT, He B, Xu XB. Repairing and regenerating injured endometrium methods[J]. *Reprod Sci*, 2023, 30(6): 1724-1736.
- [41] AAGL Elevating Gynecologic Surgery. AAGL practice report: practice guidelines on intrauterine adhesions developed in collaboration with the European Society of Gynaecological Endoscopy (ESGE)[J]. *Gynecol Surg*, 2017, 14(1): 6.
- [42] Yang JY, Liu JJ, Xu N, et al. TVT: transferable vision transformer for unsupervised domain adaptation [C]//2023 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). Piscataway, NJ, USA: IEEE, 2023: 520-530.
- [43] Misera L, Müller-Franzes G, Truhn D, et al. Weakly supervised deep learning in radiology[J]. *Radiology*, 2024, 312(1): e232085.
- [44] Wang T, Wen Y, Wang Z. nnU-Net based segmentation and 3D reconstruction of uterine fibroids with MRI images for HIFU surgery planning[J]. *BMC Med Imaging*, 2024, 24(1): 233.
- [45] Chopra H, Munjal K, Arora S, et al. Role of augmented reality in surgery: editorial[J]. *Int J Surg*, 2024, 110(5): 2526-2528.

(编辑:谭斯允)