

半监督学习模型在反流性食管炎Los Angeles分级中的应用

赵航^{1,2}, 徐晓丹², 朱锦舟¹

1. 苏州大学附属第一医院消化内科, 江苏 苏州 215506; 2. 苏州大学附属常熟医院消化内科, 江苏 苏州 215005

【摘要】目的:利用SimCLR算法的半监督学习框架,构建对内镜下反流性食管炎Los Angeles分级的分类模型。**方法:**设计的学习框架利用大型未标注数据集,通过自监督学习方式进行预训练。该框架在小型标注数据集上,按照Los Angeles分级标准进行了进一步的精准训练。在独立数据集上对该模型进行性能测试,并将其评估结果与监督学习算法的模型以及内镜医生的表现进行对比,指标包括准确度、Matthews相关系数以及Cohen's kappa值。最后,采用Grad-CAM和t-SNE对模型进行可视化解释。**结果:**采用ResNet作为骨干网络的SimCLR模型,在准确度、Matthews相关系数和Cohen's kappa值为0.840、0.800、0.960,均显著超越了以ResNet为基础的传统监督学习模型(0.680、0.601、0.870),同时也超过了低年资内镜医生的水平(0.770、0.713、0.940),与高年资内镜医生的表现(0.850、0.813、0.960)相比,仍存在一定的细微差距。此外,t-SNE的结果显示,SimCLR中的自监督学习在对多维度样本进行聚类方面,比传统的监督迁移学习更为有效。**结论:**相较传统的监督学习方法,半监督学习技术在仅具备有限标记内镜图像的情况下,仍能使深度学习模型展现出卓越的性能。

【关键词】反流性食管炎;自监督学习;对比学习视觉表示的简单框架;计算机辅助诊断;深度学习;Grad-CAM

【中图分类号】R318;R571

【文献标志码】A

【文章编号】1005-202X(2025)09-1236-09

Application of semi-supervised learning models in the Los Angeles grading of reflux esophagitis

ZHAO Hang^{1,2}, XU Xiaodan², ZHU Jinzhou¹

1. Department of Gastroenterology, the First Affiliated Hospital of Soochow University, Suzhou 215506, China; 2. Department of Gastroenterology, Changshu Affiliated Hospital of Soochow University, Suzhou 215005, China

Abstract: Objective To construct a classification model for the Los Angeles grading of endoscopic reflux esophagitis based on the SimCLR algorithm's semi-supervised learning framework. **Methods** The designed learning framework was pre-trained on a large unlabeled dataset through self-supervised learning, and further finely tuned on a small labeled dataset according to the Los Angeles grading criteria. The performance test on the model was conducted on an independent dataset, and the proposed model was compared with the models of supervised learning algorithms and endoscopists in terms of accuracy, Matthews correlation coefficient, and Cohen's kappa value. Finally, Grad-CAM and t-SNE were used for the visualization of the model's interpretation. **Results** The SimCLR model with ResNet as the backbone network showed superior performance in accuracy (0.840), Matthews correlation coefficient (0.800), and Cohen's kappa value (0.960) than the traditional supervised learning model with ResNet as the backbone (0.680, 0.601, and 0.870) as well as junior endoscopists (0.770, 0.713, and 0.940), but there was still a slight gap compared with senior endoscopists (0.850, 0.813, and 0.960). In addition, the results of t-SNE showed that self-supervised learning in SimCLR was more effective in clustering multi-dimensional samples than traditional supervised transfer learning. **Conclusion** Compared with traditional supervised learning methods, semi-supervised learning demonstrates outstanding performance even with only a small number of labeled endoscopic images.

Keywords: reflux esophagitis; self-supervised learning; simple framework for contrastive learning of visual representation; computer-aided diagnosis; deep learning; Grad-CAM

【收稿日期】2025-02-03

【基金项目】国家自然科学基金(82000540)

【作者简介】赵航, 硕士, 主治医师, 研究方向: 消化内科, E-mail: zhaohang02010527@163.com

【通信作者】朱锦舟, 博士, 副主任医师, 研究方向: 消化内科, E-mail: jzzhu@zju.edu.cn

前言

反流性食管炎是一种由胃和十二指肠内容物反流入食管引起的食管黏膜刺激或损伤的炎症反应, 是一种常见的消化道动力障碍性疾病, 其发生与食管下括约肌张力、食管清除能力降低以及胃和十二指肠功能紊乱有关, 通常表现为烧心、反酸、胸痛和

吞咽困难等症状,容易复发,给患者的工作、生活和心理健康带来巨大压力。由于生活习惯和饮食结构的改变,导致反流性食管炎的发病率呈上升趋势。据统计,约5%~10%的反流性食管炎患者会发展成Barrett食管,2%~5%的Barrett食管可发展成腺癌,这种危险度是正常人群的30~150倍^[1]。有研究报道,食管癌已是全世界范围内常见的恶性肿瘤之一,在我国,食管癌发病率及死亡率分别位列全部恶性肿瘤的第6位和第4位^[2]。因此,对于反流性食管炎的早期诊断与治疗显得尤为重要。

在内镜领域,Los Angeles分级系统^[3]将食管黏膜的破损定义为与周围黏膜分界清楚的白苔或红斑,根据黏膜破损程度分成5级:正常与A~D级。LA分类的正确标记依赖于内镜医生的判断和经验,而非组织学或病理学的确认。可用的正确标记数据来源有限,这使得通过监督迁移学习训练具有良好泛化能力的实用分类模型变得困难。传统的监督学习通过使用带有标签的训练数据来训练模型,以便模型能预测或决定未见过的数据的输出,但这项工作需要大量的标记数据,在某些领域,可能难以获得或成本高昂。在数据有限的情况下进行训练,容易导致过拟合问题,特别是反流性食管炎C、D级标记的图片数量稀少且获取难度大,这进一步影响了传统监督学习模型的表现。

与依赖于传统监督学习的计算机辅助诊断工具不同,近年来,自监督学习(Self-Supervised Learning, SSL)领域的研究取得显著进展,为减少对标注数据集的依赖奠定坚实基础,这种创新方法利用未标记的数据来预训练模型,从而减轻对大量标记数据的需求。在医学图像领域,SSL已成为一门有前途的技术,特别是对于医学图像中的复杂特征和病变的识别有着巨大的优势。在医学图像分析研究领域,对比学习作为一种新颖的SSL方法,正日益受到广泛的关注。2020年,Chen等^[4]引入一个用于视觉表示对比学习的简单框架(SimCLR),通过结合数据增强技术及更大的批量大小,SimCLR在各种对比学习方法中取得显著的成效。

本研究旨在开发一个基于LA分级系统的半监督学习框架(SimCLR),用于反流性食管炎内镜图像的分类。首先,所提出的框架在SSL下使用大量关于反流性食管炎内镜图像的未标记数据集进行训练;随后,在目标任务的有限数据集上进行微调;最后,所提出的框架在独立数据集上进行测试,并与基于监督迁移学习和内镜医生的模型进行比较。

1 资料与方法

1.1 研究方法与数据集

本研究为多中心回顾性分析,图片纳入标准:①符合《中国胃食管反流病诊疗规范》^[3]的诊断标准;②采集内镜图片清晰。排除标准:质量不合格,观察受干扰严重的图片。反流性食管炎LA分级正常(0级):食管粘膜无破损;A级:一个或一个以上粘膜破损,长径小于5 mm;B级:一个或一个以上粘膜破损,长径大于5 mm,但没有融合性病变;C级:粘膜破损有融合,但小于75%的食管周径;D级:粘膜破损有融合,至少达到75%的食管周径。本研究经苏州大学附属第一医院伦理委员会审批通过(批号:2022098)。

1.1.1 HyperKvasir HyperKvasir是一个为胃肠道内镜检查设计的大规模多类别图片和视频数据集。数据集包含多种类型的胃肠道病变图片和视频,包括息肉、癌症、炎症等病变以及正常组织的内镜图片。该数据集可以用于多种计算机视觉和机器学习任务,如图像分类、目标检测、分割以及视频分析等^[5]。苏州大学附属第一医院3名拥有超过10年经验的内镜医生对600张未标记的内镜图像进行筛选。

1.1.2 常熟一院数据集 该数据集收集428例反流性食管炎的内镜图像,为防止重复和确保图像质量,上述3名内镜医生标记了134张符合条件的反流性食管炎LA分型内镜图像。利用已标记的图像对半监督模型实施精细调整。

1.1.3 苏州大学附属第一医院数据集 共收集来自苏州大学附属第一医院的319例反流性食管炎的内镜图像,包括0级81例、A级95例、B级70例、C级53例、D级20例。3名资深内窥镜医生根据LA分型独立标记94张合格的图像。该数据集被用作外部测试数据集。

1.1.4 内镜医生 为了进一步评估模型的性能,来自测试数据集(苏州大学附属第一医院)的图像由两名独立的内镜医生进行评估,他们分别是有3年内镜经验的低年资医生和有10年以上内镜经验的高年资医生,他们没有参与训练图像的审查或标记,并且也未参与过测试集图像的收集。提供134张标记图像作为参考,然后他们分别对94张测试图像进行分类。此外,为了模拟真实的临床环境,要求这两位内镜医生在10 min内完成分类任务。为此还构建了一个网页界面,允许审阅者对每张图像进行窗口调整、放大、操作和分类。

1.2 半监督学习框架(SimCLR)

本研究提出的半监督学习框架由自监督学习(图1)和微调组成(图2)。

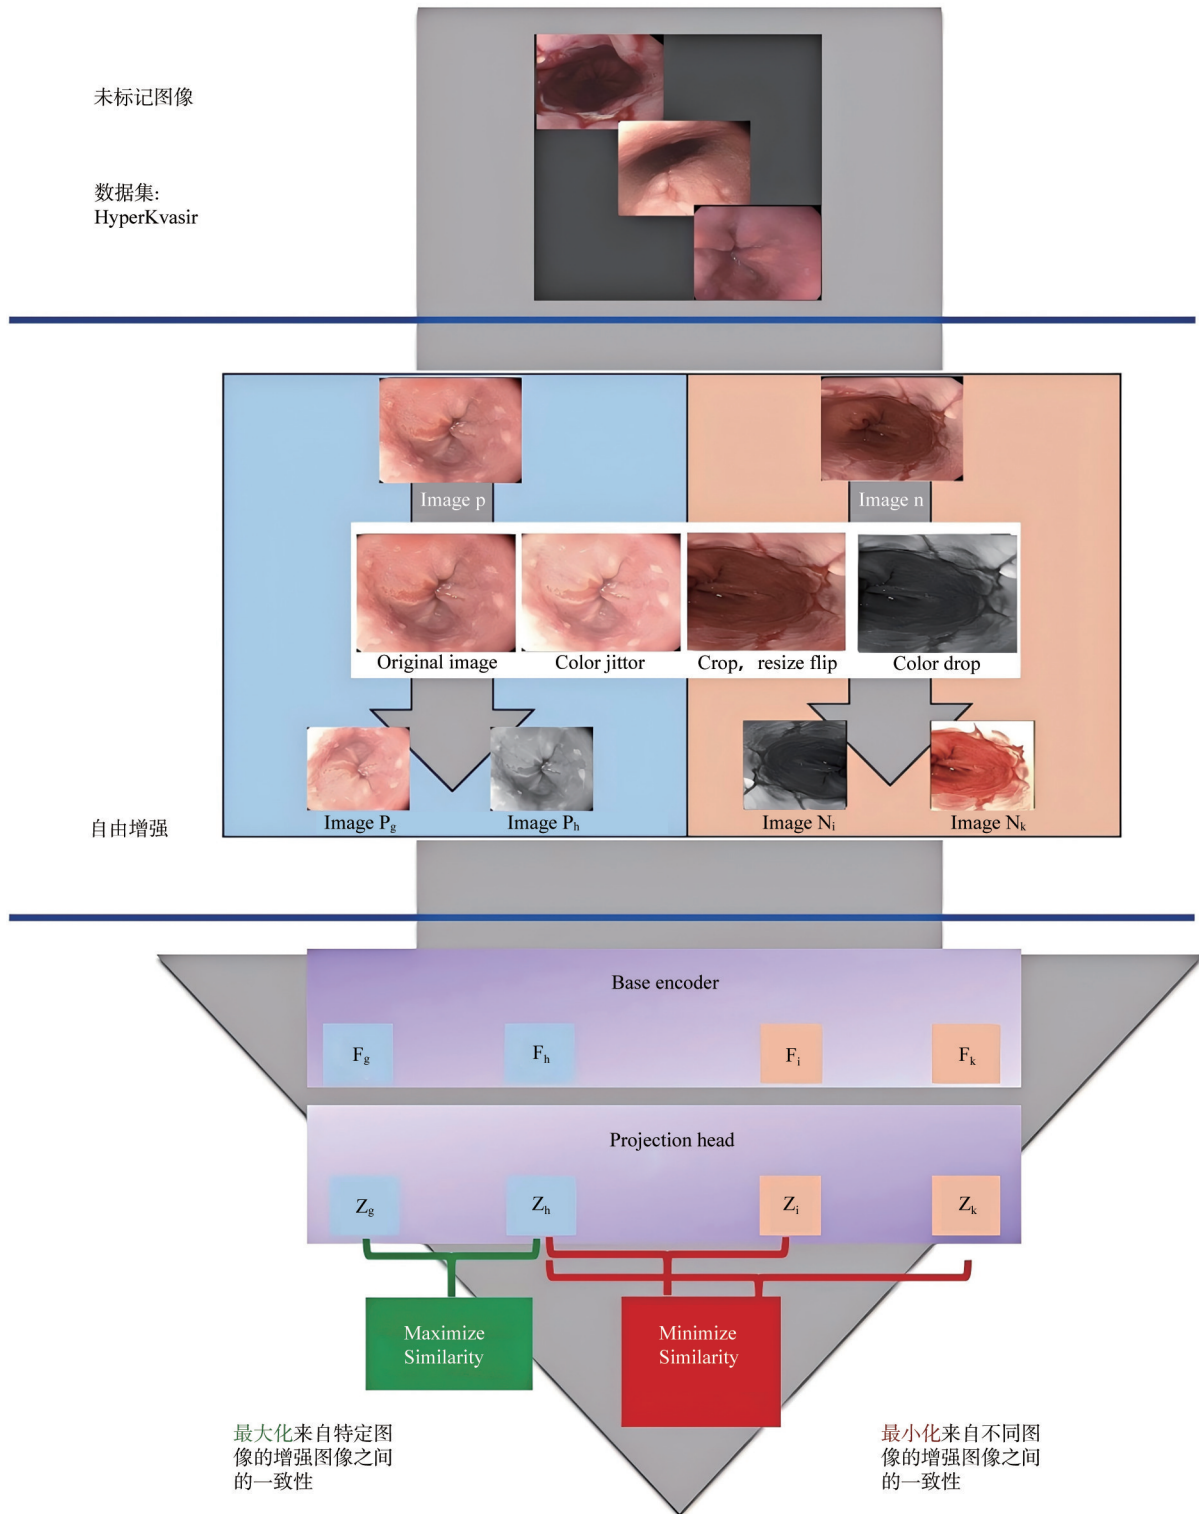


图1 自监督学习
Figure 1 Self-supervised learning

1.2.1 自我监督学习 自监督学习模型由3个主要部分组成:数据增强、基础编码器和投影头。其中,数据增强包括一系列不同的组合,如裁剪、翻转和颜色失真。增强模块通过随机变换数据样本,生成特定图像的相关视图对,如 P_g 与 P_h , 它们被视为正样本对。该模块还随机生成来自不同图像的不相关视

图,即 P_h 与 N_i 和 P_h 与 N_k , 这些是负样本对^[4]。基础编码器用于从增强后的数据样本中提取表示向量,该框架允许在没有任何限制的情况下选择不同的网络架构。投影头将表示映射到应用对比损失的空间。

本研究使用来自 HyperKvasir^[5] 的未标记 LA 反流性食管炎内镜图像来训练 SSL 模型。以 VGG16、

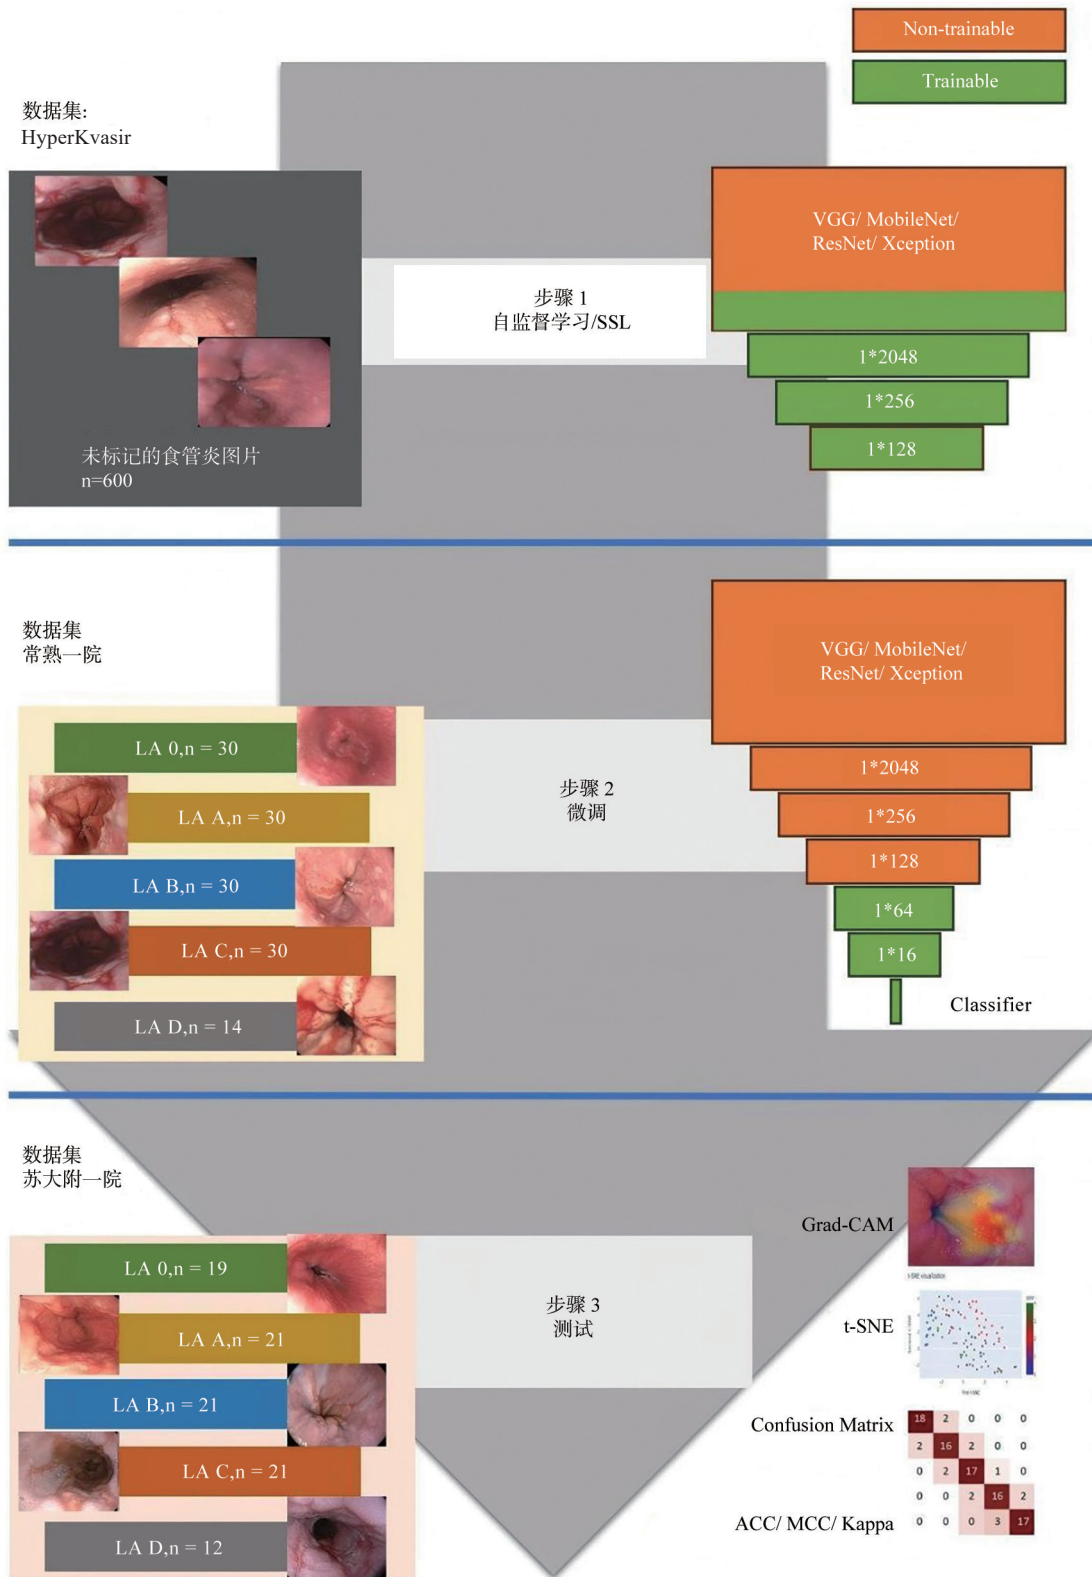


图2 SimCLR框架
Figure 2 SimCLR framework

MobileNet、ResNet50 和 Xception(经 ImageNet 初始训练)为基础编码器的主干网络,由于内镜成像的特殊性,以上卷积神经网络采用极坐标系进行图像处理,相比于笛卡尔坐标系,具有以下优势:在内镜成像中,血管结构往往是圆形或近似圆形,使用极坐标系

可以直接用距离和角度来表示点的位置,这相比在笛卡尔坐标系中使用复杂的方程或曲线来表示更直接和简单;同时在内窥镜成像中,角度信息对于病灶的识别和尺寸测量非常重要,极坐标系中角度直接用角度值表示,而在笛卡尔坐标系中则需要使用三

角函数来表示角度,因此采用极坐标系可提高数据处理效率;此外,基于极坐标系建模的图像分割方法能保证分割结果的拓扑关系符合医学先验知识,这对于临床参数的准确计算有着重要影响。综上所述,极坐标系在内窥镜成像中的应用能更好地反映像素之间的前后关系和病灶尺寸,提供一种更直观、准确的图像处理方法。在上述4个卷积神经主干网络,手动移除头部,并在基础上添加3个全连接层(1×2048、1×256和1×128)。在SSL过程中,最后3个卷积层以及所添加的3个全连接层被设定为可训练状态,而主干网络中的其余层则保持不可训练。

1.2.2 微调 在最初使用SSL模型进行训练之后,半监督模型使用常熟一院数据集中标记的反流性食管

炎图像进行了微调。添加两个额外的全连接层(1×64和1×16)以及一个分类器,在微调过程中,只有这两个新添加的层和分类器是可训练的,用于目标分类任务,而其他层则是不可训练的。

1.2.3 监督迁移学习 在数据集上进行监督迁移学习作为微调,即对常熟一院数据集进行微调。与SSL的情况一样,加载其他4个在ImageNet上预训练的网络(图3)。同样,在没有头部的主干网络上添加5个全连接层(1×2048、1×256、1×128、1×64和1×16)以及一个分类器。在监督迁移学习过程中,最后的3个卷积层、5个添加的全连接层和分类器是可训练的,而其他层是不可训练的。

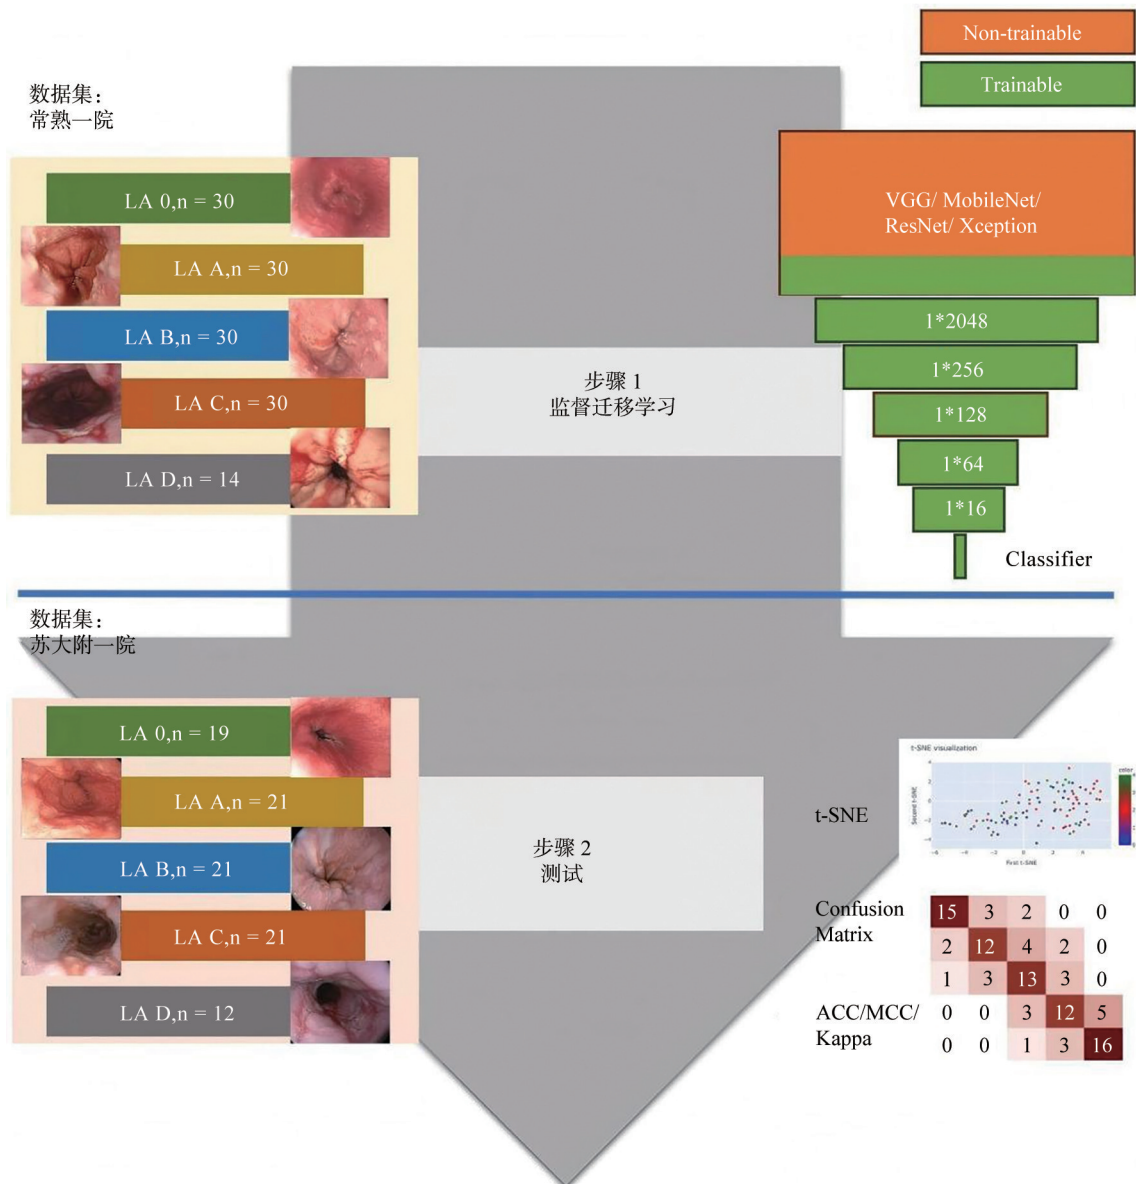


图3 监督迁移学习框架

Figure 3 Supervised transfer learning framework

1.2.4 模型训练 使用 Keras (版本 3.8.0) 和 TensorFlow (版本 2.8.0) 平台进行模型训练。每张图像被调整为 224×224 像素,并以 RGB 通道的形式输入到模型中。训练代码可在 <https://osf.io/t3g8n> 上获得。

1.3 统计学分析

构建一个混淆矩阵用于评估模型和内镜医生的性能。TN、FN、TP 和 FP 分别代表真阴性、假阴性、真阳性和假阳性。准确率表示所有样本中被正确分类的样本的比例。Matthews 相关系数 (MCC) 衡量实际值和预测值之间的差异,是总结混淆矩阵的最佳单一值分类度量指标^[6]。Cohen's Kappa 用于衡量两位评估者或裁判员之间的一致性水平,他们各自将项目分类为互斥的类别^[7]。

1.4 模型解释

1.4.1 t-SNE 分析 在本研究中,模型生成的预测聚类模式通过 t-SNE 技术进行可视化,t-SNE 是一种用于降低数据维度的无监督技术^[8]。通过结合主成分分析初始化使用 t-SNE 处理了高维向量,并将其转换为二维可视化,展现局部结构和全局几何形状。

1.4.2 Grad-CAM Grad-CAM 是一种用于可视化深度学习模型中特征重要性的工具,特别是在卷积神经网络 (CNN) 中,能突出显示输入图像中对模型输出类别决策贡献最大的区域,这项技术可以提供对网络决策过程的深入理解。

2 结果

2.1 模型的性能

本研究提出 4 种半监督学习 (SimCLR) 模型,使用不同的骨干网络 (VGG16、MobileNet、ResNet 和 Xception) 以及基于监督迁移学习的方法,都是针对 LA 分类的多元任务构建的。这些模型在外部测试集上的性能展示在表 1 中。基于 ResNet 的 SimCLR 模型达到最高的准确率 (0.840),其次是使用 Xception 的 SimCLR 模型 (0.830) 以及使用 VGG16 的 SimCLR 模型 (0.810)。SimCLR-ResNet 的 MCC 和 Cohen's kappa 值分别为 0.800 和 0.960,以及 95% 置信区间 [0.940-0.980],这些值都超过了其他模型。混淆矩阵在图 4 中进行了展示。

表 1 模型和内镜医生在外部测试集的分类性能

Table 1 Classification performance of models and endoscopists in external test dataset

模型/内镜医生		准确率	MCC	Cohen's kappa	用时/s
半监督学习 (SimCLR)	VGG16	0.810	0.763	0.950 [0.930-0.970]	3.1
	MobileNet	0.780	0.725	0.940 [0.920-0.970]	1.9
	ResNet	0.840	0.800	0.960 [0.940-0.980]	2.2
	Xception	0.830	0.788	0.960 [0.940-0.980]	2.3
监督学习	VGG16	0.630	0.538	0.830 [0.770-0.900]	3.1
	MobileNet	0.650	0.563	0.860 [0.810-0.920]	1.9
	ResNet	0.680	0.601	0.870 [0.820-0.930]	2.2
	Xception	0.690	0.613	0.860 [0.800-0.920]	2.3
低年资内镜医生		0.770	0.713	0.940 [0.920-0.970]	369.6
高年资内镜医生		0.850	0.813	0.960 [0.940-0.980]	305.4

2.2 与内镜医生的比较

高年资内镜医生拥有比 SimCLR-ResNet 模型更高的准确率、MCC 和 Cohen's kappa 系数 (分别为 0.850、0.813 和 0.960, 以及 95% 置信区间 [0.940-0.980])。低年资内镜医生的准确率、MCC 和 Cohen's kappa 系数分别为 0.770、0.713 和 0.940, 以及 95% 置信区间 [0.920-0.970], 这些指标均低于 4 个 SimCLR 模型的性能表现。

2.3 模型与内镜医师在测试集中读片用时的比较

在外部测试集中,所有深度学习模型在 94 张图

片预测用时 1.9~3.1 s, 速度显著优于内镜医生 (低年资 369.6 s, 高年资 305.4 s, 表 1)。

2.4 模型的可视化解释

利用 t-SNE 技术对监督迁移学习和 SimCLR 的特征提取层输出进行可视化处理,相关结果如图 5 所示。在 SimCLR 的半监督学习 (SSL) 架构下,多维样本的聚类效果相较于监督迁移学习表现更佳。此外,基于 SimCLR-ResNet 模型的输出,生成了 Grad-CAM 可视化图像,同时,在图 6 中提供基于人工智能推断的病变区域的推理阐释。

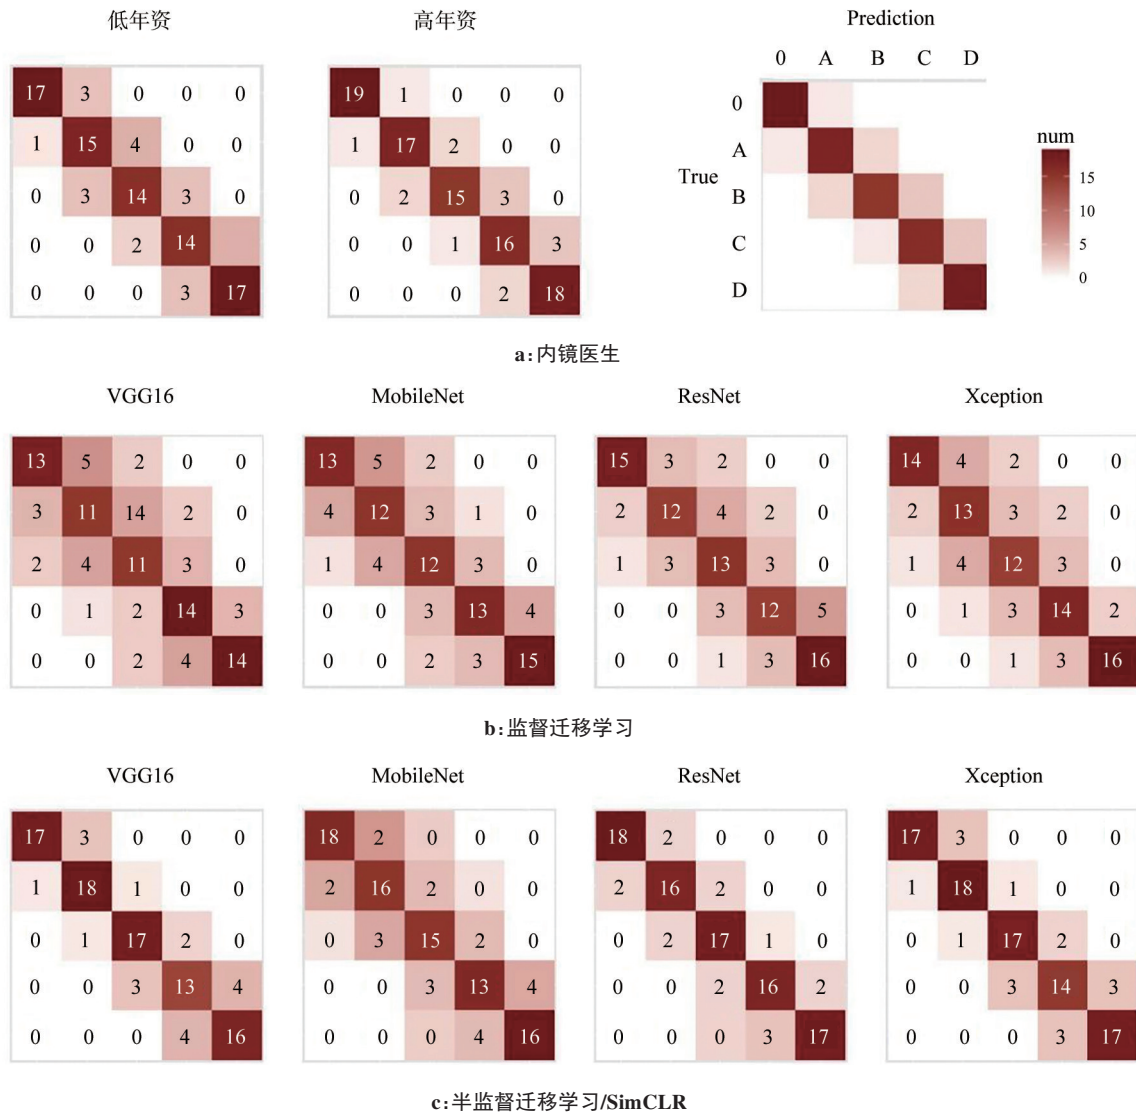


图4 混淆矩阵

Figure 4 Confusion matrices

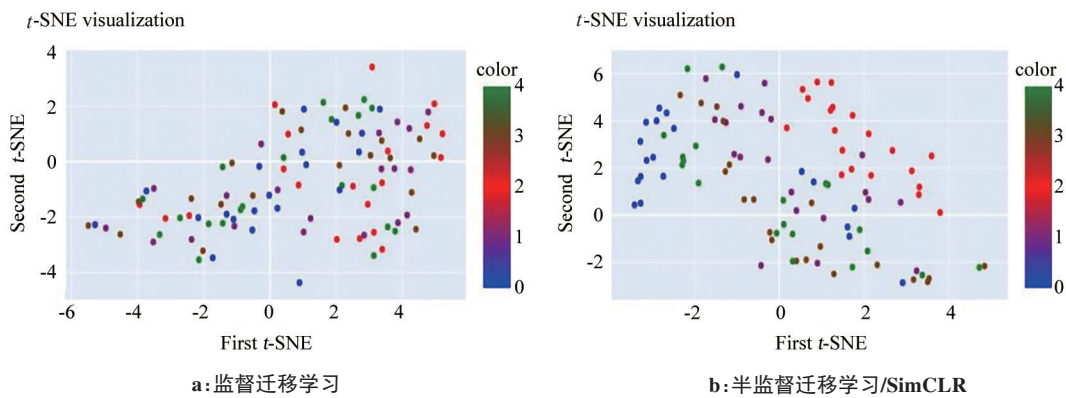


图5 t-SNE 可视化测试数据集中嵌入的特征

Figure 5 t-SNE visualization of embedded features in the test dataset

a: 监督式迁移学习: 大多数位于聚类边缘的点重叠, 边界不清晰; b: SimCLR: 多个聚类的分离显然比部分A要好得多

3 讨论

本研究基于 SimCLR 开发一系列半监督学习模

型, 用于根据 LA 分类对反流性食管炎进行分类。采用 ResNet 作为主干网络的 SimCLR 模型在性能上优

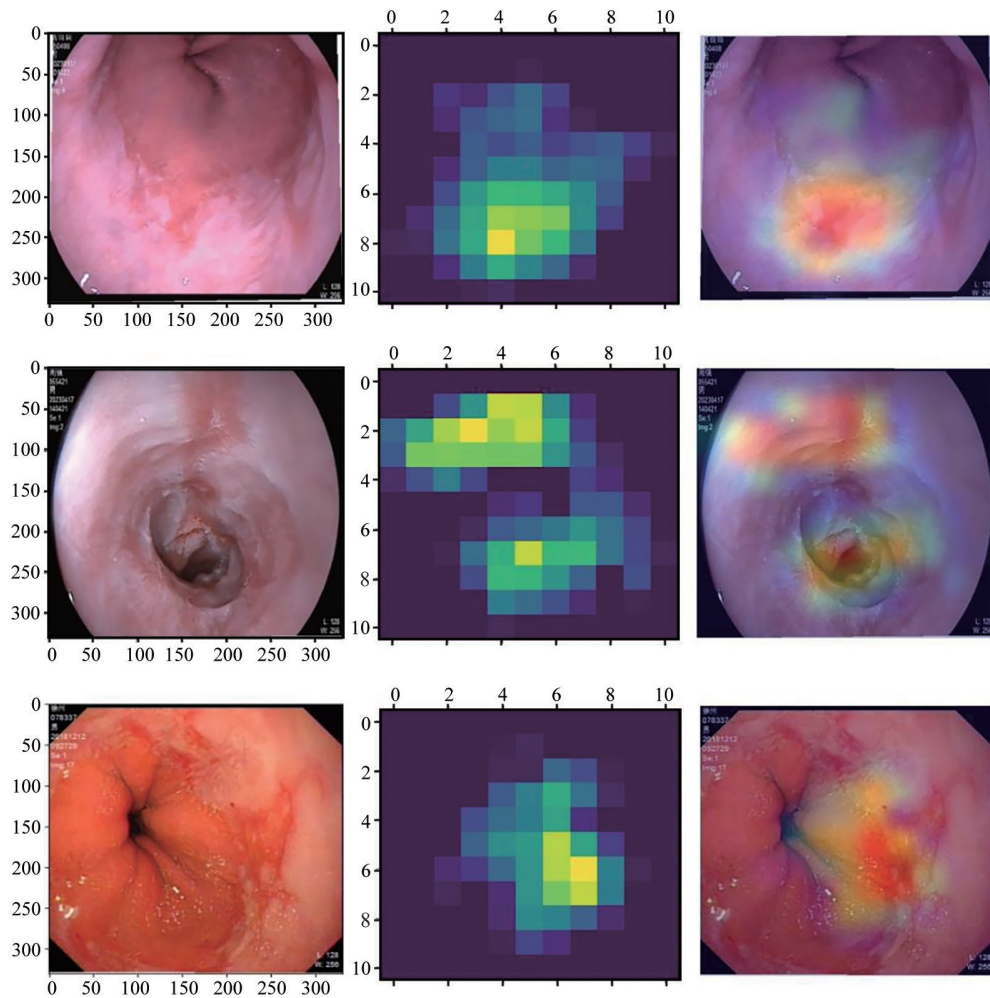


图6 通过 Grad-CAM 可视化 SimCLR-ResNet 的推理

Figure 6 Visualizing the SimCLR-ResNet inference using Grad-CAM

左列:原始的内镜图像;中列:基于 SimCLR-ResNet 特征提取器的最后一层输出的热图;右列:覆盖原始图像的 Grad-CAM 热图,突出显示模型的推理解释

于基于监督迁移学习的模型和低年资内镜医生,同时它的表现仅略低于高年资内镜医生。本研究的新框架由两部分组成:在大量未标记的食管炎内镜图像上进行 SSL 以及在少量根据 LA 分类标记的反流性食管炎内镜图像上进行微调。结果显示,相较传统上依赖大量标记数据的监督学习方法,结合 SSL 与微调的策略能促使人工智能模型在减少对大量标记数据依赖的同时展现出更优异的性能。

在医学图像分析这一领域,深度学习在诸如病理学、放射学和内窥镜检查等多个领域取得卓越的成效^[9-10]。然而,深度学习在资源有限的环境中应用时,由于可靠标记数据的缺乏,面临着挑战^[11]。SSL 是一个新颖的解决方案,它成功地利用了各种有效的深度学习模型^[12]。这些模型首先在没有监督的条件下,使用源数据集进行预训练,然后针对目标任务进行微调^[13]。针对特定领域的 SSL 已被证明在提升医学图像分类性能方面,相较通用的预训练模型更

具成效^[14]。盖晋平等^[15]采用 SimCLR 作为深度神经网络的骨干,对宫颈细胞进行分类,以少量的标注数据缓解了深度学习在解决宫颈细胞分类需要大量标注数据的问题。乔丽等^[16]通过 SimCLR 的自监督学习方法,展示了其在糖尿病视网膜病变诊断中的应用潜力。与传统的监督学习相比,SSL 可以用于辅助诊断那些标记起来困难且耗时的疾病。

当前的主流算法仍然是监督学习^[17-19]。张晨霞等^[20]提出一个基于深度学习的超声内镜下消化道黏膜下肿物诊断系统,使用 3 400 张标记的 EUS 图像,对于鉴别胃肠道间质瘤与平滑肌瘤的准确率为 86.7%。近年来,随着自监督学习的引入和成熟,它也逐渐应用于内窥镜领域。Gan 等^[21]提出一种名为特征金字塔孪生网络的自监督表示学习方法,在结直肠息肉检测任务中取得出色的表现。Guo 等^[22]提出一个 SSL 框架,通过结合课程学习来减轻由强烈数据增强引起的加性噪声的负面影响,其准确率达 88.92%,有望成为使用内镜检查监

测胃肠道疾病的可靠辅助工具。这些研究表明SSL技术在内镜诊断中的潜力^[12,14]。对比学习和SSL方法的应用在准确性和性能上取得显著的改进,解决了标记数据有限的挑战。

在食管疾病的诊治中,Ge等^[23]开发一系列基于深度学习的计算机视觉模型,这些模型通过内镜检查图像的分析,利用可解释的Grad-CAM技术评估其在反流性食管炎内镜图像多分类任务中的可行性,该研究首次表明,基于深度学习的分类器在食管炎的内镜诊断中具有显著的应用前景。Tang等^[24]训练了一个多任务深度学习模型,用于诊断食管病变(正常、癌症、食管炎),该模型在复杂分类任务中达到高准确率(93.43%),并且在语义分割方面也取得了令人满意的DSC值(77.84%)。这些研究表明,深度学习技术在食管疾病的诊断中具有巨大的潜力,能提高诊断的准确性和效率。通过自动化的特征提取和图像分析,这些模型有助于减轻医生的工作负担,并可能改善患者的治疗效果。随着技术的不断进步,预计未来在食管疾病诊断和治疗方面将有更多的创新和应用。

本研究开发了一个基于SimCLR的半监督学习框架,用于根据LA分类对反流性食管炎内镜图像进行分类,与传统的监督学习相比,SSL使深度学习模型能在有限的标记图像数量下实现性能的改进。在开发的模型中,基于ResNet的SimCLR模型比基于监督迁移学习的模型表现更好;半监督学习模型的表现超过了低年资内镜医生,仅比高年资内镜医生的准确率略低。本研究也存在一些局限性:(1)公共数据集中临床细节与患者信息的缺失,加之回顾性偏见的存在,导致无法与数据集进行深入比较并提供详尽的细节;(2)LA分类高度依赖于内镜医生的主观判断,因此不同医生对同一病变的评估可能存在差异;(3)LA分类主要聚焦于食管黏膜的宏观表现,可能无法全面反映微观组织学变化;(4)尽管比较了监督、半监督模型和内镜医生的分类表现,但未进行半监督模型辅助内镜医生分类的观察性研究;(5)需要进一步的模型部署来实现实时分类,以评估半监督模型在临床应用中的效果。

【参考文献】

- [1] 李廷青. Barrett食管与食管腺癌的关系[J]. 中华消化杂志, 2006, 26(2): 118-119.
Li YQ. The relationship between Barrett's esophagus and esophageal adenocarcinoma [J]. Chinese Journal of Digestion, 2006, 26(2): 118-119.
- [2] 中华人民共和国国家卫生健康委员会医政医管局. 食管癌诊疗指南(2022年版)[J]. 中华消化外科杂志, 2022, 21(10): 1247-1268.
Bureau of Medical Administration, National Health Commission of the People's Republic of China. Standardization for diagnosis and treatment of esophageal cancer (2022 edition)[J]. Chinese Journal of Digestive Surgery, 2022, 21(10): 1247-1268.
- [3] 中华医学会消化病学分会胃肠动力学组, 胃肠功能性疾病协作组, 食管疾病协作组. 中国胃食管反流病诊疗规范[J]. 中华消化杂志, 2023, 43(9): 588-598.
Chinese Society of Gastroenterology, Chinese Medical Association, Gastrointestinal Motility Group, Chinese Society of Gastroenterology, Chinese Medical Association, Functional Gastrointestinal Disease

- Group, Chinese Society of Gastroenterology, Chinese Medical Association, Esophageal Disease Group. Chinese guideline for diagnosis and treatment of gastroesophageal reflux disease [J]. Chinese Journal of Digestion, 2023, 43(9): 588-598.
- [4] Chen T, Kornblith S, Norouzi M, et al. A simple framework for contrastive learning of visual representations[EB/OL]. (2020-07-01) [2024-11-10]. <https://arxiv.org/abs/2002.05709>.
- [5] Borgli H, Thambawita V, Smedsrud PH, et al. HyperKvasir, a comprehensive multi-class image and video dataset for gastrointestinal endoscopy[J]. Sci Data, 2020, 7(1): 283.
- [6] Chicco D, Jurman G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation[J]. BMC Genomics, 2020, 21(1): 6.
- [7] Um Y. Assessing classification accuracy using Cohen's kappa in data mining[J]. J Korea Soc Comput Inf, 2013, 18(1): 177-183.
- [8] Liu JK, Vinck M. Improved visualization of high-dimensional data using the distance-of-distance transformation[J]. PLoS Comput Biol, 2022, 18(12): e1010764.
- [9] 黄丽, 张军, 吴慧玲, 等. 基于深度学习的内镜超声胆管扫描辅助分站系统构建[J]. 中华消化内镜杂志, 2022, 39(4): 295-300.
Huang L, Zhang J, Wu HL, et al. Development of auxiliary substation system for endoscopic ultrasound bile duct scanning based on deep learning[J]. Chinese Journal of Digestive Endoscopy, 2022, 39(4): 295-300.
- [10] 黄翔, 曹康养, 邹玉坚, 等. 基于T₂WI的ResNet深度学习模型术前预测膀胱癌病理分级的研究[J]. 磁共振成像, 2024, 15(1): 125-131.
Huang X, Cao KY, Zou YJ, et al. Preoperative prediction of pathological grading in bladder cancer by deep residual network model based on T₂WI[J]. Chinese Journal of Magnetic Resonance Imaging, 2024, 15(1): 125-131.
- [11] Theodoris CV, Xiao L, Chopra A, et al. Transfer learning enables predictions in network biology[J]. Nature, 2023, 618(7965): 616-624.
- [12] Huang SC, Pareek A, Jensen M, et al. Self-supervised learning for medical image classification: a systematic review and implementation guidelines[J]. NPJ Digit Med, 2023, 6(1): 74.
- [13] Mukashyaka P, Sheridan TB, Foroughi Pour A, et al. SAMPLER: unsupervised representations for rapid analysis of whole slide tissue images[J]. EBioMedicine, 2024, 99: 104908.
- [14] Chen YB, Mancini M, Zhu XT, et al. Semi-supervised and unsupervised deep visual learning: a survey[J]. IEEE Trans Pattern Anal Mach Intell, 2024, 46(3): 1327-1347.
- [15] 盖晋平, 秦健, 何勇军, 等. 一种自监督宫颈细胞分类方法[J]. 哈尔滨理工大学学报, 2022, 27(3): 45-51.
Gai JP, Qin J, He YJ, et al. The method of self-supervised cervical cell classification [J]. Journal of Harbin University of Science and Technology, 2022, 27(3): 45-51.
- [16] 乔丽, 乔晶晶. 一种基于自监督学习的糖尿病视网膜病变诊断方法[J]. 吕梁学院学报, 2024, 14(2): 24-26.
Qiao L, Qiao JJ. A diabetic retinopathy diagnosis method based on self-supervised learning[J]. Journal of Lyuliang University, 2024, 14(2): 24-26.
- [17] Brand M, Troya J, Krenzer A, et al. Development and evaluation of a deep learning model to improve the usability of polyp detection systems during interventions[J]. United European Gastroenterol J, 2022, 10(5): 477-484.
- [18] Krenzer A, Banck M, Makowski K, et al. A real-time polyp-detection system with clinical application in colonoscopy using deep convolutional neural networks[J]. J Imaging, 2023, 9(2): 26.
- [19] Krenzer A, Heil S, Fitting D, et al. Automated classification of polyps using deep learning architectures and few-shot learning[J]. BMC Med Imaging, 2023, 23(1): 59.
- [20] 张晨霞, 李迅, 姚理文, 等. 基于深度学习的超声内镜下消化道黏膜下肿物诊断系统[J]. 中华消化杂志, 2022, 42(7): 464-469.
Zhang CX, Li X, Yao LW, et al. Deep learning-based diagnostic system for gastrointestinal submucosal tumor under endoscopic ultrasonography [J]. Chinese Journal of Digestion, 2022, 42(7): 464-469.
- [21] Gan TY, Jin ZY, Yu LL, et al. Self-supervised representation learning using feature pyramid Siamese networks for colorectal polyp detection [J]. Sci Rep, 2023, 13(1): 21655.
- [22] Guo H, Somayajula SA, Hosseini R, et al. Improving image classification of gastrointestinal endoscopy using curriculum self-supervised learning[J]. Sci Rep, 2024, 14(1): 6100.
- [23] Ge HL, Zhou X, Wang Y, et al. Development and validation of deep learning models for the multiclassification of reflux esophagitis based on the Los Angeles classification[J]. J Healthc Eng, 2023, 2023: 7023731.
- [24] Tang SG, Yu XY, Cheang CF, et al. Diagnosis of esophageal lesions by multi-classification and segmentation using an improved multi-task deep learning model[J]. Sensors (Basel), 2022, 22(4): 1492.

(编辑:谭斯允)