

人工智能在血管超声中的应用现状及进展

罗嘉宝^{1,2}, 张 峰^{1,2}

摘要: 人工智能(AI)技术,特别是机器学习(ML)算法,近年来在医学图像分析领域取得了显著进展。血管超声作为一种无创、实时、经济的检查方式,是人工智能在医学应用中最活跃的方向之一。本文对2021—2025年AI在血管超声图像识别、自动分割、辅助诊断及风险预测等方面的最新研究进展进行综述,涵盖经颅多普勒超声、颈动脉、腹主动脉瘤、主动脉夹层、外周动脉疾病、透析通路动静脉瘘、静脉血栓及下腔静脉等内容,分析其技术创新、临床价值与研究挑战。

关键词: 人工智能; 机器学习; 超声; 血管疾病

中图分类号: R445.1 **文献标识码:** A

Application of artificial intelligence in vascular ultrasound: Current status and advances LUO Jiabao, ZHANG Feng.
(Department of Ultrasound, The Sixth Affiliated Hospital of Sun Yat-sen University, Guangzhou 510655, China)

Abstract: Artificial intelligence (AI) technologies, especially machine learning algorithms, have achieved remarkable advances in medical image analysis in recent years. As a noninvasive, real-time, and cost-effective imaging modality, vascular ultrasound is one of the most active areas for the application of AI technologies in medicine. This article reviews the latest research advances in the application of AI in vascular ultrasound image recognition, automatic segmentation, diagnostic assistance, and risk prediction in 2021—2025, covering the aspects of transcranial Doppler, carotid artery, abdominal aortic aneurysms, aortic dissection, peripheral artery disease, arteriovenous fistula, venous thrombosis, and the inferior vena cava. This article highlights the key technological innovations, clinical value, and research challenges of AI within these areas.

Key words: Artificial intelligence; Machine learning; Ultrasound; Vascular disease

随着全球人口老龄化进程加速,吸烟、缺乏运动等不良生活方式的普遍,越来越多个体出现高血压、血脂异常、糖尿病等代谢性疾病,使得血管疾病(包括心血管疾病、周围动脉疾病、脑卒中等)患病率和疾病负担持续升高。超声作为血管评估的一线工具,具有无创、安全、准确且经济等优势,从二维超声到多普勒超声、三维成像,再到腔内超声及功能性测量,其诊断深度与广度正不断提升。但其结果高度依赖操作者经验与主观判断,易受声阻抗差异和伪影干扰影响。近年来,人工智能(artificial intelligence, AI)技术在医学影像领域取得了显著进展,其中以机器学习(machine learning, ML)和深度学习(deep learning, DL)为核心的算法,凭借其强大的数据挖掘与特征学习能力,为超声图像的自动化分析提供了全新的解决方案。ML通过监督、无监督和半监督学习方式,从大量标注或未标注的影像数据中提取特征并进行预测;DL则利用多层人工神经网络,能够在无需手动设计特征提取器的前提下,自动学习分类或分割所需的图像特征,这两者共同推动了AI在医学图像处理中的快速落地与优化^[1,2]。本文综述了AI在血管超声方面的最新研究进展,涵盖经颅多普勒超声、颈动脉、腹主动脉瘤、主动脉夹层、外周动脉疾病、透析通路动静脉瘘、静脉血栓及下腔静脉等方面。

1 经颅多普勒超声

近年来,人工智能在经颅多普勒超声(transcranial Doppler, TCD)中的应用迅速发展,涵盖了超快多普勒成像、血管血流异常检测、机器人辅助监测与梗死风险预测等多个关键领域。

TCD需穿透颅骨薄弱部位(如经颞窗、眼窗、枕窗)检测颅内血管中红细胞的运动速度和方向^[3],其成像质量常受颅骨和软组织之间显著的声阻抗差的限制。为提升TCD图像的质量和准确性,将基于深度学习的颅骨声速建模与射线理论相结合,提出了一种像差校正方法^[4],实现经颅平面波成像和超快多普勒成像,降低了轴向及侧向定位偏差、提高信噪比和多普勒成像的准确性。

在动脉狭窄检测方面,基于卷积神经网络(convolutional neural network, CNN)建立对于大脑中动脉狭窄的TCD分类模型^[5],在测试集上的敏感度、特异度和AUC分别为0.84、0.86和0.80,与手动测量相

收稿日期:2025-09-13;修订日期:2025-10-27

基金项目:广东省科技厅农村特派员项目(KTPYJ2024002);中山大学临床医学研究“1010”计划项目[1010PY(2022)-26]

作者单位:(1. 中山大学附属第六医院超声科,广东 广州 510655; 2. 广州市黄埔区中六生物医学创新研究院,广东 广州 510655)

通信作者:张 峰, E-mail: Zhangf56@mail.sysu.edu.cn

当。另一项研究开发并验证了一种基于多普勒超声测量的血流动力学特征对颅外脑血管(包括颈总动脉、颈内动脉、颈外动脉以及椎动脉V2段)及颅内脑血管(包括大脑前动脉、中动脉、后动脉、椎动脉V4段和基底动脉)狭窄程度进行分类的机器学习模型^[6],并能自动生成超声报告。在台湾一家教学医院收集的2020年6月所有透析及常规超声病例数据中,随机森林模型在颅外脑血管及颅内脑血管报告中的狭窄分类准确率分别介于0.85~1.00和0.67~0.86,优于传统Logistic回归模型。表明了经颅多普勒超声联合人工智能有望提高动脉狭窄筛查效率。

大脑的正常运转需要血液的持续稳定供应,而TCD可以对大脑主要动脉的血流进行连续监测,并计算得出脑血流速度(cerebral blood flow velocity, CBFV)。因此CBFV的变化一定程度上可以提示神经系统的病变。一种基于自组织映射神经网络(Self-ONN)的深度学习模型Self-ResAttentionNet18模型^[7],可以通过监测大脑中动脉血流波形来区分神经危重症患者与无脑部疾病的健康人。虽然该模型仅使用了6名健康对照者和12名神经危重症患者的大脑中动脉血流波形进行训练,但最终实现了96.05%的分类准确率,AUC达0.99,展现了使用人工智能进行实时神经疾病筛查的可能性。此外一项研究利用CBFV、动脉血压、心电图构建用于非侵入性颅内压(non-invasive intracranial pressure, nICP)估算的域对抗神经网络(DANN)模型^[8]。其中值绝对误差(mean absolute error, MAE)为(3.88±3.26)mmHg,比传统支持向量回归(SVR)模型降低了26.7%,提升了nICP估算的精度,也为TCD与其他生理信号融合分析提供了思路。

机器人辅助TCD监测则将AI+TCD技术推向临床实用层面。一项Padua-Linz双中心研究验证了机器人辅助TCD的NovaGuide自动化系统在大脑中动脉监测中的安全性与可行性^[9],其信号质量与专业超声医师手动监测无显著差异。另一研究团队评估了NovaGuide系统在蛛网膜下腔出血患者中的安全性与性能^[10],当采用该系统测得的大脑中动脉最大血流速度≥120 cm/s为血管痉挛的阈值时,与CT血管造影(computed tomography angiography, CTA)诊断的血管痉挛结果相比较,Cohen's Kappa=0.74,表明两者高度一致,验证了NovaGuide系统在神经重症监护中血管痉挛监测的诊断价值。而后一项使用了配备AI的NovaGuide系统进行实时脑栓塞监测的初步研究^[11],结果显示该系统能够高敏感性地捕捉血流中栓子经过的信号,并在无明显不良事件的情况下完成监测。首次展现了AI+TCD应用于复杂手术神经监护的可行性。

2 颈动脉

颈动脉粥样硬化(carotid atherosclerosis, CAS)常被视为心血管疾病(cardiovascular disease, CVD)的预警信号,而多普勒超声检测颈动脉内中膜厚度(intima-media thickness, IMT)是判断CAS病变程度的可靠且便利的方法。近年来已构建了多个深度学习模型用于颈动脉IMT及斑块的自动分割与分类。在目前报道的各种深度学习算法中,卷积神经网络(CNN)和残差神经网络(ResNet)架构在图像特征分类方面表现尤为出色^[12]。并有研究表明混合深度学习模型在斑块分割与面积测量中的表现较独立模型好^[13]。一项融合了双线性CNN与ResNet的深度学习架构,即BCNN-ResNet模型^[14],可自动识别颈动脉超声静态图像中的斑块。其在内、外部验证中AUC均优于ResNet-34模型。另有一种新型CANet模型^[15],也可用于自动分割超声静态图像上颈动脉IMT及斑块,并能自动计算血管狭窄程度。在内、外部验证集上均展现了良好的性能,并在计算血管狭窄程度方面与经验丰富的超声医师具有较高的一致性。除了对于静态图像的分析,近年来也有一些研究团队关注超声视频的运用,提出了用于颈动脉超声视频中多斑块追踪和分割的全自动系统(AMPTS)^[16],AMPTS在Dice系数上达到了0.83,高于MAST、Track R-CNN、VSD等先前的模型,解决了超声视频中图像质量差、斑块形态多变以及多目标识别问题。此外基于超声横断面视频开发深度学习模型CaroNet-Dynamic^[17],也表现出不错的性能。国内一研究团队基于人工神经网络(采用YOLOv4架构)开发了“Be Easy to Use”(BETU)系统^[18],可在超声视频中实时识别斑块,且该系统可在5G网络条件下实现跨1 023 km提供150 ms级的远程诊断反馈。

目前认为,斑块进展是早期亚临床CAS发展成急性缺血事件的关键中间环节^[19],不良心血管事件的发生除了与斑块负荷相关,也与斑块的不稳定性密切相关。易损斑块(不稳定性斑块)的破裂是不良心血管事件发生的重要始动因素^[20],近年来有很多研究团队专注于此,将人工智能与超声结合,开发评估颈动脉斑块稳定性及斑块分类的模型^[21,22]。一项基于transformer的自动斑块分类模型整合了语义分割和自动分类两个关键环节,相较之前仅基于CNN的单一分类模型有显著性能提升^[23]。一研究团队创新性提出利用“水母征”(jellyfish sign)这一斑块表面回声特征,将CNN与循环神经网络(recurrent neural network, RNN)相结合,以进行斑块稳定性分类^[24]。对于临床难以区分的易损斑块,准确率相较于传统CNN模型有所提升。此外,部分研究团队关注到对比增强超声(contrast-enhanced ultrasound, CEUS)的

作用,将 CEUS 与人工智能相结合,建立 DL-DCCP 模型^[25],利用斑块新生血管、造影剂流动及纤维帽运动等动态特征,进行斑块脆弱性的自动检测与分类。而后有一种双模态深度学习模型,即斑块边界和灌注特征的视频分析模型(BP-Net)^[26],结合了 CEUS,利用灌注特征提取斑块纤维帽内部动态信号,提高对斑块纤维帽完整性的检测精度。首次实现了对于斑块纤维帽完整性的自动、准确、非侵入式评估。

图像标准化是提高模型泛化能力的关键手段之一,在上述多项研究中多未进行图像标准化的处理,一定程度影响了人工智能模型的推广。对此,一项研究中分别评估了 3 种超声图像预处理方案^[27],以达成超声图像分辨率和增益的标准化,并结合斑点噪声去除,提高了深度学习模型在所有颈动脉斑块类型的自动分割性能。

近年来多项研究表明颈动脉斑块负荷的量化即总斑块面积(total plaque area, TPA)和总斑块体积(total plaque volume, TPV)在预测心血管事件的发生中优于颈动脉 IMT^[28,29]。人工智能辅助测量 TPA 和 TPV 也是近几年的热点。先有研究团队使用基于深度学习的 U-Net 来训练自动分割模型并从纵向颈动脉超声图像中测量 TPA^[30],而后 Ding 等^[31]提出了一种基于图像配准的自我监督学习方法(Self-Supervised Learning, SSL)和一种用于超声颈动脉斑块图像分割的堆叠 U-Net 架构(SU-Net),实现从颈动脉超声静态图像中测量 TPA。该模型应用于我国中南医院独立数据集时, Dice 系数达 0.903 以及与专业超声医师手动测量的相关性为 0.985,展现出优异的性能和良好的泛化能力。

以往 TPV 主要依靠手动平面测量法进行测量计算,需要耗费大量的时间及人力^[32]。针对这一点,Phair 等^[33]研究了人工智能衍生的半自动软件测量颈动脉斑块体积的可行性。结果显示, AI 半自动软件测量的 TPV 与手动测量具有高度的一致性,且其测量时间较手动测量平均缩短了 65%,表明 AI 技术可显著提高斑块量化效率。此外,有部分研究团队针对颈动脉血管壁体积的测量,开发基于 UNet++ 框架的 3D 超声全自动测量血管壁体积的模型^[34]。

不良心血管事件的风险预测也是近年来的热点之一,有研究团队开发基于 CNN 的 AlexNet 迁移学习模型^[35],可以从颈动脉彩色多普勒超声图像中自动提取急性缺血性脑卒中患者的病变特征。之后该团队提出了一种计算机辅助诊断系统来评估颈动脉彩色多普勒超声中的多维特征^[36],包括血流形状、速度、湍流状况以及血管走行等方面,从而识别急性缺血性脑卒中患者。此外有团队综合利用颈动脉斑块特征和影像学指标,采用多种深度学习架构(包括双

向循环网络和生成对抗网络等)对心血管不良事件风险和患者生存进行预测与分层^[37]。

3 主动脉瘤与主动脉夹层

近年来,关于主动脉瘤的超声联合 AI 研究主要集中在腹主动脉瘤的辅助筛查、自动分割等方面。Zhao 等^[38]开发并评估了一种辅助筛查腹主动脉瘤的深度学习算法,有望成为一种可靠的早期筛查工具。在该算法的指导下非专业人士使用超声扫查的视频质量与资深超声医师扫查质量相当,并且其预测腹主动脉最大宽度的结果与医生的测量结果相比,平均绝对误差仅为 2.8 mm。当使用 2.5 cm 作为诊断腹主动脉瘤的临界阈值时,该模型检测腹主动脉瘤的 AUC 为 0.973。而后在此基础上进一步扩展了腹主动脉瘤的人工智能研究,运用三维时间分辨超声(3D+tUS)构建了基于 nnU-Net 架构的多模态分割模型,可在动态超声图像中自动分割腹主动脉瘤腔和动脉瘤血栓,实现精确的体积测量和形态学评估^[39,40],推动了腹主动脉瘤动态监测及评估破裂风险分析的发展。

主动脉夹层是一种严重威胁生命健康的危重症心血管疾病,其早期诊断对于及时做出准确的临床决策和改善患者的预后至关重要^[41]。升主动脉、主动脉弓、胸主动脉和腹主动脉的多个节段可以在超声图像中进行评估^[42],但其诊断极大地取决于超声医师的专业能力和经验。对此, Lin 等^[43]首次系统评估了深度学习模型在急性腹主动脉夹层超声图像中的诊断价值。研究采用 DenseNet-169 和 VGG-16 两种常见 CNN 架构进行分类训练,结果表明, DenseNet-169 在测试集上的敏感度高达 0.95, AUC 为 0.97; VGG-16 敏感度 0.93, AUC 为 0.95。二者均优于非资深专业人员的综合表现,提供了人工智能模型进行腹主动脉夹层快速筛查的可行性,有望在紧急情况下为非专业人员提供可靠的诊断依据。

4 外周动脉疾病

踝肱指数是筛查外周动脉疾病(peripheral artery disease, PAD)常用的无创血管检查方法,可初步判断肢体缺血程度。同时超声检查可以了解外周动脉结构并能测量得出血流动力学相关数据,对 PAD 的早期筛查诊断和随访管理均具有重要意义。然而,通过二维超声检查,很难在较短的时间范围内可视化下肢血管,对此前些年已经开发了几种用于血管成像的 3D 超声系统^[44-46],均展现出不错的性能,但 3D 超声的推广主要受限于其价格和较繁琐的步骤。有研究团队提出利用二维超声的“拉伸重建”技术以改进外周动脉成像^[47]。Mask-RCNN 算法分割二维超声扫查的股动脉后,利用 CNN 算法估计平面外运动,最终形成股动脉的拉伸重建图像,以便于直

接观察动脉,快速测量直径和确定病灶大小。该技术突破了传统二维超声在血管扫查中切面受限的瓶颈,为血管超声评估提供了新的选择。

在PAD的筛查与诊断中,一项基于分层深度学习架构的多层感知器和设计的分层神经网络(hierarchical neural network, HNN)模型,对下肢动脉各分段(主动脉-髂动脉-股动脉-腘动脉-腘动脉远端)狭窄程度进行自动分类^[48]。该模型预测正常结果的准确率为97.0%,预测患病病例的准确率为88.8%。有研究团队将深度学习模型应用于静息状态下胫后动脉多普勒波形的自动分析,所构建的深度学习模型在验证集中获得了AUC 0.94的优秀表现^[49]。为PAD的早期筛查提供了新的选择。随后该团队将此模型扩展用于5年内主要不良心血管事件及主要不良肢体事件的风险预测,能显著识别高风险人群:总死亡的风险比为2.44,主要不良肢体事件的风险比高达11.03^[50]。后续在糖尿病患者亚组中也验证了类似的预测性能^[51]。另一团队选用踝动脉多普勒波形建立糖尿病患者的PAD诊断模型,实现了88%的整体诊断准确率、AUC达到0.93^[52]。除了单一的超声数据分析外,融合多普勒超声检查、踝肱指数测量及血液生化指标的随机森林模型在诊断PAD方面(敏感度89.3%、特异度91.6%)优于仅使用传统踝肱指数方法(敏感度85.1%、特异度84.5%)^[53]。

对于锻炼和药物治疗反应不佳的PAD患者,手术血运重建是治疗的重要手段,旁路术是重要的手术方式之一,针对下肢动脉旁路移植术后监测,一研究团队利用术后至少2次超声检查的旁路峰值收缩期血流速度,构建双向长短时记忆网络(BiLSTM)模型^[54]。该模型预测旁路闭塞事件AUC可达0.95,显著超越了传统基于单次检查的预警能力。

5 透析通路动静脉瘘

近年来,人工智能在透析通路超声检查中的应用已由自体动静脉瘘(arteriovenous fistulas, AVF)成熟预测扩展至随访管理、远程监测和并发症预警。在成熟预测方面,构建了一种基于机器学习的预测模型,以术后4~6周超声测量的桡动脉及头静脉血管直径、流量等变量为输入,对新建桡-头动静脉瘘在1年内无干预达到成功使用进行风险预测^[55],所构建的LassoLogistic回归模型的预测性能优于现行KDOQI和UAB标准。在延续对桡-头动静脉瘘1年期通畅率预测研究的基础上,由团队研究扩展至2.5年期的桡-头动静脉瘘一期和二期通畅率预测,通过联合机器学习模型与PREDICT-AVF网络应用,并结合术后4~6周超声测量构建的模型具有优秀的预测性能^[56]。

对于自体动静脉瘘的随访管理方面,研究者提

出并临床验证了机器人断层超声(robotic tomographic ultrasound, RTU)联合人工智能分析系统管理动静脉瘘的可行性,利用半自主的机器人探头获取三维断层超声和多普勒数据,人工智能系统自动分割瘘管结构、测量流速及血管壁参数,并实时分析狭窄风险和成熟度指标^[57]。与传统超声检查相比,RTU+AI系统测量误差低于5%,平均扫描时间缩短35%。

高流量动静脉瘘可能是血液透析患者心力衰竭和死亡的可改变危险因素^[58],有研究团队利用机器学习技术构建了针对高流量动静脉瘘的预测模型,并系统评估了瘘管流量、既往心衰史及代谢性疾病对心功能和生存预后的影响^[59]。

6 静脉血栓性疾病

人工智能联合超声检查在静脉血栓领域的创新包括辅助诊断以及基于临床变量的风险预测等方面。在辅助下肢深静脉血栓(deep vein thrombosis, DVT)诊断方面,有研究提出了一种基于深度学习的图像质量分类方法,用于自动识别并提取适合诊断腘静脉血栓的超声横断面静态图像^[60]。该模型在便携式超声中同样能取得不错的表现,为后续开发面向非专业人群自助筛查静脉血栓奠定了基础。此外有研究团队关注到加压超声在诊断静脉血栓的作用,基于加压超声开发的AutoDVT系统^[61]及Think-Sono Guidance系统^[62],可以指导非专业人士进行静脉加压扫查,从而诊断静脉血栓。而后有团队将UNet与ResNet相结合,构建了自动分割多普勒超声视频中的血管壁,并基于静脉可压缩性评估完成深静脉血栓诊断的深度学习模型^[63],该模型在多中心数据集上达到超过90%的诊断准确率。此外一项面向慢性肝硬化患者的门静脉血栓(portal vein thrombosis, PVT)诊断研究中,研究者构建了SVM-Naïve Bayes-QDA堆叠模型^[64],融合多项临床数据和门静脉血流速度后其预测门静脉血栓的AUC超过0.90。

为完善机器人超声系统,进一步实现自动化加压超声检查,研究团队针对DVT评估中超声探头压迫力度的不一致问题,提出了一种基于核化运动基元(kernelised movement primitives, KMP)的模仿学习方法^[65],使机器人超声系统可以模仿超声医师的力控制和超声图像质量,推动超声检查向全自动化迈进。

关于静脉血栓的风险预测是近年来的研究热点,研究团队基于人工智能算法,结合临床变量,如D-二聚体、年龄、住院时间和既往静脉血栓栓塞病史等相关危险因素,构建深静脉血栓风险预测模型,大多都取得了不错的表现。例如针对肿瘤患者静脉血栓的个体化风险评估开发的结合D-二聚体的LR模

型表现优异,其在测试集上 AUC 达 0.773^[66],显著优于传统 Khorana 评分(AUC 0.642)。一项针对骨关节置换术后 DVT 风险预测构建的集成模型(XGBoost、RF、SVM 和 LR 模型的集成)实现了 AUC 0.9206^[67],超越了临床常用的 Caprini 评分(AUC 0.5703)。针对脑卒中后 DVT 风险预测的 RF 模型^[68],其性能也优于 Padua 评分。

7 下腔静脉

在危重症患者的血流动力学监测中,下腔静脉(inferior vena cava, IVC)超声占据重要地位,可用于评估循环血容量和预测液体反应性。目前已有成熟的 IVC 自动测量技术并已应用于临床,如 Mindray 的半自动 SmartIVC 和 GE 的 AutoIVC 等。后续研究团队利用机器学习方法对包括 IVC 塌陷指数、心输出量等在内的超声测量数据进行了综合建模,在预测严重脓毒症或脓毒性休克患者的液体反应性方面,PLS 模型(AUC 0.83)与被动抬腿实验(AUC 0.77)表现相当^[69]。最近,Yurk 等^[70]开发的深度学习模型能够从快速吸气时 IVC 超声扫描视频中自动评估右心房压力,在与金标准右心漂浮导管测量的对比中实现了 AUC 0.85,并在外部数据集中表现出优良的泛化能力,基于视频的自动化右心房压力评估有望为临床提供更可靠的循环血容量状态的判断手段。

8 总结与展望

近年来人工智能在血管超声的研究不仅包括对传统二维静态图像的定性分析,更是快速迈向多维度定量分析、自动化、精细化,落地临床应用方向。基于不同架构的深度学习模型在动脉狭窄、颈动脉斑块、腹主动脉瘤、自体动静脉瘘、静脉血栓等血管疾病的识别、分类及自动分割定量分析中的表现与人工检查表现相当,甚至优于人工检查;多模态数据融合技术进一步提升了超声成像的质量、病变检测的敏感度和不良心血管事件风险预测的准确性;机器人辅助超声和动态多普勒监测系统的建立更是朝着全自动化超声迈出了一大步,在神经重症及脑卒中风险评估、透析通路管理、深静脉血栓检查等方面展现出敏捷高效的监测能力。但距真正进入临床应用仍有相当一段路程,本综述中提到的大多数模型构建都基于超声静态图像,但仅依靠单个截面的静态图像可能会错过一些关键的动态变化,从而限制模型的泛化能力。研究者们也注意到这一点,有不少模型选择利用超声动态图像进行分析,但也存在因运动伪影而出现定位不准确的问题。如何充分利用超声实时分析这一优势,减少图像不规范、伪影等影响是未来需要努力的方向。在算法层面,可通过引入注意力机制^[71]、对抗生成网络及自适应噪声滤波^[72]等策略,抑制运动伪影并提高动态图像稳定性。

目前的研究主要基于特定的数据集,且多存在样本量较少的缺陷,缺少多中心、大样本量的研究,模型的性能和泛化能力必须进一步增强以适应复杂的临床病例,并且在不同医院和设备条件下,模型的稳定性仍然是一个挑战。因此,未来的研究应着眼于推动多中心、大样本量的数据平台建设,建立统一的图像质量评估标准,开展前瞻性、多中心随机对照试验,并将成熟的 AI 超声技术运用于临床实践,不断更新及优化模型,以充分实现人工智能在医学诊断中的潜力。总的来说,人工智能正通过标准化数据预处理、高性能模型架构和自动化工作流的构建,推动血管超声从经验驱动向数据驱动的转型,显著提升诊断一致性与效率,有望为精准医疗和远程医疗提供坚实技术支撑。

利益冲突声明:所有作者均声明不存在利益冲突。

作者贡献声明:罗嘉宝负责论文初步设计、收集文献、撰写论文;张峰负责提出研究选题、指导撰写论文、审校论文并最后定稿。

[参考文献]

- [1] Akkus Z, Cai J, Boonrod A, et al. A survey of deep-learning applications in ultrasound: Artificial intelligence-powered ultrasound for improving clinical workflow[J]. J Am Coll Radiol, 2019, 16(9 Pt B): 1318-1328.
- [2] Yi J, Kang HK, Kwon JH, et al. Technology trends and applications of deep learning in ultrasonography: Image quality enhancement, diagnostic support, and improving workflow efficiency[J]. Ultrasonography, 2021, 40(1): 7-22.
- [3] 国家卫生健康委脑卒中防治工程委员会. 中国脑卒中防治指导规范[M]. 北京:人民卫生出版社,202105:510.
- [4] Zhou J, Guo Y, Sun Q, et al. Transcranial ultrafast ultrasound Doppler imaging: A phantom study[J]. Ultrasonics, 2024, 144: 107430.
- [5] Mei YJ, Hu RT, Lin J, et al. Diagnosis of middle cerebral artery stenosis using transcranial Doppler images based on convolutional neural network[J]. World Neurosurg, 2022, 161: e118-e125.
- [6] Yeh CY, Lee HH, Islam MM, et al. Development and validation of machine learning models to classify artery stenosis for automated generating ultrasound report[J]. Diagnostics, 2022, 12(12): 3047.
- [7] Nisha NN, Podder KK, Chowdhury MEH, et al. A deep learning framework for the detection of abnormality in cerebral blood flow velocity using transcranial Doppler ultrasound[J]. Diagnostics, 2023, 13(12): 2000.
- [8] Meghani M, Terilli K, Weinerman B, et al. A deep learning framework for deriving noninvasive intracranial pressure waveforms from transcranial Doppler[J]. Ann Neurol, 2023, 94(1): 196-202.
- [9] Fattorello Salimbeni A, Kulyk C, Favruzzo F, et al. Robotic assisted transcranial Doppler monitoring in acute neurovascular care: A feasibility and safety study[J]. Neurocritical Care, 2025, 42(2): 457-464.
- [10] Esmaeeli S, Hrdlicka CM, Bastos AB, et al. Robotically assisted transcranial Doppler with artificial intelligence for assessment of

- cerebral vasospasm after subarachnoid hemorrhage[J]. *J Neurocrit Care*, 2020, 13(1): 32-40.
- [11] Baig AA, Manion C, Khawar WI, et al. Cerebral emboli detection and autonomous neuromonitoring using robotic transcranial Doppler with artificial intelligence for transcatheter aortic valve replacement with and without embolic protection devices: A pilot study[J]. *J Neurointerv Surg*, 2024, 16(11): 1167-1173.
- [12] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 770-778.
- [13] Jain PK, Sharma N, Giannopoulos AA, et al. Hybrid deep learning segmentation models for atherosclerotic plaque in internal carotid artery B-mode ultrasound[J]. *Comput Biol Med*, 2021, 136: 104721.
- [14] 赫 兰, 申 铿, 杨泽堃, 等. 基于深度学习的人工智能模型自动识别颈动脉斑块[J]. *中国医疗器械杂志*, 2024, 48(4): 361-366.
- [15] Liu M, Gao W, Song D, et al. A deep learning-based calculation system for plaque stenosis severity on common carotid artery of ultrasound images[J]. *Vascular*, 2025, 33(2): 349-356.
- [16] Li L, Hu Z, Huang Y, et al. Automatic multi-plaque tracking and segmentation in ultrasonic videos [J]. *Med Image Anal*, 2021, 74: 102201.
- [17] Liu J, Zhou X, Lin H, et al. Deep learning based on carotid transverse B-mode scan videos for the diagnosis of carotid plaque: A prospective multicenter study [J]. *Eur Radiol*, 2023, 33(5): 3478-3487.
- [18] Wei Y, Yang B, Wei L, et al. Real-time carotid plaque recognition from dynamic ultrasound videos based on artificial neural network[J]. *Ultraschall Med*, 2024, 45(5): 493-500.
- [19] Mortensen MB, Dzaye O, Steffensen FH, et al. Impact of plaque burden versus stenosis on ischemic events in patients with coronary atherosclerosis [J]. *J Am Coll Cardiol*, 2020, 76(24): 2803-2813.
- [20] 中华心血管病杂志网络版编辑委员会. 动脉粥样硬化斑块的筛查与临床管理专家共识[J]. *中华心血管病杂志(网络版)*, 2022(1): 51-63.
- [21] Song J, Zou L, Li Y, et al. Combining artificial intelligence assisted image segmentation and ultrasound based radiomics for the prediction of carotid plaque stability [J]. *BMC Med Imaging*, 2025, 25(1): 89.
- [22] Su SS, Li LY, Wang Y, et al. Stroke risk prediction by color Doppler ultrasound of carotid artery-based deep learning using Inception V3 and VGG-16[J]. *Front Neurol*, 2023, 14: 1111906.
- [23] Hirano G, Teramoto A, Takai H, et al. Automated scheme of plaque classification based on segmentation in carotid ultrasound images using transformer approach [J]. *J Med Ultrason*, 2025, 52(3): 271-282.
- [24] Yoshidomi T, Kume S, Aizawa H, et al. Classification of carotid plaque with jellyfish sign through convolutional and recurrent neural networks utilizing plaque surface edges [J]. *Annu Int Conf IEEE Eng Med Biol Soc*, 2024, 2024: 1-4.
- [25] Guang Y, He W, Ning B, et al. Deep learning-based carotid plaque vulnerability classification with multicentre contrast-enhanced ultrasound video: A comparative diagnostic study [J]. *BMJ Open*, 2021, 11(8): e047528.
- [26] Li L, Hu Z, Huang Y, et al. BP-Net: Boundary and perfusion feature guided dual-modality ultrasound video analysis network for fibrous cap integrity assessment [J]. *Comput Med Imag Graph*, 2023, 107: 102246.
- [27] Liapi GD, Loizou CP, Pattichis CS, et al. Assessing the impact of ultrasound image standardization in deep learning-based segmentation of carotid plaque types [J]. *Comput Methods Programs Biomed*, 2024, 257: 108460.
- [28] Naylor AR, Schroeder TV, Sillesen H. Clinical and imaging features associated with an increased risk of late stroke in patients with asymptomatic carotid disease[J]. *Eur J Vasc Endovasc Surg*, 2014, 48(6): 633-640.
- [29] Wannarong T, Parraga G, Buchanan D, et al. Progression of carotid plaque volume predicts cardiovascular events [J]. *Stroke*, 2013, 44(7): 1859-1865.
- [30] Zhou R, Azarpazhooh MR, Spence JD, et al. Deep learning-based carotid plaque segmentation from B-mode ultrasound images [J]. *Ultrasound Med Biol*, 2021, 47(9): 2723-2733.
- [31] Ding J, Zhou R, Fang X, et al. An image registration-based self-supervised Su-Net for carotid plaque ultrasound image segmentation [J]. *Comput Methods Programs Biomed*, 2024, 244: 107957.
- [32] Landry A, Spence JD, Fenster A. Measurement of carotid plaque volume by 3-dimensional ultrasound [J]. *Stroke*, 2004, 35(4): 864-869.
- [33] Phair AS, Carreira J, Bowling FL, et al. Accelerated measurement of carotid plaque volume using artificial intelligence enhanced 3D ultrasound[J]. *Ann Vasc Surg*, 2024, 98: 317-324.
- [34] Zhou R, Guo F, Azarpazhooh MR, et al. Carotid vessel-wall-volume ultrasound measurement via a UNet++ ensemble algorithm trained on small data sets [J]. *Ultrasound Med Biol*, 2023, 49(4): 1031-1036.
- [35] Lo CM, Hung PH. Assessing ischemic stroke with convolutional image features in carotid color Doppler[J]. *Ultrasound Med Biol*, 2021, 47(8): 2266-2276.
- [36] Lo CM, Hung PH. Computer-aided diagnosis of ischemic stroke using multi-dimensional image features in carotid color Doppler [J]. *Comput Biol Med*, 2022, 147: 105779.
- [37] Bhagawati M, Paul S, Mantella L, et al. Deep learning approach for cardiovascular disease risk stratification and survival analysis on a Canadian cohort [J]. *Int J Cardiovasc Imaging*, 2024, 40(6): 1283-1303.
- [38] Chiu IM, Chen TY, Zheng YC, et al. Prospective clinical evaluation of deep learning for ultrasonographic screening of abdominal aortic aneurysms[J]. *NPJ Digit Med*, 2024, 7(1): 282.
- [39] Nievergeld A, Çetinkaya B, Maas E, et al. Deep learning-based segmentation of abdominal aortic aneurysms and intraluminal thrombus in 3D ultrasound images [J]. *Med Biol Eng Comput*, 2024.
- [40] Maas EJ, Awasthi N, van Pelt EG, et al. Automatic segmentation of abdominal aortic aneurysms from time-resolved 3-D ultrasound images using deep learning[J]. *IEEE Trans Ultrason Ferroelectr Freq Control*, 2024, 71(11): 1420-1428.
- [41] 中国医师协会心血管外科分会大血管外科专业委员会. 主动脉夹层诊断与治疗规范中国专家共识[J]. *中华胸心血管外科杂志*, 2017, 33(11): 641-654.
- [42] Liu F, Huang L. Usefulness of ultrasound in the management of aortic dissection [J]. *Rev Cardiovasc Med*, 2018, 19(3): 103-109.

- [43] Lin Z, Zheng J, Deng Y, et al. Deep learning-aided diagnosis of acute abdominal aortic dissection by ultrasound images[J]. *Emerg Radiol*, 2025, 32(2): 233-239.
- [44] Janvier MA, Destrepes F, Soulez G, et al. Validation of a new 3D-US imaging robotic system to detect and quantify lower limb arterial stenoses[J]. *Annu Int Conf IEEE Eng Med Biol Soc*, 2007, 2007: 339-342.
- [45] Janvier MA, Soulez G, Allard L, et al. Validation of 3D reconstructions of a mimicked femoral artery with an ultrasound imaging robotic system[J]. *Med Phys*, 2010, 37(7): 3868-3879.
- [46] Janvier MA, Merouche S, Allard L, et al. A 3-D ultrasound imaging robotic system to detect and quantify lower limb arterial stenoses: In vivo feasibility [J]. *Ultrasound Med Biol*, 2014, 40(1): 232-243.
- [47] Leblanc T, Lalys F, Tollenaere Q, et al. Stretched reconstruction based on 2D freehand ultrasound for peripheral artery imaging[J]. *Int J Comput Assist Radiol Surg*, 2022, 17(7): 1281-1288.
- [48] Luo X, Ara L, Ding H, et al. Computational methods to Automate the initial interpretation of lower extremity arterial Doppler and duplex carotid ultrasound studies [J]. *J Vasc Surg*, 2021, 74(3): 988-996. e1.
- [49] McBane RD, Murphree DH, Liedl D, et al. Artificial intelligence for the evaluation of peripheral artery disease using arterial Doppler waveforms to predict abnormal ankle-brachial index [J]. *Vasc Med*, 2022, 27(4): 333-342.
- [50] McBane RD 2nd, Murphree DH, Liedl D, et al. Artificial intelligence of arterial Doppler waveforms to predict major adverse outcomes among patients evaluated for peripheral artery disease [J]. *J Am Heart Assoc*, 2024, 13(3): e031880.
- [51] McBane RD 2nd, Murphree DH, Liedl D, et al. Artificial intelligence of arterial Doppler waveforms to predict major adverse outcomes among patients with diabetes mellitus [J]. *J Vasc Surg*, 2024, 80(1): 251-259. e3.
- [52] Normahani P, Sounderajah V, Mandic D, et al. Machine learning-based classification of arterial spectral waveforms for the diagnosis of peripheral artery disease in the context of diabetes: A proof-of-concept study [J]. *Vasc Med*, 2022, 27(5): 450-456.
- [53] Gao JM, Ren ZH, Pan X, et al. Identifying peripheral arterial disease in the elderly patients using machine-learning algorithms [J]. *Aging Clin Exp Res*, 2022, 34(3): 679-685.
- [54] Luo X, Tahabi FM, Rollins DM, et al. Predicting future occlusion or stenosis of lower extremity bypass grafts using artificial intelligence to simultaneously analyze all flow velocities collected in current and previous ultrasound examinations [J]. *JVS Vasc Sci*, 2024, 5: 100192.
- [55] Heindel P, Dey T, Feliz JD, et al. Predicting radiocephalic arteriovenous fistula success with machine learning [J]. *NPJ Digit Med*, 2022, 5(1): 160.
- [56] Fitzgibbon JJ, Ruan M, Heindel P, et al. Predicting long-term patency of radiocephalic arteriovenous fistulas with machine learning and the PREDICT-AVF web app [J]. *Sci Rep*, 2025, 15(1): 19203.
- [57] Carroll J, Colley E, Cartmill M, et al. Robotic tomographic ultrasound and artificial intelligence for management of haemodialysis arteriovenous fistulae [J]. *J Vasc Access*, 2025, 26(1): 242-250.
- [58] MacRae JM, Pandeya S, Humen DP, et al. Arteriovenous fistula-associated high-output cardiac failure: A review of mechanisms [J]. *Am J Kidney Dis*, 2004, 43(5): e17-e22.
- [59] Shah NA, Byrne P, Endre ZH, et al. Predicting high-flow arteriovenous fistulas and cardiac outcomes in hemodialysis patients [J]. *J Vasc Surg*, 2025, 81(3): 751-758. e8.
- [60] Nakayama Y, Sato M, Okamoto M, et al. Deep learning-based classification of adequate sonographic images for self-diagnosing deep vein thrombosis [J]. *PLoS One*, 2023, 18(3): e0282747.
- [61] Kainz B, Heinrich MP, Makropoulos A, et al. Non-invasive diagnosis of deep vein thrombosis from ultrasound imaging with machine learning [J]. *NPJ Digit Med*, 2021, 4(1): 137.
- [62] Avgerinos E, Spiliopoulos S, Psachoulia F, et al. Novel artificial intelligence guided non-expert compression ultrasound deep vein thrombosis diagnostic pathway may reduce vascular laboratory venous testing [J]. *Eur J Vasc Endovasc Surg*, 2025, 70(4): 517-522.
- [63] Chen PW, Tseng BY, Yang ZH, et al. Deep learning model for diagnosis of venous thrombosis from lower extremity peripheral ultrasound imaging [J]. *iScience*, 2024, 27(12): 111318.
- [64] Li Y, Gao J, Zheng X, et al. Diagnostic Prediction of portal vein thrombosis in chronic cirrhosis patients using data-driven precision medicine model [J]. *Brief Bioinform*, 2023, 25(1): bbad478.
- [65] Dall'Alba D, Busellato L, Savarimuthu TR, et al. Imitation learning of compression pattern in robotic-assisted ultrasound examination using kernelized movement primitives [J]. *IEEE Trans Med Robot Bionics*, 2024, 6(4): 1567-1580.
- [66] Jin S, Qin D, Liang BS, et al. Machine learning predicts cancer-associated deep vein thrombosis using clinically available variables [J]. *Int J Med Inform*, 2022, 161: 104733.
- [67] Wang X, Xi H, Geng X, et al. Artificial intelligence-based prediction of lower extremity deep vein thrombosis risk after knee/hip arthroplasty [J]. *Clin Appl Thromb Hemost*, 2023, 29: 10760296221139263.
- [68] Liu L, Li L, Zhou J, et al. Machine learning-based prediction model of lower extremity deep vein thrombosis after stroke [J]. *J Thromb Thrombolysis*, 2024, 57(7): 1133-1144.
- [69] Bataille B, de Selle J, Moussot PE, et al. Machine learning methods to improve bedside fluid responsiveness prediction in severe sepsis or septic shock: An observational study [J]. *Br J Anaesth*, 2021, 126(4): 826-834.
- [70] Yurk D, Barrios JP, Labrecque Langlais E, et al. Automated assessment of right atrial pressure from ultrasound videos using machine learning [J]. *JACC Adv*, 2024, 3(9): 101192.
- [71] Lin Z, Zhang Q, Lan G, et al. Deep learning for motion artifact-suppressed OCTA image generation from both repeated and adjacent OCT scans [J]. *Mathematics*, 2024, 12(3): 446.
- [72] Zhang L, Zhang J. Ultrasound image denoising using generative adversarial networks with residual dense connectivity and weighted joint loss [J]. *PeerJ Comput Sci*, 2022, 8: e873.

引证本文:罗嘉宝,张 峰. 人工智能在血管超声中的应用现状及进展[J]. 中风与神经疾病杂志, 2025, 42(11): 1001-1007.