

深度学习人工智能技术在医学影像辅助分析中的应用

蒋西然¹, 蒋韬¹, 孙嘉瑶², 宋江典³, 姜文研⁴, 艾华¹, 龙哲¹, 苏娟¹, 常世杰¹, 于韬⁴

1. 中国医科大学 公共基础学院, 辽宁 沈阳 110122; 2. 中国科学院大学 计算机科学与技术学院, 北京 100049; 3. 中国医科大学 医学信息学院, 辽宁 沈阳 110122; 4. 辽宁省肿瘤医院 中国医科大学肿瘤医院 医学影像科, 辽宁 沈阳 110042

[摘要] 随着医学影像分析技术的快速发展和临床影像数据量的急剧增长, 如何快速准确地针对不同疾病医学影像进行精确诊断、分类和预后评估, 是现代医学工作者面临的重大挑战。深度学习是一种高通量自动化提取高维度特征信息的新一代人工智能技术, 目前已广泛应用于临床医学大数据分析领域, 为临床医学影像的快速识别、精准分割和辅助诊断等分析工作提供了新的契机。本文综述了近年来深度学习技术在医学影像分析领域的最新研究进展, 探讨了深度学习在MRI、CT、超声和X线等医学影像分析中的重要方法和典型应用, 展望了深度学习人工智能在医学影像分析中的发展前景。

[关键词] 人工智能; 深度学习; 医学影像; 辅助诊断; 图像处理

Deep Learning in Computer Aided Analyses of Medical Images

JIANG Xiran¹, JIANG Tao¹, SUN Jiayao², SONG Jiangdian³, JIANG Wenyan⁴, AI Hua¹,
LONG Zhe¹, SU Juan¹, CHANG Shijie¹, YU Tao⁴

1. Institute of Public Basic, China Medical University, Shenyang Liaoning 110122, China; 2. Department of Computer Science and Technology, University of Chinese Academy of Sciences, Beijing 100049, China; 3. Department of Medical Information, China Medical University, Shenyang Liaoning 110122, China; 4. Department of Medical Imaging, Liaoning Cancer Hospital, Cancer Hospital of China Medical University, Shenyang Liaoning 110042, China

Abstract: With the rapidly development of medical image analysis technology and clinical image data, how to accurately diagnose, classify and evaluate the prognosis of different diseases is a major challenge for the modern medical workers. Deep learning is a new generation of artificial intelligence technology with high-throughput automatic extraction and high-dimensional feature information. Deep learning has been widely used in the field of clinical medical big data analysis, it providing a new opportunity for identification, accurate segmentation and auxiliary diagnosis of clinical medical images. This paper reviews the latest research progress of deep learning technology in the field of medical image analysis; it also discusses the important methods and typical applications of deep learning in medical image analysis such as MRI, CT, ultrasound and X-ray, and the prospect of deep learning artificial intelligence in medical image analysis.

Key words: artificial intelligence; deep learning; medical imaging; auxiliary diagnosis; image processing

[中图分类号] R445

[文献标识码] A

doi: 10.3969/j.issn.1674-1633.2021.06.040

[文章编号] 1674-1633(2021)06-0164-08

引言

临床医学影像通过反映人体组织器官的形态及功能, 在临床疾病的诊断和预后中发挥着重要作用。当前对医学影像数据的分析多依赖于医生肉眼观察阅片, 医生本身的经验和主观因素差异会影响诊断的准确性, 而临床影像数据量的急剧增长也极大地增加了医生的工作量。近年来,

医学影像数字化和人工智能辅助诊断的快速发展对医疗影像分析带来了巨大变革, 利用深度学习技术模拟人脑自动学习数据各层次抽象特征来分析医学影像并给出辅助诊断结论已成为现代临床影像分析工作中的重要发展趋势, 合理使用人工智能技术将有效提高临床诊断的效率和准确性。

1998年Lecun等^[1]首次提出了神经网络雏形LeNet, 利用反向传播算法训练多层神经网络为深度学习奠定了基础。在此之后涌现出更多优秀的深度学习算法, 如2012年ImageNet图像分类竞赛冠军AlexNet^[2], 2014年ILSVRC定位任务第一名和分类任务第二名的VGGNet^[3], ImageNet竞赛冠军GoogLeNet^[4]等, 这些算法在医学影像分类、定

收稿日期: 2020-07-28

基金项目: 国家自然科学基金面上项目(81872363); 国家重点研发计划(2016YFC1303002); 辽宁省科技厅博士启动基金(81501833); 沈阳市科技计划重大项目(17230907); 中国医科大学健康医疗大数据研究课题(HMB201903101)。

通信作者: 于韬, 医学硕士, 副主任医师, 主要研究方向为肿瘤影像学诊断和介入治疗研究。

通信作者邮箱: dryutao@hotmail.com

位、分割和重建方面均取得了较好的效果。新一代非监督深度学习网络如 PixelRNN/ 卷积神经网络 (Convolutional Neural Network, CNN)、变分自编码器、生成式对抗网络和多层降噪自动编码器 (Stacked Denoising Auto Encoder, SDAE) 等无需使用带标签的数据训练, 能解决影像训练样本不足的问题, 并节省了人工标记影像感兴趣区域 (Region of Interest, ROI) 的步骤^[5]。近年发展较快的深度强化学习^[6]具有自动学习的功能, 能够根据反馈不断调整自己的输出以达到最优结果。其他深度学习网络模型如循环神经网络 (Recurrent Neural Network, RNN)^[7]、全卷积神经网络^[8]和 U-net^[9]等也都在具有不同特点的医学影像分析中取得了较好的效果。由于医学影像存在着对比度低、可变性大和结构复杂等特点, 目前尚无一种通用的方法来解决不同成像方式和不同疾病的辅助诊断, 本文按照不同成像方式对现有的深度学习方法应用进行了梳理, 列举了近年来深度学习方法在不同医学场景的应用。总结表明, 将传统的深度学习方法与实际图像特点相结合的改进方法能够有效适应医学图像的特征, 将是医学辅助诊断发展的重要趋势。

1 深度学习在MRI影像分析中的应用

MRI 可获得反映不同人体组织器官特性的影像数据, 是临床影像检查中的常用方法。由于不同序列 MRI 影像中信息量较大, 一些组织器官的信号相近, 临床上依赖有一定工作经验的影像科医生进行阅片解读。近年来, 随着深度学习人工智能的快速发展, 针对 MRI 影像的计算机辅助分析技术能够快速准确地批量处理大量影像数据, 在对不同疾病进行准确诊断、精准分割、分类和预后等方面显示出巨大的应用潜力, 得到医学影像工作者的高度关注^[10-12]。当前用于 MRI 影像分析的深度学习方法主要有三类: 基于小块图像组的 Patch-Wise CNN 模型, 基于语义的 Semantic-Wise CNN 模型和基于级联网络的 Cascade CNN 模型^[13]。

基于小块图像组的 Patch-Wise CNN 模型结构具有收敛速度快的特点, 在医学图像诊断和分割领域中已有广泛应用^[14], Ghafoorian 等^[15]使用 Patch-Wise CNN 尝试分割白质高信号区域, 网络获得的分割结果与医生手工分割图像没有统计学差异。Moeskops 等^[16]采用了不同尺寸的 2D 图像组作为输入, 并使用了不同大小的卷积核, 获得分割图像 Dice 相似系数 (Dice Similarity Coefficient, DSC) 值范围为 0.82~0.91, 并表明小尺寸图像组训练的网络可以对微小组织结构进行精细分析。Mehta 等^[17]提出的 BrainSegNet 框架则将 2D 和 3D 图像分别输入后, 再经过不同的小卷积核进行卷积处理, 获得了优于单一图像输入的分割效果。Kamnitsas 等^[18]设计了含有双通路的 3D 卷积网络 DeepMedic 模型, 使用条件随机场 (Conditional Random Fields, CRF) 作为后处理, 在 TBI、BRATS 2015 和 ISLES-SISS 2015 数据库中测试的 DSC 值分别达到了 63.0、89.8 和 66.0。Liu 等^[19]进一步对 DeepMedic 模型进行改进,

并用于脑转移瘤 MRI 影像的分割, 将 DSC 值分别提高到 75.0、81.0 和 67.0。这些研究均表明 Patch-Wise CNN 框架在 MRI 影像的分割中具有重要的研究价值和应用潜力。与 Patch-Wise CNN 模型只能将固定尺寸的影像输入网络不同, 基于语义的 Semantic-Wise CNN 模型先通过卷积获得图像的高层次特征, 再通过去卷积输出分割图像^[13], 从而能够将任意大小的影像作为输入, 且具有更少的网络参数, 训练所需的耗时更短^[14]。Jonathan 等^[20]最早基于语义分割思想提出了端对端的全卷积网络 (Fully Convolutional Network, FCN) 概念, 对整幅输入影像进行卷积处理, 学习高维度抽象信息, 再通过去卷积处理获得对不同种像素的分割输出。Brosch 等^[21]将 FCN 网络框架用于多发性硬化病灶 MRI 影像的分割研究, 虽然分割使用的数据集较小, 仍获得了 68.4 的 DSC 值。Nile 等^[22]进一步采用使用该网络框架对人体正常组织的 MRI 影像进行了分割, 并测试了单模态和多模态输入对网络的影响, 表明模型从多模态输入中获取更丰富的高维度信息。基于级联网络的 Cascade CNN 模型是将一个 CNN 的输出作为另一个 CNN 的输入, 第一个 CNN 用来勾画组织器官的大体区域, 第二个 CNN 则用来进行精细分割, 判断每个像素是否属于该组织器官^[14], 这可以使得整个网络更加高效, 且所需影像的训练样本较少^[23]。该网络的主要特点是在第二轮计算中只针对筛选出的感兴趣区进行分析, 可以显著减少冗余计算, 不仅能区分正常组织和病变区域, 而且在病变区域内部还可以进一步实现细分类^[24-26]。Valverde 等^[26]利用 Cascade CNN 网络对多发性硬化症 MRI 影像进行了分割, 结果表明 Cascade CNN 网络可以在保持假阳性率较低的基础上大幅提高分割精确度。Havaei 等^[24]基于级联网络思路设计构建了三种含有不同卷积层结构的 Cascade CNN 网络 (LocalCascadeCNN、FCascadeCNN 和 InputCascadeCNN), 并针对脑部水肿区、坏死区和增强/非增强区 MRI 影像进行了分割测试, 表明 LocalCascadeCNN 在检测整个肿瘤区域时的假阳性率最低, MFCascadeCNN 输出的肿瘤边界最平滑, 而 InputCascadeCNN 的分割耗时最短。Cui 等^[25]也使用 CascadeCNN 对脑胶质瘤 MRI 影像进行了分割, 他们采用 FCN 网络结合迁移学习的方法先挑选出影像中的肿瘤区域, 再使用深层 CNN 网络结合小卷积核进一步对肿瘤影像进行精确分割, 该方法在 BRATS 2015 公开 MRI 影像数据集上的 DSC 值可达 0.89, 计算耗时仅需 1.54 s。表 1 为近年提出的一些有代表性的用于脑部 MRI 影像分割的重要深度学习模型。

2 深度学习在CT影像分析中的应用

针对 CT 影像的计算机辅助分析技术的研究时间最长, 且技术发展较为成熟。已有大量研究表明, 利用深度学习对多层 CT 影像进行筛选和分类的辅助诊断技术能为临床医生提供有价值的参考意见^[31-32]。对 CT 影像进行适当的预处理可以有效提高深度学习模型对肺结节的分类能力,

表1 用于脑部MRI影像分割的深度学习网络模型

作者	年份	分割对象	数据	深度学习模型	结果
Zhang等 ^[27]	2017	丘脑区	MICCAI 公开数据集	MALSF	SI: (0.9239 ± 0.01) ~ (0.9106 ± 0.02)
Guerrero等 ^[28]	2018	脑白质	临床扫描MRI图像	uResNet	DSC: 69.5 ± 16.1
Florian等 ^[29]	2020	脑脊液和脑容量	BrainWeb公开数据集	Fast	DSC: 0.87
Pierrick等 ^[30]	2020	正常脑组织	Neuromorphometrics公开数据集	AssemblyNet	DSC: 92.8

Ciampi 等^[33]通过将肺部 CT 影像垂直的横切面、矢状面和冠状面进行旋转扩充,获得不同切面的结节图像,从而解决了临床训练数据不足的问题。Shen 等^[34]则模拟医生阅片时的远观和近看过程,对同一结节图像进行了缩放处理后再进入深度学习网络,模型的分类效果获得了显著提高。Tu 等^[35]深入对比了针对结节影像采样的 SINGLE 策略和 ALL 策略(SINGLE 策略在一个结节的横切面、矢状面和冠状面影像中,仅抽取位于中央的图像用于训练和测试,而 ALL 策略则取出三个互相垂直的切面中的全部图像用于训练和测试),指出采用 ALL 策略的模型获得预测准确率比 SINGLE 策略有大幅提高。此外,近年的研究发现,使用自然图像对神经网络进行预先训练后,再利用肺 CT 影像对模型二次训练,可以显著提高结节的分类效果。Ciampi 等^[36]使用 ImageNet 数据库预先训练好的网络,并通过微调使其更加适用于肺结节的分类任务。Hoo-Chang 等^[37]也利用 ImageNet 对 AlexNet 和 GoogLeNet 分别进行训练和微调,分类效果也得到了明显提升。Erhan 等^[38]则进一步采用无监督预训练联合监督式微调进行训练,提高了对肺结节的分类能力。

多种网络模型融合策略也常用于肺部 CT 影像中结节分类鉴定。Zhao 等^[39]将 LeNet 和 AlexNet 进行融合后,分类准确率为 82.25%,AUC 值达到 87.70%。Shen 等^[40]提出含有特殊池化层结构的 Multi-Crop CNN 模型,能将卷积层输出的中心特征提取出来,再将多个 Multi-Crop 提取的特征进行集合后再继续卷积操作,该模型的分类准确率为 87.14%,AUC 值高达 0.93。Kang 等^[41]进一步建立了考虑 CT 片层空间关系的 3D inception 和 3D Inception-ResNet 模型,分类错误率 4.59%,敏感度 95.68%,特异性 94.51%。Cheng 等^[42]则尝试非监督学习的方法,即采用 SDAE 模型和 ALL 策略,获得分类准确率为 94.4%,敏感度 90.8%,特异性 98.1%。Ali 等^[43]在现有 CNN 网络模型的基础上,进一步提出了强化学习(Reinforcement Learning, RL)模型,并在 LIDC-IDRI 数据集上进行了测试,结果表明 RL 模型在训练集中能得到很高的准确率和敏感度,但在测试集上却较低,这可能是由于 RL 模型对数据量的需求较大,对于大于 3 mm 的结节,单个放射科医师的错误发现率为 65.2%,而 RL 模型的为 44.7%,体现了强化学习策略在 CT 影像分析中的优势。

在术前定位及放疗定位中,病灶轮廓勾画的不精确会对放疗计划的剂量学特性产生巨大影响及对正常组织造成毒性损伤,因此基于 CT 影像的器官轮廓精准分割有着重要的临床价值,而现有分割方法多采用手动分割,存在人

为误差。近年来,深度学习技术在 CT 影像分割领域取得了一系列重要研究进展。Swierczynski 等^[44]将肺部图像配准和分割结合在一起,取得了良好的肺分割准确率。Feng 等^[45]提出的基于 CNN 的弱监督肺结节分割网络,仅需要图像级别的标签就能够完成对结节的自动分割,真阳性率可达 0.77。Lustberg 等^[46]则对比了基于图谱区域划分技术(Mirada RTx 1.6 和 Workflow Box 1.4)与深度学习区域划分技术(Mirada DLC Expert),发现用这两种勾画区域技术均比手工方式耗时更短,但训练集由于医生对轮廓勾画存在人为误差以及勾画方式不同(包含或排除心脏的血管),而深度学习网络试图将这些差异结合起来,因此会导致最终结果不准确。在腹部 CT 影像分割领域,由于腹部器官较多且 CT 值相近,因此精准分割各器官轮廓是非常困难的。Fu 等^[47]首先在 FCN 的基础上采用多层级上采样结构对胰腺进行了自动分割,该算法用上采样 up-sampling 将各阶段通过卷积得到的特征恢复成原图大小,保证了分割边界的清晰,DSC 值达到 76.36%。Roth 等^[48]则进一步使用神经网络(Holistically-Nested convolutional Network, HNN)将胰腺所在区域标注出来,再使用另外一个 HNN 勾画胰腺轮廓,DSC 可以提高到 81.27%。他们进一步提出的 3D U-net 神经网络结构,采用了两个阶段从粗到精的方法,先用 3D-FCN 筛选出粗略的感兴趣区,再输入第二个 3D-FCN 进行具体分析,有利于对精细区域的分割,DSC 范围达 0.69~0.82,为当前最佳水平^[49]。Gibson 等^[50]提出了另外一种神经网络构架—NiftyNet,该网络对腹腔脏器分割的 DSC 为 0.62~0.94,其中对肝脏的分割 DSC 达 0.94。在对病变组织的划分问题上,Drozdal 等^[51]利用 FCN 和 FC-ResNets 的整合网络进行肝脏病灶划分,先将数据输入低容量 FCN,将该 FCN 用作图像归一化,再输入 FC-ResNet 进行分割。对肝脏病灶分割的 DSC 达到 0.711。盆腔器官的分割复杂度与腹腔器官类似,Cha 等^[52]提出了 DL-CNN 网络构架对膀胱癌的肿瘤部分进行分割,获得了较高的分割准确率。Xu 等^[53]则利用双通道预处理的方法处理盆腔 CT 影像,然后利用 CNN 粗略处理选出膀胱所在范围,再使用 3D CRF-RNN 精确勾画膀胱轮廓,DSC 达到了 92.24%,高于常规 V-net 方法。表 2 列举了近年发表的有代表性的用于人体组织器官 CT 影像分割研究的深度学习模型。

3 深度学习在超声影像分析中的应用

超声检查在临床工作中具有操作简单和价格低廉的优势,超声科医生可根据超声图像的形态及回声特点来判断

组织器官的疾病状态。Wang 等^[61]基于离散小波变换特征对不同模式下的超声图进行归类,对甲状腺结节恶性风险进行评分,取得了 98.9%~100% 的准确性,这种方法提取的“计算机决定的特征”不同于临床微钙化灶等人工经验,为深度学习应用开辟了先河,结合预处理和参数微调之后,深度学习技术识别甲状腺肿瘤良恶性的准确率、灵敏度和特异性可达到 96.34%、82.8%、99.3%^[62]。深度学习还应用于识别新生儿的心脏疾病分类,Armato 等^[63]在心脏超声图像上直接训练了 CNN 模型,从五种不同的幼儿中区分先天性心脏病,在有限的训练数据下取得了优异的表现。为了进一步提高分类效果,有学者尝试了对超声影像在 Caffe 框架下进行预处理,之后对一个预先训练的深度学习网络 GoogLeNet 模型进行微调,最后使用有监督机器学习分类器 Cost-Sensitive Random Forest 进行二分类,该方法尤其适用于对甲状腺结节超声影像的分析^[7]。Ciompi 等^[36]对深度学习网络在肝脏超声影像的特征分层中的应用进行了优化,提出一个有 22 层的神经网络的深度学习网络 Symtosis,通过设置 Dropout 参数值抑制一定比例神经元活性,生成的不同模型平均,去除肝脏原始图像的背景,得到了 100% 的平均准确率。在超声检测方面,Azizi 等^[64-66]结合时间增强型超声的前列腺影像,提取出高维深度学习特征,成功完成前列腺癌的检测和分级。在阑尾炎超声诊断方面,深度学习能通过协助定位为急性阑尾炎患者的精确诊断提供依据,如无监督深度学习模型 Fuzzy Art 可使得阑尾炎诊断区域的准确性提高至 95%,达到与 CT 诊断能力相当的水平^[67]。在胎儿超声诊断中,标准平面的获取是先决条件,除了使用传统的机器学习方法检测胎儿 US 标准平面外,最近使用深度学习算法检测胎儿超声标准平面的趋势越来越明显。Baumgartner 等^[68-69]和 Chen 等^[70-71]通过模型,分别完成了二维超声图像中 13 个胎儿标准面(如肾脏、大脑、腹部、脊柱、股骨和心脏平面)和胎儿腹部(或面部和四腔)标准面的检测。在分割方面,Norman 等^[9]针对乳腺超声病变检测问题比较了 LeNet、U-Net 和 FCN-Alex Net 网络模型,其中基于 patch 的 LeNet 和转移学习 FCN-AlexNet 分别在不同的数据集上取得了最好结果,显著优于传统 U-Net 方法。Huang 等^[31]进一步对 U-Net 加以改进,提出 multiple U-net 算法,添加了手动分割掩模,通过实时扫描,同时从不同的角度、方向和不同的预压缩水平,对乳腺超声影像中的可疑肿块进行分割,并将同一肿块的不同截面信息图像分别作为独立情况处理,增加了神经网络学习的信息量。超声弹性成像也是临床上常用的超声成像方式,有研究者尝试将深度学习应用于二维剪切波弹性成像(Shear-Wave Elastography, SWE)数据分析,相比于统计学特征,深度学习方法将准确率、灵敏度和特异性分别提高至 93.4%、88.6% 和 97.1%,AUC 可达 94.7%。此外,通常认为 SWE 图像中的颜色缺失区域(“黑洞”区域)的剪切波速或弹性模量的计算是不确定的,而深度学习模型可以捕获肿瘤中存在的“黑洞”的信息并用于区分肿瘤

的良恶性^[33]。

表2 深度学习在人体组织和器官CT影像分割中的应用

作者	年份	器官/疾病	方法	结果(Dice score)
Ren等 ^[54]	2018	头颈	Interleaved CNNs	0.58 ± 0.17 (视交叉),
				0.71 ± 0.08 (视神经)
Zhang等 ^[55]	2018	骨肉瘤	MSRN	89.22%
Zhou等 ^[56]	2019	脊椎	N-Net	0.9499 ± 0.02
Chen等 ^[57]	2020	胰腺	MsFF	87.26%
Fan等 ^[58]	2020	新冠肺炎	Semi-Inf-Net	73.9%
Zhou等 ^[59]	2020	新冠肺炎	U-Net	83.1%
Lei等 ^[60]	2020	前列腺	MRI-aided deep attention fully convolution network	0.09

4 深度学习在X线影像分析中的应用

X 线检查是重要的临床早期筛查方法,对于人体密度相差大的部位(如胸部和骨骼等)成像效果好,但由于 X 线影像中含有多种人体组织器官的重叠,医生难以对各组织器官的具体位置进行精准判断^[72]。近年来,深度学习在 X 线早期筛查领域得到了快速发展,Kooi 等^[73]一种基于 X 线诊断乳腺癌良性孤立性囊肿和恶性肿瘤的深度学习模型,通过采用组织增强的方法来对重叠组织进行分类,准确率达到 80%。Qiu 等^[74]进一步将风险预测模型应用到乳腺癌早期预测,准确率达到 71.4%。Li 等^[75]利用迁移学习区分乳腺癌高风险和低风险人群,发现该模型较传统纹理分析能更好的提取不同人群的特征,取得更好的预测效果。为了提高对 X 线影像信息的利用能力,当前应用较多的 CAD4TB 软件可以针对胸部 X 线影像中的病灶区域进行形状和纹理评分并辅助预测肺结核^[76],在不同的 CXRs (Chest X-rays) 数据集上的 AUC 值可达到 0.71~0.84^[76-80]。近年有学者对 CAD4TB 进行改进,构建对 X 线影像更加敏感的深度学习模型,如 Hwang 等^[81]使用自我学习(Self-transfer Learning, STL)方法,同时训练分类和定位网络,可以在没有任何预先训练模型的情况下,仅采用图像层面的标记数据集给出准确的 ROI 的精确定位,使用 STL 在三个不同的 CXRs 公开数据集上进行结核病分类的 AUC 值分别达到 0.96、0.93 和 0.88,相比 CAD4TB 有了显著提升^[82]。此外,为了解决临床影像数据量不足的问题,Bar 等^[83]率先在胸部 X 线影像诊断中引入迁移学习方法,他们抽取了经 Imagenet 公开数据集预先训练的 CNN 网络的第 5~7 层并分别放入新的网络中进行训练,再与图像编码融合,用于检测胸腔积液的 AUC 值可达 0.93。Lakhani 等^[84]则在 Caffe 深度学习框架下使用 AlexNet 和 GoogLeNet 网络模型对 X 线影像进行检测,使用两个网络进行集成融合的网络获得预测 AUC 值可提高至 0.99,表明深度学习在 X 线影像分

析中具有较大应用潜力。

5 总结与展望

经过近几年的快速发展,深度学习技术在临床医学影像辅助分析中得到了越来越多的重视,基于深度学习建立的计算机辅助分析方法已经涵盖了几乎全部的医学影像种类,涉及的疾病类别十分广泛,已经能够在临床影像的分类、分割、配准和重建等方面提供高效可靠的解决方案^[85-86]。

然而,当前深度学习技术的应用也存在一些问题,如对影像数据的训练过程中,需要医生在影像上对病灶区域进行人工标注,较为耗时耗力,限制了深度学习技术的大规模应用。针对这一问题,可通过引入非监督式或弱监督学习方法,能减少复杂的标记分割工作,同时不会带来主观因素造成的误差,能够很好地提高识别效率和识别结果的准确性,因此非监督式和弱监督学习方法将成为医学图像分析的重要趋势。此外,由于医学影像对比度较低,正常组织与异常组织边界模糊,还存在较多的如神经、血管等微细结构,经典的深度学习方法对这些细微结构的适用性还有待提高,研究者应结合不同医学影像自身特点建立有针对性的深度学习模型,这是未来人工智能医学影像分析的一个重要发展方向。

总之,深度学习技术在医学影像分析领域已经体现出较大的发展潜力和广阔的应用前景,随着神经网络模型的日益完善,网络对疾病的识别速度、准确度、特异度和灵敏度均有望进一步大幅提高,伴随当前医疗信息大数据发展趋势,深度学习技术必将辅助医生提升临床分析能力,助力我国医疗水平发展,引领医学影像学进入一个新阶段。

[参考文献]

- [1] Lecun Y,Bottou L,Bengio Y,et al.Gradient-based learning applied to document recognition[J].*Proceedings of the IEEE*,1998,86(11):2278-2324.
- [2] Krizhevsky A,Sutskever I,Hinton GE.ImageNet classification with deep convolutional neural networks[J].*Communications of the ACM*,2017,60(6):84-90.
- [3] Simonyan K,Zisserman A.Very deep convolutional networks for large-scale image recognition[J].*arXiv preprint arXiv:1409.1556*,2014.
- [4] Szegedy C,Liu W,Jia Y,et al.Going deeper with convolutions[C].*Proceedings of the IEEE conference on computer vision and pattern recognition*,2015:1-9.
- [5] Stanford vision and learning laboratory.Application of convolutional neural network in visual recognition[R/OL].(2018-03-01)[2019-07-27].<http://cs231n.stanford.edu>.
- [6] Tseng HH,Luo Y,Cui S,et al.Deep reinforcement learning for automated radiation adaptation in lung cancer[J].*Med Phys*,2017,44(12):6690-6705.
- [7] Lipton ZC.A critical review of recurrent neural networks for sequence learning[J].*Computer Science*,2015.
- [8] Abdullah-Al N,Ali MM,Yinan K.Histopathological breast cancer image classification by deep neural network techniques guided by local clustering[J].*BioMed Res Int*,2018,(2018):1-20.
- [9] Norman B,Pedroia V,Majumdar S,et al.Use of 2D U-Net Convolutional Neural Networks for automated cartilage and meniscus segmentation of knee mr imaging data to determine relaxometry and morphometry[J].*Radiology*,2018,288(1):177-185.
- [10] Jose MCT,Arif M,Niessen WJ,et al.Automated classification of significant prostate cancer on mri: A systematic review on the performance of machine learning applications[J].*Cancers*,2020,12(6):1606.
- [11] Selvikvag A,Arvid L.An overview of deep learning in medical imaging focusing on MRI[J].*Z Med Phys*,2019,29(2):102-127.
- [12] Mazurowski MA,Buda M,Saha A,et al.Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI[J].*J Magn Reson Imaging*,2019,49(4):939-954.
- [13] Brosch T,Tang LYW,Yoo Y,et al.Deep 3D convolutional encoder networks with shortcuts for multiscale feature integration applied to multiple sclerosis lesion segmentation[J].*IEEE Trans Med Imaging*,2016,35(5):1229-1239.
- [14] Akkus Z,Galimzianova A,Hoogi A,et al.Deep learning for brain MRI segmentation: State of the art and future directions[J].*J Digit Imaging*,2017,(30):449-459.
- [15] Ghafoorian M,Karssemeijer N,Heskes T,et al.Location sensitive deep convolutional neural networks for segmentation of white matter hyperintensities[J].*Sci Rep*,2017,7(1):5110.
- [16] Moeskops P,Viergever MA,Mendrik AM,et al.Automatic segmentation of MR brain images with a convolutional neural network[J].*IEEE Trans Med Imaging*,2016,35(5):1252-1261.
- [17] Mehta R,Majumdar A,Sivaswamy J.BrainSegNet: A convolutional neural network architecture for automated segmentation of human brain structures[J].*J Med Imaging*,2017,4(2):024003.
- [18] Kamnitsas K,Ledig C,Virginia FJN,et al.Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation[J].*Med Image Anal*,2016,(36):61-78.
- [19] Liu Y,Stojadinovic S,Hrycushko B,et al.A deep convolutional neural network-based automatic delineation strategy for multiple brain metastases stereotactic radiosurgery[J].*PLoS One*,2017,12(10):e0185844.
- [20] Jonathan L,Evan S,Trevor D.Fully convolutional networks

- for semantic segmentation[J].*IEEE Trans Pattern Anal Mach Intell*,2015;3431-3440.
- [21] Brosch T,Tang L,Yoo Y,*et al*.Deep 3D convolutional encoder networks with shortcuts for multiscale feature integration applied to multiple sclerosis lesion segmentation[J].*IEEE Trans Med Imaging*,2016,35(5):1229-1239.
- [22] Nile D,Wang L,Gao Y,*et al*.Fully convolutional networks for multi-modality isointense infant brain image segmentation[J].*Proc IEEE Int Symp Biomed Imaging*,2016,(2016):1342-1345.
- [23] Choi H,Jin K.Fast and robust segmentation of the striatum using deep convolutional neural networks[J].*J Neurosci Methods*,2016,(274):146-153.
- [24] Havaei M,Davy A,Warde-Farley D,*et al*.Brain tumor segmentation with deep neural networks[J].*Med Image Anal*,2017,(35):18-31.
- [25] Cui SG,Lei M,Jingfeng J,*et al*.Automatic semantic segmentation of brain gliomas from MRI images using a deep cascaded neural network[J].*J Healthc Eng*,2018,(2018):4940593.
- [26] Valverde S,Cabezas M,Roura E,*et al*.Improving automated multiple sclerosis lesion segmentation with a cascaded 3D convolutional neural network approach[J].*Neuro Image*,2017,(155):159-168.
- [27] Zhang MH,Lu ZT,Feng QJ,*et al*.Automatic thalamus segmentation from magnetic resonance images using multiple atlases level set framework[J].*Sci Rep*,2017,7(1):4274.
- [28] Guerrero R,Qin C,Oktay O,*et al*.White matter hyperintensity and stroke lesion segmentation and differentiation using convolutional neural networks[J].*Neuro Image: Clin*,2018,(17):918-934.
- [29] Florian G,Florian E,Susonne R,*et al*.Semantic segmentation of cerebrospinal fluid and brain volume with a convolutional neural network in pediatric hydrocephalus—transfer learning from existing algorithms[J].*Acta Neurochir*,2020,162(10):1-12.
- [30] Pierrick C,Boris U,Midiae C,*et al*.AssemblyNet: A large ensemble of CNNs for 3D whole brain MRI segmentation[J].*Neuro Image*,2020,(219):117026.
- [31] Huang Y,Gao L,Preuhs A,*et al*.Field of view extension in computed tomography using deep learning prior[J].2019.
- [32] Nowak S,Faron A,Luetkens JA,*et al*.Fully automated segmentation of connective tissue compartments for ct-based body composition analysis: a deep learning approach[J].*Invest Radiol*,2020,(55).
- [33] Ciompi F,Chung K,van Riel SJ,*et al*.Towards automatic pulmonary nodule management in lung cancer screening with deep learning[J].*Sci Rep*,2017,(7):46479.
- [34] Shen W,Zhou M,Yang F,*et al*.Multi-scale convolutional neural networks for lung nodule classification[J].*Inf Process Med Imaging*,2015,(24):588-599.
- [35] Tu XG,Xie M,Gao JJ,*et al*.Automatic categorization and scoring of solid, part-solid and non-solid pulmonary nodules in CT images with convolutional neural network[J].*Sci Rep*,2017,7(1):8533.
- [36] Ciompi F,de Hoop B,van Riel SJ,*et al*.Automatic classification of pulmonary peri-fissural nodules in computed tomography using an ensemble of 2D views and a convolutional neural network out-of-the-box[J].*Med Image Anal*,2015,26(1):195-202.
- [37] Hoo-Chang S,Roth HR,Gao M,*et al*.Deep convolutional neural networks for Computer-Aided detection: CNN architectures, dataset characteristics and transfer learning[J].*IEEE Trans Med Imaging*,2016,35(5):1285-1298.
- [38] Erhan D,Bengio Y,Courville A,*et al*.Why does unsupervised pre-training help deep learning?[J].*J Mach Learn Res*,2010,11(3):625-660.
- [39] Zhao X,Liu L,Qi S,*et al*.Agile convolutional neural network for pulmonary nodule classification using CT images[J].*Int J Comput Assist Radiol Surg*,2018,13(4):585-595.
- [40] Shen W,Zhou M,Yang F,*et al*.Multi-crop convolutional neural networks for lung nodule malignancy suspiciousness classification[J].*Pattern Recognition*,2016,61(61):663-673.
- [41] Kang GX,Liu K,Hou B,*et al*.Multiview convolutional neural networks for lung nodule classification[J].*Int J Imaging Syst Technol*,2017,27(1):12-22.
- [42] Cheng JZ,Ni D,Chou YH,*et al*.Computer-aided diagnosis with deep learning architecture: Applications to breast lesions in US images and pulmonary nodules in CT scans[J].*Sci Rep*,2016,(6):24454.
- [43] Ali I,Hart GR,Gunabushanam G,*et al*.Lung nodule detection via deep reinforcement learning[J].*Front Oncol*,2018,(8):108.
- [44] Swierczynski P,Papież BW,Schnabel JA,*et al*.A level-set approach to joint image segmentation and registration with application to CT lung imaging[J].*Comput Med imaging Graph*,2018,(65):58-68.
- [45] Feng XY,Yang J,Laine AF,*et al*.Discriminative localization in CNNs for weakly-supervised segmentation of pulmonary nodules[J].*Med Image Comput Comput Assist Interv*,2017,(10435):568-576.
- [46] Lustberg T,van Soest J,Gooding M,*et al*.Clinical evaluation of atlas and deep learning based automatic contouring for lung

- cancer[J].*Radiother Oncol*,2018,126(2):312-317.
- [47] Fu Min,Wu WM,Hong XF,*et al.*Hierarchical combinatorial deep learning architecture for pancreas segmentation of medical computed tomography cancer images[J].*BMC Syst Biol*,2018,12(4):56.
- [48] Roth HR,Lu L,Lay N,*et al.*Spatial aggregation of holistically-nested convolutional neural networks for automated pancreas localization and segmentation[J].*Med Image Anal*,2018,4(5):94-107.
- [49] Holger RR,Hirohisa O,Xiangrong Z,*et al.*An application of cascaded 3D fully convolutional networks for medical image segmentation[J].*Comput Med Imaging Graph*,2018,(66):90-99.
- [50] Gibson E,Li WQ,Sudre C,*et al.*NiftyNet: A deep-learning platform for medical imaging[J].*Comput Methods Programs Biomed*,2018,(158):113-122.
- [51] Drozdal M,Chartrand G,Vorontsov E,*et al.*Learning normalized inputs for iterative estimation in medical image segmentation[J].*Med Image Anal*,2017,(44):1-13.
- [52] Cha KH,Hadjjiiski LM,Samala Rk,*et al.*Bladder cancer segmentation in CT for treatment response assessment: Application of deep-learning convolution neural network—A pilot study[J].*Tomo graphy*,2016,2(4):421-429.
- [53] Xu XN,Zhou FG,Liu B.Automatic bladder segmentation from CT images using deep CNN and 3D fully connected CRF-RNN[J].*Int J Comput Assist Radiol Surg*,2018,13(7):967-975.
- [54] Ren XH,Xiang L,Nie D,*et al.*Interleaved 3D-CNNs for joint segmentation of small-volume structures in head and neck CT images[J].*Med Phys*,2018,45(5):2063-2075.
- [55] Zhang R,Huang L,Xia W,*et al.*Multiple supervised residual network for osteosarcoma segmentation in CT images[J].*Comput Med Imaging Graph*,2018,(63):1-8.
- [56] Zhou W,Lin L,Ge G.N-Net: 3D Fully Convolution Network-Based Vertebrae Segmentation from CT Spinal Images[J].*In J Pattern Recogn*,2019,33(6):1957003.1-1957003.15.
- [57] Chen Z,Wang X,Yan K,*et al.*Deep multi-scale feature fusion for pancreas segmentation from CT images[J].*Int J Comput Assist Radiol Surg*,2020,15(3):415-423.
- [58] Fan DP,Zhou T,Ji GP,*et al.*Inf-Net: Automatic COVID-19 Lung Infection Segmentation from CT Scans[J].*IEEE Trans Med Imaging*,2020,PP(99):1.
- [59] Zhou T,Canu S,Ruan S.An automatic COVID-19 CT segmentation network using spatial and channel attention mechanism[J].*Int J Imaging Syst Technol*,2020.
- [60] Lei Y,Dong X,Tian Z,*et al.*CT prostate segmentation based on synthetic MRI-aided deep attention fully convolution network[J].*Med Phys*,2020,47(2):530-540.
- [61] Wang X,Yang W,Weinreb J,*et al.*Searching for prostate cancer by fully automated magnetic resonance imaging classification: Deep learning versus non-deep learning[J].*Sci Rep*,2017,7(1):15415.
- [62] Luo S,Kim EH,Dighe M,*et al.*Thyroid nodule classification using ultrasound elastography via linear discriminant analysis[J].*Ultrasonics*,2011,51(4):425-431.
- [63] Armato SG,Petrack NA,Perrin DP,*et al.*Application of convolutional artificial neural networks to echocardiograms for differentiating congenital heart diseases in a pediatric population[C]//Spie Medical Imaging,2017:1013431.
- [64] Azizi S,Imani F,Zhuang B,*et al.*Ultrasound-Based Detection of Prostate Cancer Using Automatic Feature Selection with Deep Belief Networks[C]//International Conference on Medical Image Computing & Computer-assisted Intervention.Springer International Publishing,2015.
- [65] Azizi S,Imani F,Ghavidel S,*et al.*Detection of prostate cancer using temporal sequences of ultrasound data: a large clinical feasibility study[J].*Int J Comput Assist Radiol Surg*,2016,11(6):947-956.
- [66] Azizi S,Bayat S,Yan P,*et al.*Detection and grading of prostate cancer using temporal enhanced ultrasound: Combining deep neural networks and tissue mimicking simulations[J].*Int J Comput Assist Radiol Surg*,2017,12(8):1293-1305.
- [67] KIM KB,Hyun JP,Song DH,*et al.*Developing an intelligent automatic appendix extraction method from ultrasonography based on fuzzy ART and image processing[J].*Comput Math Methods Med*,2015,(2015).
- [68] Baumgartner CF,Kamnitsas K,Matthew J,*et al.*Real-time standard scan plane detection and localisation in fetal ultrasound using fully convolutional neural networks[C]//Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016. Springer, Cham,2016.
- [69] Baumgartner CF,Kamnitsas K,Matthew J,*et al.*SonoNet: Real-time detection and localisation of fetal standard scan planes in freehand ultrasound[J].*IEEE Trans Med Imaging*,2017,36(11):2204-2215.
- [70] Chen H,Dong N,Jing Q,*et al.*Standard plane localization in fetal ultrasound via domain transferred deep neural networks[J].*IEEE J Biomed Health Inform*,2015,19(5):1627-1636.
- [71] Chen H,Ni D,Yang X,*et al.*Fetal abdominal standard plane localization through representation learning with knowledge transfer[C]//Mlmi. Springer,Cham,2014.
- [72] Hemdan ED,Shouman MA,Karar ME.COVIDX-Net: A framework of deep learning classifiers to diagnose COVID-19

in X-Ray Images[J].2020.

- [73] Kooi T,van Ginneken B,Karssemeijer N,*et al.*Discriminating solitary cysts from soft tissue lesions in mammography using a pretrained deep convolutional neural network[J].*Med Phys*,2017,44(3):1017-1027.
- [74] Qiu Y,Wang Y,Yan S,*et al.*An initial investigation on developing a new method to predict short-term breast cancer risk based on deep learning technology[J].*Proc SPIE - Int Soc Opt Eng*,2016,(9785):978521.
- [75] Li H,Giger ML,Huynh BQ,*et al.*Deep learning in breast cancer risk assessment: evaluation of convolutional neural networks on a clinical dataset of full-field digital mammograms[J].*J Med Imaging*,2017,4(4):041304.
- [76] Maduskar P,Muyoyeta M,Ayles H,*et al.*Detection of tuberculosis using digital chest radiography: Automated reading vs. interpretation by clinical officers[J].*Int J Tuberc Lung Dis*,2013,17(12):1613-1620.
- [77] Monde M,Pragnya M,Maureen M,*et al.*The sensitivity and specificity of using a computer aided diagnosis program for automatically scoring chest X-Rays of presumptive TB patients compared with Xpert MTB/RIF in lusaka zambia[J].*PLoS One*,2014,9(4):e93757.
- [78] Rahman MT,Codlin AJ,Rahman MM,*et al.*An evaluation of automated chest radiography reading software for tuberculosis screening among public- and private-sector patients[J].*Eur Respir J*,2017,49(5):1602159.
- [79] Steiner A,Mangu C,van den Hombergh J,*et al.*Screening for pulmonary tuberculosis in a Tanzanian prison and computer-

aided interpretation of chest X-rays[J].*Public Health Action*,2015,5(4):249-254.

- [80] Breuninger M,Ginneken BV,Philipsen RHHM,*et al.*Diagnostic accuracy of computer-aided detection of pulmonary tuberculosis in chest radiographs: A validation study from sub-saharan africa[J].*PloS One*,2014,9(9):e106381.
- [81] Hwang S,Kim HE.Self-transfer learning for weakly supervised lesion localization[C].International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham,2016:239-246.
- [82] Hwang S,Kim HE,Jeong J,*et al.*A novel approach for tuberculosis screening based on deep convolutional neural networks[C].International Society for Optics and Photonics,2016.
- [83] Bar Y,Diamant I,Wolf L,*et al.*Deep learning with non-medical training used for chest pathology identification[C].International Society for Optics and Photonics,2015.
- [84] Lakhani P,Sundaram B.Deep learning at chest radiography: Automated classification of pulmonary tuberculosis by using convolutional neural networks[J].*Radiology*,2017,284(2):574-582.
- [85] Moeskops P,Wolterink JM,van der Velden BHM,*et al.*Deep learning for multi-task medical image segmentation in multiple modalities[C].Springer,Cham,2016:478-486.
- [86] Moeskops P,de Bresser J,Kuijff HJ,*et al.*Evaluation of a deep learning approach for the segmentation of brain tissues and white matter hyperintensities of presumed vascular origin in MRI[J].*NeuroImage: Clin*,2018,(17):251-262.

本文编辑 皮志超

上接第135页

- [18] Rim J,Mouna KB,Mohamed AS,*et al.*A stochastic closed-loop supply chain network design problem with multiple recovery options[J].*Comput Ind Eng*,2018,118:23-32.
- [19] 胡建平.医院信息系统功能设计指导[M].北京:人民卫生出版社,2018.
- [20] 曾琦.区域门诊服务中心医疗信息平台的建设与应用[J].中国卫生标准管理,2019,10(13):4-6.

上接第138页

- [15] 宋天一,孙文波,薛炼,等.气动物流传输系统对血气分析结果的影响评价[J].中国医疗设备,2017,32(2):28-30.
- [16] 马军.三维ST160C气动物流系统效率的提升实践研究[J].医疗装备,2018,31(3):72-73.
- [17] Yu W,Wen K,Min Y,*et al.*A methodology to quantify the gas supply capacity of natural gas transmission pipeline system using reliability theory[J].*Reliab Eng Syst Safe*,2018,175:128-141.

[21] 施识帆,张昕,曹凯迪,等.负载均衡技术在大型公立医院中的应用[J].中国医疗设备,2018,33(11):155-157.

[22] 李雄英,董庆贺,何倩,等.面向智慧医疗云的SDN动态负载均衡方法[J].计算机科学,2018,45(11):75-81.

[23] 吴昊,秦立春,罗柳容.基于提升度的KNN分类子的分类原则改良模型[J].广西师范大学学报(自然科学版),2019,37(2):75-81.

本文编辑 王晨晨

[18] 马军.三维气动物流系统常见故障分析[J].中国医疗设备,2016,31(5):161-162.

[19] 孙红利.医院气动物流系统在临床工作中存在的问题分析及对策[J].世界最新医学信息文摘,2018,18(56):203-204.

[20] 朱建波,李桂明,王永胜,等.我院智能化轨道小物流传输系统管理方法探讨[J].中国医疗设备,2019,34(8):145-148.

本文编辑 王晨晨