

基于深度学习的急性缺血性脑卒中病灶分割与检测综述^①



毛天驰, 李 杨, 李 明, 孙 兴, 马金刚

(山东中医药大学 智能与信息工程学院, 济南 250355)

通信作者: 马金刚, E-mail: ma_jingang@126.com

摘 要: 急性缺血性脑卒中是临床上最常见的卒中类型, 因其症状突发且治疗时间窗较短等特点, 成为全球导致残疾和死亡的重要因素之一. 随着人工智能领域的迅速发展, 深度学习技术在急性缺血性脑卒中的诊疗中展现出巨大的潜力. 深度学习模型能够快速高效地根据患者脑部图像对病灶进行分割与检测. 本文介绍深度学习模型的发展历程和用于脑卒中研究的常用公开数据集. 针对计算机断层扫描 (computerized tomography, CT) 和磁共振成像 (magnetic resonance imaging, MRI) 衍生出的多种模态和扫描序列, 详细阐述了深度学习技术在急性缺血性脑卒中病灶分割与检测领域的研究进展, 总结并分析了相关研究的改进思路. 最后, 指出了深度学习在该领域现存的挑战并提出了可能的解决方案.

关键词: 脑卒中; 医学图像分割; 计算机视觉; 深度学习; 计算机断层扫描; 磁共振成像

引用格式: 毛天驰, 李杨, 李明, 孙兴, 马金刚. 基于深度学习的急性缺血性脑卒中病灶分割与检测综述. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9709.html>

Survey on Deep Learning-based Lesion Segmentation and Detection in Acute Ischemic Stroke

MAO Tian-Chi, LI Yang, LI Ming, SUN Xing, MA Jin-Gang

(College of Intelligence and Information Engineering, Shandong University of Traditional Chinese Medicine, Jinan 250355, China)

Abstract: Acute ischemic stroke is the most common type of stroke in clinical practice. Due to its sudden onset and short treatment time window, it becomes one of the important factors leading to disability and death world wide. With the rapid development of artificial intelligence, deep learning technology shows great potential in the diagnosis and treatment of acute ischemic stroke. Deep learning models can quickly and efficiently segment and detect lesions based on patients' brain images. This study introduces the development history of deep learning models and commonly used public datasets for stroke research. For various modalities and scanning sequences derived from computerized tomography (CT) and magnetic resonance imaging (MRI), it elaborates on the research progress of deep learning technology in the field of lesion segmentation and detection in acute ischemic stroke and summarizes and analyzes the improvement ideas of related research. Finally, it points out existing challenges of deep learning in this field and proposes possible solutions.

Key words: stroke; medical image segmentation; computer vision; deep learning; computerized tomography (CT); magnetic resonance imaging (MRI)

脑卒中又称中风, 是指脑血管突发性破裂或者血管堵塞, 导致大脑部分区域的血液供应受到影响的疾病. 这一病症可能导致大脑细胞因氧气和养分不足而受损或死亡, 进而引发一系列严重的健康问题^[1]. 脑

^① 基金项目: 国家自然科学基金 (81973981, 82074579); 2022 年山东省研究生优质教育教学资源项目 (SDYAL2022041)

收稿时间: 2024-06-01; 修改时间: 2024-06-28; 采用时间: 2024-07-04; csa 在线出版时间: 2024-11-15

卒中是公认的急性脑血管疾病,是世界范围内导致残疾和死亡的第2大主要因素,脑卒中不仅对患者和患者家庭带来了沉重的经济负担与心理负担,同时脑卒中也对社会医疗资源带来了不小压力^[2].脑卒中通常分为两大类型:缺血性脑卒中和出血性脑卒中.缺血性脑卒中是由于大脑血管被血栓或者动脉粥样硬化物堵塞,导致血液供应中断.而出血性脑卒中则是由于脑血管破裂,血液泄漏到脑组织中.据统计,脑卒中主要以缺血性脑卒中为主,约占所有脑卒中病例的80%–85%^[3].

然而急性期脑卒中治疗的时间窗一般为发病后6h.

因此它需要临床医生的快速决策和适当干预^[4].如图1所示,以CT和MRI所代表的神经影像学技术,已成为急性卒中检测和预后的关键工具.由于其生成的脑卒中病变在强度和形状上与CT或MRI伪影相似,因此给影像科医生带来了巨大的挑战^[5].在过去的几十年里,各种机器学习技术,包括支持向量机、决策树、随机森林等技术的应用已经在脑卒中图像分割中取得了较好的效果^[6],然而传统的机器学习主要使用特征工程,需要进行人工提取和数据清洗.图像特征优化、易受多模态图像干扰等问题仍需要进一步探索和改进^[7].

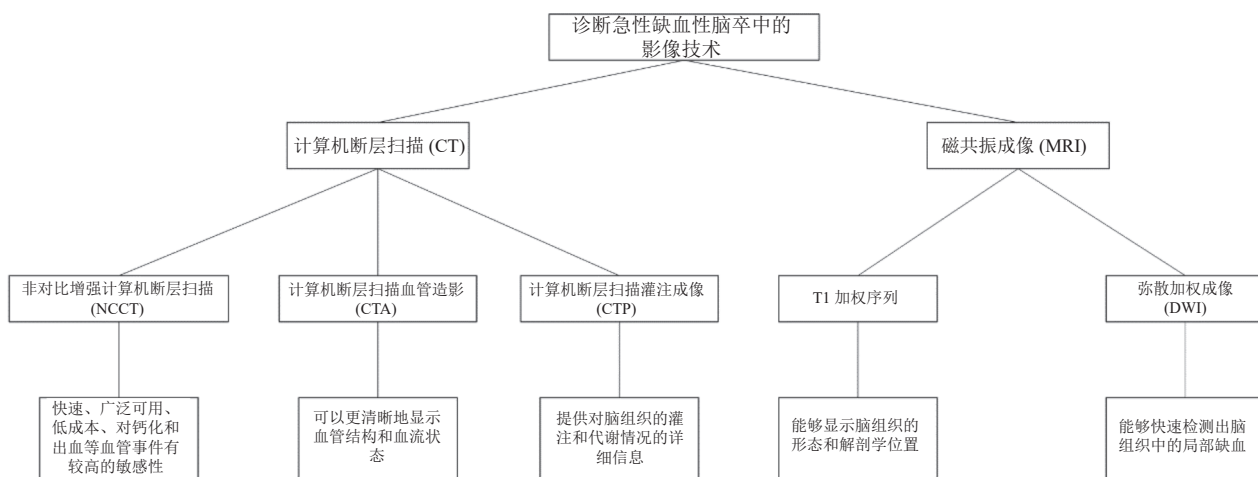


图1 诊断急性缺血性脑卒中常用的成像技术及其特点

近几年迅速发展的人工智能技术,尤其是深度学习为解决这些问题带来新的途径.它能够进行端到端学习,从而可以提供更为精准的医疗信息和更合理的临床决策.与传统机器学习方法相比,在定位卒中中病灶核心的CT或MRI图像方面深度学习能够自动提取并表达数据中的复杂特征^[8-11].这种方法不仅节省了影像科医生的时间和精力,还能够捕获病变的像素级信息,从而有助于提高诊断的准确性.在图像识别领域中最具代表性的深度学习模型是卷积神经网络(convolutional neural network, CNN),它是用于处理图像和空间数据的一类特殊神经网络.如图2所示,其结构包括卷积层、池化层和全连接层^[12].卷积层的作用是通过卷积操作从输入图像(数据集)中提取特征.池化层通过对输入特征图进行池化操作,降低图像的空间分辨率.全连接层通过整合来自卷积层和池化层的特征,学习更高级的特征表示,使网络能够更好地理解输入数据^[13,14].基于CNN,一系列深度卷积神经网络模型相继

提出,它们通过不断加深网络结构并改进训练技术,在各类图像识别、目标检测等任务中取得了卓越成绩.其中,在医学图像处理领域中的经典网络主要有:VGGNet^[15]、U-Net^[16]、ResNet^[17]、DenseNet^[18]、GoogLeNet^[19]等.现如今在医学图像分割识别领域的许多模型也都是基于以上的经典网络加以改进和调整的.虽然如今的深度学习模型数量众多且各有特点,但针对脑卒中图像的模态多样性,不同模型的性能表现也是不同的^[20].

在卒中中病灶分割与检测领域,近年来发表了几篇优秀综述^[21-23],文献^[21]总结了基于深度学习的卒中中病灶分割方法的创新与进展,但仅总结了MRI图像上的研究.文献^[22]对人工智能在急性缺血性脑卒中影像的研究进展做了简要介绍,但并未对基于深度学习的缺血性脑卒中病灶分割与检测进行系统的概述.文献^[23]综述了人工智能在脑卒中诊断与预测中的研究进展,但并未提及对现存问题可能的解决方法.针对上述不足,本文将围绕脑卒中患者的CT图像和MRI图

像,回顾近几年深度学习技术在上述图像中分割与检测脑卒中病灶的研究进展,旨在总结深度学习技术应

用于脑卒中图像的方法,优缺点及优化思路,最后讨论了在该领域研究中存在的挑战以及可能的解决途径。




图2 CNN结构

1 数据集介绍

深度学习中的数据集是指用于训练、验证和测试深度学习模型的一组数据^[24]。在缺血性脑卒中病灶的

识别与检测任务中,常用的公开数据主要有以下5个,表1汇总了这些数据集的模态、创立时间、样本数量和特点。如图3中示例显示,它们涵盖了多种模态。

表1 用于脑卒中病灶分割的常用公开数据集总结

数据集	扫描模态	创立年份	样本数量	数据集特点
ATLAS v1.2	MRI T1序列	2018	304	样本数量较多,但扫描序列单一且不包含单独的测试集
ATLAS v2.0	MRI T1序列	2021	955	样本数量多且创立年份较新,但扫描序列单一
ISLES 2015-SISS	MRI T1、T2、FLAIR、DWI序列	2015	64	涵盖多扫描序列且标注详细,但样本数量较少
ISLES 2018	CTP、MRI DWI序列	2018	103	涵盖多模态且标注详细,但样本数量较少
ISLES 2022	MRI FLAIR、DWI序列	2022	400	样本数量较多、标注详细且年份较新,但测试集并未公开




图3 缺血性脑卒中中的部分模态图像示例

● **ATLAS 数据集:** 这是一个用于脑卒中研究的重要数据集,使用了 T1 加权序列作为主要模态,由医学影像学家和神经科学家共同创建。该数据集收集了来自多个中风患者的 MRI 扫描图像,并通过手动标注来标识患者脑卒中病灶的轮廓。发展至今,ATLAS 共有两个版本。2018 年发布的 v1.2 版本涵盖了全球 11 个研究中心的 304 个病例,虽然这些病例的图像得到了专业医生的手动分割标注,但它并不包含单独的测试集,这使得使用该数据集的研究者很难可靠地评估算法的性能^[25]。在 2021 年,ATLAS 数据集又更新到了 v2.0 版本。目前,ATLAS v2.0 已全面覆盖了 ATLAS v1.2。与之前的版本相比,新版的数据集拥有更大的数据量,并且划分了训练集和测试集,ATLAS v2.0 提供了 1271

例图像。其中,955 例为公开图像,分为 655 例训练集图像和 300 例带有隐藏标注的测试集图像。另外,还有 316 例来自新的样本组的、之前未公开过的图像^[26]。

● **ISLES 2015-SISS:** ISLES 2015 挑战赛是一个国际性的比赛,旨在推动自动化脑卒中病灶分割算法的发展。随之诞生的另一个重要数据集是 ISLES 2015-SISS。该数据集收集了临床上 64 例亚急性缺血性脑卒中患者的图像数据,包含的 MRI 扫描序列有 T1 加权、T2 加权、液体衰减反转恢复 (fluid attenuated inversion recovery, FLAIR) 和弥散加权成像 (diffusion weighted image, DWI),这些图像都由经验丰富的专家手动分割标注,手动分割的工作主要在 FLAIR 序列上进行,其他序列则为其提供附加信息,数据集包括 28 个训练样本和 36 个测试样本^[27]。目前 ISLES 2015-SISS 也已经成为该研究领域的重要数据集。

● **ISLES 2018 数据集:** 这是在 2018 年举办的 ISLES 挑战赛的背景下诞生的公开数据集,挑战的目标是准确地从计算机断层扫描灌注成像 (computed tomography perfusion imaging, CTP) 中分割出梗死核心。这些梗死核心已经在患者的 DWI 图像中得到专家的精确标注,以此来检验深度学习模型分割的准确性。来自 3 个美

国中心医院和 1 个澳大利亚中心医院的 103 例急性大动脉闭塞前循环缺血性脑卒中患者构成了 ISLES 2018 数据集. 这些患者在脑卒中发作后 8 h 内就诊并在 CTP 扫描后 3 h 内接受了 MRI 扫描. 其中 40 名患者被纳入了这项挑战的测试集, 其余 63 人为训练集^[28]. 该数据集不仅包括不同患者的 CTP 图像. 此外数据集还包括 DWI 图像以及详细的脑卒中病变标注.

● ISLES 2022 数据集: 这是一个专家标注的、多中心的 MRI 数据集, 用于分割急性和亚急性缺血性脑卒中病灶. 数据集包括 400 张患者的 MRI 图像, MRI 模态涵盖了 FLAIR 和 DWI. 其中, 病灶大小、病灶数量和病灶位置的差异性很大. ISLES 2022 包括 250 个训练集样本和 150 个测试集样本. 所有训练集数据已经公开发布. 但测试集数据仅用于模型验证, 并不对公众发布^[29]. 该数据集作为 ISLES 2022 挑战的基础, 旨在寻找算法与方法, 以实现缺血性脑卒中分割模型的开发和基准测试.

2 急性缺血性脑卒中 CT 图像上的研究

CT 在临床上对脑卒中的诊断、治疗和监测起到了重要作用, 其扫描速度快的优点非常适合于紧急情况下急性脑卒中的诊断^[30]. 另外, CT 具有广泛的可用性, 此外, 相比于 MRI, CT 扫描的成本通常更低. 在脑卒中的诊断领域, 非对比增强计算机断层扫描 (non-contrast enhanced computed tomography, NCCT)、计算机断层扫描血管造影 (computed tomography angiography, CTA) 和 CTP 的应用尤其广泛. NCCT 是急诊科最常用的工具, 其优势在于快速性和低成本, 它可以快速排除出血性脑卒中的可能性, 所以 NCCT 更常用于缺血性脑卒中的前期筛查中^[31]. CTA 结合了 CT 和血管造影技术, CTA 通过注射造影剂进入患者的血管, 然后使用 CT 扫描仪进行成像, 以获取高分辨率的血管图像^[32]. CTP 则是通过结合 CT 和注射造影剂来获取关于脑部血流的信息, 它可以提供关于脑组织血流的定量信息, 包括脑血管的灌注量、血流速率、峰值时间等参数. 这些参数对于评估脑卒中患者的病情和预测患者的预后具有重要意义^[33]. 基于此, 目前大多数在急性缺血性脑卒中 CT 上的深度学习研究都围绕着这 3 种成像技术展开.

2.1 NCCT 的深度学习研究

NCCT 由于应用广泛、检查时间短、检查费用较

低, 以及可准确检查蛛网膜下腔出血和脑实质出血等优点, 已经成为急性脑卒中的一线影像学检查方法, 但它不能发现早期梗死的显著变化. 为解决此问题, Lu 等^[34]开发了一个用以识别 NCCT 中早期不可见缺血性脑卒中的深度学习模型, 该模型的定位模块建立在 YOLOv3 上, 它可以将整个图像划分为多个区域, 并预测每个区域的边界框和概率. 分类模块则使用了 ResNet 网络. 该模型结合了定位和分类网络的优势, 可以告知病变的区域和疾病的风险程度. 同样使用了 ResNet 网络的还有 Pan 等^[35], 他们的实验采用 ResNet 网络结合最大后验概率模块和后处理方法在 NCCT 图像上检测梗死核心. 构建的最大后验概率模块可以将不同尺寸的小块病灶分类结果和领域信息进行整合, 有效的弥补了 ResNet 在梗死区域识别方面的局限. 在此基础上, 模型还运用了决策曲线分析法建立模型, 分析了该方法在临床中的应用价值. 该实验的结果显示, 在一个 142 例患者组成的数据集中进行训练和测试后, 该模型在 NCCT 上检测梗死核心的识别准确率可以达到 75.9%.

相比于 NCCT, 先前的研究更多的将研究方向集中在 MRI 图像上的病灶分割, 其中一种名为 DeepMedic 的 CNN 模型取得了较好的评价指标并获得了广泛的认可^[36]. 与 MRI 图像相比, 由于 NCCT 图像中的缺血性变化更不明显, 因此 NCCT 上的病灶分割更具挑战性. 在随后的研究中, Tuladhar 等^[37]基于 DeepMedic 模型, 针对 NCCT 脑卒中病变分割进行了修改, 通过交叉验证对网络参数进行优化. 除此之外, 模型还加入了后处理机制, 后处理可以排除由噪声造成的伪影, 从而进一步提高分割准确性. 这为开发更先进的 NCCT 图像自动病变分析工具奠定了基础.

综上所述, 近年来在基于深度学习的缺血性脑卒中病灶分割与检测领域, 针对 NCCT 图像的研究较少. 原因是 NCCT 图像中早期梗死组织与正常脑组织的区别度较弱, 肉眼难以观测出病灶位置, 甚至对深度学习模型来说也是不小的挑战. 然而, NCCT 应用广泛, 成本低且可以快速成像. 考虑到脑卒中的特点, 若能利用 NCCT 图像快速筛查脑卒中病灶, 将节省患者的诊疗时间. 大多数最近的研究采用现有的神经网络, 在现有模型的基础上增加模块或优化算法, 取得了更好的检测结果. 然而, 针对 NCCT 上的分割与检测, 仍存在一些局限性. 首先, 模型准确率不够高, 难以达到临床应用标准. 其次, 缺乏公开数据集作为训练和测

试的标准, 导致实验结果缺乏可比性. 最后, 一些实验所用数据集的采集流程不够严格, 可能影响实验结果

和严谨性. 表 2 汇总了上述研究的主要贡献、局限性和评价指标等.

表 2 深度学习技术在 NCCT 上分割与检测缺血性脑卒中病灶的研究总结

参考文献	年份	研究模型	主要贡献	局限性	Dice系数	准确率
Lu等 ^[34]	2022	YOLOv3+ResNet	可以筛查早期病灶, 且具有较高的检测准确率	CT和MRI的扫描时间间隔长	—	0.89
Pan等 ^[35]	2021	ResNet+MAP	结合最大后验概率模块和后处理方法以提高准确率	训练样本存在类不平衡问题	—	0.76
Tuladhar等 ^[37]	2020	DeepMedic	将DeepMedic应用于NCCT图像中	小病灶分割效果仍需改进	0.50	—

2.2 CTA 的深度学习研究

CTA 最关键的应用是检测大血管阻塞 (large vessel occlusion, LVO). 大血管阻塞是指脑卒中患者大脑主要血管中发生的严重阻塞或闭塞情况. 这些主要血管包括中大脑动脉 (middle cerebral artery, MCA)、内大脑动脉 (internal carotid artery, ICA) 等. 大血管阻塞通常是由血栓或栓子形成, 阻塞了大脑血管, 导致血流受限, 从而引发脑卒中^[38]. 大血管阻塞是一种严重的脑卒中类型, 因为它可能导致更广泛的脑组织受损, 造成更严重的神经系统症状. 患有大血管阻塞的中风患者通常呈现出较严重的卒中症状, 如瘫痪、失语、失明等.

在许多西方国家, 影像科正面临着日益增加的工作量, 这往往导致人员短缺, 基于这种背景下, 一些企业已经开发了多种商业软件, 用于大血管阻塞的自动检测. 目前, 通过 CTA 图像检测识别脑卒中病灶的技术已经较为成熟, CTA 上大血管阻塞自动检测的商用软件平台有 Brainomix e-CTA^[39]、Rapid CTA^[40]、Rapid LVO^[41]、Viz LVO 等^[42]. 尽管这些商业软件都是基于 CNN 算法来检测大血管阻塞, 但每个供应商都对该网络进行了不同的修改, 并且可能以牺牲特异度为代价来追求高召回率, 反之亦然. 在这些商业软件的基础上, Brugnara 等^[43]开发了一种基于 RetinaNet 的人工神经网络 (artificial neural network, ANN). 该神经网络由编码器、解码器和检测头组成, 能在 2 min 内自动检测血管异常, 标记血管闭塞, 且无先验限制. 其优势在于处理高分辨率 CTA 的数据时无需大量预处理. 该 ANN 使用 Heidelberg 队列数据集进行训练和测试, 结果显示在测试集中预测 CTA 血管闭塞的召回率为 94%, 特异度为 83%. 与两种商业软件相比, 该 ANN 召回率显著提高, 尤其在中等血管阻塞情况下表现最佳.

在临床中通过 CTA 图像诊断脑卒中中, 主要是观察其中是否存在大血管阻塞. 然而, 现有的一些基于深度学习技术的方法往往存在局限性. 例如, 他们的方法大

多需要较长的预测时间, 且当处理涉及 ICA 起源的血块和近端重建的情况时, 可能会遇到一些麻烦. Kumar 等^[44]提出了一种基于 ResNet 的模型, 它用于从 CTA 扫描中检测 ICA 和 MCA 中的大血管阻塞. 该实验引入了一种新的框架, 该框架利用斑块级预测并汇总它们以获得最终决策, 有效的解决了上述的问题. 同时, 所提出的模型可以在 40 s 内对大血管阻塞进行检测并分类, 这对于帮助影像科医生和临床医生快速诊断并治疗脑卒中患者具有重要意义. 除了以上这些基于传统 CTA 图像的研究, 多种由 CTA 延伸的成像技术在临床上的应用也尤为广泛, 它们相较于传统的 CTA 有更多的维度、更快的扫描速度和更高的空间分辨率等优势. 许多用于分割和检测急性缺血性脑卒中病灶的深度学习模型也尝试在其中得到应用. 四维计算机断层扫描血管造影 (four-dimensional computed tomography angiography, 4D CTA) 是一种能够可视化脑血流动力学的成像方式, 在包括急性脑卒中在内的各种神经血管疾病的诊断评估中发挥着越来越重要的作用. Mejis 等^[45]使用三维 CNN 架构构建了一种用于自动检测颅内前循环动脉闭塞的模型, 它可以用于分析 4D CTA 图像. 为了在缩小的 3D 空间中捕获时间信息, 研究团队导出了 4D CTA 的归一化时间信号图, 最终该模型表现良好. 除了 4D CTA, 多相计算机断层扫描血管造影 (multiphase computed tomography angiography, mCTA) 可用于评估侧支血管的状况, 它与传统的单相 CTA 相比, mCTA 具有更高的互连可靠性以及对侧支状态评估更高的准确性, 但这种检查的人工视觉评估是耗时的. Huang 等^[46]提出了一个旨在利用 CNN 建立 mCTA 侧支状态的人工智能自动预测模型. 最终的实验结果表明该模型的预测准确率可达到 70% 以上, 这证明深度学习模型用于自动评估侧支状态是可行的.

先前的许多研究主要集中在对前循环卒中 (anterior circulation stroke, ACS) 进行分割和检测, 但对于后循环卒中 (posterior circulation stroke, PCS) 的相关研究明

显缺乏. 与 ACS 患者的血栓形成相反, PCS 患者的血栓发生在脑干周围更有限的区域. 该特性可用于改进基于 CNN 的血栓定位和分割方法的性能. CNN 可以学习如何将移动的感兴趣体积集中在脑干上, 并评估血栓可能性高的位置. 基于此种特征, Zoetmulder 等^[47]开发了一种在 CT 上自动定位和分割 PCS 患者血栓的模型 (Polar-UNet). 它可以在发生遮挡的区域内进行分割, 并可以有效排除小物体的干扰. 实验结果表明, 将感兴趣体积限制在脑干可以有效提高血栓定位准确率. 除此之外, Polar-UNet 有效的减少了分割小病灶时误报的数量.

综上所述, 近几年基于 CTA 图像的深度学习研究主要集中在检测大血管阻塞, 在实验模型方面, ResNet

网络因其结构层次深和泛化能力强而备受青睐. 最新研究通过改进 ResNet 网络的模块从而解决了受干扰影响时模型性能不佳的问题, 同时也解决了在处理极端位置病灶时遇到的一些麻烦. 随着医学成像技术的进步, 一些实验也在关注延伸的 CTA 技术, 相关的实验结果表明, 将 CNN 模型应用于这些延伸的 CTA 技术时也可以取得较好的准确率和召回率. 但由于训练和测试的图像数量有限, 模型的泛化性可能存在不足. 在 PCS 方面, 尽管研究相对较少, 但基于 CNN 的新方法可自动定位和分割脑干区域的血栓, 减少小目标误报, 但精确度仍待提高, 且需建立针对 PCS 的大型数据集. 表 3 汇总了上述研究的主要贡献、局限性以及评价指标等.

表 3 深度学习技术在 CTA 上分割与检测缺血性脑卒中病灶的研究总结

参考文献	年份	研究模型	主要贡献	局限性	Dice系数	准确率	召回率
Brugnara等 ^[43]	2023	RetinaNet	在中等血管阻塞情况下的检测表现较好, 且检测所需时间较短	数据集中存在类不平衡问题	—	—	0.94
Kumar等 ^[44]	2023	ResNet	模型计算复杂度较低, 检测所需时间较短且准确率高	数据集样本较少且无法检测远端闭塞	0.90	0.91	0.89
Mejis等 ^[45]	2020	3D CNN	可以在4D CTA中检测病灶	无法分类或定位不同类型的闭塞	—	—	0.95
Huang等 ^[46]	2023	CNN	可以在mCTA中自动评估侧支状态	数据集规模较小且类不平衡	—	0.75	—
Zoetmulder等 ^[47]	2022	Polar-UNet	可以分割PCS患者的病灶, 并有效的减少了分割小病灶时误报的数量	数据集规模较小且定位和分割椎动脉和后颅内动脉中的血栓时不够准确	0.44	0.65	0.75

2.3 CTP 的深度学习研究

CTP 目前已经成为临床上诊断脑卒中的一种常见造影技术, CTP 成像是为患者注射造影剂, 通过 CT 扫描连续成像大约 60 s. 然后, 将 4D CT 体积序列总结为某些 3D 脑血流量定量图. 4 个常用的图谱是脑血容量、脑血流量、平均传输时间和峰值时间^[48]. 在临床上, 这些图谱用于检测受缺血性卒中影响的脑区域. 目前用于分割缺血性卒中病变的临床标准是通过 CTP 图谱的阈值而设定的.

在脑卒中病灶分割领域不可绕开的话题是 ISLES 挑战赛, 2018 年的 ISLES 挑战赛是在 CTP 图像上分割脑卒中的梗死组织, 并使用 DWI 作为参考标准^[49]. 来自中国的 3 个研究团队包揽了这项挑战赛的前 3 名. 获得冠军的是 Song 等^[50], 他们使用了一种生成对抗网络 (generative adversarial network, GAN) 算法, 并使用 CTP 数据来创建基于 U-Net 架构的伪 DWI 图像, 他们把基于 U-Net 架构生成的伪 DWI 图像使用鉴别器将其与真实 DWI 图像进行比较, 并区分所呈现图像的真伪和特征. 然后将区分的特征反馈到生成器中, 以此来

提高其预测病变的能力.

Liu 等^[51]获得了挑战赛的亚军, 他们采用了一种基于残差连接的二维 U-Net 的卷积神经网络作为模型主干. 为了平衡训练阶段正负区域的梯度并突出脑卒中损伤, 他们提出了一种新的损失函数, 该函数包含权重交叉熵损失和广义 Dice 系数损失. 在训练阶段的实验中, 研究团队发现这种混合损失函数具有较好的稳定性. 挑战赛的季军是 Chen 等^[52], 他们使用了一个 2.5 维框架, 该框架基于包括 U-Net 在内的网络集合, 可以从不同的模式中提取并融合信息. 这项挑战的结果显示了将深度学习应用于脑卒中患者的优势, 特别是证明了顶尖团队开发的算法在 CTP 图像中检测梗死核心方面具有不俗的准确率, 该挑战赛为后续的研究指明了方向. 基于 ISLES 2018 数据集的这些实验也有一些局限性, 这些局限性主要是由于数据集采集时严格要求患者的 CTP 和 DWI 图像的间隔时间小于 3 h, 因此数据集的数量相对较小. 其次, 将 DWI 图像作为 CTP 图像上分割和识别的参考标准可能会造成结果并不完全匹配, 这也是由于两种模态数据采集时的时间间隔

可能会导致病灶进一步扩大. 最后, 由于该数据集是在 2004–2012 年期间获取的, 因此一些扫描是在较旧的设备上进行的. 虽然这些年间在改善 CTP 对比度和噪声方面没有重大突破, 但扫描仪在过去 20 年中对脑部 CTP 图像的 Z 轴覆盖范围有所增加, 这间接导致了数据库图像的偏差.

随后几年的研究在此挑战赛的基础上取得了新的进展, Wang 等^[53]的思路与 2018 年 ISLES 挑战赛中摘得冠军的 Song 等^[50]的方法相似, 他们提出了一种基于灌注参数图合成伪图像的框架, 以获得更好的图像质量, 从而实现更准确的分割. 该框架首先使用特征提取器获取原始图像的低级和高级紧凑表示. 其次, 使用生成器将 CTP 灌注参数图和提取的特征合成为伪 DWI 图像. 最后, 从合成的图像中分割损伤区域. 实验得到的结果明显优于 Song 等^[50]提出的方法. 2018 年的 ISLES 挑战赛不仅影响着上述研究者的研究方向与思路, 挑战赛所留

下的数据集依然被后续研究所采用. 同样使用了 ISLES 2018 数据集的还有 Shi 等^[54], 与先前在现有模型基础上改进的思路不同, 他们开发了一种新的深度学习网络 C²MA-Net, 该网络采用了一种跨模态和交叉注意力机制, 该机制建立了不同模态特征之间的空间关系, 并通过群体注意块进行动态群体的重新校准. C²MA-Net 具有多路径编码器-解码器架构, 其中每个模态在编码路径上的不同流中进行处理, 并且相关的参数模态可以通过 C²MA 模块在多模态信息之间建立注意力连接. 研究团队将这种模型在 ISLES 2018 数据集上进行了测试评估, 通过与其他几种优秀的模型进行比较, C²MA-Net 将召回率提高了 6%. 将 ISLES 2018 作为研究数据集的还有 Soltanpour 等^[55], 他们提出了一种新的端到端缺血性脑卒中病灶分割模型 (MultiRes U-Net), 该模型可以从 CTP 图像中分割病灶. 提出的模型是基于原始 U-Net 的修改版本, 原始 U-Net 结构如图 4 所示.




图 4 U-Net 结构

改进后的模型经过重新设计, 在检测各种尺度和不规则外观的物体方面具有鲁棒性. MultiRes U-Net 在原始 U-Net 的基础上做了两处修改, 首先是扩展了卷积操作, 这使得 MultiRes U-Net 的 CNN 层更有能力进行多分辨率分析. 第 2 个修改是加入了简单的跳过连接, 这解决了原始 U-Net 将来自不同层次的特征组合在一起时可能导致的语义差距的问题. 实验的最后, 研究团队使用 ISLES 2018 数据集对所提出的方法进行了评估. 结果表明, 与现有的分割方法相比, 该方法在

分割任务的精确度上有了很大提高. 这种方法虽然有所进步和创新, 但也忽略了其他对检测缺血性脑卒中病灶至关重要的因素, 例如血液检查结果、年龄、性别等. 未来的研究可以加入相关的因素来进一步提高方法的准确性. Kasasbeh 等^[56]注意到了这一问题, 基于此, 他们设计了一种 ANN 来对急性脑卒中患者的缺血核心进行优化预测. 该神经网络经过改进后可以结合患者的临床数据. 这种模型是一种具有监督训练的前馈神经网络, 并利用反向传播方法以监督的方式调整

神经网络连接的权值. 对该模型的验证与测试结果显示, 在最佳阈值下, 预测缺血核心的召回率为 0.90, 特异度为 0.62. 最大 Dice 系数为 0.48. 将 CTP 数据与就诊时可用的临床数据结合使用后, 召回率和特异度分别为 0.91 和 0.65. 该项研究表明结合 CTP 数据和临床数据的人工神经网络可以更准确地预测缺血核心.

先前 CTP 数据的自动分割研究常使用预处理的 3D 参数图, 另一种方法是逐层使用原始 CTP 数据作为 2D+时间输入. 这些处理方式忽略了体积上的空间信息, 此外, 这些方法主要侧重于分割缺血核心区域, 忽略了对于半暗带的检测和分割. Tomasetti 等^[57]的一项研究中利用了整个原始 4D CTP 作为输入, 这种方法可以充分利用时空信息, 并且可以对缺血核心区域和半暗带进行有效的分割和检测. 本项研究提出了一个四维卷积层, 并利用它构建了一个深度神经网络模型:

4D mJ-Net. 此外, 研究团队还在先前研究的基础上构建了 4D+time mJNet 模型. 两种模型在分割缺血核心和半暗带的任务中都取得较好结果.

综上所述, 在深度学习领域一直不乏对 CTP 图像的研究. 先前的研究已证明 U-Net 网络在分割任务中表现优异, 最新的研究多致力于改进 U-Net 的性能, 如加入残差连接、引入新损失函数、改变网络维度或扩展卷积操作等. 虽然这些方法提高了模型精确度, 但忽略了识别缺血性卒中病变的重要因素, 如年龄、性别等. 个别研究注意到了这一问题, 通过加入反向传播机制并结合临床数据的方法, 有效的提高了分割的召回率. 另一些研究采用 GAN 网络生成伪 DWI 图像或引入交叉注意力机制, 提高了模型检测的准确率, 证实了优化改进方法的有效性. 表 4 总结了上述研究的主要贡献、局限性和评价指标等.

表 4 深度学习技术在 CTP 上分割与检测缺血性脑卒中病灶的研究总结

参考文献	年份	研究模型	数据集	主要贡献	局限性	Dice系数	精确度	召回率
Song等 ^[50]	2018	U-Net	ISLES 2018	使用GAN合成伪图像, 提高了模型分割病灶的能力	数据集样本量较小	0.51	0.55	0.55
Liu等 ^[51]	2018	U-Net	ISLES 2018	优化损失函数使其能平衡正负区域的梯度, 并突出脑卒中的损伤区域	数据集中的CTP图像与参考标准并不完全匹配	0.49	0.56	0.53
Chen等 ^[52]	2018	U-Net	ISLES 2018	构建可以从不同模式中提取并融合信息的2.5维框架	数据集中部分样本采集年份久远	0.48	0.59	0.46
Wang等 ^[53]	2020	SLNet	ISLES 2018	提出了一种基于灌注参数图合成伪图像的框架, 从而实现更准确的分割	合成的伪DWI图像和真实图像之间存在域偏移从而造成过拟合	0.54	0.69	0.64
Shi等 ^[54]	2021	C ² MA-Net	ISLES 2018	构建了一种具有跨模态和交叉注意力机制的网络, 以解决模态之间的信息交互问题	将注意力模块应用于多个层会导致过拟合	0.48	0.48	0.59
Soltanpour等 ^[55]	2021	MultiRes U-Net	ISLES 2018	在原始U-Net基础上扩展卷积操作并加入跳过连接, 使其更具鲁棒性	忽略了对识别缺血性卒中造成影响的其他因素	0.68	—	—
Kasasbeh等 ^[56]	2019	ANN	128个样本组成的非公开数据集	构建了一种具有监督训练的前馈神经网络, 并整合了临床数据	模型容易高估缺血核心的体积	0.48	—	0.90
Tomasetti等 ^[57]	2023	4D mJ-Net	152个样本组成的非公开数据集	构建了一个具有四维卷积层的网络, 可以在4D CTP中分割病灶	数据集缺乏多样性	0.53	—	—

3 急性缺血性脑卒中 MRI 图像上的研究

众所周知, CT 和 MRI 是检测脑卒中病变的常用成像技术. 虽然 CT 具有成像速度快、成本较低和受噪声影响较小等优点, 但大脑的一些病变在 CT 中并不是清晰可见的. 并且 CT 往往会伴随着召回率较低、对软组织分辨率较差等问题. 虽然 MRI 扫描时间长、成本较高, 但它能够有效的克服 CT 的一些缺陷, 并且能够在 CT 之前更早的发现大脑中的梗死区域. 因此, 目前 MRI 更常用于发现大脑中的病灶^[58]. 然而 MRI 有多种

扫描序列, 在 MRI 的深度学习研究领域, T1 加权序列和 DWI 是深度学习模型在诊断缺血性脑卒中患者时最常用的扫描序列^[59].

3.1 MRI T1 加权序列的深度学习研究

T1 加权序列具有较好的信噪比和对比度, 并且可以清晰地显示脑部的解剖结果, 因此 T1 加权序列在临床上常用于脑卒中的诊断. 深度学习结合 T1 加权序列分割和检测病灶的研究因其在促进脑卒中精确诊断和手术规划方面的能力而备受关注. 基于 MRI T1 加权序

列, Paing 等^[60]开发了一个三维 U-Net 模型, 用于对梗死区域进行逐块分割. 作为主要创新, 他们提出的模型结合了变分模态分解. 首先将变分模态分解应用在预处理阶段, 以区分梗死区域与不需要的非梗死组织. 其次, 提出了重叠块策略, 以减少基于深度学习模型在分割任务中的工作量. 最终在 ATLAS 数据集上测试的结果显示, 该模型获得了 0.67 的 Dice 系数. 然而, 关于在 MRI T1 加权序列上分割脑卒中病灶仍然存在许多挑战, 包括处理不同位置的病灶、病灶尺度的变化以及模糊的病灶边界. 为了解决这些挑战, Liu 等^[61]提出了一种名为多尺度深度融合网络 (MSDF-Net) 的深度网络架构, 其中使用了 Atrous 空间金字塔池化来提取不同尺度的特征. 并且包含了胶囊网络以处理复杂的相关实体. 所提出的方法本质上是一个端到端的深度编码器-解码器神经网络. 编码器和解码器之间的交叉连接保证了特征映射的高分辨率. 同样使用了胶囊网络的还有 Sahayam 等^[62]提出的一种名为 MUDCap3 的 U 形 3D 胶囊网络, 它由一系列卷积层和以 U-Net 形式聚集的卷积胶囊组成, 采用局部约束动态路由算法进行图像分割. 该模型解决了空间信息丢失的问题, 采用的算法不仅提高了分割的准确性, 同时也减少了胶囊网络中参数膨胀的问题. 由于存储在胶囊网络中的特征信息具有矢量化和仿射不变性, 并且使用了局部约束的路由算法, 有效的解决了类别不平衡的问题. 与 Sahayam 的方向类似, Li 等^[63]也将研究方向放在解决类不平衡问题上, 他们提出了一种面向目标的监督残差学习框架 (TSRL-Net) 用于脑卒中病灶的分割. 考虑到正负样本的不平衡问题, 设计了一种创新的面向目标的损失函数, 以扩张强注意区域, 高度关注正样本损失, 并补偿目标周围负样本损失. 然后, 研究团队开发了一个粗粒度残差学习模块, 以减轻由类内模糊性引起的假阴性数量高的问题. 尽管研究提出的损失函数

能够应对类别不平衡的挑战, 但当前的损失函数并不适用于多目标分割任务. 在未来的研究中, 还需探索损失函数在多目标分割中的应用, 收集更多的训练样本来提高分割精度.

近年来, 以 Transformer 为代表的注意力机制成为深度学习领域热门的技术, 目前也不乏将这一机制引入到脑卒中病灶分割领域的实验, 其中实验结果较好的是 Wang 等^[64]开发的一种基于自注意力和空间-通道注意力机制的高效网络 (METrans). 它克服了 U-Net 无法实现长距离上下文交互的缺点. 与传统分割方法不同, 使用了具有不同尺度的 4 个编码器以提取多尺度特征. 然后, 将特征图馈送到 Transformer 模块进行全局特征建模. 所提出的方法在 ATLAS v1.2、ISLES 2015 和 ISLES 2018 数据集上进行了测试. 在 ISLES 2018 中的实验结果表明, METrans 在分割任务上实现了与现有技术相比明显的进步, 测试结果令人印象深刻. 其中在 ISLES2018 数据集中得出了 0.67 的 Dice 系数和 0.64 的召回率. 在 ATLAS v1.2 数据集上更是达到了 0.93 的 Dice 系数和 0.91 的召回率.

综上所述, 最新关于 T1 加权序列的脑卒中分割与检测领域的深度学习模型大多采用 U-Net 架构, 但研究者们根据不同的问题进行了一些针对性修改. 例如, 在 U-Net 中加入重叠块可减少工作量并提升分割性能, 而基于 U-Net 架构的胶囊网络则通过局部约束动态路由算法解决了空间信息丢失的问题, 并在处理复杂相关实体时表现优越. 针对类不平衡问题, 优化损失函数和引入粗粒度残差学习模块都取得了有效结果. 近年来, 注意力机制的发展使其在脑卒中病灶分割与检测领域受到关注, 相关实验证明基于注意力机制的 Transformer 能够增强病灶特征表示, 提高分割的准确率和鲁棒性. 表 5 总结了上述研究的主要贡献、局限性以及评价指标等.

表 5 深度学习技术在 MRI T1 加权序列上分割与检测缺血性脑卒中病灶的研究总结

参考文献	年份	研究模型	数据集	主要贡献	局限性	Dice系数	召回率
Paing等 ^[60]	2021	U-Net	ATLAS	利用变分模态分解进行预处理并引入重叠块策略, 减少了模型的计算复杂度	模型只适用于T1序列的MRI图像	0.67	—
Liu等 ^[61]	2019	MSDF-Net	ATLAS	使用ASPP提取不同尺度的特征, 并加入了胶囊网络以处理复杂的相关实体	该方法是非概率模型无法量化结果的不确定性	0.69	0.82
Sahayam等 ^[62]	2020	MUDCap3	ATLAS	在模型中加入局部约束动态路由算法, 克服了池化层丢失重要信息的缺点	网络参数过大	0.67	—

表5 深度学习技术在MRI T1加权序列上分割与检测缺血性卒中病灶的研究总结(续)

参考文献	年份	研究模型	数据集	主要贡献	局限性	Dice系数	召回率
Li等 ^[63]	2023	TSRL-Net	ATLAS和	为构建的网络设计了新的损失函数,解决了类不平衡和类内模糊的问题	损失函数并不适用于多目标分割任务	0.63 (ATLAS)	0.65 (ATLAS)
			ISLES			0.64 (ISLES)	0.67 (ISLES)
			2015-SISS			0.67 (2015-SISS)	0.67 (2015-SISS)
Wang等 ^[64]	2022	METrans	ATLAS和 ISLES 2018	提出了一种新的多编码器转换器,克服了U-Nets无法模拟远程上下文交互的缺点	模型参数庞大可能会导致分割与检测速度偏慢	0.93 (ATLAS) 0.67 (ISLES 2018)	0.91 (ATLAS) 0.64 (ISLES 2018)

3.2 DWI 的深度学习研究

作为MRI的一种扫描序列,DWI在临床诊断卒中领域里有举足轻重的地位,DWI可反映水分子的扩散情况,在脑卒中的早期诊断中应用尤为广泛,有人又称其为“卒中序列”^[65]。同时,它也是判断急性卒中患者最终梗死体积的常用影像学检查手段。针对这一扫描序列,Liu等^[66]开发了一种深度学习网络模型(3D DAGMNet),该模型在2348例急性和亚急性缺血性卒中患者的临床DWI数据集上进行了训练和测试,并在外部数据集STIR(Stanford image reconstruction)的280例图像上进行了进一步的泛化测试。他们提出的这一模型与其他模型相比(FCN、U-Net和DeepMedic)在小病变方面表现更为优秀,具有更低的假阳性率,更高的精确度和召回率,并且对数据扰动(例如伪影、低分辨率等)具有鲁棒性。Yu等^[67]的研究团队同样将DWI作为主要的扫描序列,他们先是构建了一个名为Attention-Gated U-Net的神经网络,该网络在U-Net的基础上加入了注意力机制。然后基于这一网络,研究团队探索了3种改进的方法,分别是预训练法,分离法和阈值法。首先将研究的患者分为4类:最小灌注、部分灌注、主要灌注和未知灌注。简而言之,预训练法是使用部分和未知再灌注的患者开发单一模型,然后微调以创建最小和主要再灌注的两个独立模型。实验结果表明,在对危险组织和缺血核心的检测中,预训练法明显好于其他两种方法。预训练法可以最大限度地利用所有可用的数据来提高检测准确率。同样为了提高模型分割的准确率,Cui等^[68]的研究团队为在DWI图像上分割卒中病变提供了新的思路,他们构建了一种名为DeepSym-3D-CNN的卷积神经网络,该网络可以将3D DWI脑图像分成左右半球输入到两个路径中,通过L2归一化计算出两个路径的特征之后,再经过4个多尺度卷积层产生最终预测结果。此外,该模型还引入了Inception模块。在与另外3个卒中分割与检测的模型对比后,DeepSym-3D-CNN以0.85的准确率

显著优于3种比较模型。在之前的卒中分割工作中,许多研究尚未完全考虑到脑部图像的不变性。卷积操作在本质上是平移不变的;然而,输入图像的旋转和翻转可能会扭曲卷积输出。虽然许多研究引入数据增强来提高鲁棒性,但这并不能保证脑部图像的不变性。针对这一问题,Wong等^[69]开发了一个具有对图像旋转和翻转较强鲁棒性的深度学习模型,该模型是建立在一个旋转-翻转等变U-Net上的,使用了分组卷积神经网络和Dice损失函数。面对输入图像的90°旋转、翻转,该网络结构更具高效性和鲁棒性,保证了与常规输入图像相同的图像输出。这使得该模型可以准确地从由各种不同MRI扫描仪生成的图像中分割梗死区域。除了输入图像的旋转与翻转会对输出结果造成影响,基于深度学习的卒中病灶分割与检测也经常受到数据库规模较小的阻碍。例如,ISLES 2015-SISS数据集仅包含64个卒中病例,先前使用该数据集的研究也都受此制约,因为收集大量标记图像涉及伦理和隐私问题,在可预见的未来,很难指望用于训练深度学习模型的医学图像数量会有实质性的改善。针对这一问题,Federau等^[70]开发了一种强大的算法,这种算法通过从临床图像中提取卒中病变的一般特征,并将这些特征与正常的DWI图像结合起来,以此来生成逼真的卒中病变的合成DWI图像。由于组合的可能性,这样的算法可以生成数量庞大的训练数据集,并且由于病变是人工生成的,因此真实的病变位置是确切已知的。基于人类标注的数据集和算法生成的合成数据集,研究团队使用3D U-Net展开了多种组合实验。实验结果表明,在人类标注的数据集和算法生成的合成数据集的组合训练下,3D U-Net模型的分割和检测性能明显优于仅在人类标注的数据集上训练的模型。这种方法可以提高3D U-Net在检测DWI图像上的急性卒中病变方面的性能,所提出的方法可能适用于其他病理情况,并且可能会在医学成像应用中实质性地改善深度学习模型的性能。

综上所述,在小病变分割方面,最新的实验证明在不同尺度的感受野上水平捕获语义特征可以提高模型分割的准确率.在模型的训练策略方面,研究发现采用预训练和微调相结合的方法能够充分利用数据,以此提高模型性能.针对数据集规模较小的问题,有研究提出了合成伪图像的思路,还有研究采用了具有图像旋

转和翻转功能的分组卷积,这些方法都有效解决了这一难题.此外,最新的研究还聚焦于提高模型在分割任务中的准确性和鲁棒性,相关研究通过采用多尺度卷积和路径归一化等方法,优化了脑部图像的分割效果,取得了显著进展.表6总结了上述研究的主要贡献、局限性以及评价指标.

表6 深度学习技术在DWI上分割与检测缺血性脑卒中病灶的研究总结

参考文献	年份	研究模型	主要贡献	局限性	Dice系数	准确率	召回率
Liu等 ^[66]	2021	3D DAGMNet	修改了感受野的尺度,使其在小病灶的分割和检测方面表现更优越	数据集中部分样本存在颅骨剥离错误	0.84	—	0.78
Yu等 ^[67]	2021	Attention-Gated U-Net	在U-Net的基础上加入了注意力机制并探索了3种改进的方法	并未考虑其他临床因素	0.57	—	—
Cui等 ^[68]	2021	DeepSym-3D-CNN	构造了一种深度对称三维CNN,提高了模型分割与检测的准确率	数据集样本较少导致泛化性难以验证	—	0.85	—
Wong等 ^[69]	2022	U-Net	在原始U-Net中加入分组卷积和新的损失函数,增强了对输入图像翻转、旋转的鲁棒性	难以检测脑干区域的中风病灶	0.88	0.75	—
Federau等 ^[70]	2020	3D U-Net	开发了一种可提取特征并合成图像的算法,可以有效地扩充数据集的样本量	数据集缺乏多样性	0.72	—	0.91

4 总结与分析

随着深度学习技术在医学图像处理领域的迅速发展,研究者们针对深度学习技术在分割与检测缺血性脑卒中病灶时遇到的不同困难,提出了不同的优化策略和改进方法.本节将汇总近几年相关研究的改进思路,并分析其改进方法的优势.

(1) 在提高模型分割与识别的准确率方面,研究者的思路是在模型中加入最大后验概率模块、Inception模块、和后处理机制.其中,最大后验概率模块能够整合不同尺寸的小块病灶分类结果和领域信息,有效地弥补了ResNet在梗死区域识别方面的不足.Inception模块则可以同时使用不同大小的卷积核来提取多尺度的特征,有助于提高模型对不同大小病灶分割与识别的准确率.后处理机制的加入可以排除由噪声造成的伪影,从而进一步提高分割准确率.例如,Pan等^[35]利用ResNet网络结合最大后验概率模块和后处理方法,在NCCT上对脑卒中病灶的检测准确率达到75.9%.Cui等^[68]将Inception模块加入到模型后,准确率可达85%,此外,生成伪图像、在建模时使用预训练法也都被证明能有效的提升分割准确率.例如,Song等^[50]把基于U-Net架构生成的伪DWI图像使用鉴别器将其与真实DWI图像进行比较,以此来提高其预测病灶的准确率.Yu等^[67]在U-Net的基础上加入了注意力机制,并且证明了所提出的预训练法是一种很有前途的方法,可以最大限度地利用所有可用的数据来提高分割的准

准确率.

(2) 在优化对模糊病灶的分割能力、增强模型鲁棒性方面,研究者的思路是修改感受野尺度和对抗图像的旋转、翻转,也有研究者通过扩展卷积并加入跳跃连接来解决此类问题.例如,Liu等^[66]构造了一种可以从输入图像的不同尺度的感受野水平捕获语义特征的模型,他们提出的这一模型与其他模型相比在小病变方面表现更为优秀,并且对数据扰动更具鲁棒性.Wong等^[69]开发了一个具有对图像旋转和翻转较强鲁棒性的深度学习模型,该模型保证了与常规输入图像相同的图像输出.这使其可以准确地从由各种不同MRI扫描仪生成的图像中分割梗死区域.Soltanpour等^[55]在U-Net的基础上扩展了卷积操作,这使得模型更有能力进行多分辨率分析.在加入了简单的跳跃连接后,解决了原始U-Net将来自不同层次的特征组合在一起时可能导致的语义差距的问题.这些改进都使模型在检测各种尺度和不规则病灶方面具有鲁棒性.此外,还有研究证明胶囊网络结合Atrous空间金字塔池化可以优化对模糊病灶的分割能力.例如,Liu等^[61]提出了一种多尺度深度融合方法,将胶囊网络的特点和Atrous空间金字塔池化在多尺度预测中的优点相结合,该方法充分利用全局上下文来减少病灶边缘模糊对病灶分割的影响.

(3) 在降低计算复杂度、缩短分割所用时间方面,生成高质量的最大强度投影被证实有助于缩短分割时

间, 变分模态分解和堆叠块策略的引入则可以帮助降低模型的计算复杂度. 例如, Kumar 等^[44]通过生成高质量的最大强度投影, 使得所提出的模型可以在 40 s 内对大血管阻塞进行检测. Paing 等^[60]提出的模型结合了变分模态分解. 变分模态分解可以区分梗死区域与不需要的非梗死组织. 重叠块策略则以减少模型的计算工作量. 此外, 也有研究者利用原始时空的 CTA 图像合成更高质量的伪 DWI, 研究证明此方法有助于减少任务所需的内存和计算时间. 例如, Wang 等^[53]提出的框架首先使用特征提取器获取原始时空 CTA 图像的低级和高级紧凑表示. 其次, 使用伪 DWI 生成器将 CTP 灌注参数图和提取的特征合成为伪 DWI 图像. 最后, 从合成的伪 DWI 图像中分割损伤区域.

(4) 区别于传统扫描方式, 在 4D CTA 和 mCTA 中的分割与检测方面, 一些研究已经将 CNN 模型应用到了其中, 并且取得了较好的评价指标. 例如, Mejis 等^[45]使用三维 CNN 架构构建了一种用于自动检测颅内前循环动脉闭塞的模型, 它可以用于分析 4D CTA 图像. Huang 等^[46]则提出了一个旨在利用 CNN 建立 mCTA 侧支状态的人工智能自动预测模型.

(5) 在解决模态之间的信息交互问题上, 跨模态交叉注意力机制给出了答案. 例如, Shi 等^[54]提出了一种全新深度学习网络. 该网络采用了跨模态和交叉注意力机制, 用于捕捉不同模态特征之间的空间关系. 这一机制通过群体注意块进行动态群体的重新校准, 证明了注意力机制在跨模态相互作用的潜力.

(6) 在解决输入数据缺乏临床信息的问题上, 相关研究表明, 结合了图像数据和临床信息的 ANN 可以更准确的检测缺血核心. 例如, Kasasbeh 等^[56]开发了一种 ANN, 旨在优化对急性卒中患者缺血核心的检测. 该模型经过改进, 能够结合患者的临床数据. 结合后的检测召回率和特异度分别提高了 0.01 和 0.03.

5 挑战与展望

深度学习在急性缺血性卒中病灶分割与检测方面正处于快速发展的阶段, 其已经展现出了广阔的应用前景和良好的潜力, 但目前仍然有许多亟待解决的问题.

(1) 脑卒中数据集获取和标注困难

获取大规模且高质量的带标注的脑卒中图像数据集是一项巨大的挑战. 对于急性缺血性卒中中的图像

数据, 牵扯到患者的数据隐私和临床部署的设备不足等问题, 增加了数据集获取的难度. 此外临床医生对于病灶区域的手动标记是病灶分割任务的金标准, 然而, 大多数临床医生经常忙于医院一线的诊疗工作. 因此数据获取和标注困难是困扰这一领域的难题之一.

解决脑卒中图像数据集获取和标注困难的问题可以采取以下策略, 首先可以利用合成数据技术生成合成脑卒中图像数据, 以填补真实数据的不足. 这可以通过使用 GAN 网络、开发合成算法等技术来生成具有真实特征的合成图像, 以增加数据集的规模和多样性. 最后, 研究并应用自动标注技术, 减轻临床医生手动标注的负担也是解决方案之一.

(2) 病灶的边界模糊

脑卒中病灶边界模糊也是深度学习在脑卒中病灶分割与检测中常见的问题之一, 由于其病理本身特征的复杂性, 脑卒中病灶的形态、大小和分布可能受多种因素影响如病变类型、病程阶段、个体差异等. 这些复杂性导致了病灶边界的不规则性和模糊性.

针对这些问题, 可以考虑设计与边界相关的损失函数, 通过优化损失函数从而提高模型对边界的注意力. 其次, 可以考虑将 CT 和 MRI 模态的图像结合分析以提供更全面的信息, 这有助于更准确地检测和分割脑卒中病灶. 最后, 结合图像处理技术对图像进行预处理, 如边缘增强、分割平滑等也可以有效解决此类问题.

(3) 检测和分割精度难以满足临床要求

对于脑卒中病灶的分割与检测, 精确度至关重要. ATLES 数据集的创建者认为, 如果一个模型在 MRI 图像上对病灶的识别精度达到 Dice 系数 0.85 以上, 那么才能认为这个模型具有替代人工识别的能力^[29]. 显然, 目前对于大多数模型来说, 达到这个分数是困难的. 虽然有个别的研究宣称自己开发的模型可以达到 Dice 系数 0.85 以上, 但这些研究的模型大多都是在非公开数据集中进行训练或测试, 所以实验结果缺乏可比性与可信度. 由此可知, 虽然脑卒中病灶的自动分割与检测具有巨大潜力, 但距离真正的临床应用还有一段路要走.

解决此类问题的方法可以考虑在现存较为成熟的神经网络中加入注意力机制, 还可以修改卷积块以更好的捕捉图像中的特征信息, 从而达到提升分割与检测准确率的目的^[75]. 此外, 将图像与患者的年龄、性别等临床信息结合后进行训练也可以有效解决此问题.

参考文献

- 1 Herpich F, Rincon F. Management of acute ischemic stroke. *Critical Care Medicine*, 2020, 48(11): 1654–1663. [doi: [10.1097/CCM.0000000000004597](https://doi.org/10.1097/CCM.0000000000004597)]
- 2 Powers WJ. Acute ischemic stroke. *New England Journal of Medicine*, 2020, 383(3): 252–260. [doi: [10.1056/NEJMc1917030](https://doi.org/10.1056/NEJMc1917030)]
- 3 Feske SK. Ischemic stroke. *The American Journal of Medicine*, 2021, 134(12): 1457–1464. [doi: [10.1016/j.amjmed.2021.07.027](https://doi.org/10.1016/j.amjmed.2021.07.027)]
- 4 Lakhan SE, Kirchgessner A, Hofer M. Inflammatory mechanisms in ischemic stroke: Therapeutic approaches. *Journal of Translational Medicine*, 2009, 7(1): 97. [doi: [10.1186/1479-5876-7-97](https://doi.org/10.1186/1479-5876-7-97)]
- 5 Barthels D, Das H. Current advances in ischemic stroke research and therapies. *Biochimica et Biophysica Acta (BBA)-Molecular Basis of Disease*, 2020, 1866(4): 165260.
- 6 Brugnara G, Neuberger U, Mahmutoglu MA, *et al.* Multimodal predictive modeling of endovascular treatment outcome for acute ischemic stroke using machine-learning. *Stroke*, 2020, 51(12): 3541–3551. [doi: [10.1161/STROKEAHA.120.030287](https://doi.org/10.1161/STROKEAHA.120.030287)]
- 7 van Os HJA, Ramos LA, Hilbert A, *et al.* Predicting outcome of endovascular treatment for acute ischemic stroke: Potential value of machine learning algorithms. *Frontiers in Neurology*, 2018, 9: 784. [doi: [10.3389/fneur.2018.00784](https://doi.org/10.3389/fneur.2018.00784)]
- 8 Nielsen A, Hansen MB, Tietze A, *et al.* Prediction of tissue outcome and assessment of treatment effect in acute ischemic stroke using deep learning. *Stroke*, 2018, 49(6): 1394–1401. [doi: [10.1161/STROKEAHA.117.019740](https://doi.org/10.1161/STROKEAHA.117.019740)]
- 9 Cui LY, Fan ZY, Yang YJ, *et al.* Deep learning in ischemic stroke imaging analysis: A comprehensive review. *BioMed Research International*, 2022, 2022: 2456550.
- 10 Lecun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521(7553): 436–444. [doi: [10.1038/nature14539](https://doi.org/10.1038/nature14539)]
- 11 Goodfellow I, Bengio Y, Courville A. *Deep Learning*. Cambridge: MIT Press, 2016.
- 12 Li ZW, Liu F, Yang WJ, *et al.* A survey of convolutional neural networks: Analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(12): 6999–7019. [doi: [10.1109/TNNLS.2021.3084827](https://doi.org/10.1109/TNNLS.2021.3084827)]
- 13 Gu JX, Wang ZH, Kuen J, *et al.* Recent advances in convolutional neural networks. *Pattern Recognition*, 2018, 77: 354–377. [doi: [10.1016/j.patcog.2017.10.013](https://doi.org/10.1016/j.patcog.2017.10.013)]
- 14 O'shea K, Nash R. An introduction to convolutional neural networks. arXiv:1511.08458, 2015.
- 15 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *Proceedings of the 3rd International Conference on Learning Representations*. San Diego: ICLR, 2015.
- 16 Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. *Proceedings of the 18th International Conference on Medical Image Computing and Computer-assisted Intervention*. Munich: Springer, 2015. 234–241.
- 17 He KM, Zhang XY, Ren SQ, *et al.* Deep residual learning for image recognition. *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016. 770–778.
- 18 Huang G, Liu Z, van der Maaten L, *et al.* Densely connected convolutional networks. *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017. 2261–2269.
- 19 Szegedy C, Liu W, Jia YQ, *et al.* Going deeper with convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015. 1–9.
- 20 Mokli Y, Pfaff J, Dos Santos DP, *et al.* Computer-aided imaging analysis in acute ischemic stroke-background and clinical applications. *Neurological Research and Practice*, 2019, 1(1): 23. [doi: [10.1186/s42466-019-0028-y](https://doi.org/10.1186/s42466-019-0028-y)]
- 21 余唯一, 陈涛, 张军平, 等. 基于深度学习的MRI脑卒中病灶分割方法综述. *智能科学与技术学报*, 2023, 5(3): 293–312.
- 22 於帆, Arman Sha, 张苗, 等. 人工智能在急性缺血性脑卒中影像的研究进展. *中华老年心脑血管病杂志*, 2023, 25(3): 334–336. [doi: [10.3969/j.issn.1009-0126.2023.03.029](https://doi.org/10.3969/j.issn.1009-0126.2023.03.029)]
- 23 叶珍丽, 蒋家鑫, 屈云. 基于人工智能的脑卒中诊断与预测系统的研究进展. *华西医学*, 2022, 37(12): 1887–1890. [doi: [10.7507/1002-0179.202012292](https://doi.org/10.7507/1002-0179.202012292)]
- 24 Chavva IR, Crawford AL, Mazurek MH, *et al.* Deep learning applications for acute stroke management. *Annals of Neurology*, 2022, 92(4): 574–587. [doi: [10.1002/ana.26435](https://doi.org/10.1002/ana.26435)]
- 25 Liew SL, Anglin JM, Banks NW, *et al.* A large, open source dataset of stroke anatomical brain images and manual lesion segmentations. *Scientific Data*, 2018, 5(1): 180011. [doi: [10.1038/sdata.2018.11](https://doi.org/10.1038/sdata.2018.11)]
- 26 Liew SL, Lo BP, Donnelly MR, *et al.* A large, curated, open-source stroke neuroimaging dataset to improve lesion segmentation algorithms. *Scientific Data*, 2022, 9(1): 320. [doi: [10.1038/s41597-022-01401-7](https://doi.org/10.1038/s41597-022-01401-7)]
- 27 Maier O, Menze BH, Von Der Gabelentz J, *et al.* ISLES 2015—A public evaluation benchmark for ischemic stroke lesion segmentation from multispectral MRI. *Medical Image Analysis*, 2017, 35: 250–269. [doi: [10.1016/j.media.2016.07](https://doi.org/10.1016/j.media.2016.07)]

- 009]
- 28 Tureckova A, Rodríguez-Sánchez AJ. ISLES challenge: U-shaped convolution neural network with dilated convolution for 3D stroke lesion segmentation. Proceedings of the 4th International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Granada: Springer, 2019. 319–327.
- 29 Hernandez Petzsche MR, De La Rosa E, Hanning U, *et al.* ISLES 2022: A multi-center magnetic resonance imaging stroke lesion segmentation dataset. Scientific Data, 2022, 9(1): 762. [doi: [10.1038/s41597-022-01875-5](https://doi.org/10.1038/s41597-022-01875-5)]
- 30 Chilamkurthy S, Ghosh R, Tanamala S, *et al.* Deep learning algorithms for detection of critical findings in head CT scans: A retrospective study. The Lancet, 2018, 392(10162): 2388–2396. [doi: [10.1016/S0140-6736\(18\)31645-3](https://doi.org/10.1016/S0140-6736(18)31645-3)]
- 31 Radhiana H, Syazarina SO, Shahizon Azura MM, *et al.* Non-contrast computed tomography in acute ischaemic stroke: A pictorial review. The Medical Journal of Malaysia, 2013, 68(1): 93–100.
- 32 Chilamkurthy S, Ghosh R, Tanamala S, *et al.* Development and validation of deep learning algorithms for detection of critical findings in head CT scans. arXiv:1803.05854, 2018.
- 33 Byrne D, Walsh JP, Sugrue G, *et al.* CT imaging of acute ischemic stroke. Canadian Association of Radiologists Journal, 2020, 71(3): 266–280. [doi: [10.1177/0846537120902068](https://doi.org/10.1177/0846537120902068)]
- 34 Lu J, Zhou YR, Lv WZ, *et al.* Identification of early invisible acute ischemic stroke in non-contrast computed tomography using two-stage deep-learning model. Theranostics, 2022, 12(12): 5564–5573. [doi: [10.7150/thno.74125](https://doi.org/10.7150/thno.74125)]
- 35 Pan JW, Wu GQ, Yu JH, *et al.* Detecting the early infarct core on non-contrast CT images with a deep learning residual network. Journal of Stroke and Cerebrovascular Diseases, 2021, 30(6): 105752. [doi: [10.1016/j.jstrokecerebrovasdis.2021.105752](https://doi.org/10.1016/j.jstrokecerebrovasdis.2021.105752)]
- 36 Kamnitsas K, Ferrante E, Parisot S, *et al.* DeepMedic for brain tumor segmentation. Proceedings of the 2nd International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Athens: Springer, 2016. 138–149.
- 37 Tuladhar A, Schimert S, Rajashekar D, *et al.* Automatic segmentation of stroke lesions in non-contrast computed tomography datasets with convolutional neural networks. IEEE Access, 2020, 8: 94871–94879. [doi: [10.1109/ACCESS.2020.2995632](https://doi.org/10.1109/ACCESS.2020.2995632)]
- 38 Verro P, Tanenbaum LN, Borden N, *et al.* Clinical application of CT angiography in acute ischemic stroke. Clinical Neurology and Neurosurgery, 2007, 109(2): 138–145.
- 39 Seker F, Pfaff JAR, Mokli Y, *et al.* Diagnostic accuracy of automated occlusion detection in CT angiography using e-CTA. International Journal of Stroke, 2022, 17(1): 77–82. [doi: [10.1177/1747493021992592](https://doi.org/10.1177/1747493021992592)]
- 40 Adhya J, Li C, Eisenmenger L, *et al.* Positive predictive value and stroke workflow outcomes using automated vessel density (RAPID-CTA) in stroke patients: One year experience. The Neuroradiology Journal, 2021, 34(5): 476–481.
- 41 Amukotuwa SA, Straka M, Dehkharghani S, *et al.* Fast automatic detection of large vessel occlusions on CT angiography. Stroke, 2019, 50(12): 3431–3438. [doi: [10.1161/STROKEAHA.119.027076](https://doi.org/10.1161/STROKEAHA.119.027076)]
- 42 Morey JR, Fiano E, Yaeger KA, *et al.* Impact of Viz LVO on time-to-treatment and clinical outcomes in large vessel occlusion stroke patients presenting to primary stroke centers. medRxiv, 2020. [doi: [10.1101/2020.07.02.20143834](https://doi.org/10.1101/2020.07.02.20143834)]
- 43 Brugnara G, Baumgartner M, Scholze ED, *et al.* Deep-learning based detection of vessel occlusions on CT-angiography in patients with suspected acute ischemic stroke. Nature Communications, 2023, 14(1): 4938. [doi: [10.1038/s41467-023-40564-8](https://doi.org/10.1038/s41467-023-40564-8)]
- 44 Kumar S, Agarwal A, Golla S, *et al.* Mind the clot: Automated LVO detection on CTA using deep learning. Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision. Paris: IEEE, 2023. 2495–2504.
- 45 Meijs M, Meijer FJA, Prokop M, *et al.* Image-level detection of arterial occlusions in 4D-CTA of acute stroke patients using deep learning. Medical Image Analysis, 2020, 66: 101810. [doi: [10.1016/j.media.2020.101810](https://doi.org/10.1016/j.media.2020.101810)]
- 46 Huang CC, Chiang HF, Hsieh CC, *et al.* Using deep-learning-based artificial intelligence technique to automatically evaluate the collateral status of multiphase CTA in acute ischemic stroke. Tomography, 2023, 9(2): 647–656. [doi: [10.3390/tomography9020052](https://doi.org/10.3390/tomography9020052)]
- 47 Zoetmulder R, Bruggeman AAE, Išgum I, *et al.* Deep-learning-based thrombus localization and segmentation in patients with posterior circulation stroke. Diagnostics, 2022, 12(6): 1400. [doi: [10.3390/diagnostics12061400](https://doi.org/10.3390/diagnostics12061400)]
- 48 Mayer TE, Hamann GF, Baranczyk J, *et al.* Dynamic CT perfusion imaging of acute stroke. American Journal of Neuroradiology, 2000, 21(8): 1441–1449.
- 49 Hakim A, Christensen S, Winzeck S, *et al.* Predicting infarct core from computed tomography perfusion in acute ischemia with machine learning: Lessons from the ISLES challenge. Stroke, 2021, 52(7): 2328–2337. [doi: [10.1161/STROKEAHA.120.044444](https://doi.org/10.1161/STROKEAHA.120.044444)]

- 120.030696]
- 50 Song T. 3D multi-scale U-net with atrous convolution for ischemic stroke lesion segmentation. Proceedings of the 2018 International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI), 2018.
- 51 Liu PB. Stroke lesion segmentation with 2D novel CNN pipeline and novel loss function. Proceedings of the 4th International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Granada: Springer, 2019. 253–262.
- 52 Chen Y, Li Y, Zheng Y. Ensembles of modalities fused model for ischemic stroke lesion segmentation. Proceedings of the 2018 International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI), 2018.
- 53 Wang GT, Song T, Dong Q, *et al.* Automatic ischemic stroke lesion segmentation from computed tomography perfusion images by image synthesis and attention-based deep neural networks. *Medical Image Analysis*, 2020, 65: 101787. [doi: [10.1016/j.media.2020.101787](https://doi.org/10.1016/j.media.2020.101787)]
- 54 Shi TY, Jiang HY, Zheng B. C²MA-Net: Cross-modal cross-attention network for acute ischemic stroke lesion segmentation based on CT perfusion scans. *IEEE Transactions on Biomedical Engineering*, 2022, 69(1): 108–118. [doi: [10.1109/TBME.2021.3087612](https://doi.org/10.1109/TBME.2021.3087612)]
- 55 Soltanpour M, Greiner R, Boulanger P, *et al.* Improvement of automatic ischemic stroke lesion segmentation in CT perfusion maps using a learned deep neural network. *Computers in Biology and Medicine*, 2021, 137: 104849. [doi: [10.1016/j.combiomed.2021.104849](https://doi.org/10.1016/j.combiomed.2021.104849)]
- 56 Kasasbeh AS, Christensen S, Parsons MW, *et al.* Artificial neural network CT perfusion prediction of ischemic core. *Stroke*, 2019, 50(6): 1578–1581. [doi: [10.1161/STROKEAHA.118.022649](https://doi.org/10.1161/STROKEAHA.118.022649)]
- 57 Tomasetti L, Engan K, Hølleli LJ, *et al.* CT perfusion is all we need: 4D CNN segmentation of penumbra and core in patients with suspected acute ischemic stroke. *IEEE Access*, 2023, 11: 138936–138953. [doi: [10.1109/ACCESS.2023.3336590](https://doi.org/10.1109/ACCESS.2023.3336590)]
- 58 González RG. Clinical MRI of acute ischemic stroke. *Journal of Magnetic Resonance Imaging*, 2012, 36(2): 259–271. [doi: [10.1002/jmri.23595](https://doi.org/10.1002/jmri.23595)]
- 59 Kloska SP, Wintermark M, Engelhorn T, *et al.* Acute stroke magnetic resonance imaging: Current status and future perspective. *Neuroradiology*, 2010, 52(3): 189–201. [doi: [10.1007/s00234-009-0637-1](https://doi.org/10.1007/s00234-009-0637-1)]
- 60 Paing MP, Tungjitkusolmun S, Bui TH, *et al.* Automated segmentation of infarct lesions in T1-weighted MRI scans using variational mode decomposition and deep learning. *Sensors*, 2021, 21(6): 1952. [doi: [10.3390/s21061952](https://doi.org/10.3390/s21061952)]
- 61 Liu XF, Yang H, Qi KH, *et al.* MSDF-Net: Multi-scale deep fusion network for stroke lesion segmentation. *IEEE Access*, 2019, 7: 178486–178495. [doi: [10.1109/ACCESS.2019.2958384](https://doi.org/10.1109/ACCESS.2019.2958384)]
- 62 Sahayam S, Abirami A, Jayaraman U. A novel modified U-shaped 3-D capsule network (MUDCap3) for stroke lesion segmentation from brain MRI. Proceedings of the 4th IEEE Conference on Information & Communication Technology (CICT). Chennai: IEEE, 2020. 1–6.
- 63 Li L, Ma KP, Song YH, *et al.* TSRL-Net: Target-aware supervision residual learning for stroke segmentation. *Computers in Biology and Medicine*, 2023, 159: 106840. [doi: [10.1016/j.combiomed.2023.106840](https://doi.org/10.1016/j.combiomed.2023.106840)]
- 64 Wang J, Wang SY, Liang W. METrans: Multi-encoder Transformer for ischemic stroke segmentation. *Electronics Letters*, 2022, 58(9): 340–342. [doi: [10.1049/el12.12444](https://doi.org/10.1049/el12.12444)]
- 65 Khoo MMY, Tyler PA, Saifuddin A, *et al.* Diffusion-weighted imaging (DWI) in musculoskeletal MRI: A critical review. *Skeletal Radiology*, 2011, 40(6): 665–681. [doi: [10.1007/s00256-011-1106-6](https://doi.org/10.1007/s00256-011-1106-6)]
- 66 Liu CF, Hsu J, Xu X, *et al.* Deep learning-based detection and segmentation of diffusion abnormalities in acute ischemic stroke. *Communications Medicine*, 2021, 1(1): 61. [doi: [10.1038/s43856-021-00062-8](https://doi.org/10.1038/s43856-021-00062-8)]
- 67 Yu Y, Xie Y, Thamm T, *et al.* Tissue at risk and ischemic core estimation using deep learning in acute stroke. *American Journal of Neuroradiology*, 2021, 42(6): 1030–1037. [doi: [10.3174/ajnr.A7081](https://doi.org/10.3174/ajnr.A7081)]
- 68 Cui LY, Han SH, Qi SL, *et al.* Deep symmetric three-dimensional convolutional neural networks for identifying acute ischemic stroke via diffusion-weighted images. *Journal of X-Ray Science and Technology*, 2021, 29(4): 551–566. [doi: [10.3233/XST-210861](https://doi.org/10.3233/XST-210861)]
- 69 Wong KK, Cummock JS, Li GH, *et al.* Automatic segmentation in acute ischemic stroke: Prognostic significance of topological stroke volumes on stroke outcome. *Stroke*, 2022, 53(9): 2896–2905. [doi: [10.1161/STROKEAHA.121.037982](https://doi.org/10.1161/STROKEAHA.121.037982)]
- 70 Federau C, Christensen S, Scherrer N, *et al.* Improved segmentation and detection sensitivity of diffusion-weighted stroke lesions with synthetically enhanced deep learning. *Radiology: Artificial Intelligence*, 2020, 2(5): e190217. [doi: [10.1148/ryai.2020190217](https://doi.org/10.1148/ryai.2020190217)]

(校对责编: 张重毅)