

DOI: 10.16781/j.CN31-2187/R.20210040

· 综述 ·

人工智能在前列腺多参数磁共振成像中的应用及展望

邢朋毅, 孟英豪, 阳青松, 陈 炜*

海军军医大学(第二军医大学)第一附属医院影像医学科, 上海 200433

[摘要] 前列腺癌(PCa)是世界上最常见的肿瘤之一。多参数磁共振成像(mpMRI)作为一种非侵入性工具,可以改善前列腺病变的检测、分类和体积量化。机器学习是人工智能(AI)的一个分支,能够快速、准确地分析mpMRI图像,在识别前列腺病变方面有较好的一致性,能够加强PCa的标准化管理,已经成为提高放射科医师诊断效率和准确度的工具。本文总结了AI在前列腺mpMRI中的应用,主要包括前列腺分割,病变检测、分割,以及病变分类表征等,并对未来发展进行了展望。

[关键词] 前列腺肿瘤;多参数磁共振成像;机器学习;人工智能;神经网络

[中图分类号] R 737.25 **[文献标志码]** A **[文章编号]** 2097-1338(2022)07-0808-08

Artificial intelligence in multi-parameter magnetic resonance imaging of the prostate: application and prospect

XING Peng-yi, MENG Ying-hao, YANG Qing-song, CHEN Wei*

Department of Radiology, The First Affiliated Hospital of Naval Medical University (Second Military Medical University), Shanghai 200433, China

[Abstract] Prostate cancer is one of the most common tumors in the world. Multi-parameter magnetic resonance imaging (mpMRI) as a non-invasive tool, can improve the detection, classification and volume quantification of prostate lesions. Machine learning is a branch of artificial intelligence (AI). It can quickly and accurately analyze mpMRI images, has good consistency in identifying prostate lesions, and can strengthen the standardized management of prostate cancer. It has become a tool for improving the diagnostic efficiency and accuracy of radiologists. This review summarizes the application of AI in mpMRI of the prostate (mainly including prostate segmentation, lesion detection and segmentation, and lesion feature description) and its development in the future.

[Key words] prostatic neoplasms; multi-parameter magnetic resonance imaging; machine learning; artificial intelligence; neural network

[Acad J Naval Med Univ, 2022, 43(7): 808-815]

前列腺癌(prostate cancer, PCa)是老年男性健康和生活质量的巨大威胁^[1]。2019年美国癌症研究协会和美国国家癌症研究所的数据表明,PCa发病率居全球男性常见肿瘤的第2位^[2]。随着日益加剧的人口老龄化以及生活环境和饮食结构的改变,PCa发病率呈持续上升趋势^[3]。PCa管理的一个主要挑战是缺乏区分侵袭性肿瘤和非侵袭性肿瘤的非侵入性工具,这可能会导致PCa的过度诊疗,进行不必要的活检、手术、放射治疗或化疗,引起患者的焦虑^[4]。基于多参数磁共振成像(multi-parameter magnetic resonance imaging, mpMRI)

对PCa较高的阴性预测值,其被越来越多地应用于PCa检测^[5]。mpMRI分析可减少PCa的过度诊断,从而实现更好的病灶检测、病灶分类(良性与恶性)和病灶体积的量化。

人工智能(artificial intelligence, AI)通过对mpMRI图像的系统分析与评估,进行前列腺病变的检测、特征提取以及体积量化。机器学习(machine learning, ML)是AI的一个分支,深度学习(deep learning, DL)是ML的子集,DL有解释大量数据的能力,成为医学成像中极具吸引力的技术^[6]。通过将前列腺mpMRI数据应用于ML,

[收稿日期] 2021-01-15 **[接受日期]** 2021-05-07

[基金项目] 国家临床重点专科军队建设项目(总后卫生部),上海市卫生和计划生育委员会面上项目(M20140149)。Supported by Military Construction Project for National Clinical Key Speciality (Health Department of PLA General Logistics) and General Project of Shanghai Municipal Commission of Health and Family Planning (M20140149).

[作者简介] 邢朋毅,博士,副主任医师。E-mail: drxingpengyi@163.com

*通信作者(Corresponding author)。Tel: 021-31162161, E-mail: cw12345cw@126.com

可以改善基于影像学的PCa临床诊治决策。本文总结了AI在前列腺mpMRI成像中的应用,涉及前列腺分割、病变检测和分割以及病变特征提取,并进行了展望。

1 mpMRI 简介

前列腺mpMRI将标准解剖序列与功能成像相结合,是一种先进的非侵入性成像形式。它由T1加权像(T1-weighted imaging, T1WI)、T2加权像(T2-weighted imaging, T2WI)和一些功能序列组成[包括表观扩散系数(apparent diffusion coefficient map, ADC)的弥散加权成像(diffusion-weighted imaging, DWI)和动态对比增强(dynamic contrast enhancement, DCE)]。DWI和DCE是常用的功能成像技术。T2WI、DWI和DCE联合检测PCa具有较高的特异度、灵敏度和阴性预测值^[7-8]。研究表明,mpMRI对PCa诊断的阳性预测值可达98%^[9]。mpMRI的功能成像有助于预测肿瘤的生物行为,也可用于前列腺疾病的管理。前列腺mpMRI已被广泛应用于PCa的主动监测、肿瘤定位、临床分期、治疗计划制定和复发监测^[10-11]。

mpMRI具有一定局限性。不同机构间图像采集技术和协议的差异会导致成像质量有差异,使图像对比出现偏差,判读mpMRI影像学习曲线的斜率较大,且存在观察者间的差异,放射科医师的阅片经验会影响前列腺mpMRI图像的临床效用。此外,有些前列腺良性病变的影像表现与PCa相似,鉴别诊断较为困难。在良性前列腺增生症(benign prostatic hyperplasia, BPH)的背景下,移行区细胞成分多样,mpMRI检测PCa的灵敏度受到该区异质性的限制,从而使鉴别变得更加复杂。与患者个体相关的因素,如患者体质、既往手术史和解剖变异都可能影响成像效果,直肠内气体和金属植入物产生的伪影亦会对前列腺mpMRI报告的撰写有较大影响,PCa治疗后的改变与病灶的局部复发也难以鉴别。为了使前列腺MRI的采集、解释和报告标准化,欧洲泌尿生殖放射学会(European Society of Urogenital Radiology, ESUR)于2012年开发了前列腺成像报告和数据系统(prostate imaging reporting and data system, PI-RADS)^[12]。ESUR与美国放射学会和AdMeTech基金会合作,于2015年发布了更新版的PI-RADS v2,于2019年又发布了

PI-RADS v2.1^[13-14]。所有PI-RADS版本都为图像采集的协议和规范提供了指导。PI-RADS提供了评估T2WI、DWI和DCE的单个序列的标准,并整合为1~5分的总体风险评估标准,该评估有助于活检的确定和临床显著PCa的管理。

2 AI 范例: ML 和 DL

AI是涵盖ML和DL的广义术语,DL是ML的子集。AI是指借助任何工具将先前的知识、经验、目标和观察结果输入完成后,创建实施某项操作技能的输出,通过计算机对大量的数据进行运算并创建适当的输出方式来完成既定任务。

AI通常需要固定的、基于规则的计算方法,而ML能够随着数据的输入和训练动态地改进计算方法。在传统编程中,计算机接收数据和程序作为输入,然后以一对一的方式输出,对结果的所有改进都源于对程序和规则的修改。在ML中,计算机接收数据和特征标签作为输入,将预输出结果与已经定义并与标签相关联的数据进行比较来学习,然后自我创建程序来优化输出,以将自己的输出与标签达到最佳匹配。程序的有效性高度依赖于ML所接收数据的质量和数据量的大小。可用于ML算法的数据类型多样,包括数字化手写、文档中的文本、DNA序列、面部图像等。ML算法可利用这些数据对计算机进行训练并对新输入的数据做出结果预测。使用ML算法的医学成像研究通常使用3种数据集类型设计:训练集、验证集和测试集^[15]。这些研究首先输入训练数据,以完成目的输出,在训练过程中算法不断地使用验证数据提供的反馈进行修正,算法开发完成后使用测试数据评估最终的性能。ML最常见的2种实现形式是分类和回归,在分类中,ML接收数据,然后判定数据中每个项目的类别;实现回归时,ML接收数据,然后预测数据中每个项目的数值。

DL在2010年ImageNet大规模视觉识别竞赛中取得了开创性的成果,因此受到极大的关注,在该竞赛中参赛者使用公共图像数据集的子集开发算法^[16]。DL算法在训练之前不需要特征选择,仅接收输入,在DL训练期间学习其显著特征。DL体系结构由许多层级组成,类似于大脑的神经网络,这些分级使DL能够从更小的输入数据集内提取特征,并允许增加特征的复杂性。尽管存在各种

DL 体系结构, 其中的卷积神经网络 (convolutional neural network, CNN) 被认为非常适合医学成像。这些技术的总体目标是允许机器自动确定和优化特征, 对图像进行评估与分类。

3 前列腺分割和体积评估

前列腺分割和体积评估可极大改善 PCa 和 BPH 患者的管理, 但受限于现有技术水平, 目前前列腺分割以人工或半自动的方式进行, 受观察者间差异性较大的限制。在 Rasch 等^[17]的研究中, 3 名放射肿瘤学家基于特定扫描方式对前列腺进行分割, 得到的体积与平均前列腺体积之间的比率为 0.95~1.08。目前, 前列腺体积通常是通过经直肠超声 (transrectal ultrasound, TRUS) 检查, 利用椭圆公式估计或在前列腺 CT 或 MRI 检查中测算出来的近似值。尽管这种 TRUS 近似体积估算方法较为常用, 但存在明显的观察者间差异, 没有基于 MRI 的算法精确。目前已研究者尝试用软件评估前列腺体积, 但通过简单培训的医学生对前列腺的分割和体积评估比商业上可用的评估工具更为准确^[18]。为了满足对自动、精确的前列腺分割和体积估算工具的需求, 使用计算机对输入的 mpMRI 图像进行数据分析, 并应用开发的 ML 算法来正确识别前列腺的边界。

ML 已被各种团体的多家机构用于前列腺分割。Rundo 等^[19]通过无监督学习将数据分组, 利用模糊 C-均值聚类的 ML 方法在 mpMRI 的 T1WI 和 T2WI 上分割前列腺, 对 21 例疑似 PCa 患者进行了评估, 得出的平均 Dice 分数为 0.91。Dice 分数是评估 2 幅图像之间空间交叉的标准统计数据, 数值范围为 0 (无重叠)~1 (完全重叠)^[20], Dice 评分为 0.91 表明该技术能够以高精度分割和估计前列腺体积。DL 算法也被广泛应用于前列腺全腺体的分割。国际医学图像计算和计算机辅助干预协会举办的 2012 年前列腺磁共振图像分割 (The Prostate MR Image Segmentation, PROMISE12) 挑战赛中, 涵盖 100 例患者的 PROMISE12 数据集的发布, 引发了许多关于这一主题的研究。Tian 等^[21]对 140 例患者的 mpMRI T2WI 进行了基于 CNN 的 MRI 前列腺分割训练, Dice 分数为 0.85; Karimi 等^[22]的 CNN 在 49 张 mpMRI T2WI 的有限数据集上训练, 并进行了数据扩充, Dice 分数为 0.88。这

2 项研究获得了较高的 Dice 评分, 证明以常用的技术设计可以实现前列腺分割。

4 前列腺病灶检测、分割和体积评估

前列腺病灶的检测、分割和体积评估可以使 PCa 管理受益, 但目前没有使这些过程完全自动化的有效工具。在前列腺病灶的人工检测过程中, 卫星小病灶的检测极具挑战性。Steenbergen 等^[23]在研究中将 12 名图像分析人员分为 6 个小组, 每个小组由 1 名放射科医师和 1 名放射肿瘤科医师组成, 20 例 PCa 患者的 69 个卫星病灶中有 66 个被 6 个小组均漏诊, 这说明 PCa 卫星病灶的漏诊在日常诊断中极为常见。前列腺病灶有时除了难以检测外, 人工分割也相当困难, 部分病灶由良性腺体和间质组成, 确切轮廓不易勾勒。对多个机构的前列腺病灶人工分割结果进行比较, 分割出的轮廓显示出相当大的差异^[24]。人工分割的不精准导致前列腺病灶的体积评估常小于真实的组织病理学体积^[25]。ML 可以对 mpMRI 图像中这些病灶的特征识别进行学习, 以改进临床对病灶分割的精度。

在前列腺病灶的检测中, ML 已被用于识别潜在的恶性肿瘤。Lay 等^[26]使用基于随机森林模型的计算机辅助诊断 (computer-aided diagnosis, CAD) 技术检测前列腺病灶, 数据集使用了 224 例患者的 3 个 MRI 序列 (T2WI、ADC 和 DWI), 共有 287 个良性病灶和 123 个格里森评分 (Gleason score, GS) ≥ 6 分的病灶 (GS ≥ 6 分提示病灶有恶性潜能^[27]), 该研究的 AUC (一种二进制分类的测量方法, 数值为 0~1) 为 0.93。这项研究表明 ML 模型可以高精度地检测出 PCa。

DL 技术也已被应用于前列腺病灶检测。残差网络 (residual network, ResNet) 是 He 等^[28]提出的 CNN, 在 2015 年的 ImageNet 大规模视觉识别竞赛中获得了物体识别和图像分类的优胜奖。ResNet 的特点是易于优化, 并且可以通过增加适当的深度来提高识别准确率, 其内部的残差块使用跳跃连接, 缓解了神经网络深度增加带来的梯度消失问题。Xu 等^[29]运用 ResNet 在 T2WI、ADC 和 DWI 上探测前列腺病灶, 该研究使用了来自癌症影像档案数据库的图像, 共纳入 346 例患者, ResNet 检测前列腺病灶的 ROC 曲线 AUC 为 0.97, 结果表明基于 CNN 的 DL 用于前列腺病灶检测具有较高的效能。

虽然前列腺病灶检测已可以用ML实现,但前列腺病灶的自动化分割和体积估算仍未完全解决。由于缺乏完善、精确的数据和技术要求,开展这项研究的机构不多。进而,缺乏跨机构的前列腺病灶轮廓勾勒指南,导致前列腺病灶分割时观察者之间存在显著差异。尽管缺乏标准化,仍有3项研究尝试进行前列腺病灶分割。Liu等^[30]的研究纳入了11例PCa患者,使用模糊马尔可夫随机场(fuzzy Markov random fields)获得了0.62的Dice分数。Kohl等^[31]使用152例PCa患者的数据集,并结合对抗网络实施了U形网络(U-shaped network, U-Net),该DL算法对前列腺病灶分割的平均Dice分数为0.41。Dai等^[32]运用高度专业化的DL算法掩膜-候选区域卷积神经网络(mask region-based convolutional neural network, Mask-RCNN),用63例患者的数据集进行训练,Dice分数为0.46。这3项研究中采集病灶数据的主体不同,Dai等^[32]的分割数据来自临床医师,Kohl等^[31]的病灶分割在放射科医师的协助下完成,而Liu等^[30]请病理学家进行了最初的分割工作。这些研究较低的Dice分数表明目前的技术精度有限,前列腺病灶分割和体积评估仍然具有挑战性,如果要开发更多的ML模型完成这项工作,就必须有更大的数据集和更统一的标签。

5 前列腺病变分类表征

自2013年以来,越来越多的前列腺病变采用mpMRI,由于放射科医师和机构分类标准的差异,前列腺病变的表征缺乏统一性。为了对前列腺mpMRI进行更好、更标准的评价,PI-RADS评分系统于2012年创建,有多项研究阐明了PI-RADS v1、PI-RADS v2和PI-RADS v2.1的临床实用性,提出PI-RADS面临的挑战包括阅片者间的一致性、放射科医师的经验以及对图像解释的时间^[5,33-34]。临床对病变特征进行标准化表征的需求使ML成为一种极具吸引力的方法,它可以提高诊断的准确率并加快分类的速度。PI-RADS v2提出不同的序列在不同的解剖部位有各自的优势,DWI序列是外周带疾病诊断的关键序列,而T2WI是诊断移行带疾病的基本序列^[35]。PI-RADS v2去除了繁琐的磁共振波谱(magnetic resonance spectroscopy, MRS)和类型各异的增强曲线评分,

DCE序列仅在外周带良恶性不能确定(PI-RADS评分为3分)时使用,而移行带在恶性不能确定时需结合DWI评估^[36]。Schimmöller等^[36]和Feng等^[37]的研究表明PI-RADS v2对前列腺移行带肿瘤的诊断准确性更高,而PI-RADS v1是诊断外周带肿瘤更好的方法。Tewes等^[38]的研究表明,使用PI-RADS v2的一致性略高于PI-RADS v1,并且PI-RADS v2的评分更加客观准确;PI-RADS v2和PI-RADS v1诊断PCa的准确性相当,但PI-RADS v2比PI-RADS v1用时更少,更符合临床诊断的实用性需求。PI-RADS v2.1在PI-RADS v2的基础上对扫描技术、评分标准及病变描述作了进一步细化^[37]。

ML算法可以增强PI-RADS评分系统的临床应用效能,并且可以独立地对病变进行分类。Litjens等^[39]创建了一个应用随机森林模型对疑似恶性前列腺病变进行表征的CAD系统,共纳入107例患者,在结合了ML生成的分数和放射科医师对病灶的PI-RADS评分后,总体AUC大于ML生成的分数或PI-RADS v1评分。Wang等^[40]收集54例患者的数据,应用支持向量机(support vector machine, SVM)算法提高了放射科医师PI-RADS v2评分的效能(AUC=0.95)。Song等^[41]使用195例患者的数据,基于视觉几何团队网络(visual geometry group net, VGGNet)的DL算法改善了放射科医师PI-RADS v2评分的效能(AUC=0.94)。Sanford等^[42]纳入687例患者开发的PI-RADS v2分类AI模型,在mpMRI上对分割的病灶进行PI-RADS v2评分,与放射科专家的意见基本一致,两者检测临床显著癌症的能力未见显著差异无统计学意义。Schelb等^[43]用T2WI和扩散磁共振成像训练的U-Net实现了与PI-RADS评估相似的性能。

ML算法除了可以协助放射科医师对病变进行分类外,还被训练用于独立表征前列腺病变。许多机构利用2017年发布的PROSTATEx挑战数据集开展了探索性研究^[44]。PROSTATEx数据集来自344例患者,包含局灶性病变及其病理学的GS。在这个公共数据库中,Wang等^[45]运行2个CNN进行前列腺自动分割,得到的AUC为0.96。Mehrtaash等^[46]构建了一个3D CNN,识别PCa的AUC达0.80。Kwak等^[47]使用自己的专有数据集实现了一种SVM,该SVM根据T2WI和DWI来表征前列腺病变;共纳入244例患者,包含333个良性病灶和

146个恶性病灶,用SVM方法进行特征识别训练,其AUC达0.89。以上关于前列腺病变表征的研究中,前列腺病灶表征的标准由放射学家来确定,这些研究强调了基于GS的DL算法预测前列腺恶性病变的能力。

6 影像组学在PCa中的应用

影像组学是当前AI在前列腺mpMRI放射诊断中应用的重要组成部分,它结合了ML和医学影像数据定量处理的方法,是改进AI和CAD的关键技术。影像组学通过对传统的医学影像数据进行定量分析并提取有效特征,运用ML学习建立与临床相关的预测模型。影像组学在PCa中的应用包括肿瘤检测、鉴别诊断、病理分级、临床决策及疗效评估等。Fehr等^[48]开发的CAD系统利用随机森林分类的方法从T2WI、ADC和 b 值为 $2\ 000\ \text{s}/\text{mm}^2$ 的DWI中提取纹理特征来检测PCa,结果显示该方法检测PCa的AUC为0.93,优于使用SVM的检测结果。Litjens等^[49]分析了70例前列腺全切患者术前的mpMRI影像组学特征,发现高 b 值的DWI序列对PCa与BPH的鉴别更有价值,DCE序列鉴别PCa与前列腺萎缩或炎症效能更高,而ADC是诊断高级别PCa的优势指标。Sidhu等^[50]研究了移行带肿瘤的组学特征,发现移行带的肿瘤较正常前列腺组织纹理特征的T1熵和ADC直方图峰度降低。Sun等^[51]对30例术前经mpMRI检查的PCa患者进行回顾性分析,用T2WI纹理分析结合mpMRI预测PCa的级别高低,区分 $\text{GS}\geq 4+3$ 分与 $\text{GS}\leq 3+4$ 分,并与单独使用mpMRI进行了对比。结果表明灰度共生矩阵(gray-level co-occurrence matrix, GLCM)与灰度游程矩阵(gray-level run-length matrix, GLRLM)分别加上mpMRI影像组学特征对肿瘤病理风险等级分层的AUC分别为0.84和0.82,二者结合的AUC为0.91(95% CI 0.87~0.95)。Xu等^[52]开发了一个基于mpMRI的放射组学模型,用于PCa患者前列腺外侵犯(extraprostatic extension, EPE)的术前预测,结果显示放射组模型优于临床模型(AUC=0.865),与临床-影像组学结合列线图(AUC=0.857, $P=0.644$)的预测效能相当。影像组学无创性、低成本、高通量的数据分析方法有利于肿瘤的检测及个性化诊疗,必将在临床肿瘤学乃至整个医学领域得

到广泛应用。

7 展望

ML在PCa中的应用潜能远不止体积评估、病变检测和病变表征。ML算法更实际的临床应用还包括对肿瘤风险的分级预测,综合人口统计学和生化数据来增强PCa的临床管理,帮助临床医师在是否活检、放射治疗剂量及肿瘤复发方面做出更为准确的判断。使用ML工具可以不必进行活检就能对PCa做出诊断。Hu等^[53]和Chen等^[54]的研究使用年龄、直肠指诊结果、前列腺特异抗原(prostate-specific antigen, PSA)和前列腺体积等数据进行前列腺活检预测,最终做出了准确的PCa诊断,显示了ML取代活检的潜力。除诊断外,ML还可计算PCa放射治疗的射线剂量。放射治疗剂量的精确程度通常取决于操作者的经验^[55],而ML可以对个体剂量进行标准化定制,减少了对操作人员的依赖,使放射治疗剂量更精准。Nicolae等^[56]通过分析患者的影像资料和既往的治疗计划,用ML预测前列腺近距离放射治疗的剂量,结果表明ML能够完成放射治疗医师的部分工作。DL可以代替传统的ML算法,其除了进行肿瘤诊断和制定放射治疗计划,亦可用于预测前列腺切除术后肿瘤复发。Wong等^[57]和Cordon-Cardo等^[58]在研究中收集了诸如GS、PSA、精囊侵犯和手术切缘等数据,可以预测前列腺切除术后的复发情况,通过结合术后影像数据还能够提高ML预测复发的能力,并增加研究的准确性。

AI在前列腺MRI中的应用具有广阔前景,能够对影像资料进行更高效的分析 and 更有效的解释,从而改善前列腺疾病的临床管理。在单纯的图像判读中,ML在前列腺分割和体积估计方面的研究取得了显著进展。随着前列腺病变数据的不断完善,ML在病变检测、体积评估和特征鉴别方面将会更加准确。随着ML的发展,它将毫无疑问地改变放射科医师的工作流程,一些简单的图像解释工作可以由AI完成,然而,ML并不能取代放射科医师解决复杂的临床问题。AI将提高放射科医师的决策能力,完善对患者的管理,但不能取代临床对放射科医师的需求。ML在不同领域评估复杂数据集的能力表明,该技术可以促进高级成像(如mpMRI)与新兴生物标志物分析或肿瘤遗传学的

衔接。借助更大的数据集和更复杂的数学技术, ML可能会发展成为完全自动化的工具,接收患者的前列腺 mpMRI 图像,然后输出所需特征及病理结果。ML 是放射基因组学的基础,可以整合成像数据、血液生化分析及病理评估,从而形成可以预测治疗效果的复杂模型。

[参考文献]

- [1] WONG M C, GOGGINS W B, WANG H H, FUNG F D, LEUNG C, WONG S Y, et al. Global incidence and mortality for prostate cancer: analysis of temporal patterns and trends in 36 countries[J]. *Eur Urol*, 2016, 70: 862-874.
- [2] CULP M B, SOERJOMATARAM I, EFSTATHIOU J A, BRAY F, JEMAL A. Recent global patterns in prostate cancer incidence and mortality rates[J]. *Eur Urol*, 2020, 77: 38-52.
- [3] SIEGEL R L, MILLER K D, JEMAL A. Cancer statistics, 2020[J]. *CA Cancer J Clin*, 2020, 70: 7-30.
- [4] HUGOSSON J, CARLSSON S. Overdetection in screening for prostate cancer[J]. *Curr Opin Urol*, 2014, 24: 256-263.
- [5] OBERLIN D T, CASALINO D D, MILLER F H, MEEKS J J. Dramatic increase in the utilization of multiparametric magnetic resonance imaging for detection and management of prostate cancer[J]. *Abdom Radiol (NY)*, 2017, 42: 1255-1258.
- [6] JORDAN M I, MITCHELL T M. Machine learning: trends, perspectives, and prospects[J]. *Science*, 2015, 349: 255-260.
- [7] DE ROOIJ M, HAMOEN E H, FÜTTERER J J, BARENTSZ J O, ROVERS M M. Accuracy of multiparametric MRI for prostate cancer detection: a meta-analysis[J]. *AJR Am J Roentgenol*, 2014, 202: 343-351.
- [8] FÜTTERER J J, BRIGANTI A, DE VISSCHERE P, EMBERTON M, GIANNARINI G, KIRKHAM A, et al. Can clinically significant prostate cancer be detected with multiparametric magnetic resonance imaging? A systematic review of the literature[J]. *Eur Urol*, 2015, 68: 1045-1053.
- [9] TURKBAY B, MANI H, SHAH V, RASTINEHAD A R, BERNARDO M, POHIDA T, et al. Multiparametric 3T prostate magnetic resonance imaging to detect cancer: histopathological correlation using prostatectomy specimens processed in customized magnetic resonance imaging based molds[J]. *J Urol*, 2011, 186: 1818-1824.
- [10] JOHNSON L M, TURKBAY B, FIGG W D, CHOYKE P L. Multiparametric MRI in prostate cancer management[J]. *Nat Rev Clin Oncol*, 2014, 11: 346-353.
- [11] SANDLER K, PATEL M, LYNNE C, PAREKH D J, PUNNEN S, JORDA M, et al. Multiparametric-MRI and targeted biopsies in the management of prostate cancer patients on active surveillance[J/OL]. *Front Oncol*, 2015, 5: 4. DOI: 10.3389/fonc.2015.00004.
- [12] BARENTSZ J O, RICHENBERG J, CLEMENTS R, CHOYKE P, VERMA S, VILLEIRS G, et al. ESUR prostate MR guidelines 2012[J]. *Eur Radiol*, 2012, 22: 746-757.
- [13] WEINREB J C, BARENTSZ J O, CHOYKE P L, CORNUD F, HAIDER M A, MACURA K J, et al. PI-RADS prostate imaging-reporting and data system: 2015, version 2[J]. *Eur Urol*, 2016, 69: 16-40.
- [14] TURKBAY B, ROSENKRANTZ A B, HAIDER M A, PADHANI A R, VILLEIRS G, MACURA K J, et al. Prostate imaging reporting and data system version 2.1: 2019 update of prostate imaging reporting and data system version 2[J]. *Eur Urol*, 2019, 76: 340-351.
- [15] UEDA D, SHIMAZAKI A, MIKI Y. Technical and clinical overview of deep learning in radiology[J]. *Jpn J Radiol*, 2019, 37: 15-33.
- [16] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Commun ACM*, 2017, 60: 84-90.
- [17] RASCH C, BARILLOT I, REMEIJER P, TOUW A, VAN HERK M, LEBESQUE J V. Definition of the prostate in CT and MRI: a multi-observer study[J]. *Int J Radiat Oncol Biol Phys*, 1999, 43: 57-66.
- [18] BEZINQUE A, MORIARITY A, FARRELL C, PEABODY H, NOYES S L, LANE B R. Determination of prostate volume: a comparison of contemporary methods[J]. *Acad Radiol*, 2018, 25: 1582-1587.
- [19] RUNDO L, MILITELLO C, RUSSO G, GARUFI A, VITABILE S, GILARDI M C, et al. Automated prostate gland segmentation based on an unsupervised fuzzy C-Means clustering technique using multispectral T1W and T2W MR imaging[J/OL]. *Information*, 2017, 8: 49. DOI: 10.3390/info8020049.
- [20] ZOU K H, WARFIELD S K, BHARATHA A, TEMPANY C M, KAUS M R, HAKER S J, et al. Statistical validation of image segmentation quality based on a spatial overlap index[J]. *Acad Radiol*, 2004, 11: 178-189.
- [21] TIAN Z, LIU L, ZHANG Z, FEI B. PSNet: prostate segmentation on MRI based on a convolutional neural network[J/OL]. *J Med Imaging (Bellingham)*, 2018, 5: 021208. DOI: 10.1117/1.JMI.5.2.021208.
- [22] KARIMI D, SAMEI G, KESCH C, NIR G, SALCUDEAN S E. Prostate segmentation in MRI using a convolutional neural network architecture and training

- strategy based on statistical shape models[J]. *Int J Comput Assist Radiol Surg*, 2018, 13: 1211-1219.
- [23] STEENBERGEN P, HAUSERMANS K, LERUT E, OYEN R, DE WEVER L, VAN DEN BERGH L, et al. Prostate tumor delineation using multiparametric magnetic resonance imaging: inter-observer variability and pathology validation[J]. *Radiother Oncol*, 2015, 115: 186-190.
- [24] VAN SCHIE M A, DINH C V, HOUDT P J V, POS F J, HEIJMINK S W T J P, KERKMEIJER L G W, et al. Contouring of prostate tumors on multiparametric MRI: evaluation of clinical delineations in a multicenter radiotherapy trial[J]. *Radiother Oncol*, 2018, 128: 321-326.
- [25] LE NOBIN J, ORCZYK C, DENG F M, MELAMED J, RUSINEK H, TANEJA S S, et al. Prostate tumour volumes: evaluation of the agreement between magnetic resonance imaging and histology using novel co-registration software[J/OL]. *BJU Int*, 2014, 114: E105-E112. DOI: 10.1111/bju.12750.
- [26] LAY N, TSEHAY Y, GREER M D, TURKBEBY B, KWAK J T, CHOYKE P L, et al. Detection of prostate cancer in multiparametric MRI using random forest with instance weighting[J/OL]. *J Med Imaging (Bellingham)*, 2017, 4: 024506. DOI: 10.1117/1.JMI.4.2.024506.
- [27] EPSTEIN J I, ZELEFSKY M J, SJOBERG D D, NELSON J B, EGEVAD L, MAGI-GALLUZZI C, et al. A contemporary prostate cancer grading system: a validated alternative to the gleason score[J]. *Eur Urol*, 2016, 69: 428-435.
- [28] HE K M, ZHANG X Y, REN S Q, SUN J. Deep residual learning for image recognition[C/OL]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, USA, 2016: 770-778[2021-01-14]. <https://ieeexplore.ieee.org/document/7780459>.
- [29] XU H, BAXTER J S H, AKIN O, CANTOR-RIVERA D. Prostate cancer detection using residual networks[J]. *Int J Comput Assist Radiol Surg*, 2019, 14: 1647-1650.
- [30] LIU X, LANGER D L, HAIDER M A, YANG Y, WERNICK M N, YETIK I S. Prostate cancer segmentation with simultaneous estimation of Markov random field parameters and class[J]. *IEEE Trans Med Imaging*, 2009, 28: 906-915.
- [31] KOHL S, BONEKAMP D, SCHLEMMER H P, YAQUBI K, HOHENFELLNER M, HADASCHIK B, et al. Adversarial networks for the detection of aggressive prostate cancer[EB/OL]. (2017-02-26)[2021-01-10]. <https://arxiv.org/abs/1702.08014>.
- [32] DAI Z, CARVER E, LIU C, LEE J, FELDMAN A, ZONG W, et al. Segmentation of the prostatic gland and the intraprostatic lesions on multiparametric magnetic resonance imaging using mask region-based convolutional neural networks[J]. *Adv Radiat Oncol*, 2020, 5: 473-481.
- [33] LEAKE J L, HARDMAN R, OJILI V, THOMPSON I, SHANBHOGUE A, HERNANDEZ J, et al. Prostate MRI: access to and current practice of prostate MRI in the United States[J]. *J Am Coll Radiol*, 2014, 11: 156-160.
- [34] DICKINSON L, AHMED H U, ALLEN C, BARENTSZ J O, CAREY B, FUTTERER J J, et al. Scoring systems used for the interpretation and reporting of multiparametric MRI for prostate cancer detection, localization, and characterization: could standardization lead to improved utilization of imaging within the diagnostic pathway?[J]. *J Magn Reson Imaging*, 2013, 37: 48-58.
- [35] FRANIEL T, ASBACH P, TEICHGRÄBER U, HAMM B, FOLLER S. Prostate imaging: an update[J]. *Rofo*, 2015, 187: 751-759.
- [36] SCHIMMÖLLER L, QUENTIN M, ARSOV C, HIESTER A, BUCHBENDER C, RABENALT R, et al. MR-sequences for prostate cancer diagnostics: validation based on the PI-RADS scoring system and targeted MR-guided in-bore biopsy[J]. *Eur Radiol*, 2014, 24: 2582-2589.
- [37] FENG Z Y, WANG L, MIN X D, WANG S G, WANG G P, CAI J. Prostate cancer detection with multiparametric magnetic resonance imaging: Prostate Imaging Reporting and Data System version 1 versus version 2[J]. *Chin Med J (Engl)*, 2016, 129: 2451-2459.
- [38] TEWES S, MOKOV N, HARTUNG D, SCHICK V, PETERS I, SCHEDL P, et al. Standardized reporting of prostate MRI: comparison of the Prostate Imaging Reporting and Data System (PI-RADS) version 1 and version 2[J/OL]. *PLoS One*, 2016, 11: e0162879. DOI: 10.1371/journal.pone.0162879.
- [39] LITJENS G J, BARENTSZ J O, KARSSEMEIJER N, HUISMAN H J. Clinical evaluation of a computer-aided diagnosis system for determining cancer aggressiveness in prostate MRI[J]. *Eur Radiol*, 2015, 25: 3187-3199.
- [40] WANG J, WU C J, BAO M L, ZHANG J, WANG X N, ZHANG Y D. Machine learning-based analysis of MR radiomics can help to improve the diagnostic performance of PI-RADS v2 in clinically relevant prostate cancer[J]. *Eur Radiol*, 2017, 27: 4082-4090.
- [41] SONG Y, ZHANG Y D, YAN X, LIU H, ZHOU M, HU B, et al. Computer-aided diagnosis of prostate cancer using a deep convolutional neural network from multiparametric MRI[J]. *J Magn Reson Imaging*, 2018, 48: 1570-1577.
- [42] SANFORD T, HARMON S A, TURKBEBY E B,

- KESANI D, TUNCER S, MADARIAGA M, et al. Deep-learning-based artificial intelligence for PI-RADS classification to assist multiparametric prostate MRI interpretation: a development study[J]. *J Magn Reson Imaging*, 2020, 52: 1499-1507.
- [43] SCHEL B P, KOHL S, RADTKE J P, WIESENFARTH M, KICKINGEREDER P, BICKELHAUPT S, et al. Classification of cancer at prostate MRI: deep learning versus clinical PI-RADS assessment[J]. *Radiology*, 2019, 293: 607-617.
- [44] ARMATO S G, HUISMAN H, DRUKKER K, HADJIISKI L, KIRBY J S, PETRICK N, et al. PROSTATEx Challenges for computerized classification of prostate lesions from multiparametric magnetic resonance images[J/OL]. *J Med Imaging (Bellingham)*, 2018, 5: 044501. DOI: 10.1117/1.JMI.5.4.044501.
- [45] WANG B, LEI Y, TIAN S, WANG T, LIU Y, PATEL P, et al. Deeply supervised 3D fully convolutional networks with group dilated convolution for automatic MRI prostate segmentation[J]. *Med Phys*, 2019, 46: 1707-1718.
- [46] MEHRTASH A, SEDGHI A, GHAFOORIAN M, TAGHIPOUR M, TEMPANY C M, WELLS W M 3rd, et al. Classification of clinical significance of MRI prostate findings using 3D convolutional neural networks[J/OL]. *Proc SPIE Int Soc Opt Eng*, 2017, 10134: 101342A. DOI: 10.1117/12.2277123.
- [47] KWAK J T, XU S, WOOD B J, TURKBEBY B, CHOYKE P L, PINTO P A, et al. Automated prostate cancer detection using T2-weighted and high-*b*-value diffusion-weighted magnetic resonance imaging[J]. *Med Phys*, 2015, 42: 2368-2378.
- [48] FEHR D, VEERARAGHAVAN H, WIBMER A, GONDO T, MATSUMOTO K, VARGAS H A, et al. Automatic classification of prostate cancer Gleason scores from multiparametric magnetic resonance images [J/OL]. *PNAS*, 2015, 112: E6265-E6273. DOI: 10.1073/pnas.1505935112.
- [49] LITJENS G J, ELLIOTT R, SHIH N N, FELDMAN M D, KOBUS T, HULSBERGEN-VAN DE KAA C, et al. Computer-extracted features can distinguish noncancerous confounding disease from prostatic adenocarcinoma at multiparametric MR imaging[J]. *Radiology*, 2016, 278: 135-145.
- [50] SIDHU H S, BENIGNO S, GANESHAN B, DIKAIOS N, JOHNSTON E W, ALLEN C, et al. "Textural analysis of multiparametric MRI detects transition zone prostate cancer"[J]. *Eur Radiol*, 2017, 27: 2348-2358.
- [51] SUN Y, REYNOLDS H M, WRAITH D, WILLIAMS S, FINNEGAN M E, MITCHELL C, et al. Automatic stratification of prostate tumour aggressiveness using multiparametric MRI: a horizontal comparison of texture features[J]. *Acta Oncol*, 2019, 58: 1118-1126.
- [52] XU L, ZHANG G, ZHAO L, MAO L, LI X, YAN W, et al. Radiomics based on multiparametric magnetic resonance imaging to predict extraprostatic extension of prostate cancer[J/OL]. *Front Oncol*, 2020, 10: 940. DOI: 10.3389/fonc.2020.00940.
- [53] HU X, CAMMANN H, MEYER H A, MILLER K, JUNG K, STEPHAN C. Artificial neural networks and prostate cancer: tools for diagnosis and management[J]. *Nat Rev Urol*, 2013, 10: 174-182.
- [54] CHEN T, LI M, GU Y, ZHANG Y, YANG S, WEI C, et al. Prostate cancer differentiation and aggressiveness: assessment with a radiomic-based model vs. PI-RADS v2[J]. *J Magn Reson Imaging*, 2019, 49: 875-884.
- [55] European Society of Radiology (ESR). What the radiologist should know about artificial intelligence—an ESR white paper[J/OL]. *Insights Imaging*, 2019, 10: 44. DOI: 10.1186/s13244-019-0738-2.
- [56] NICOLAE A, MORTON G, CHUNG H, LOBLAW A, JAIN S, MITCHELL D, et al. Evaluation of a machine-learning algorithm for treatment planning in prostate low-dose-rate brachytherapy[J]. *Int J Radiat Oncol Biol Phys*, 2017, 97: 822-829.
- [57] WONG N C, LAM C, PATTERSON L, SHAYEGAN B. Use of machine learning to predict early biochemical recurrence after robot-assisted prostatectomy[J]. *BJU Int*, 2019, 123: 51-57.
- [58] CORDON-CARDO C, KOTSIANTI A, VERBEL D A, TEVEROVSKIY M, CAPODIECI P, HAMANN S, et al. Improved prediction of prostate cancer recurrence through systems pathology[J]. *J Clin Invest*, 2007, 117: 1876-1883.

[本文编辑] 魏莎莎