XXXX DOI:

人工智能在结石成分预测中的应用与展望

王笑晨,杨博宇,赵有权,王小川,孙满江,李 钧
(首都医科大学附属北京友谊医院泌尿外科,北京 100000)

【摘 要】泌尿系结石作为一种发病率与复发率持续攀升的全球性健康问题,其精准诊疗依赖于结石成分的准确分析。传统方法如红外光谱与计算机断层扫描(computed tomography,CT)因成本昂贵及鉴别能力有限而难以满足临床需求。近年来,人工智能(artificial intelligence,AI)技术通过整合CT影像特征、生化指标及电子健康记录等多模态数据,在无创结石成分预测中实现了重大突破。然而,AI技术的临床转化仍面临多重障碍:数据缺乏统一标准削弱模型泛化能力;深度学习模型的"黑箱"特性降低了使用者信任度;高昂经济成本与设备兼容性问题阻碍技术普及;数据隐私与算法偏见引发的伦理争议仍需解决。未来研究应聚焦多模态数据融合、基于联合学习的跨机构安全协作机制,以及符合临床需求的解释性标准化语言(如自然语言生成的决策报告)。通过推动数据集标准化合作、前瞻性临床试验验证及伦理-监管体系完善,AI驱动的结石成分分析有望突破创新技术与临床应用间的壁垒,最终推动泌尿系结石管理向精准医学转型,减少侵入性操作并改善患者预后。

【关键词】泌尿系结石;人工智能;结石成分分析;多模态数据融合;精准医学
【中图分类号】R69 【文献标志码】A 【收稿日期】2025-07-01

Artificial intelligence in predicting urinary stone composition: applications and prospects

Wang Xiaochen, Yang Boyu, Zhao Youquan, Wang Xiaochuan, Sun Manjiang, Li Jun
(*Department of Urology, Beijing Friendship Hospital, Capital Medical University*)

【**Abstract**】Urinary stones are a global health issue with continuously rising incidence and recurrence rates, and their precision treatment rely on an accurate stone composition analysis. Traditional methods, such as infrared spectroscopy and computed tomography (CT), struggle to meet clinical demands due to their high costs and limited discrimination capabilities. In recent years, artificial intelligence (AI) technology has achieved significant breakthroughs in non-invasive stone composition prediction by integrating multimodal data including CT features, biochemical indicators, and electronic health records. However, the clinical translation of AI technology still faces multiple obstacles: data heterogeneity weakens models' generalization ability; the "black box" nature of deep learning models reduces clinical trust; high computational costs and device compatibility issues hinder technology adoption; ethical concerns arising from data privacy and algorithmic bias still need to be addressed. Future research should focus on multimodal data fusion, cross-institutional secure collaboration mechanisms based on federated learning, and explanatory standardized language that meets clinical needs (such as decision reports generated with natural language). Through promoting cooperation in dataset standardization, prospective clinical trial validation, and the improvement of ethical-regulatory systems, AI-driven stone composition analysis has the potential to break through the barriers from innovative technology to clinical application, ultimately driving the transformation of urinary stone management towards precision medicine, reducing invasive procedures, and improving patient outcomes.

【**Key words**】urinary stone; artificial intelligence; stone composition analysis; multimodal data fusion; precision medicine

尿石症(Urolithiasis)是全球范围内最高发的泌尿系统疾病之一,其发病率逐年上升,现在已成为重要的公共卫生问题[1]。流行病学数据显示,泌尿系结石的患病率在全球高达5%~10%[2],且造成了患者反复住院、肾功能受损等一系列问题,严重影响了泌尿系结石患者的生活质量。地域、饮食习惯和代谢综合征等因素进一步提高了其发病风险,尤其在工业化国家中,高蛋白和高盐饮食的普及与结石发病率呈正相关[3]。这一疾病亟需更精准的诊疗策略以改善患者预后。

作者介绍:王笑晨,Email:wxcdoct@163.com,
研究方向:泌尿系结石。
通信作者:李 钧,Email:lljun@yeah.net。
基金项目:北京市自然科学基金面上资助项目(编号:7232027)。

泌尿系结石的成分多样性是临床管理的关键挑战之一。草酸钙、磷酸钙、尿酸及感染性结石等不同成分的结石，在病因机制、治疗方案及预防措施上均存在明显差异[4]。例如，尿酸结石可通过尿液碱化这一治疗方式进行有效溶解，而大多数草酸钙结石的治疗改善则需要基于对患者代谢状况评估后的长期管理，如针对患者的高钙尿症或高草酸尿症进行干预等[5]。因此，结石成分的早期精准预测能够指导医生对患者进行个性化治疗，降低侵入性手术需求并减少结石复发风险[6]。目前，临床常用的结石成分分析方法包括化学分析、红外光谱（fourier transform infrared spectroscopy，FTIR）分析、X射线衍射（X-ray diffraction，XRD）及计算机断层扫描（computed tomography，CT）等。尽管这些方法被广泛采用，其局限性仍不容忽视：化学分析灵敏度低且难以区分混合成分；XRD和FTIR需要结石离体样本，需要进行侵入性手术；而CT扫描虽能提供结石形态信息，但对结石成分的鉴别准确性有限（尤其是尿酸与胱氨酸结石）[7-8]。此外，上述技术依赖于专业设备和人员，同时具有时间和经济成本较高的缺点，限制了其在基层医疗中的推广[9]。这些局限性促使研究者探索更为高效、精准的分析技术。

近年来，人工智能（artificial intelligence，AI）技术在医学领域的快速发展为泌尿系结石的诊断和治疗提供了新的可能性。AI通过深度学习算法可高效识别医学影像中的微观特征，例如CT值分布、结石纹理及空间异质性，从而实现无创性结石成分预测[10]。此外，AI可通过整合多种类型的数据（如尿液代谢参数、临床病史）来构建预测模型，从而进一步优化诊疗决策[11]。AI技术的引入不仅有望克服传统方法的局限性，还可能推动泌尿系结石管理向精准化、智能化方向革新。

1 泌尿系结石成分分析

1.1 泌尿系结石成分分类及特点

泌尿系结石的组成复杂多样，其分类依据主要基于结石的化学成分和晶体结构。根据国际尿石症联盟（International Urolithiasis Society）的分类标准，结石主要分为以下类型：草酸钙结石（占比70%~80%）是最常见的类型，其形成与高钙尿症、高草酸尿症或低柠檬酸尿症密切相关，具有高硬度和易复发的特性，其治疗与预防需长期调控代谢[12,29]。磷酸钙结石（10%~15%）常与肾小管酸中毒或慢性感染相关，易导致肾实质钙化，因此需针对性纠正酸碱失衡来达到治疗目的[4]。尿酸结石（5%~10%）多见于低尿pH值（<5.5）和嘌呤代谢异常患者，可通过尿液碱化实现非手术溶解，需与胱氨酸结石鉴别[13]。特殊类型如胱氨酸结石（1%~2%）由遗传性胱氨酸尿症引起，而感染性结石（主要成分为磷酸铵镁）则与产脲酶细菌（如变形杆菌）感染相关，需联合抗感染治疗[14]。不同成分结石的硬度、影像学表现及复发风险差异明显，例如，尿酸结石的CT值（Hounsfield unit，HU）通常低于500 HU，而草酸钙结石的CT值通常高于1 000 HU。这一特性则会直接影响体外冲击波碎石术（extracorporeal Sshock wave lithotripsy，ESWL）的疗效[7]。结石成分的差异直接影响了医生对于治疗策略的选择（如药物溶解、体外冲击波碎石或手术干预）及长期预防方案，因此精准的结石成分分析是优化诊疗流程的核心环节。

1.2 传统结石成分分析

传统结石成分分析方法分离体检测与无创评估两类。离体检测中，FTIR和XRD因能解析晶体结构，被视为结石成分分析“金标准”，不过这2种方法都依赖手术，需术后获取结石样本，无法用于术前决策[6]。扫描电子显微镜（scanning electron microscope，SEM）结合能谱分析（energy dispersive spectroscopy，EDS）可表征结石微观元素分布，但有成本高、操作复杂的局限[15]。在无创影像学方法中，非增强CT（non-contrast computed tomography，NCCT）可通过测量结石HU值区分尿酸与非尿酸结石，但对草酸钙、磷酸钙及胱氨酸结石鉴别准确性有限，需结合临床或双能CT（dual-energy computed tomography，DECT）进一步分析[4]。DECT利用多能量X射线衰减差异，可将尿酸结石鉴别准确率提至90%，不过其设备普及率低、辐射剂量高[16]。此外，尿液化学分析可通过检测钙、草酸、尿酸等代谢标志物间接评估结石风险，但受饮食、采样时间及检测方法影响，特异性不高[17]。

此外，传统泌尿系结石成分分析面临多重技术瓶颈与临床实践矛盾。其一，离体分析技术（如红外光谱、X射线衍射）依赖术后样本分析，无法术中实时指导，检测周期24~48 h，延误术后预防策略制定[8]；其二，传统方式鉴别混合成分结石能力不足，约25%~35%结石为多成分混合型，但传统影像学方法（如单能CT）仅提供结石整体HU值，难以解析空间异质性，增加诊断误差[19]；另外，因技术可及性与成本限制，DECT、显微CT等先进设备在基层医疗机构普及率低，检测成本高于普通CT，限制广泛应用[20]。这些挑战凸显了开发高效、无创、实时分析结石成分技术的迫切需求。

2 AI与结石成分分析

2.1 AI概述

AI技术在泌尿系结石诊疗中的应用主要依托于三大核心技术：机器学习（machine learning，ML）、深度学习（deep learning，DL）和自然语言处理（natural language processing，NLP）技术。

机器学习根据不同的学习方式，分为监督学习、无监督学习和强化学习。监督学习是指以带标签的数据（输入-输出对）为基础对AI进行训练，从而学习输入到输出的映射关系。通过监督学习（如随机森林、支持向量机）可以从结构化的临床数据（如尿液代谢参数、CT影像特征）中构建预测模型，使其结石成分分类准确率极大提升。无监督学习（如聚类分析）可以从无标签数据中发现隐藏的结构或模式，可以用于分类不同特征的临床表现，例如根据代谢特征将结石患者分为高草酸型、低柠檬酸型等亚群，从而指导针对性干预。

强化学习则是通过与环境的交互学习最优策略，进而通过奖励或惩罚机制调整行为，如通过动态交互优化决策[21]，从而基于患者治疗情况来实时调整预防方案。

深度学习通过多层神经网络提取复杂特征[31]，其中卷积神经网络（convolutional neural network，CNN）可以在CT影像中自动识别结石的纹理、衰减值分布及空间异质性，对草酸钙与尿酸结石的分类准确率较高[22]；递归神经网络（recurrent neural network，RNN）则擅长分析综合不同时间的数据（如多次影像检查结果），从而预测结石生长趋势及复发风险。

自然语言处理是AI的核心分支之一，旨在让计算机理解、生成和处理人类语言。其结合计算机科学、语言学和机器学习，赋予机器“读、写、说”的能力，广泛应用于搜索引擎、翻译系统、智能客服、医疗文本分析等领域。通过BERT等模型解析电子病历（electronic health record，EHR）中的非结构化文本（如病史描述、手术记录），结合影像与实验室数据构建多模态预测框架，可以提升结石检测的灵敏度[25]，同时知识图谱技术整合基因组学与代谢组学数据，为个性化预防提供循证建议。

当前，AI技术通过多模态数据融合（影像+文本+生化）突破了许多传统方法的局限性，提升了结石成分分析的准确性和灵敏度，为医生个性化指导患者治疗、改善预后提供了极大帮助。但其临床转化仍需解决数据多样性偏差（如设备、人种差异）与模型泛化能力不足等挑战[11]。

2.2 AI与结石成分分析

2.2.1 AI与医学影像（如CT、MRI、X光） AI技术，特别是深度学习与影像组学的融合，正明显革新泌尿系结石成分的无创分析。基于CT影像的AI模型不仅分析结石的Hounsfield单位（HU值），还通过提取三维空间分布、纹理异质性及局部衰减梯度等多尺度特征，实现结石成分的高精度区分。例如，CNN结合影像组学特征（如GLCM纹理、GLSZM区域特征）构建的融合模型（deep learning radiomics，DLR），在鉴别髓质海绵肾（medullary sponge kidney，MSK）结石与非MSK结石时，AUC高达0.98，明显超越传统CT阈值分析法（AUC 0.85）[16]。此外，河北大学团队开发的Faster R-CNN模型，针对单纯性草酸钙与尿酸结石的二分类任务，平均精度均值（mean average precision，mAP）达84.67%，召回率超91%，其性能优势源于模型对结石边缘锐利度与内部密度不均性的深层语义捕捉[20]。这些进展大幅降低了传统侵入性成分分析的依赖，为个体化治疗（如尿酸结石的碱化疗法）提供了关键支持。

在X射线平片与双能CT领域，AI通过图像增强与多参数分析突破了阴性结石的检出瓶颈。生成对抗网络（generative adversarial network，GAN）技术可对低分辨率X光图像进行超分辨率重建，增强尿酸结石等低对比度目标的显影能力，使传统方法漏诊率较高的阴性结石检出率提升超20%。而DECT结合AI算法，则通过双能量衰减比（dual-energy index，DEI）与有效原子序数（effective atomic number，Eff-Z）的综合分析优化了成分鉴别流程。例如，双源CT在儿童上尿路结石研究中，利用80 kV/140 kV双电压下CT值差值及DEI值的明显性差异（$P<0.05$），实现了草酸钙、尿酸、羟基磷灰石和胱氨酸四类纯结石的区分，准确率与红外光谱法相当[32]。然而，胱氨酸结石因与磷酸钙的衰减特性重叠，其特异性鉴别仍是难点——现有模型对其识别AUC普遍较低，需进一步融合分子影像或代谢数据以提升精度。

2.2.2 AI与临床数据挖掘 在NLP与影像组学技术的交叉领域中，研究者们已经取得了明显的进展，特别是在结石成分分析的敏感性和特异性方面。2025年发表于*Frontiers in Medicine*的1项研究为例[16]，该研究开发了1种名为DLR的融合模型。该模型采用ResNet101架构，从CT尿路造影（computed tomography urography，CTU）图像中提取深度学习特征，并结合了15项影像组学特征（例如结石的空间分布、髓质区的密度异质性等），成功区分了髓质海绵肾（medullary sponge kidney，MSK）结石与非MSK结石。该模型的曲线下面积（area under the curve，AUC）达到了0.98。此外，该模型还解析了电子健康记录（electronic health record，EHR）中的非结构化文本（例如“复发性结石”、“家族性高胆固醇血症”等），并利用Grad-CAM可视化技术定位CT影像中的微结构差异，从而将早期MSK病例的误诊率降低了37%。在类似的研究中，斯坦福大学的ChatEHR系统运用了大型语言模型，实时分析病程描述，并自动生成结构化的诊断报告，这不仅减轻了临床医生的文书工作负担，还提高了对结石相关基因突变的筛查效率。

3 现存研究挑战和争议

3.1 数据质量与数据集问题

AI模型在泌尿系结石成分预测中的性能高度依赖于高质量、多样化的数据集。然而，现有数据集存在明显局限性。首先，数据代表性不足，由于结石成分多样（如草酸钙、尿酸、胱氨酸）且数据来源分散（如不同医院、地区），现有数据集难以覆盖所有亚型，导致模型泛化能力受限。例如，Ronneberger O等[22]的1项多中心研究显示，基于单一机构数据训练的模型在外部验证中AUC下降。另外包括临床数据的不一致性（如不同实验室检测方法）、缺失值（如24 h尿液分析不完整）及标签不准确（如影像标注主观性）所造成的数据质量问题会明显影响模型训练与优化[8]。此外，结石成分和影像的标注方法缺乏统一标准（如CT影像中HU值阈值差异），而这进一步加剧了模型训练的困难与结果的不一致性。

3.2 算法的可解释性

尽管深度学习模型（如CNN、Transformer）对于结石成分预测具有高准确性的优势，但其“黑箱”特性仍是临床应用的重大挑战[10]。医生和患者难以理解模型的决策依据（如为何将某结石分类为草酸钙而非尿酸），这限制了AI在临床中的信任度与采纳率。为提高可解释性，研究者可尝试结合可解释人工智能（explainable artificial intelligence，XAI）技术。

XAI技术是一类旨在提高人工智能模型透明度和可理解性的技术，使人类用户能够理解、信任并有效管理AI的决策过程。根据解释的生成方式和目标，XAI技术可分为2类。一类是事前可解释模型，即直接构建本身具有透明结构的模型，适用于特征维度低、需快速解释的场景（如电子病历风险评估）。另一类是事后解释方法，对复杂模型（如神经网络）的决策进行事后解释，这种方法不改变模型结构，通过附加方法生成解释。例如通过沙普利加性解释（Shapley Additive Explanations，SHAP）值量化各特征（如HU值、尿钙水平）对预测结果的影响，或使用决策树可视化展示不同类型的结石成分。然而，这些方法在复杂模型（如深度神经网络）中的应用仍面临计算复杂度高与解释粒度不足的问题[22]。

3.3 AI模型的泛化能力问题

AI模型在训练数据上表现优异，但在实际临床环境中常因数据分布差异（如不同地区、性别、年龄组）而导致预测的准确率和稳定性下降[30]。例如，针对欧美人群训练的模型AUC低于亚洲患者[24]。为提高泛化能力，研究者提出以下策略：首先构建统一标准化数据集，通过多中心合作整合不同地区、设备的数据，并采用统一标注标准（如国际尿石症联盟指南）[23]；另外可进行迁移学习，利用预训练模型（如ImageNet）在小样本数据上微调，减少对大规模标注数据的依赖[24]；同时还可利用联合学习，在不共享原始数据的前提下跨机构联合训练模型，提升AI模型对不同患者群体的适应性[23]。

3.4 临床应用中的可行性与成本问题

尽管AI在理论上具有巨大潜力，其临床转化面临多重现实挑战。首当其冲就是成本问题，AI模型的开发、部署与维护需高昂投入（如高性能计算设备、数据存储与处理），且医院需额外配置硬件（如GPU服务器）与培训专业人员[26]。另外，需要保证设备兼容性，不同医院的影像设备（如CT扫描仪品牌、参数设置）差异可能影响AI模型的性能稳定性[18]。还有就是临床验证不足的缺陷，现有研究多基于回顾性数据，缺乏前瞻性临床试验验证AI在实际诊疗环境中的效用[27]。

3.5 伦理与隐私问题

AI在医学预测中的应用涉及患者数据隐私与伦理风险。例如，训练AI模型需大量患者数据（如影像、病历），这些数据可能包含敏感信息（如遗传病史），若未妥善保护可能导致隐私泄露[26]。此外，AI算法可能存在偏见（如对特定种族或性别的预测偏差），影响诊疗公平性。为应对这些问题，需要对数据进行匿名化与加密，以便在数据共享与传输过程中保护患者隐私[23]；同时进行伦理审查与监管，确保AI模型的开发与应用符合医学伦理规范（如知情同意、数据最小化原则）[28]。

4 总 结

泌尿系结石作为一种高发病率、高复发率的全球性健康问题，其精准诊疗依赖于结石成分的准确分析。传统方法（如化学分析、CT扫描）虽在临床中广泛应用，但受限于侵入性、成本高及准确性不足等问题，难以满足个性化治疗的需求。近年来，AI技术的快速发展为结石成分分析提供了全新的解决方案。通过ML、DL和NLP等技术，AI能够从影像数据、实验室测试数据及临床信息中提取复杂特征，实现结石成分的无创预测与个性化治疗推荐。

然而，AI技术的临床转化仍面临多重挑战。结石成分数据质量与标准化问题是首要障碍：结石成分的多样性与数据来源的异质性导致模型泛化能力受限，而标注不一致性（如CT阈值差异）进一步加剧了训练偏差。算法可解释性不足（如“黑箱”特性）降低了使用者的信任度，尽管可解释AI技术（如SHAP值）提供了一定解决方案，但其在复杂模型中的应用仍待优化。此外，模型泛化能力受限于地区、设备及人群差异，需通过联合学习与迁移学习提升其适应性。临床应用可行性则受制于高昂成本（如硬件配置与维护费用）及设备兼容性问题（如CT参数差异），而伦理隐私风险（如遗传数据泄露）也需通过数据匿名化及加强伦理审查与监管加以管控。

因此，AI辅助结石成分分析这项技术未来发展的核心应该在于构建一种“技术-临床-伦理”协同的创新体系。技术层面需要突破多模态动态建模，将影像特征与实时代谢指标（如尿液pH值、离子浓度）及基因组数据（如胱氨酸尿症相关基因突变）深度融合，利用图神经网络嵌入病理知识，从而提升模型的可解释性与医学逻辑适配性。同时，通过联合学习实现跨机构、跨地域数据的安全共享，结合迁移学习优化模型对不同设备（如CT品牌差异）和人群（如代谢特征差异）的泛化能力。针对可解释性难题，还需开发面向临床场景的标准化解释框架，例如利用NLG技术输出符合医生认知的决策报告等。

技术研究者和临床团队应优先推动多中心协作的标准化数据库建设，制定结石成分空间异质性标注规范，如标注结石与肾脏解剖结构的关系（“肾盂嵌顿型”“肾盏憩室内生型”等）并记录接触面特征（如黏膜粘连、钙化斑等）；关联24 h尿生化（如钙/草酸/枸橼酸比值）、基因突变（如SLC34A3磷酸盐转运体缺陷），并在标注中记录代谢异常类型编码等。并且针对混合型结石还可以设计对于不同层级的分析算法。另外，医疗机构还可以主导一些前瞻性临床试验，验证AI在真实诊疗场景中的效价比与长期预后价值。与此同时，政策制定者也应该完善医疗AI伦理审查体系，建立数据共享激励机制与隐私计算标准。唯有通过跨学科协作、技术普惠化与监管创新，才能实现泌尿系结石管理从“经验驱动”到“智能驱动”的全面革新，最终让精准医疗惠及每一位患者。

总之，AI技术在泌尿系结石成分分析中的应用展现了巨大的潜力，其不仅克服了传统方法的局限性，还为精准医疗提供了创新工具。然而，要实现AI在临床中的全面推广，仍需解决数据、技术、伦理等多方面的挑战。通过跨学科合作与持续创新，AI有望成为泌尿系结石管理的核心驱动力，

为患者提供更高效、精准的诊疗服务。

参 考 文 献

[1] Yang BY, Zhao FZ, Li J, et al. Epitranscriptomic profiling of m6A RNA methylation in renal epithelial tubular cells stimulated with calcium oxalate crystals through microarray analysis[J]. Urolithiasis, 2023, 51(1):57.

[2] Yang BY, Zhao MS, Lv JC, et al. Porous Se@SiO_2 nanospheres inhibit calcium oxalate kidney stone formation by oxidation resistance[J]. Ceramics International, 2023, 49:8856-8862.

[3] Sorokin I, Mamoulakis C, Miyazawa K, et al. Epidemiology of stone disease across the world[J]. World J Urol, 2017, 35(9):1301-1320.

[4] Daudon M, Bader CA, Jungers P. Urinary calculi: Review of classification methods and correlations with etiology[J]. Scanning Microsc, 1993, 7(3):1081-1104.

[5] Sakhaee K. Recent advances in the pathophysiology of nephrolithiasis[J]. Kidney Int, 2009, 75(6):585-595.

[6] Türk C, Petřík A, Sarica K, et al. EAU Guidelines on Diagnosis and Conservative Management of Urolithiasis[J]. Eur Urol, 2016, 69(3): 468-474.

[7] Hesse A, Tiselius HG, Siener R. Urinary Stones: Diagnosis, Treatment, and Prevention of Recurrence[M]. 3rd ed. Basel: Karger, 2009.

[8] Zarse CA, McAteer JA, Tann M, et al. Helical CT accurately reports urinary stone composition using attenuation values[J]. Urology, 2004, 63(5):828-833.

[9] Van Appledorn S, Ball AJ, et al. Limitations of Noncontrast CT for Measuring Ureteral Stones[J]. J Endourol, 2003, 17(10):851-854.

[10] Litjens G, Kooi T, Bejnordi BE, et al. A survey on deep learning in medical image analysis[J]. Med Image Anal, 2017, 42:60-88.

[11] Kocak B, Kus EA, Kilickesmez O. How to read and review papers on machine learning and artificial intelligence in radiology: A survival guide to key methodological concepts[J]. Eur Radiol, 2021, 31(4): 1819-1830.

[12] Coe FL, Evan AP, Worcester EM. Kidney stone disease[J]. J Clin Investig, 2005, 115(10):2598-2608.

[13] Daudon M, Jungers P. Clinical value of crystalluria and quantitative morphoconstitutional analysis of urinary calculi[J]. Nephron Physiol, 2004, 98(2):31-36.

[14] Qiao LD, Chen XH, Wu WQ, et al. Interpretation of Chinese Expert Consensus on Diagnosis and Treatment of Upper Urinary Tract Infectious Stones (2024 Edition)[J]. J Clin Urol, 2025, 40(02):101-104.

[15] Moe OW. Kidney stones: Pathophysiology and medical management[J]. Lancet, 2006, 367(9507):333-344.

[16] Liu Y, Song H, Luo D, et al.Zhang G and Li J(2025) Integrated radiomics and deep learning model for identifying medullary sponge kidney stones. Front Med, 12:1623850. doi: 10.3389/fmed.2025.1623850

[17] Kambadakone AR, Eisner BH, Catalano OA, et al. New and evolving concepts in the imaging and management of urolithiasis[J]. Radiographics, 2010, 30(3):603-623.

[18] Jendeberg J, Thunberg P, Popiolek M, et al. Single-energy CT predicts uric acid stones with accuracy comparable to dual-energy CT—prospective validation of a quantitative method[J]. Eur Radiol, 2021, 31: 5980 - 5989.

[19] Pearle MS, Goldfarb DS, Assimos DG, et al. Medical Management of Kidney Stones: AUA Guideline[J]. J Urol, 2014, 192(2):316-324.

[20] Zhan XF. Establishment and validation of a predictive model for urinary stone composition based on artificial intelligence and CT images [D]. Baoding: Hebei University, 2022.

[21] Sutton RS, Barto AG. Reinforcement Learning: An Introduction [M]. 2nd ed. Cambridge: MIT Press, 2018.

[22] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[J]. Med Image Anal, 2015: 234-241.

[23] Dayan I, Roth HR, Zhong A, et al. Federated learning for predicting clinical outcomes in patients with COVID-19[J]. Nat Med, 2021, 27 (10):1735-1743.

[24] Zilberman DE, Ferrandino MN, Preminger GM, et al. In vivo determination of urinary stone composition using dual energy CT with advanced post-acquisition processing[J]. J Urol, 2010, 184(6): 2354-2359.

[25] Lundberg SM, Lee SI. A unified approach to interpreting model predictions[C]. Advances in Neural Information Processing Systems, 2017, 30:4765-4774.

[26] Kazemi Y, Mirroshandel SA. A novel method for predicting kidney stone type using ensemble learning[J]. Artif Intell Med, 2018, 84: 117-126.

[27] Lundberg SM, Nair B, Vavilala MS, et al. Explainable machine-learning predictions for the prevention of hypoxaemia during surgery[J]. Nat Biomed Eng, 2018, 2(10):749-760.

[28] Topol EJ. High-performance medicine: the convergence of human and artificial intelligence[J]. Nat Med, 2019, 25(1):44-56.

[29] Zhao YQ, Yang BY, Wang XC, et al. Exploring the Interplay between Calcium Oxalate Crystals and Renal Tubular Epithelial Cell Injury: Implications for the Formation and Prevention of Kidney Stones[J]. Integr Med Nephrol Androl, 2024, 11:e23-00022.

[30] Wang J, Chen D, Huang W, et al. Aptamer-functionalized field-effect transistor biosensors for disease diagnosis and environmental monitoring[J]. Exploration, 2023, 3:20210027.

[31] You C, Shen Y, Sun S, et al. Artificial intelligence in breast imaging: Current situation and clinical challenges[J]. Exploration, 2023, 3: 20230007.

[32] Tang Q, Wu GW, Sun L, et al. Diagnostic value of a dual-source CT-based imaging model for upper urinary tract stones in children[J]. Chin J CT MRI, 2025(01):143-146.

(责任编辑:周一青)