

深度学习在冠心病影像学诊断的研究进展

凯赛尔江·卡地尔 艾克力亚尔·艾尼瓦尔 秦练 热娜·热合木丁 马翔
(新疆医科大学第一附属医院心脏中心, 新疆 乌鲁木齐 830054)

【摘要】在心血管领域,医学影像与人工智能融合能深入挖掘影像数据特征,并且辅助疾病的诊断。冠心病的诊断主要依靠影像学检查,由于医生之间资历、水平的不同,个体主观原因产生的误差让诊断结果的准确性有所降低,处理数量庞大的影像数据也耗费着医生大量的时间和精力。目前,深度学习作为人工智能的重要分支,在图像数据的处理上发挥着独特的优势,应用于冠心病影像诊断可提高诊断效率和准确性。现就深度学习技术在冠心病影像学诊断中的应用进行综述。

【关键词】深度学习;冠心病;医学影像;辅助诊断

【DOI】10.16806/j.cnki.issn.1004-3934.2022.04.012

Deep Learning in Imaging Diagnosis of Coronary Heart Disease

Kaisaierjiang Kadier, Aikeliyaer Ainiwaer, QIN Lian, Rena Rehemuding, MA Xiang
(Heart Center, The First Affiliated Hospital of Xinjiang Medical University, Urumqi 830054, Xinjiang, China)

【Abstract】In the cardiovascular field, the fusion of medical imaging and artificial intelligence can deeply explore the features of imaging data and assist in the diagnosis of diseases. The diagnosis of coronary heart disease mainly relies on imaging examinations, and the accuracy of diagnostic results is reduced due to the differences in qualifications and levels among doctors and errors arising from individual subjective reasons. Processing the huge amount of image data consumes a lot of time and energy of doctors. At present, as an important branch of artificial intelligence, deep learning plays a unique advantage in image data processing which can be applied to coronary heart disease image diagnosis to improve diagnostic efficiency and accuracy. In this paper, we review the application of deep learning technology in the diagnosis of coronary artery disease imaging.

【Key words】Deep learning; Coronary heart disease; Medical imaging; Auxiliary diagnosis

随着社会经济的发展,国民生活发生了巨大的改变,中国心血管病的患病人数在持续增加,其中冠心病是严重威胁生存健康的心血管疾病之一,并且其死亡率也呈上升趋势^[1],冠心病的影像诊断一直是研究的热门领域。冠心病的影像诊断发展迅速,通过计算机断层扫描(computed tomography, CT)、心血管磁共振成像(cardiovascular magnetic resonance, CMR)和单光子发射计算机断层扫描(single photon emission computed tomography, SPECT)等影像技术可制定精准个体化诊疗方案,但影像数据的判读结果受医生水平、个体主观因素和精力等问题影响。随着医学大数据井喷式的增长及数据共享时代的开启,人工智能作为交叉学科在医学领域发挥着越来越重要的作用,计算机辅助诊断模式提高了影像数据处理效率和诊断准确性。现就人工智能中的研究热点技术深度学习(deep learning, DL)在冠心病影像学诊断中的应用进

行综述,为该领域进一步深入研究提供参考。

1 DL 概述

DL 是机器学习的子集,模拟了人脑神经网络的学习机制,通过一系列不断增加的抽象层来学习数据的特征。DL 算法类型包括:监督学习、非监督学习和强化学习^[2],前二者之间的区别在于数据是否被人工注释,其中监督学习模型卷积神经网络(convolutional neural network, CNN)是医学图像处理领域最受欢迎的架构^[3]。DL 与强化学习结合的交互式网络深度强化学习是目前最前沿的技术,它使学习主体与环境互动获取奖励或惩罚来实现最大化获益,同时具备感知和决策能力。深度强化网络更接近人类思维方式,被视为实现人工智能的重要途径,在神经科学领域已展现出了广泛的研究潜力^[4]。

DL 算法通常由一个或多个中间层组成,中间层使网络变得“深入”,可认为它通过组合低层数据形成更

基金项目:国家自然科学基金地区科学基金(81960097)

通信作者:马翔, E-mail: maxiangxj@163.com

加抽象的高层数据,以发现数据的特征。人工神经网络的每一层都由“神经元”的排列组成,每一层都将一组加权值作为输入,并将它们转换为单个输出值,然后将结果传递给后续层中的“神经元”,可理解为中间层允许人工神经网络通过连续提取更高级别的数据并将其传递给后续层来了解输入和输出之间的非线性关系。DL 算法必须通过训练才能发现数据特征,第一层的输入值通常由人工选择,算法最初的权重也是随机化的,经过大量数据的训练,反复修改节点之间连接的权重最终在输出层产出期望的结果。

在过去的十年里,DL 发展迅速,在计算机视觉处

理、生物信息和医学图像分析等各个领域都表现出了优异的性能。DL 与支持向量机和随机森林等传统机器学习算法的关键区别在于,其可自动学习数据的特征,而不需人工干预^[5]。因此,它特别适用于大量复杂数据集的科学领域。

2 基于 CT 的应用

CT 已成为冠心病诊断的重要手段,但影像数据判读过程复杂耗时,诊断结果缺乏客观性,医生的失误和疲劳也容易造成误诊和漏诊,人工智能 DL 技术克服了以上的局限性。DL 在 CT 的应用主要包括:图像质量优化及分割、计算机辅助诊断技术等,以下作简单介绍(表 1)。

表 1 DL 在冠心病 CT 诊断中的应用

应用项目	作者及年份	DL 方法	研究结论
图像降噪和伪影校正	Liu 等 ^[6] ,2020	生成式对抗网络	DL 通过降噪有效提高低剂量 CCTA 的图像质量
	Benz 等 ^[7] ,2020	DL 图像重建	DL 与自适应统计迭代重建相比,能显著降噪
	Hong 等 ^[8] ,2020	U-Net 模型	DL 与迭代重建相结合,可增强 CCTA 图像的降噪性能,图像质量显著改善
	Lossau 等 ^[9] ,2019	CNN 模型,卷积回归网络	滤波反投影重建获取无伪影的 CCTA 图像数据,以此训练的 DL 模型能识别和预测伪影
	Jung 等 ^[10] ,2020	超分辨率 DL 模型	跨相转换获取无伪影的 CCTA 图像数据,以此训练的超分辨率 DL 模型能识别及校正伪影
图像分割	Xiao 等 ^[11] ,2020	U-Net 模型	DL 分割冠状动脉构建 3D 图像,能识别冠状动脉斑块和狭窄
	Jun 等 ^[12] ,2020	U-Net 模型	DL 从 CCTA 图像中分割左心室轮廓
	He 等 ^[13] ,2020	U-Net 模型	DL 从 CCTA 图像中分割心外膜脂肪组织轮廓
	Commandeur 等 ^[14] ,2018	级联 CNN 模型	DL 从 CT 平扫图像中分割和定量分析心外膜脂肪组织和胸廓脂肪组织
FFR 的应用	Wang 等 ^[15] ,2019	多层神经网络,双向递归神经网络	开发了 DEEPVESSEL-FFR 在线平台,能半自动化获取 CCTA 重建的冠状动脉树 FFR 的分布
	Kumamaru 等 ^[16] ,2020	生成式对抗网络,CNN 模型	DL 模型可通过未分割和重建的 CCTA 数据自动化获取 FFR,并且能检测异常 FFR
	Zreik 等 ^[17] ,2020	自动编码器	DL 模型无监督分析 CCTA 数据,以 FFR 为参考标准来筛查需侵入性冠状动脉造影的患者
冠状动脉钙化的应用	van den Oever 等 ^[18] ,2020	CNN 模型	DL 能识别冠状动脉钙化为阴性的 CT 平扫结果
	Lessmann 等 ^[19] ,2018	CNN 模型	DL 能检测冠状动脉、胸主动脉和心脏瓣膜的钙化
	Zhang 等 ^[20] ,2021	多视图立体重建条件生成模型	DL 实现了冠状动脉整体水平和单一血管特异水平的 CACS 准确量化
	van Velzen 等 ^[21] ,2020	CNN 模型	DL 能在多种 CT 扫描方案中准确量化 CACS

注:CCTA 为冠状动脉 CT 血管成像;FFR 为血流储备分数;CACS 为冠状动脉钙化积分。


2.1 图像降噪和伪影校正

冠状动脉 CT 血管成像(cardiac CT angiography, CCTA),通过 3D 重建心脏结构和冠状动脉走行,清晰显示血管病理改变,已被广泛应用于冠心病的诊断,但其造成的过量辐射问题引发了对于过度使用该项技术的担忧^[22]。因此,迫切需低辐射剂量 CCTA 应用

于冠心病的诊断,迭代重建技术作出了初步尝试并且大幅降低了辐射剂量^[23]。然而,辐射剂量的进一步降低会使图像噪声增加从而导致图像质量的下降,影响诊断结果。Liu 等^[6]的一项前瞻性研究显示,生成式对抗网络能明显降低图像噪声,采用 80 kVp 的心电门控 CCTA 图像质量与采用 100 kVp 时相当,并且处理

速度快于迭代重建技术。Benz 等^[7]比较了基于 CCTA 的 DL 图像重建和自适应统计迭代重建,前者降低了 43% 的图像噪声,同时提高了 138% 的图像质量,以冠状动脉造影为参考标准时,诊断准确度无显著统计学差异。Hong 等^[8]修改了传统模型的 U-Net 结构,通过减少卷积滤波器的数量和采用批归一化技术改进的 CNN 模型更加适应图像去噪的目的,防止过拟合的同时解决了梯度弥散的问题,提高了模型的稳健性。其利用改良 CNN 模型的去噪性能,将其应用于低剂量 CCTA 图像的迭代重建,边缘响应函数从最终像素强度的 10% 上升到 90% 所需的距离明显降低,图像质量显著提高。以上研究表明利用 DL 技术的图像质量优化性能,通过极低辐射剂量的 CCTA 诊断冠心病成为可能。

CCTA 中心脏跳动引起的伪影会干扰冠状动脉疾病的检测和诊断,并使后续制定临床治疗决策变得困难(图 1 所示)。Lossau 等^[9]将基于心电门控 CCTA 数据的冠状动脉运动伪影,采用运动补偿滤波反投影算法校正去除,以此训练的 CNN 模型在识别运动伪影准确度达到 $93.3\% \pm 1.8\%$,卷积回归网络预测伪影运动水平平均绝对误差为 1.12 ± 0.07 。Jung 等^[10]通过裁剪存在伪影的原始 4D CT 图像,应用跨相转换的方法校正伪影,以此获得的 2D 无伪影图像数据库训练超分辨率深度网络模型。该模型结合了 CNN 和残差学习的优点,具有稳健的性能和较快的收敛速度。其研究克服了如何获得无伪影的 CCTA 图像数据的问题,所构建的模型能有效校正运动伪影,使冠状动脉边界更加清晰,具有很强的观察者间一致性。



注:红框所示为 CCTA 中冠状动脉显影时随着心脏跳动引起的伪影,使冠状动脉边界模糊。

图 1 运动伪影

2.2 图像分割

冠状动脉分割在冠心病临床诊断、血流动力学仿真以及血管解剖结构分析等研究中至关重要,但边界追踪法、区域生长法等传统的冠状动脉分割方法工作量大、主观性强、分割精度有待提高。DL 算法在图像分割上有着独到的优势,能高效、自动化地完成任务。Xiao 等^[11]利用 U-Net 网络模型和中心线提取技术用于冠状动脉分割,可为医生提供冠状动脉的 3D 可视

化图像,方便医生的诊断和制定治疗方案,但在图像细节处理方面需改进。由左心室 CCTA 形态学分析获得的左心室心肌质量、左心室容积以及射血分数等参数对冠心病的诊断和预后十分重要。Jun 等^[12]开发的 U-Net 算法实现了 CCTA 图像左心室轮廓分割,模型性能达到专家水平, Dice 相似性系数为 91.6%,为影像形态学和病理学分析提供了潜在的模型支持。He 等^[13]和 Commandeur 等^[14]基于 DL 模型高精度地分割了心外膜脂肪组织,其量化方法对改善冠心病风险分层和预测主要心血管不良事件具有重要意义。

2.3 血流储备分数的应用

侵入性冠状动脉造影联合血流储备分数(fractional flow reserve, FFR)是诊断冠心病的“金标准”,后者能有效反映心肌缺血程度,是血流动力学评估指标,但 FFR 的有创性、操作难及费用高等问题限制了这项技术的发展^[24]。一些文献已报道,人工智能 DL 算法无需侵入性冠状动脉造影,仅通过 CCTA 就可无创获取 FFR 值。Wang 等^[15]利用多层神经网络和双向递归神经网络作为算法结构体系开发了 DEEPVESSEL-FFR 在线平台,能在 5 min 内半自动化获取基于 CCTA 重建的冠状动脉树 FFR 的分布,该模型是无创评估冠状动脉狭窄缺血风险的有效方法,在临床上适用于冠心病筛查,但该前瞻性研究纳入的患者数量较少,需更进一步研究来验证诊断准确度。Kumamaru 等^[16]构建的 DL 模型可通过未分割和重建的 CCTA 数据自动化获取 FFR,技术关键在于使用生成式对抗网络和 3D CNN 网络自动提取图像特征,虚拟对抗训练正则化方法减少过拟合,检测异常 FFR 准确度为 76%。Zreik 等^[17]通过提取 CCTA 冠状动脉中心线,对动脉血管容积进行多平面重建,使用两个不相交自动编码器执行动脉体积和固定长度编码。支持向量机将编码作为标签,以 FFR 为参考标准,判断其是否存在功能上的显著狭窄来筛查需侵入性冠状动脉造影的患者。DL 算法为基于 CCTA 的无创 FFR 测定提供了技术支持,形态学和功能学的结合也有助于提高其在冠心病诊断上的准确性。

2.4 冠状动脉钙化的应用

冠状动脉钙化是预测冠心病患者不良心血管事件的独立危险因素之一,其钙化程度通常由心脏 CT 平扫进行定量检测,表示为冠状动脉钙化积分(coronary artery calcium score, CACS)^[25]。van den Oever 等^[18]构建的 CNN 模型能识别 86% 冠状动脉钙化阴性的心脏 CT 平扫检查结果,大幅减轻了医生的工作量。Lessmann 等^[19]基于低剂量胸部 CT 的 CNN 模型能自动检测冠状动脉、胸主动脉和心脏瓣膜的钙

化,在肺癌筛查的同时能间接评估患者心血管疾病风险从而降低筛查成本。Zhang 等^[20]用基于 DL 的血管分割模型和回归预测模型实现了冠状动脉整体水平和单一血管特异水平的 CACS 准确量化,与专家评估结果具有一致性。van Velzen 等^[21]的研究验证了 CNN 模型在多种 CT 扫描方案中评估 CACS 的性能,而不只是局限于心脏 CT 平扫,具有普适性。DL 模型在冠状动脉钙化检测上的应用为冠心病风险分层和预后预测提供了新的研究方向。

3 基于其他影像技术的应用

3.1 CMR 的应用

CMR 具有安全无电离辐射等特点,利用对比剂通过心肌引起的信号改变,可直接反映心肌组织的血流灌注情况,应用于冠心病心肌缺血的诊断。Tan 等^[26]利用短轴和长轴扫描的 CMR 图像,构建全自动 CNN 算法分割了从心尖至心底的左心室心肌,覆盖了完整的心脏时相,无需放射科医师手动勾画,就能获取左心室结构和功能指标。Hosseini 等^[27]提出的 SPIRiT-RAKI 技术,利用添加稀疏正则化模块的非线性增强自洽 CNN 算法,缩短了 CMR 冠状动脉成像时间。Scannell 等^[28]构建了 CNN 模型用于 CMR 图像的预处理,包括心肌的分割、心肌灌注定量等,其显示出图像数据处理的高精确度,得到与人工读图相似的量化值并且所需时间更短。上述研究结果提示,基于 DL 的 CMR 通过图像分割、加速成像等手段可快速准确地诊断冠心病并且评估心功能。Zhang 等^[29]的文献报道使用 DL 技术可在无需注射钆对比剂的前提下,通过 CMR 来识别陈旧性心肌梗死并且构建瘢痕轮廓,该方法有助于评估冠心病合并肾脏疾病患者心肌梗死的病情进展及预后。

3.2 SPECT 的应用

SPECT 利用示踪剂在心脏内的分布特性进行心肌灌注评估,应用于冠状动脉阻塞的识别。SPECT 图像通常由影像学专家通过视觉评估判读,读图结果将直接影响心肌灌注成像的量化^[30]。Kaplan Berkaya 等^[31]将 DL 和先验知识算法融合构建了 SPECT 计算机辅助诊断模型,以识别心肌灌注异常(心肌缺血和/或阻塞),结果显示模型的最大准确度、灵敏度和特异度分别为 94%、88% 和 100%,使用 DL 技术辅助临床诊断,有助于提高读图结果的客观性,从而提高诊断效能。2018 年, Betancur 等^[32]开展了一项多中心的研究,来评估 DL 模型在 SPECT 心肌灌注成像自动诊断冠状动脉梗阻性疾病的能力,结果显示其在患者水平和血管水平均优于传统评价指标——总灌注缺损。2019 年, Betancur 等^[33]进一步研究发现使用 DL 联合

量化半直立位和仰卧位两种体位下 SPECT 心肌灌注成像结果,可有效减轻衰减伪影,有助于提高诊断效能。Otaki 等^[34]构建的基于 SPECT 心肌灌注成像的 DL 模型,在诊断冠状动脉梗阻性疾病方面,显著超过了总灌注缺损和专家视觉读图的准确率。该模型的优势在于利用加权梯度类激活映射的方法解释模型来克服“黑匣子”诊断的问题,能向医生突出显示对诊断有贡献的心肌区域,并且模型可集成到临床软件中,诊断时间 < 12 s。Liu 等^[35]使用 37 243 例单纯负荷心肌灌注图像构建的 CNN 模型准确诊断冠心病,该模型的受试者操作特征曲线下面积明显高于传统的负荷灌注缺损面积的方法。

3.3 光学相干断层扫描的应用

光学相干断层扫描(optical coherence tomography, OCT)具有更高的分辨率,可直观显示血管内壁的病理改变,其正成为识别冠状动脉斑块的方法之一。Gessert 等^[36]采用图像处理领域最先进的 DL 框架 ResNet50-V2 和 DenseNet121,使用笛卡尔坐标进行图像数据增强,迁移学习技术提高模型学习效率,实现 OCT 冠状动脉斑块的检测和分类,组合模型表现出最佳性能,准确度为 91.7%,灵敏度为 90.9%,特异度为 92.4%。Gharaibeh 等^[37]通过 CNN 模型分割了血管管腔和钙化斑块,量化了钙化斑块的钙化深度、角度和厚度等属性,其性能达到了专家级水平。Liu 等^[38]将研究重点放在了纤维斑块的识别,构建的 CNN 模型在鲁棒性和准确性上展现出优势。以上研究表明,DL 在 OCT 斑块检测及临床辅助诊断系统中的应用具有可行性。

3.4 超声心动图的应用

超声心动图是一种应用于评价冠心病患者节段性室壁运动异常的无创性影像检查方法,与其他影像学检测一样,其检测结果也依赖于医生主观分析,容易产生误读。Kusunose 等^[39]的研究实现了 CNN 在超声心动图领域能自动诊断心肌缺血,并能区分出心肌梗死的区域。Ouyang 等^[40]提出了基于超声心动图视频数据的 DL 算法 EchoNet-Dynamic,利用多个心脏周期的视频信息,可完成分割左心室、计算射血分数和评估心功能等关键任务,在外部验证数据集中,预测射血分数平均绝对误差为 6.0%,识别射血分数降低性心力衰竭曲线下面积为 0.96。Huang 等^[41]构建了多级神经网络,首先使用 CNN 模型用于超声心动图高质量视图分类,其次 U-Net 模型对图像进行分割,标注每个左心室壁的位置,最终的 CNN 模型评估局部室壁运动异常,创新点在于本研究是对超声心动图的动态视频进行分析,涵盖了空间和时间信息,并且进行了

外部验证,该方法为后续相关研究提供了多元化的思路。

4 小结与展望

DL 在冠心病的影像学诊断领域表现出了优越的性能,超越了传统的诊疗手段,可很大程度地帮助医生提高诊断效率,明显提升了诊断的标准性和客观性,作为一项辅助临床决策的技术,有利于冠心病的大面积筛查。在一些影像图像的分析中,DL 的某些表现可与该领域的专家相媲美,其对缩小不同资历医生之间的差距有一定价值。DL 不仅能缓解医院的诊疗压力,而且将会解决医疗资源分配不均的问题,尤其适用于医疗水平欠发达的基层医院,但将 DL 技术应用于临床上还存在一些问题:(1)低质量和小样本的数据会导致结果出现偏差;(2)数据标注需多位专业人士完成,标注过程成本高和时间长;(3)模型对于特殊性、复杂性数据样本识别能力差;(4)大多数心血管医生对于模型算法认识还不够清楚,利用“黑匣子”下诊断与医学伦理相违背;(5)模型在特定数据中训练,对其他数据兼容性差。随着国内外医学数据库的完善和数据共享的加强,通过标准、规范和权威的数据实现算法的进一步优化,DL 技术有着很大的研究和临床应用潜力。

参 考 文 献

- [1] 胡盛寿,高润霖,刘力生,等.《中国心血管病报告 2018》概要[J]. 中国循环杂志,2019,34(3):209-220.
- [2] 凯赛尔江·卡地尔,艾克力亚尔·艾尼瓦尔,马翔. 人工智能在主动脉夹层影像学诊断与风险预测中的应用[J]. 中华心血管病杂志,2021,49(11):1152-1156.
- [3] Premaladha J, Ravichandran KS. Novel approaches for diagnosing melanoma skin lesions through supervised and deep learning algorithms[J]. J Med Syst, 2016,40(4):96.
- [4] Botvinick M, Wang JX, Dabney W, et al. Deep reinforcement learning and its neuroscientific implications[J]. Neuron, 2020,107(4):603-616.
- [5] Wen B, Zeng WF, Liao Y, et al. Deep learning in proteomics[J]. Proteomics, 2020,20(21-22):e1900335.
- [6] Liu P, Wang M, Wang Y, et al. Impact of deep learning-based optimization algorithm on image quality of low-dose coronary CT angiography with noise reduction: a prospective study[J]. Acad Radiol, 2020,27(9):1241-1248.
- [7] Benz DC, Benetos G, Rampidis G, et al. Validation of deep-learning image reconstruction for coronary computed tomography angiography: impact on noise, image quality and diagnostic accuracy[J]. J Cardiovasc Comput Tomogr, 2020,14(5):444-451.
- [8] Hong JH, Park EA, Lee W, et al. Incremental image noise reduction in coronary CT angiography using a deep learning-based technique with iterative reconstruction[J]. Korean J Radiol, 2020,21(10):1165-1177.
- [9] Lossau T, Nickisch H, Wissel T, et al. Motion artifact recognition and quantification in coronary CT angiography using convolutional neural networks[J]. Med Image Anal, 2019,52:68-79.
- [10] Jung S, Lee S, Jeon B, et al. Deep learning cross-phase style transfer for motion artifact correction in coronary computed tomography angiography[J]. IEEE Access, 2020,8:81849-81863.
- [11] Xiao C, Li Y, Jiang Y. Heart coronary artery segmentation and disease risk warning based on a deep learning algorithm[J]. IEEE Access, 2020,8:140108-140121.
- [12] Jun Guo B, He X, Lei Y, et al. Automated left ventricular myocardium segmentation using 3D deeply supervised attention U-net for coronary computed tomography angiography; CT myocardium segmentation[J]. Med Phys, 2020,47(4):1775-1785.
- [13] He X, Guo BJ, Lei Y, et al. Automatic segmentation and quantification of epicardial adipose tissue from coronary computed tomography angiography[J]. Phys Med Biol, 2020,65(9):095012.
- [14] Commandeur F, Goeller M, Betancur J, et al. Deep learning for quantification of epicardial and thoracic adipose tissue from non-contrast CT[J]. IEEE Trans Med Imaging, 2018,37(8):1835-1846.
- [15] Wang ZQ, Zhou YJ, Zhao YX, et al. Diagnostic accuracy of a deep learning approach to calculate FFR from coronary CT angiography[J]. J Geriatr Cardiol, 2019,16(1):42-48.
- [16] Kumamaru KK, Fujimoto S, Otsuka Y, et al. Diagnostic accuracy of 3D deep-learning-based fully automated estimation of patient-level minimum fractional flow reserve from coronary computed tomography angiography[J]. Eur Heart J Cardiovasc Imaging, 2020,21(4):437-445.
- [17] Zreik M, van Hamersvelt RW, Khalili N, et al. Deep learning analysis of coronary arteries in cardiac CT angiography for detection of patients requiring invasive coronary angiography[J]. IEEE Trans Med Imaging, 2020,39(5):1545-1557.
- [18] van den Oever LB, Cornelissen L, Vonder M, et al. Deep learning for automated exclusion of cardiac CT examinations negative for coronary artery calcium[J]. Eur J Radiol, 2020,129:109114.
- [19] Lessmann N, van Ginneken B, Zreik M, et al. Automatic calcium scoring in low-dose chest CT using deep neural networks with dilated convolutions[J]. IEEE Trans Med Imaging, 2018,37(2):615-625.
- [20] Zhang N, Yang G, Zhang W, et al. Fully automatic framework for comprehensive coronary artery calcium scores analysis on non-contrast cardiac-gated CT scan: total and vessel-specific quantifications[J]. Eur J Radiol, 2021,134:109420.
- [21] van Velzen SGM, Lessmann N, Velthuis BK, et al. Deep learning for automatic calcium scoring in CT: validation using multiple cardiac CT and chest CT protocols[J]. Radiology, 2020,295(1):66-79.
- [22] Sodickson A, Baeyens PF, Andriole KP, et al. Recurrent CT, cumulative radiation exposure, and associated radiation-induced cancer risks from CT of adults[J]. Radiology, 2009,251(1):175-184.
- [23] Benz DC, Fuchs TA, Gräni C, et al. Head-to-head comparison of adaptive statistical and model-based iterative reconstruction algorithms for submillisievert coronary CT angiography[J]. Eur Heart J Cardiovasc Imaging, 2018,19(2):193-198.
- [24] 李宸,徐少华,陆丽洁,等. 基于冠状动脉 CT 血管成像的无创血流储备分数的研究进展[J]. 心血管病学进展, 2021,42(5):445-448.
- [25] Hecht HS. Coronary artery calcium scanning: past, present, and future[J]. JACC Cardiovasc Imaging, 2015,8(5):579-596.
- [26] Tan LK, McLaughlin RA, Lim E, et al. Fully automated segmentation of the left ventricle in cine cardiac MRI using neural network regression[J]. J Magn Reson Imaging, 2018,48(1):140-152.
- [27] Hosseini Hosseini SA, Moeller S, Weingärtner S, et al. Accelerated coronary MRI using 3D SPIRiT-RAKI with sparsity regularization[J]. Proc IEEE Int Symp Biomed Imaging, 2019,2019:1692-1695.
- [28] Scannell CM, Veta M, Villa ADM, et al. Deep-learning-based preprocessing for quantitative myocardial perfusion MRI[J]. J Magn Reson Imaging, 2020,51(6):1689-1696.
- [29] Zhang N, Yang G, Gao Z, et al. Deep learning for diagnosis of chronic

- myocardial infarction on nonenhanced cardiac cine MRI[J]. *Radiology*, 2019, 291(3):606-617.
- [30] Shibutani T, Nakajima K, Wakabayashi H, et al. Accuracy of an artificial neural network for detecting a regional abnormality in myocardial perfusion SPECT[J]. *Ann Nucl Med*, 2019, 33(2):86-92.
- [31] Kaplan Berkaya S, Ak Sivriköz I, Gunal S. Classification models for SPECT myocardial perfusion imaging[J]. *Comput Biol Med*, 2020, 123:103893.
- [32] Betancur J, Commandeur F, Motlagh M, et al. Deep learning for prediction of obstructive disease from fast myocardial perfusion SPECT: a multicenter study[J]. *JACC Cardiovasc Imaging*, 2018, 11(11):1654-1663.
- [33] Betancur J, Hu LH, Commandeur F, et al. Deep learning analysis of upright-supine high-efficiency SPECT myocardial perfusion imaging for prediction of obstructive coronary artery disease: a multicenter study[J]. *J Nucl Med*, 2019, 60(5):664-670.
- [34] Otaki Y, Singh A, Kavanagh P, et al. Clinical deployment of explainable artificial intelligence of SPECT for diagnosis of coronary artery disease[J]. *JACC Cardiovasc Imaging*, 2021, S1936-878X(21)00438-1.
- [35] Liu H, Wu J, Miller EJ, et al. Diagnostic accuracy of stress-only myocardial perfusion SPECT improved by deep learning[J]. *Eur J Nucl Med Mol Imaging*, 2021, 48(9):2793-2800.
- [36] Gessert N, Lutz M, Heyder M, et al. Automatic plaque detection in IVOCT pullbacks using convolutional neural networks[J]. *IEEE Trans Med Imaging*, 2019, 38(2):426-434.
- [37] Gharaibeh Y, Prabhu DS, Kolluru C, et al. Coronary calcification segmentation in intravascular OCT images using deep learning: application to calcification scoring[J]. *J Med Imaging (Bellingham)*, 2019, 6(4):045002.
- [38] Liu X, Du J, Yang J, et al. Coronary artery fibrous plaque detection based on multi-scale convolutional neural networks[J]. *J Sign Process Syst*, 2020, 92(3):325-333.
- [39] Kusunose K, Abe T, Haga A, et al. A deep learning approach for assessment of regional wall motion abnormality from echocardiographic images[J]. *JACC Cardiovasc Imaging*, 2020, 13(2 Pt 1):374-381.
- [40] Ouyang D, He B, Ghorbani A, et al. Video-based AI for beat-to-beat assessment of cardiac function[J]. *Nature*, 2020, 580(7802):252-256.
- [41] Huang MS, Wang CS, Chiang JH, et al. Automated recognition of regional wall motion abnormalities through deep neural network interpretation of transthoracic echocardiography[J]. *Circulation*, 2020, 142(16):1510-1520.

收稿日期:2021-07-15

(上接第 334 页)

- [20] Yancy CW, Jessup M, Bozkurt B, et al. 2013 ACCF/AHA guideline for the management of heart failure: a report of the American College of Cardiology Foundation/American Heart Association Task Force on Practice Guidelines[J]. *J Am Coll Cardiol*, 2013, 62(16):e147-e239.
- [21] Ye Z, Miranda WR, Yeung DF, et al. Left atrial strain in evaluation of heart failure with preserved ejection fraction[J]. *Am Soc Echocardiogr*, 2020, 33(12):1490-1499.
- [22] Melenovsky V, Hwang SJ, Redfield MM, et al. Left atrial remodeling and function in advanced heart failure with preserved or reduced ejection fraction[J]. *Circ Heart Fail*, 2015, 8(2):295-303.
- [23] Almeida P, Rodrigues J, Lourenço P, et al. Left atrial volume index is critical for the diagnosis of heart failure with preserved ejection fraction[J]. *J Cardiovasc Med (Hagerstown)*, 2018, 19(6):304-309.
- [24] 李娟, 张勇, 王健. 肥胖和阻塞性睡眠呼吸暂停综合征对左室质量及左室几何构型的影响[J]. *中西医结合心脑血管病杂志*, 2021, 19(1):133-138.
- [25] D'Andrea A, Radmilovic J, Ballo P, et al. Left ventricular hypertrophy or storage disease? the incremental value of speckle tracking strain bull's-eye[J]. *Echocardiography*, 2017, 34(5):746-759.
- [26] Ran H, Schneider M, Pistrutto AM, et al. Echocardiographic evaluation of left ventricular filling pressures in patients with pulmonary hypertension[J]. *Int J Cardiovasc Imaging*, 2019, 35(5):861-868.
- [27] Narang A, Mor-Avi V, Prado A, et al. Machine learning based automated dynamic quantification of left heart chamber volumes[J]. *Eur Heart J Cardiovasc Imaging*, 2019, 20(5):541-549.
- [28] Sharifov OF, Schiros CG, Aban I, et al. Diagnostic accuracy of tissue Doppler index E/e' for evaluating left ventricular filling pressure and diastolic dysfunction/heart failure with preserved ejection fraction: a systematic review and meta-analysis[J]. *Am Heart Assoc*, 2016, 5(1):e002530.
- [29] Koestenberger M, Friedberg MK, Nestaas E, et al. Transthoracic echocardiography in the evaluation of pediatric pulmonary hypertension and ventricular dysfunction[J]. *Pulm Circ*, 2016, 6(1):15-29.
- [30] 孙丹丹, 侯颖, 侯传举, 等. 应用三尖瓣血流速度图评估肺动脉高压的研究[J]. *中国医学影像学杂志*, 2017, 25(1):13-16.
- [31] Dzioeva O, Belyavskiy E. Diagnosis and management of patients with heart failure with preserved ejection fraction (HFpEF): current perspectives and recommendations[J]. *Ther Clin Risk Manag*, 2020, 16:769-785.
- [32] Notomi Y, Isomura T, Kanai S, et al. Pre-operative left ventricular torsion, QRS width/CRT, and post-mitral surgery outcomes in patients with nonischemic, chronic, severe secondary mitral regurgitation[J]. *JACC Basic Transl Sci*, 2016, 1(4):193-202.
- [33] Zhang Y, Li SY, Xie JJ, et al. Twist/untwist parameters are promising evaluators of myocardial mechanic changes in heart failure patients with preserved ejection fraction[J]. *Clin Cardiol*, 2020, 43(6):587-593.
- [34] Sakane K, Kanzaki Y, Tsuda K, et al. Disproportionately low BNP levels in patients of acute heart failure with preserved vs reduced ejection fraction[J]. *Int J Cardiol*, 2021, 327(5):105-110.
- [35] Carubelli V, Lombardi C, Lazzarini V, et al. N-terminal pro-B-type natriuretic peptide-guided therapy in patients hospitalized for acute heart failure[J]. *J Cardiovasc Med (Hagerstown)*, 2016, 17(11):828-839.

收稿日期:2021-09-02