

深度学习在脑小血管病影像学标志物中的研究进展

白雪冬 张小雷 夏爽

【摘要】 随着人工智能技术的飞速发展,特别是深度学习算法的应用,使脑小血管病典型影像学标志物的检测及量化评估速度增快、准确性提高。本文拟综述深度学习算法在脑微出血、脑白质高信号、扩大的血管周围间隙、腔隙、近期皮质下梗死及脑萎缩等脑小血管病影像学标志物中的研究进展,以为脑小血管病的精准医疗提供支持。

【关键词】 大脑小血管疾病; 深度学习; 综述

Progress of deep learning in cerebral small vessel disease imaging markers

BAI Xue-dong¹, ZHANG Xiao-lei², XIA Shuang³

¹Department of Radiology, Affiliated Hospital of Chengde Medical University, Chengde 067000, Hebei, China

²Department of Biomedical and Engineering, Chengde Medical University, Chengde 067000, Hebei, China

³Department of Radiology, Tianjin First Central Hospital, School of Medicine, Nankai University, Tianjin 300192, China

Corresponding author: XIA Shuang (Email: xiashuang77@163.com)

【Abstract】 With the rapid development of artificial intelligence (AI) technology, especially the application of deep learning (DL), the detection and quantitative evaluation of typical imaging markers of small cerebral vascular disease (CSVD) has been accelerated and the accuracy has been improved. In recent years, it has attracted much attention in the field of medical imaging. This paper intends to summarize the research progress and problems of deep learning in the imaging markers of CSVD such as cerebral microbleeds (CMBs), white matter hyperintensities (WMH), enlarged perivascular space (EPVS), lacunes, recent small subcortical infarcts (RSSI) and cerebral atrophy, so as to provide support for the precise treatment of CSVD.

【Key words】 Cerebral small vessel diseases; Deep learning; Review

This study was supported by the National Natural Science Foundation of China (No. 82171916), and Hebei Provincial Health Commission Science and Technology Research Program (No. 20200385).

Conflicts of interest: none declared

脑小血管病(CSVD)系多种危险因素影响颅内小动脉、微动脉、毛细血管、微静脉和小静脉导致的一系列临床、影像和病理综合征,具有起病隐匿、症状复杂、异质性大、动态变化、可预防的特点,约占脑卒中病因的25%、痴呆病因的45%^[1]。临床主要表现为认知功能下降、痴呆及步态障碍。神经影像学血管性改变报告标准(STRIVE)提出6种脑小血

管病影像学标志物,即脑微出血(CMBs)、脑白质高信号(WMH)、扩大的血管周围间隙(EPVS)、腔隙、近期皮质下梗死(RSSI)、脑萎缩^[2]。目前的影像学评估主要依靠人工阅片,存在费时费力、主观性大、易出错等问题,随着人工智能(AI)技术的飞速发展,基于深度学习(DL)算法的医学影像学分析技术简便快捷、准确性高,可重复性佳,备受医学影像学领域的关注^[3],其在脑小血管病研究中的应用也越来越广泛。本文拟综述深度学习算法在脑小血管病影像学标志物中的研究进展,以期提高脑小血管病影像学标志物的诊断效率和准确性,以为疾病精准医疗提供支持。

一、深度学习算法简介

深度学习是机器学习(ML)算法的一种,一般意

doi: 10.3969/j.issn.1672-6731.2023.01.003

基金项目:国家自然科学基金资助项目(项目编号:82171916);
河北省卫生健康委重点科技研究计划项目(项目编号:20200385)

作者单位:067000 承德医学院附属医院放射科(白雪冬);
067000 承德医学院生物医学工程系(张小雷);300192 南开大学附属第一医院放射科(夏爽)

通讯作者:夏爽,Email:xiashuang77@163.com

义指具有更深层次结构的神经网络,“深度”指其算法结构模型中设计更深、更精巧的结构,有助于该算法在数据中提取更高层次的特征;“学习”指该算法为数据驱动型,可自动化学习数据特征,可模仿如文字识别、图片分类、行为检测等人类行为^[4]。深度学习的本质是构建含有大量可优化参数的针对大数据的数学模型,通过对大数据的分析、特征提取和规律学习,对数据进行分类和预测^[5]。相较传统的 Logistic 回归(LR)、随机森林(RF)、支持向量机(SVM)、决策树(DT)等浅层学习,深度学习具有以下优势:第一,可自动化提取数据特征,省略人工设计特征的复杂环节;第二,准确性随数据规模的增大而提高,可仅通过增大数据规模以获得更好的模型性能;第三,具有更深的结构设计,可包含更多的参数和学习单元,使其在各领域的表现均优于浅层学习模型。卷积神经网络(CNN)作为深度学习算法中最重要的算法,是在传统神经网络基础上发展起来的,模型结构与神经网络有很大相似性,但也有区别^[6]:卷积神经网络主要由输入层、卷积层、归一化层、池化层、全连接层、输出层组成,而传统神经网络仅由输入层、全连接层和输出层组成。卷积神经网络主要通过一系列连续的线性层和非线性层将成像滤波器与神经网络相结合,从图像中学习越来越高级的特征,并将图像输入映射至所需的输出,在图像分类、检测、分割、配准任务中显示出巨大潜力^[7]。深度学习算法可以用于处理大规模医学影像学数据,为疾病筛查、诊断、疗效评价提供科学方法^[8]。

二、深度学习在脑小血管病影像学标志物中的应用

1. 对脑微出血的自动检测及鉴别 脑微出血表现为 T_2^* -梯度回波序列(T_2^* -GRE)孤立或散在分布的直径 2~10 毫米的点状、圆形或类圆形低信号灶。SWI 的检出率较高,但受限于人工阅片以及钙化、髓静脉、铁沉积等可能与脑微出血相似的表现^[9],亟待探究一致性较高、应用广泛的脑微出血定量检测方法。近年来,基于卷积神经网络的脑微出血检测备受关注且检测效能显著提高。该方法自动检测脑微出血主要分为两阶段,即潜在风险候选区域的检测阶段和假阳性数减少的判别阶段^[10]。有研究提出一种利用 SWI 图像自动检测脑微出血的两阶段卷积神经网络算法,以 3D 完全卷积网络(FCN)作为检测阶段、3D 卷积神经网络作为判别阶段,可消除

大量冗余计算,显著增快检测进程,同时可提取脑微出血具有代表性的高级特征,从而获得更高的检测精度^[11]。天津市第一中心医院夏爽教授团队与美国韦恩州立大学 Haacke 教授团队合作研发出基于 SWI 图像的检测阶段以及基于 SWI 和相位图像的判别阶段的 3D 深度学习残差网络,该模型检测脑微出血的灵敏度为 95.80%、精确度为 70.90%,假阳性数为 1.6^[12]。亦有研究提出一种高效检测脑微出血的全自动两阶段集成深度学习算法,即用于检测阶段的基于区域 YOLO 算法(You Only Look Once)和用于判别阶段的 3D 卷积神经网络,检测阶段结果显示,基于区域 YOLO 算法可有效检出脑微出血,灵敏度为 93.62%,每位受试者在五次交叉验证中的平均假阳性数为 52.18;判别阶段结果显示,基于 3D 卷积神经网络可使假阳性数降至 1.42^[13]。两项研究均表明深度学习算法用于脑微出血的检测具有较高的敏感性。Rashid 等^[14]基于具有更高分辨率层数的 U-Net 模型,结合 T_2 WI、SWI 和定量磁敏感图(QSM),研发出一种基于深度神经网络(DNN)的深度学习分割方法,可提高脑微出血与铁沉积鉴别诊断的敏感性和准确性。由此可见,深度学习算法用于脑微出血研究具有巨大应用潜力,可提高诊断效能和准确性。

2. 对脑白质高信号的自动分割及变化预测 脑白质高信号通常呈现 T_2 WI 或 FLAIR 成像高信号,其自动分割对探究脑小血管病、认知功能障碍和运动障碍性疾病等的病理生理学机制具有重要意义^[15]。传统的手动分割方法费时费力,且存在过拟合问题,限制模型的训练和分割性能。深度学习算法在一定程度上解决了上述问题。有研究基于 U-Net 模型经典的编码器-解码器结构,借鉴密集连接和多次卷积思想,构建一种新的集成模型,可进一步提高算法的鲁棒性和分割性能,为分析脑白质高信号特征提供重要的算法支撑^[16]。但卷积神经网络缺乏将解剖位置特征纳入决策过程的能力,临床实践中解剖位置特征对疾病的准确诊断至关重要。鉴于此,有研究提出采用多尺度补丁或在模型训练时采用显示解剖位置特征的深度卷积神经网络模型并应用于大数据集,结果显示,整合解剖位置特征的深度卷积神经网络对脑白质高信号的分割精度显著优于传统手动分割方法或不整合解剖位置特征的卷积神经网络^[17]。Sundaresan 等^[18]提出一种准确的脑白质高信号自动分割方法,即采用 3D U-Net

集成网络(TrUE-Net)对头部 MRI 图像进行分析,并进行 5 个外部数据集的验证,发现该方法评估脑深部和脑室周围白质高信号的鲁棒性和可比性最佳。他们还在脑白质高信号自动分割的基础上进一步探究转移学习方法和领域对抗性学习方法(包括领域对抗性神经网络和领域遗忘),可提高 TrUE-Net 的通用性,其中领域对抗性神经网络的诊断性能最佳,对脑白质高信号自动分割的鲁棒性最高^[19]。应注意的是,脑白质高信号有可能在一段时间内自行演变(缩小或扩大),一旦发生演变即可能成为无法预知的临床危险因素,预测上述变化极具挑战性。疾病演变预测模型(DEP)是 Rachmadi 等^[20]提出的一种端到端的训练模型,该模型以生成对抗网络(GAN)和 U-残差网络(UResNet)作为深度学习算法的基本架构,自动预测和空间估计脑白质高信号的动态演变,临床医师可通过该模型及时评估脑白质高信号的位置、范围和严重程度,从而选择更有效的治疗方法。上述研究表明,深度学习算法在脑白质高信号研究中具有巨大应用潜力,可显著提高自动分割和预测精度。

3. 对扩大的血管周围间隙的自动识别及量化
血管周围间隙(亦称 Virchow-Robin 间隙)是静脉或动脉与软脑膜之间的间隙。典型的扩大的血管周围间隙 T₂WI 呈高信号、FLAIR 成像呈低信号,病变较小且形态各异,手动标识极具挑战性且耗时,故自动识别方法的研发迫在眉睫。Frangi 过滤器是最早的扩大的血管周围间隙分割方法,但仅可对单个病变进行手动分割,耗时较长且准确性较低^[21]。此后,研究者转变思路,不再进行单个扩大的血管周围间隙的分割,而是采用支持向量机表述为二分类评分(即很少或很多扩大的血管周围间隙)^[22]。随后, Dubost 等^[23]进一步深化研究,将二分类评分改为连续评分,使评价标准更接近扩大的血管周围间隙的实际数量,该项研究首次对较大数据集(2000 次 MRI 扫描)的扩大的血管周围间隙进行量化,并提出一种基于 3D 回归卷积神经网络的自动评分方法以量化评估基底节区扩大的血管周围间隙数量,结果显示,仅 200 次 MRI 扫描的训练集即已获得良好诊断性能;训练集为 1000 次 MRI 扫描时,该评估方法与视觉评估(肉眼观察)之间的组内相关系数(ICC)达 0.74,一致性较高且可重复性较高。该方法在扩大的血管周围间隙自动量化方面的优势超过基于强度、尺度不变特征变换和随机森林等传

统自动化方法。除外基底节区,该方法还可扩展应用于中脑、海马和半卵圆中心等区域。后续研究进一步引入包括人口统计学、心血管危险因素、载脂蛋白 E(ApoE)基因型等信息,可以在流行病学和临床研究领域取代传统视觉评分,推进对扩大的血管周围间隙病因学及其作为小血管疾病危险因素潜力的研究,且量化评估方法逐步成熟和稳定。

4. 对腔隙的自动检测及识别
腔隙在 FLAIR 成像上主要表现为中央脑脊液样低信号和周围边缘高信号^[24]。腔隙的自动检测对影像学 and 临床研究具有重要意义,计算机辅助检测系统提出多种自动化检测方法;Uchiyama 等^[25]首先通过区域生长技术在 T₁WI 图像上分割脑区,再对分割脑区的 T₂WI 图像采用顶帽变换和多相位二值化的数字图像处理办法,进而研发出一种检测腔隙的计算机辅助诊断方法,该方法对腔隙的检出率达 96.77%(90/93),假阳性数为 0.76;随后,他们基于规则和支持向量机分类器,采用特征空间模板匹配的假阳性数约简方法(一种深度学习算法),结果显示,这种联合方法检测腔隙的灵敏度为 96.8%,每层图像的假阳性数降至 0.47^[26]。考虑到解剖位置特征在腔隙分析中的重要性,有研究者提出一种基于卷积神经网络的两阶段自动识别方法,首先通过完全卷积网络进行初筛,再采用 3D 卷积神经网络排除假阳性,然后结合多尺度分析和明确位置特征的方法,构建 3D 深度卷积神经网络,并在大数据集上对卷积神经网络进行训练、验证和测试,该方法可自动检出 94% 的腔隙,与传统手动分割方法相比,卷积神经网络与解剖位置特征整合方法检测腔隙的灵敏度达 97.4%,每层图像的假阳性数降至 0.13^[27]。

5. 对近期皮质下梗死的自动分割及检测
近期皮质下梗死在 DWI 上表现为高信号,可资与陈旧性梗死相区别。传统的聚类分析技术和机器学习算法在近期皮质下梗死分割中应用较多,但分割精度有待提高。基于局部信息的模糊 C 均值聚类算法(FLICM)是一种深度学习算法,图像分割过程中不仅考虑每个像素的域信息,而且通过不断迭代更新参数,可有效提高图像分割精度。Ma 等^[28]引入 Canny 边缘检测算法和傅里叶形状描述子(Fourier descriptor)对模糊 C 均值聚类算法进行优化,该算法优化后 Jaccard 系数、Dice 系数、峰值信噪比、结构相似性指数、运行时间和分割精度均提高^[28]。CT 平扫是疑诊急性缺血性卒中的推荐检查方法,但无法

检出疾病早期梗死灶的变化。Finck 等^[29]报告一种弱监督深度学习算法,主要用于检测急性缺血性卒中患者 CT 特征性表现,结果显示,该方法鉴别诊断近期皮质下梗死与其他类型脑梗死的准确性较高(曲线下面积为 0.98,95%CI:0.970~1.000),灵敏度达 100%、特异度为 40.6%,阳性预测值为 80.6%、阴性预测值为 100%,为缺血性卒中的鉴别诊断、分诊治疗提供有效方法。还有研究分析基于深度学习智能压缩感知技术的 T₂-FLAIR 成像对近期皮质下梗死的检测效能,该方法在图像质量、信噪比、对比噪声比等方面与传统 T₂-FLAIR 成像无显著差异,但扫描时间减少 40%^[30]。

6. 对脑萎缩的自动分割及精准测量 精准的脑形态测量对深入了解脑部病变性质至关重要。常用的定量脑形态测量方法有基于体素的形态学分析(VBM),但为手动分割、测量工作量大且准确性较低,而基于深度学习算法的脑萎缩自动分割和测量解决了上述问题,相关研究既有横断面研究,又有队列研究。(1)横断面研究:著名的开源 FreeSurfer 算法可提供包括脑组织体积、皮质厚度和曲率等在内的多项影像学标志物^[31],但计算量较大、耗时较长,严重阻碍其临床应用。Rebsamen 等^[32]提出一种基于 FreeSurfer 6.0 的深度学习算法,可直接基于 T₁WI 图像测量皮质下兴趣区(ROI)体积、平均皮质厚度和曲率,进而定量检测脑萎缩程度,在保证检测准确性的同时,将图像处理时间缩短至数秒钟。(2)队列研究:相关队列研究要求量化脑萎缩的深度学习算法可以检出不同扫描时间点的脑形态变化,但传统手动分割繁琐、耗时且易出错,自动分割亦存在不准确性,因此,队列研究评估脑形态变化的准确性较低。深度学习生成合成图像方法可以解决这一问题,用于评估模型配准、估计和纠正纵向分析偏差、生成缺失模式和增加训练集等^[33],如模拟脑组织损失的转换模型以及模拟对抗生成网络等。2021 年, Bernal 等^[34]提出一种深度学习模型,根据分割图像的要求对 T₁WI 进行变形以生成纵向数据集,该模型包含一个级联多路径 U 形网络,该网络通过多目标损耗进行优化,允许其路径精确生成不同脑区,准确生成纵向数据集,从而纵向评估脑萎缩程度,该项研究在 MRI 图像上采用完全卷积网络和组织分割准确生成合成脑萎缩变化图像的深度学习算法,从而显著提高脑萎缩的分割效率和精度。

三、深度学习在脑小血管病影像学标志物应用中存在的问题及展望

深度学习算法在脑小血管病影像学标志物研究中的应有越来越广泛,但仍存在诸多问题。

1. 算法过拟合和频谱偏差 机器学习算法本质上易出现过拟合和频谱偏差,且目前还未建立专门针对脑小血管病机器学习算法的质量评估标准^[35]。未来尚待构建一个稳健的研究设计以减少这种偏差,提高临床应用的普遍性。

2. 大数据集获取难度大 深度学习算法需大量的模型训练数据,而大数据集价格昂贵且难以获得。鉴于隐私保护和获取成本的原因,大多数脑小血管病影像学数据集规模较小,样本之间不平衡。未来尚待探究更高效的深度学习算法,如从有监督学习转向弱监督和无监督学习,以及从无模型方法转向基于模型的方法等是未来发展方向。

3. 多中心数据库建设滞后 国内多中心合作的标准化、规范化、智能化多模态脑小血管病影像学数据库建设滞后,对人工智能的临床转化尚未形成助力;不同类型设备和参数所产生的数据集之间存在显著差异,使数据集之间难以比较和合并。未来尚待建设标准化、规范化、智能化多模态脑小血管病数据库,以助力深度学习算法在脑小血管病精准医疗中的应用,实现产学研用、数据合作共享,多中心数据无障碍沟通以及保护数据隐私等领域将有极大发展潜力。

综上所述,基于深度学习算法的影像学分析技术在脑小血管病影像学标志物中的应用将脑小血管病的图像分析带入一个新层次,取得诸多进展。未来将进一步助力深度学习算法在脑小血管病精准医疗中的应用,充分发挥医学影像学、计算机科学、生物医学工程学、数据科学等学科优势,形成可持续发展的人工智能以及医学影像学产学研用新范式,为脑小血管病的精准医疗奠定基础。

利益冲突 无

参 考 文 献

- [1] Murray NM, Unberath M, Hager GD, Hui FK. Artificial intelligence to diagnose ischemic stroke and identify large vessel occlusions: a systematic review[J]. J Neurointerv Surg, 2020, 12:156-164.
- [2] Gorelick PB, Scuteri A, Black SE, Decarli C, Greenberg SM, Iadecola C, Launer LJ, Laurent S, Lopez OL, Nyenhuis D, Petersen RC, Schneider JA, Tzourio C, Arnett DK, Bennett DA, Chui HC, Higashida RT, Lindquist R, Nilsson PM, Roman GC, Sellke FW, Seshadri S; American Heart Association Stroke

- Council, Council on Epidemiology and Prevention, Council on Cardiovascular Nursing, Council on Cardiovascular Radiology and Intervention, and Council on Cardiovascular Surgery and Anesthesia. Vascular contributions to cognitive impairment and dementia: a statement for healthcare professionals from the American Heart Association/American Stroke Association [J]. *Stroke*, 2011, 42:2672-2713.
- [3] Nannoni S, Ohlmeier L, Brown RB, Morris RG, MacKinnon AD, Markus HS; DNA Lacunar 2 investigators. Cognitive impact of cerebral microbleeds in patients with symptomatic small vessel disease[J]. *Int J Stroke*, 2022, 17:415-424.
- [4] Ahmed - Aristizabal D, Armin MA, Denman S, Fookes C, Petersson L. A survey on graph - based deep learning for computational histopathology [J]. *Comput Med Imaging Graph*, 2022, 95:102027.
- [5] Aljabri M, AlAmir M, AlGhamdi M, Abdel-Mottaleb M, Collado-Mesa F. Towards a better understanding of annotation tools for medical imaging: a survey[J]. *Multimed Tools Appl*, 2022, 81: 25877-25911.
- [6] Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, Santamaría J, Fadhel MA, Al-Amidie M, Farhan L. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions[J]. *J Big Data*, 2021, 8:53.
- [7] Guan H, Liu M. Domain adaptation for medical image analysis: a survey[J]. *IEEE Trans Biomed Eng*, 2022, 69:1173-1185.
- [8] Zhao X, Zhao XM. Deep learning of brain magnetic resonance images: a brief review[J]. *Methods*, 2021, 192:131-140.
- [9] Charidimou A, Krishnan A, Werring DJ, Rolf Jäger H. Cerebral microbleeds: a guide to detection and clinical relevance in different disease settings[J]. *Neuroradiology*, 2013, 55:655-674.
- [10] Al-Masni MA, Kim WR, Kim EY, Noh Y, Kim DH. Automated detection of cerebral microbleeds in MR images: a two-stage deep learning approach[J]. *Neuroimage Clin*, 2020, 28:102464.
- [11] Dou Q, Chen H, Yu L, Zhao L, Qin J, Wang DF, Mok VC, Shi L, Heng PA. Automatic detection of cerebral microbleeds from MR images via 3D convolutional neural networks [J]. *IEEE Trans Med Imaging*, 2016, 35:1182-1195.
- [12] Liu S, Utriainen D, Chai C, Chen Y, Wang L, Sethi SK, Xia S, Haacke EM. Cerebral microbleed detection using susceptibility weighted imaging and deep learning[J]. *Neuroimage*, 2019, 198: 271-282.
- [13] Al-Masni MA, Kim WR, Kim EY, Noh Y, Kim DH. A two cascaded network integrating regional - based YOLO and 3D - CNN for cerebral microbleeds detection [J]. *Annu Int Conf IEEE Eng Med Biol Soc*, 2020:1055-1058.
- [14] Rashid T, Abdulkadir A, Nasrallah IM, Ware JB, Liu H, Spincemaille P, Romero JR, Bryan RN, Heckbert SR, Habes M. DEPMIR: a deep neural network for differential detection of cerebral microbleeds and iron deposits in MRI [J]. *Sci Rep*, 2021, 11:14124.
- [15] Shi Y, Zhao Z, Tang H, Huang S. Intellectual structure and emerging trends of white matter hyperintensity studies: a bibliometric analysis from 2012 to 2021 [J]. *Front Neurosci*, 2022, 16:866312.
- [16] Li XX, Wang XX, Cheng J, Xu H, Li ZX, Liu T. White matter hyperintensities segmentation using neural network ensembles [J]. *Zhongguo Zu Zhong Za Zhi*, 2020, 15:234-242. [李鑫鑫, 汪绪先, 程健, 徐红, 李子孝, 刘涛. 基于多网络集成的脑白质高信号分割方法[J]. *中国卒中杂志*, 2020, 15:234-242.]
- [17] Ghafoorian M, Karssemeijer N, Heskes T, van Uden IWM, Sanchez CI, Litjens G, de Leeuw FE, van Ginneken B, Marchiori E, Platel B. Location sensitive deep convolutional neural networks for segmentation of white matter hyperintensities [J]. *Sci Rep*, 2017, 7:5110.
- [18] Sundaresan V, Zamboni G, Rothwell PM, Jenkinson M, Griffanti L. Triplanar ensemble U - Net model for white matter hyperintensities segmentation on MR images [J]. *Med Image Anal*, 2021, 73:102184.
- [19] Sundaresan V, Zamboni G, Dinsdale NK, Rothwell PM, Griffanti L, Jenkinson M. Comparison of domain adaptation techniques for white matter hyperintensity segmentation in brain MR images[J]. *Med Image Anal*, 2021, 74:102215.
- [20] Rachmadi MF, Valdés-Hernández MDC, Makin S, Wardlaw J, Komura T. Automatic spatial estimation of white matter hyperintensities evolution in brain MRI using disease evolution predictor deep neural networks[J]. *Med Image Anal*, 2020, 63: 101712.
- [21] Ballerini L, Lovreglio R, Valdés Hernández MDC, Gonzalez - Castro V, Maniega SM, Pellegrini E, Bastin ME, Deary IJ, Wardlaw JM. Application of the ordered logit model to optimising Frangi filter parameters for segmentation of perivascular spaces[J]. *Procedia Comput Sci*, 2016, 90:61-67.
- [22] González - Castro V, Valdés Hernández MDC, Chappell FM, Armitage PA, Makin S, Wardlaw JM. Reliability of an automatic classifier for brain enlarged perivascular spaces burden and comparison with human performance [J]. *Clin Sci (Lond)*, 2017, 131:1465-1481.
- [23] Dubost F, Adams H, Bortsova G, Ikram MA, Niessen W, Vernooij M, de Bruijne M. 3D regression neural network for the quantification of enlarged perivascular spaces in brain MRI [J]. *Med Image Anal*, 2019, 51:89-100.
- [24] Wardlaw JM, Smith EE, Biessels GJ, Cordonnier C, Fazekas F, Frayne R, Lindley RI, O'Brien JT, Barkhof F, Benavente OR, Black SE, Brayne C, Breteler M, Chabriat H, Decarli C, de Leeuw FE, Doubal F, Duering M, Fox NC, Greenberg S, Hachinski V, Kilimann I, Mok V, Oostenbrugge RV, Pantoni L, Speck O, Stephan BC, Teipel S, Viswanathan A, Werring D, Chen C, Smith C, van Buchem M, Norring B, Gorelick PB, Dichgans M; STandards for Reporting Vascular changes on neuroimaging (STRIVE v1). Neuroimaging standards for research into small vessel disease and its contribution to ageing and neurodegeneration[J]. *Lancet Neurol*, 2013, 12:822-838.
- [25] Uchiyama Y, Yokoyama R, Ando H, Asano T, Kato H, Yamakawa H, Yamakawa H, Hara T, Iwama T, Hoshi H, Fujita H. Computer-aided diagnosis scheme for detection of lacunar infarcts on MR images[J]. *Acad Radiol*, 2007, 14:1554-1561.
- [26] Uchiyama Y, Abe A, Muramatsu C, Hara T, Shiraiishi J, Fujita H. Eigenspace template matching for detection of lacunar infarcts on MR images[J]. *J Digit Imaging*, 2015, 28:116-122.
- [27] Ghafoorian M, Karssemeijer N, Heskes T, Bergkamp M, Wissink J, Obels J, Keizer K, de Leeuw FE, Ginneken BV, Marchiori E, Platel B. Deep multi - scale location - aware 3D convolutional neural networks for automated detection of lacunes of presumed vascular origin [J]. *Neuroimage Clin*, 2017, 14:391-399.
- [28] Ma C, Li H, Zhang K, Gao Y, Yang L. Risk factors of restroke in patients with lacunar cerebral infarction using magnetic resonance imaging image features under deep learning algorithm [J]. *Contrast Media Mol Imaging*, 2021:ID2527595.
- [29] Finck T, Schinz D, Grundl L, Eisawy R, Yigitsoy M, Moosbauer J, Zimmer C, Pfister F, Wiestler B. Automated detection of ischemic stroke and subsequent patient triage in routinely acquired head CT [J]. *Clin Neuroradiol*, 2022, 32:419-426.
- [30] Hou Y, Liu Q, Chen J, Wu B, Zeng F, Yang Z, Song H, Liu Y. Application value of T2 fluid - attenuated inversion recovery

- sequence based on deep learning in static lacunar infarction[J]. Acta Radiol, 2022.[Epub ahead of print]
- [31] Ozzoude M, Ramirez J, Raamana PR, Holmes MF, Walker K, Scott CJM, Gao F, Goubran M, Kwan D, Tartaglia MC, Beaton D, Saposnik G, Hassan A, Lawrence-Dewar J, Dowlatsahi D, Strother SC, Symons S, Bartha R, Swartz RH, Black SE. Cortical thickness estimation in individuals with cerebral small vessel disease, focal atrophy, and chronic stroke lesions [J]. Front Neurosci, 2020, 14:598868.
- [32] Rebsamen M, Suter Y, Wiest R, Reyes M, Rummel C. Brain morphometry estimation: from hours to seconds using deep learning[J]. Front Neurol, 2020, 11:244.
- [33] Frid-Adar M, Diamant I, Klang E, Amitai M, Goldberger J, Greenspan H. GAN - based synthetic medical image augmentation for increased CNN performance in liver lesion classification[J]. Neurocomput, 2018, 321:321-331.
- [34] Bernal J, Valverde S, Kushibar K, Cabezas M, Oliver A, Lladó X; Alzheimer's Disease Neuroimaging Initiative. Generating longitudinal atrophy evaluation datasets on brain magnetic resonance images using convolutional neural networks and segmentation priors [J]. Neuroinformatics, 2021, 19:477-492.
- [35] Gregory J, Welliver S, Chong J. Top 10 reviewer critiques of radiology artificial intelligence (AI) articles: qualitative thematic analysis of reviewer critiques of machine learning/deep learning manuscripts submitted to JMIR [J]. J Magn Reson Imaging, 2020, 52:248-254.
- (收稿日期:2023-01-18)
(本文编辑:袁云)

· 小词典 ·

中英文对照名词词汇(一)

- 阿尔茨海默病 Alzheimer's disease(AD)
- 阿尔茨海默病神经影像学计划
Alzheimer's Disease Neuroimaging Initiative(ADNI)
- 闭锁综合征 locked-in syndrome(LIS)
- 标记后延迟时间 post label delay(PLD)
- 表面肌电信号 surface electromyography(sEMG)
- 部分容积效应 partial volume effect(PVE)
- 低频振荡振幅
amplitude of low-frequency fluctuation(ALFF)
- 电子病历 electronic health record(EHR)
- β -淀粉样蛋白 amyloid β -protein(A β)
- 定量磁敏感图 quantitative susceptibility mapping(QSM)
- 动脉自旋标记 arterial spin labeling(ASL)
- 短潜伏期体感诱发电位
short latency somatosensory-evoked potential(SSEP)
- 多学科诊疗模式 multi-disciplinary team(MDT)
- 分类回归树 classification and regression tree(CART)
- 弗莱明翰卒中量表 Framingham Stroke Profile(FSP)
- 辅助运动区 supplementary motor area(SMA)
- 改良 Ashworth 量表 modified Ashworth Scale(MAS)
- 感觉运动节律 sensorimotor rhythm(SMR)
- 工业机器人双侧康复系统
industrial robot-based bilateral rehabilitation system
(IRBRS)
- 功能独立性评价 Function Independent Measure(FIM)
- 功能性步行分级量表
Functional Ambulation Category Scale(FAC)
- 功能性电刺激 function electrical stimulation(FES)
- 功能性神经系统疾病 functional neurological disorder(FND)
- 功能性运动障碍 functional movement disorder(FMD)
- CT灌注成像 CT perfusion imaging(CTP)
- 灌注成像 perfusion-weighted imaging(PWI)
- 光纤布拉格光栅 fiber Bragg grating(FBG)
- 国际功能性神经病学学会
Functional Neurological Disorder Society(FNDS)
- 国际疾病分类法-11
International Classification of Disease-11(ICD-11)
- 国际运动障碍协会 Movement Disorder Society(MDS)
- 盒子和障碍物测验 Box and Block Test(BBT)
- Logistic 回归 Logistic regression(LR)
- 昏迷恢复量表-修订版
Coma Recovery Scale-Revised(CRS-R)
- Glasgow 昏迷量表 Glasgow Coma Scale(GCS)
- 机器辅助 robot-assisted(RA)
- 机器学习 machine learning(ML)
- 基于体素的形态学分析 voxel-based morphometry(VBM)
- 经颅磁刺激 transcranial magnetic stimulation(TMS)
- 静息态脑电图 resting-state electroencephalography(rsEEG)
- 局部信息的模糊 C 均值聚类算法
fuzzy local information C-means clustering(FLICM)
- 局部一致性 regional homogeneity(ReHo)
- 卷积神经网络 convolution neural network(CNN)
- 决策树 decision tree(DT)
- 扩大的血管周围间隙 enlarged perivascular space(EPVS)
- 扩展的 Glasgow 昏迷量表
Glasgow Coma Scale-Extended(GCSE)
- 连续式动脉自旋标记
continuous arterial spin labeling(CASL)
- 洛桑急性脑卒中登记分析
Acute Stroke Registry and Analysis of Lausanne(ASTRAL)
- 脉冲式动脉自旋标记 pulsed arterial spin labeling(PASL)
- 美国癫痫协会 American Epilepsy Society(AES)
- 美国国家老龄化研究所-阿尔茨海默病学会
National Institute on Aging-Alzheimer's Association
(NIA-AA)