

DOI: <https://doi.org/10.17816/DD515814>



Prospects of using computer vision technology to detect urinary stones and liver and kidney neoplasms on computed tomography images of the abdomen and retroperitoneal space

Yuriy A. Vasilev^{1,2}, Anton V. Vladzimyrskyy^{1,3}, Kirill M. Arzamasov¹, David U. Shikhmuradov¹, Andrey V. Pankratov¹, Iliya V. Ulyanov¹, Nikolay B. Nечаев¹

¹ Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies, Moscow, Russia;

² National Medical and Surgical Center Named after N.I. Pirogov, Moscow, Russia;

³ I.M. Sechenov First Moscow State Medical University, Moscow, Russia

ABSTRACT

The article presents a selective literature review on the use of computer vision algorithms for the diagnosis of liver and kidney neoplasms and urinary stones using computed tomography images of the abdomen and retroperitoneal space. The review included articles published between January 1, 2020, and April 24, 2023. Pixel-based algorithms showed the greatest diagnostic accuracy parameters for segmenting the liver and its neoplasms (accuracy, 99.6%; Dice similarity coefficient, 0.99). Voxel-based algorithms were superior at classifying liver neoplasms (accuracy, 82.5%). Pixel- and voxel-based algorithms fared equally well in segmenting kidneys and their neoplasms, as well as classifying kidney tumors (accuracy, 99.3%; Dice similarity coefficient, 0.97). Computer vision algorithms can detect urinary stones measuring 3 mm or larger with a high degree of accuracy of up to 93.0%. Thus, existing computer vision algorithms not only effectively detect liver and kidney neoplasms and urinary stones but also accurately determine their quantitative and qualitative characteristics. Evaluating voxel data improves the accuracy of neoplasm type determination since the algorithm analyzes the neoplasm in three dimensions rather than only the plane of one slice.

Keywords: computed tomography; neural networks; deep learning; abdomen; urolithiasis; renal neoplasms; liver neoplasms.

To cite this article:

Vasilev YuA, Vladzimyrskyy AV, Arzamasov KM, Shikhmuradov DU, Pankratov AV, Ulyanov IV, Nечаев NB. Prospects of using computer vision technology to detect urinary stones and liver and kidney neoplasms on computed tomography images of the abdomen and retroperitoneal space. *Digital Diagnostics*. 2024;5(1):101–119. DOI: <https://doi.org/10.17816/DD515814>

Submitted: 27.06.2023

Accepted: 22.12.2023

Published online: 11.03.2024

DOI: <https://doi.org/10.17816/DD515814>

Перспективы применения компьютерного зрения для выявления камней в мочевыделительной системе и новообразований печени и почек на изображениях компьютерной томографии органов брюшной полости и забрюшинного пространства

Ю.А. Васильев^{1,2}, А.В. Владзимирский^{1,3}, К.М. Арзамасов¹, Д.У. Шихмурадов¹, А.В. Панкратов¹, И.В. Ульянов¹, Н.Б. Нечаев¹

¹ Научно-практический клинический центр диагностики и телемедицинских технологий, Москва, Россия;

² Национальный медико-хирургический Центр имени Н.И. Пирогова, Москва, Россия;

³ Первый Московский государственный медицинский университет имени И.М. Сеченова, Москва, Россия

АННОТАЦИЯ

В работе представлен селективный обзор литературы, посвящённый использованию алгоритмов компьютерного зрения для диагностики новообразований печени и почек, а также камней в мочевыделительной системе на изображениях компьютерной томографии органов брюшной полости и забрюшинного пространства.

В обзор были включены статьи, опубликованные за период с 01.01.2020 по 24.04.2023 гг.

В задаче сегментации печени и её новообразований алгоритмы, оперирующие пикселями, показали наибольшие значения параметров диагностической точности (точность достигает 99,6%; коэффициент сходства Дайса — 0,99). Задачи классификации новообразований печени на текущий момент лучше решаются воксельными алгоритмами (точность до 82,5%).

Сегментация почек и их новообразований, а также классификация опухолей почек одинаково хорошо выполняются алгоритмами, анализирующими как пиксели, так и воксели (точность достигает 99,3%, коэффициент сходства Дайса — 0,97).

Алгоритмы компьютерного зрения в настоящее время также способны с высокой степенью точности определять конкременты в мочевыделительной системе размерами от 3 мм (точность достигает 93,0%).

Таким образом, существующие алгоритмы компьютерного зрения позволяют не только эффективно выявлять новообразования печени и почек, а также конкременты в мочевыделительной системе, но и с высокой точностью определять их количественные и качественные характеристики.

Более высокая точность определения вида новообразования может быть достигнута за счёт оценки воксельных данных, поскольку в этом случае алгоритм анализирует новообразование полностью в трёх измерениях, а не только в плоскости одного среза.

Ключевые слова: компьютерная томография; нейронные сети; глубокое машинное обучение; органы брюшной полости; мочекаменная болезнь; образования почек; образования печени.

Как цитировать:

Васильев Ю.А., Владзимирский А.В., Арзамасов К.М., Шихмурадов Д.У., Панкратов А.В., Ульянов И.В., Нечаев Н.Б. Перспективы применения компьютерного зрения для выявления камней в мочевыделительной системе и новообразований печени и почек на изображениях компьютерной томографии органов брюшной полости и забрюшинного пространства // Digital Diagnostics. 2024. Т. 5, № 1. С. 101–119. DOI: <https://doi.org/10.17816/DD515814>

Рукопись получена: 27.06.2023

Рукопись одобрена: 22.12.2023

Опубликована online: 11.03.2024

DOI: <https://doi.org/10.17816/DD515814>

计算机视觉在腹部和腹膜后计算机断层扫描图片上检测泌尿系统结石和肝肾肿块的应用前景

Yuriy A. Vasilev^{1,2}, Anton V. Vladzimyrskyy^{1,3}, Kirill M. Arzamasov¹, David U. Shikhmuradov¹, Andrey V. Pankratov¹, Iliya V. Ulyanov¹, Nikolay B. Nечаев¹

¹ Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies, Moscow, Russia;

² National Medical and Surgical Center Named after N.I. Pirogov, Moscow, Russia;

³ I.M. Sechenov First Moscow State Medical University, Moscow, Russia

摘要

本文对计算机视觉算法在腹部和腹膜后计算机断层扫描图片被用于诊断肝肾肿块以及泌尿系统结石的情况进行了有选择性的文献综述。

综述中的文章发表于2020年1月1日至2023年4月24日。

在肝脏及其肿块的分割任务中，使用像素算法显示出最高的诊断准确率参数值（准确率达到99.6%；Dice相似系数为0.99）。目前，基于体素的算法能较好地解决肝肿块分类任务（准确率高达82.5%）。

通过分析像素和体素的算法，肾脏及其肿块的分割和肾肿块的分类同样出色（准确率达到99.3%，Dice相似系数为0.97）。

现在，计算机视觉算法也能高度准确地检测出泌尿系统中3毫米及以上大小的结石（准确率达到93.0%）。

因此，现有的计算机视觉算法不仅能有效检测肝肾肿块以及泌尿系统中的结石，还能高度准确地确定它们的定量和定性特征。

通过评估体素数据，可以提高肿块类检测的准确度。在这种情况下，算法会对整个肿块进行三维分析，而不仅只是在一个切片的平面上进行分析。

关键词：电子计算机断层扫描；神经网络；深度机器学习；腹部器官；泌尿系结石病；肾肿块；肝肿块。

引用本文：

Vasilev YuA, Vladzimyrskyy AV, Arzamasov KM, Shikhmuradov DU, Pankratov AV, Ulyanov IV, Nечаев NB. 计算机视觉在腹部和腹膜后计算机断层扫描图片上检测泌尿系统结石和肝肾肿块的应用前景. *Digital Diagnostics*. 2024;5(1):101–119. DOI: <https://doi.org/10.17816/DD515814>

收到: 27.06.2023

接受: 22.12.2023

发布日期: 11.03.2024

绪论

在过去几年中，放射诊断发生了一系列重大变化。特别是，基于计算机视觉的技术已被积极用于解读计算机断层扫描(CT)图片，以改善和加快疾病诊断，减轻医务人员的负担[1-3]。一些分析胸部CT图片的人工智能算法已经证明，某些疾病的诊断准确率很高(ROC曲线下面积达到0.88)[3]。

计算机视觉在腹部病理诊断方面也在积极发展。在过去五年中，发表在PubMed资源上的有关这一问题的研究数量增加了12倍(从2018年的34篇增加到2022年的411篇)。科学研究数量的快速增长可归因于越来越多的人可以接受CT扫描检查，可检测疾病的清单相当庞大且不断增加，以及使用CT扫描验证疾病的准确性较高。

目前，已有基于计算机视觉技术的现成解决方案，可以在腹部和腹膜后CT扫描图片中检测出肝肾肿块以及泌尿系统结石等常见病症[4]。

这些决定基于算法，根据其功能可分为两类：

- 1、识别(分割)器官及其病理；
- 2、进行病理分类。

同时，所述解决方案显示出不同程度的诊断准确性，这在一定程度上可能是由于深度学习网络和计算机视觉算法的基础架构造成的。基于卷积神经网络的深度机器学习架构目前在分类领域最为流行[5]。

本综述致力于研究计算机视觉算法的诊断准确性，这些算法旨在检测CT图片上的肝肾肿块以及泌尿系统结石，具体准确性取决于这些算法的目的(分割或分类)以及其基础架构。

搜索方法

我们进行了一项分析性研究：选择性文献综述，重点关注为初级诊断设计的算法，这些算法被用于肝肾肿块和尿石病等常见疾病。

虽然腹部和腹膜后CT可以检测到的其他一些肿瘤(如胰腺肿瘤)也很常见，但在本综述中，作者只关注肝肾肿块和泌尿系统结节。关于使用计算机视觉检测这些解剖区域内其他器官肿瘤的研究较少或没有。

通过PubMed互联网服务(访问日期：2023年4月31日)使用关键词组合搜索科学出版物：[“Deep Learning”，“Neural Network”，“Artificial intelligence”]+[“Liver tumor”，“Kidney tumor”，“Hepatocellular carcinoma”，“Kidney Stone”]+“Computed Tomography”。

此外，还通过关键词“Искусственный интеллект”+“компьютерная томография”(“人工智能”+“计算机断层扫描”)在科学出版物电子图书馆和俄罗斯科学引文索引的国家信息和分析系统eLibrary(访问日期：2023年4月31日)中搜索了2019年至今的研究，但没有发现直接致力于深度学习算法诊断腹部和腹膜后病理的著作。

从使用PubMed互联网服务找到的研究中，分析包括使用计算机视觉算法对腹部和腹膜后CT图片上的

靶向病理进行分割和分类的论文，这些论文描述了深度学习算法的架构，并使用其中一个指标展示了算法操作的结果：在分割和准确性任务中使用戴斯相似性系数，在分类任务中使用F1分数或ROC曲线下面积(AUC)[6]。

搜索深度限于2020年1月1日至2023年4月24日。

结果

因此，有21篇论文被纳入本综述，其数据见附录1。对所选论文进行了架构分析，并对诊断指标进行了评估。与未纳入分析的其他公开论文进行了比较。

肝脏肿块

目前诊断肝脏肿块信息量最大的方法是对比增强CT和磁共振成像(MRI)[7]。同时，CT与MRI相比有许多优势，如设备可用性、专家培训、检查速度和成本效益[8]。由于无造影剂检查的信息量较低，在怀疑肝脏肿块时，使用对比增强是标准方法。然而，在其他一些疾病中，大量的腹部CT检查都是在没有造影剂的情况下进行的。计算机视觉算法在原始CT图片上检测肝脏肿块的能力可用于筛查这种病变[9-11]。

U-Net架构及其修改(特别是ResNet块的使用)最常用于肝脏及其肿块的分割任务，显示出相当高的诊断准确性。H.Rahman等人在使用ResUNet完成的肝脏及其肿块分割任务范围获得了最高性能：戴斯相似性系数为0.99，准确率为99.6%[12]。肝脏肿块分割的示例见图1。

与使用体素(三维图像)的算法相比，使用像素(二维图像)进行分割的算法显示出更好的诊断指标[12-18]。

在肝脏肿块分类任务中，基于体素的算法具有更好的诊断性能。同时，我们已经可以看到，这些算法可以将肿块分为良性和恶性，而且可靠性很高(准确率达到82.5%)。目前，确定恶性肿瘤具体类型的准确率较低，仅为73.4%[19, 20]。

尽管深度机器学习得到了发展和广泛应用，但值得注意的是，一些经典的机器学习算法(如支持向量机——support vector machine, SVM)在对肝脏肿瘤进行分类时也显示出很高的诊断指标：准确率达到84.6%[19, 21]。

如今，在莫斯科市卫生局诊断和远程医疗技术科学实践临床中心的基础上，正在开展一项工作，以创建一种计算机视觉算法，利用对比度增强技术分割和区分病理肝脏肿块的类别。这项工作的一个示例见图2。

肾脏肿块

在27-50%的病例中，肾脏肿块是无症状的，是偶然发现的[22]。CT不仅能确定肿块的位置和大小，还能评估肿块与肾盂和主要血管的关系。

在所分析的研究中，U-Net架构及其修改版最常用于解决肾脏及其肿块的分割问题。目前，使用三

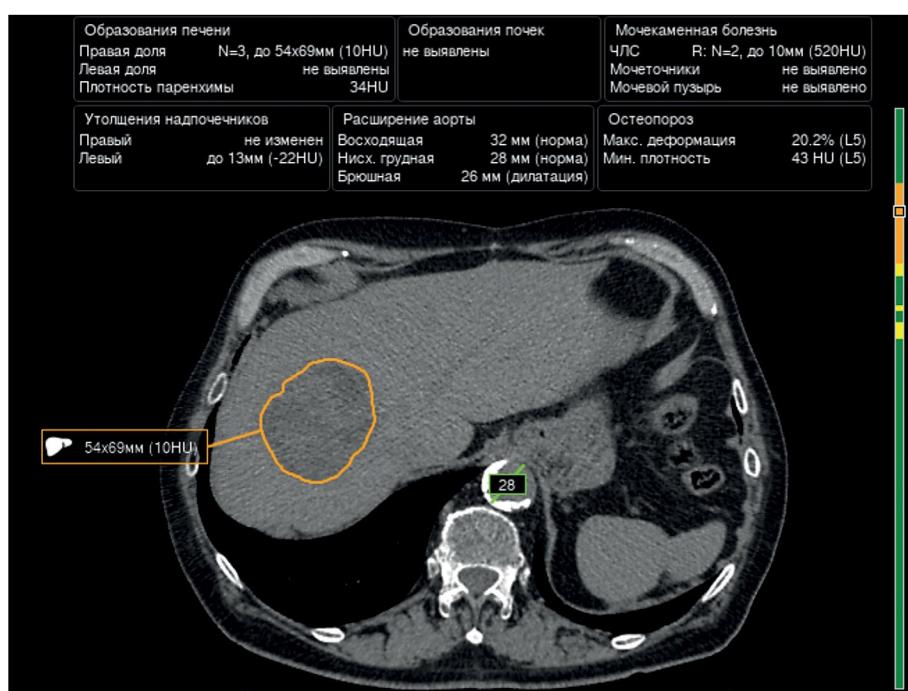


图1。一种算法对肝脏肿块进行分割的示例。

维U-Net架构进行肾脏分割的戴斯相似性系数达到0.97[23]。使用相同的架构，在肾肿瘤(0.84)和肾囊肿(0.54)的分割任务中获得了最高的戴斯相似性系数。因此，肾脏肿块的分割准确度仍然低于肾脏本身的分割准确度。

此外，值得注意的是，基于体素架构的CT切片上肾脏及其肿块的分割诊断准确率并不比基于像素的经典算法差[23–26]。

其他架构（如EffectiveNet）在分割肾脏及其肿块时也显示出较高的戴斯相似性系数值（高达0.95）[27, 28]。肾脏肿块分割的示例见图3。

经典机器学习算法和基于深度机器学习的算法[24, 26, 29–31]都被用于解决肾脏肿块分类问题。Swin Transformers架构的准确率最高(99.3%)[29]。

经典机器学习算法和前向传播架构在数据限制条件下表现良好[26]。正如在分割肾脏及其肿块的任务

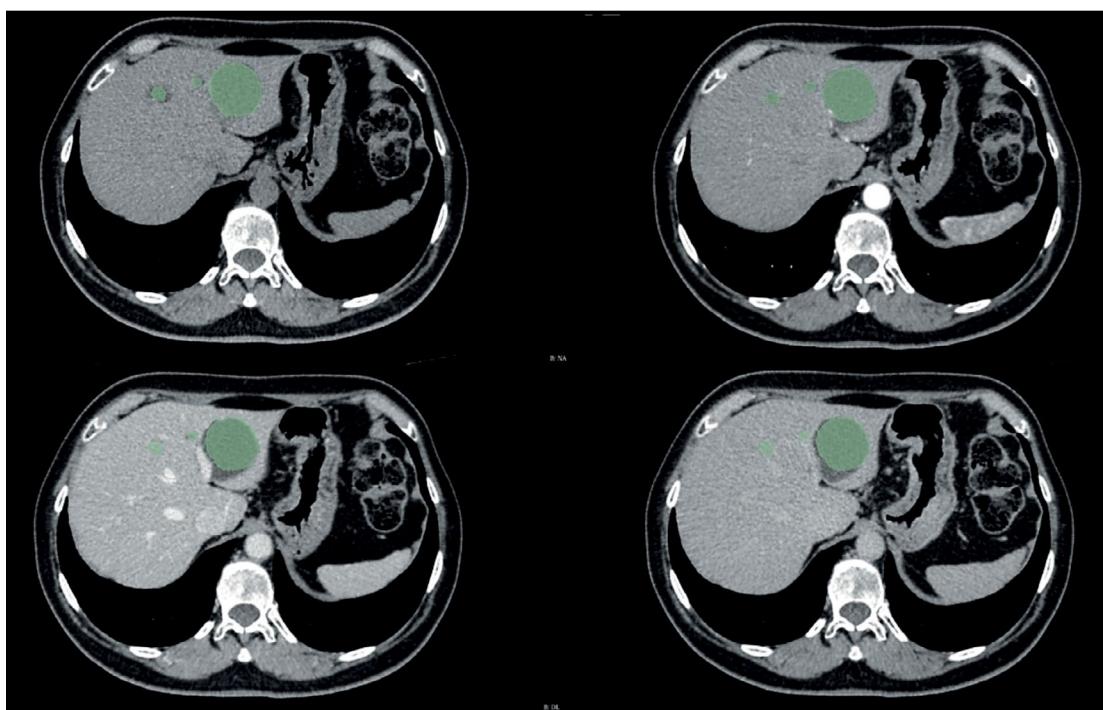


图2。一种算法对对比增强计算机断层扫描图片进行肝脏肿块分割的示例。

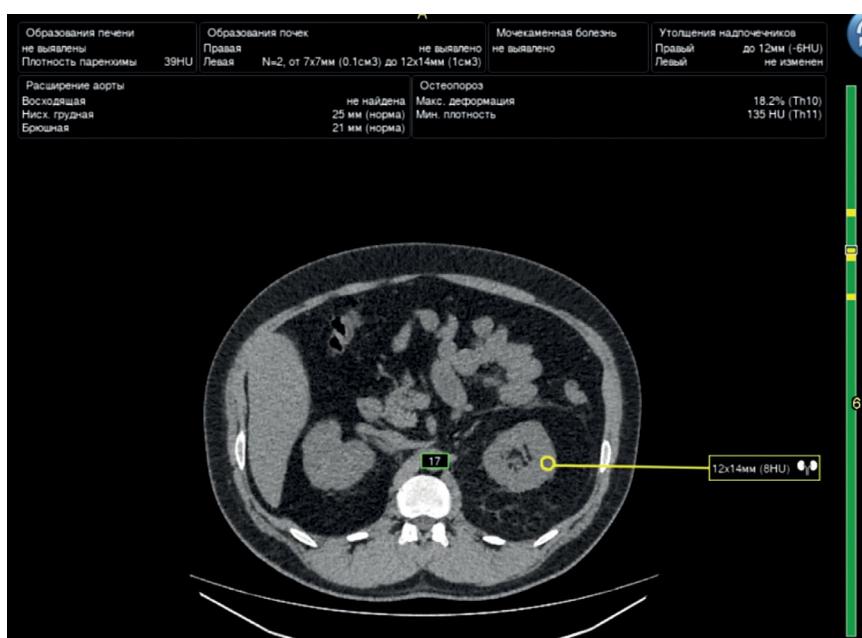


图3。右肾肿块的分割示例。

中, 使用体素的架构与使用像素的架构在解决分类问题上同样准确[31]。

尿石病

尿石病是第二大最常发现的泌尿系统疾病[32]。与此同时, 在俄罗斯联邦的所有地区, 尿石病的发病率及其在成年人口中的流行率都在稳步上升。根据N.Gadzhiev等人的研究, 15年间, 尿石病的流行率增加了35.4%, 发病率增加了16.2%[33]。

在尿石病的诊断中, 腹膜后CT是金标准, 可确定不透射线的结石的位置、形状、大小和数量, 灵敏度高达96%, 特异性高达100%[34]。

所分析的文章显示, 检测结石的准确率直接取决于结石的大小。基于卷积神经网络的算法的准确率随着大小的增大而提高[35, 36]。因此, 小于1cm的结石检测准确率为85%, 1至2cm的结石检测准确率为89%, 大于2cm的结石检测准确率为93%。

基于变换器 (Swin Transformers) 的算法是迄今为止检测泌尿系统结石准确率最高 (98%) 的算法 [29]。一种算法检测结石的示例见图4。

使用计算机视觉算法诊断尿石病时, 在检测小结石时可能会遇到困难, 因为肾动脉壁上会存在小的动脉粥样硬化斑块, 其密度与尿酸盐结石相对应[36]。

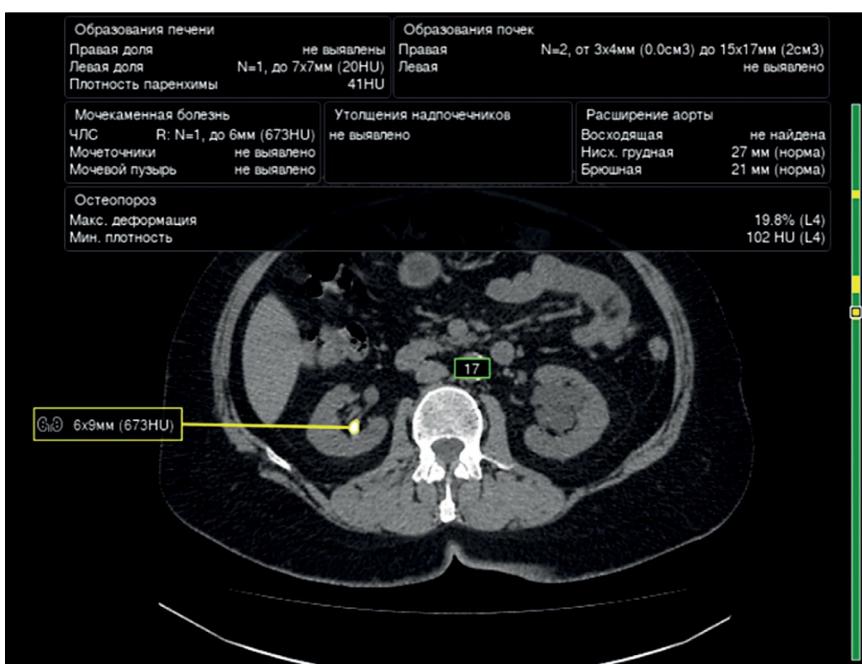


图4。一种算法检测结石的示例。

与此同时，深度机器学习和计算机视觉领域的现代技术使得在低辐射照射下检测3mm大小的结石成为可能，而5mm或更大的结石被认为具有临床意义[37]。

确定结石类型是影响后续治疗策略的最重要因素之一[35, 37]。关于确定术后预后（尤其是无复发病程），以及基于机器学习技术确定结石类型的研究使用许多基于CT的不同特征[38–41]。一些关于使用双能量CT (Dual-Energy CT, DECT) 的研究表明，可以使用这种成像方法来确定结石的化学成分[42, 43]，但这种方法有许多局限性，首先，这种方法在常规实践中的应用有限[44]。

Y.Cui等人的研究表明了，利用高度专业化的卷积神经网络，可以使用S.T.O.N.E.肾结石评价系统评估结石，其结果与放射科医生的结论相当[45]。这种方法还能估计患者的预后因素[46]。

讨论

在许多论文中，研究都是在公共数据集上进行的，如LiTS、KiTS' 19、3D-IRCADb等，这些数据集主要包含对比检查。在使用自己CT图片的研究中，数据集也主要包含对比检查或混合数据。

根据所分析的出版物，目前开发的深度机器学习算法可以在CT图片上实现高精度的肝脏分割（最大戴斯相似性系数为0.99，平均为 0.92 ± 0.09 ）和肾脏分割（最大戴斯相似性系数为0.97，平均为 0.94 ± 0.02 ）（见附录1）。

在肝脏分割任务中，像素算法的诊断准确性指标值最高（最大戴斯相似性系数为0.99，平均为 0.97 ± 0.01 ），而在肾脏分割任务中，基于体素的算法并不比基于像素的算法差。这可能是由于这些实质器官的大小和密度不同，以及算法开发的历史特点造成的。使用体素需要更高的性能，而这种计算系统的广泛使用是最近才出现的，它们现在已有了研究中心正在开发的大量改进的、基于像素的算法基础。

肝肾肿块的分割准确度低于这些器官本身的分割准确度。肿块分割不准确的主要原因是分割不完全。肿块边界的正确确定取决于肿块的生长类型和结构，因此外生性异质肿块的分割效果最好[23]。简单等密度囊肿、血管瘤等的分割准确度低也与此有关[20]。

在使用分割算法之前对数据进行预处理，可以部分解决这个问题[27, 28]。K.Yildirim等人的研究表明了，利用深度机器学习算法分析其他CT切片（如矢状切面或冠状切面）也能提高病理检测的准确率[47]。

根据已分析的文献，使用体素而非像素进行肿块分类更为合理，因为肿块结构的类型可用于确定其性质[19, 26, 31]。基于深度学习的技术可以高精度地将腹部肿块分为良性肿块和恶性肿块[19, 20, 31]。

分割的完整性对后续分类的正确性至关重要。目前，可以结合使用二维算法进行分割和三维算法进行分类[19, 24]。此外，将深度机器学习算法与经典机器学习算法（包括梯度提升）结合使用，可以改善诊断指标[19]。在所分析的作品中，可以区分出这些算法组合的两种变体。L.Yang等人和M.Shehata等人

提出通过算法方法形成特征，并将其用于前向传播网络[30, 31]。E.Trivizakis等人和X.L.Zhu等人则相反，他们从深度学习网络中形成特征，并使用经典机器学习算法对其进行分类[19, 26]。

同样重要的是将变换器架构用于肿块分类，但其使用受到训练数据量的限制。在使用变换器架构时，要想获得较高的指标，需要比超精确神经网络多好几倍的训练数据[29]。

所分析的论文使用标准指标来评估深度机器学习算法的质量，但各篇论文的研究方法各不相同，因此很难对诊断准确性进行充分的比较评估。另一个限制因素是，大多数作者未能为诊断准确性参数的所得值提供95%的置信区间，因此无法评估使用不同神经网络架构和方法所得指标之间差异的可靠性。引入标准化的评估方法可能有助于找出效果更好的算法[48]。此外，有必要指出的是，我们所分析的一些研究的样本有限。

深度机器学习算法的另一个用途是提高低剂量检查中获得的CT图片的质量。例如，F.R.Schwartz等人建议在进行双能量CT检查时使用深度机器学习算法来进行数据插值和重建[49–51]。有了这种方法，就有可能在低辐射剂量下获得高能量图片。

因此，计算机视觉算法目前在检测CT图片上的泌尿系统结石以及肝肾肿块方面已经显示出很高的诊断准确性参数。下一步的任务是将计算机视觉融入医疗机构的工作中，以改进和加快疾病诊断，减轻医务人员的负担。还需要进一步开展更大规模、前瞻性、详细的研究，这些研究要与基于人工智能的腹部肿块筛查软件的功效评估有关，而且需要对这些研究进行定性和定量评估，并对其结果进行验证。

结论

现有的用于腹部和腹膜后CT评估的计算机视觉系统不仅能有效检测肝肾脏肿块以及泌尿系统结石，还能高精度地确定其定量和定性特征。进一步的技术发展将促进三维深度学习算法的发展，提高其诊断准确性，从而获得更可靠的结果，特别是在多类分类任务中。使用体素数据可以更准确地确定病理类型，因为在这种情况下，算法可以在三维空间而不仅仅是在单个切片的平面上完整地分析病理形成。

今后可对由此产生的计算机视觉数据进行更深入的评估，以确定对比增强检查各阶段的“价值”。提高CT图片质量的方法开发将允许根据特定目的只扫描特定阶段（如动脉和排泄），从而减少患者接受的有效辐射剂量。

ADDITIONAL INFORMATION

Funding source. This article was prepared by a group of authors as a part of the research and development effort titled “Evidence-based methodologies for sustainable development of artificial intelligence in medical imaging” (USIS No. 123031500004-5) in accordance with the Order No. 1196 dated December 21, 2022 “On approval of state

assignments funded by means of allocations from the budget of the city of Moscow to the state budgetary (autonomous) institutions subordinate to the Moscow Health Care Department, for 2023 and the planned period of 2024 and 2025" issued by the Moscow Health Care Department.

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. Yu.A. Vasiliev, A.V. Vladzimirsky, K.M. Arzamasov — research concept; N.B. Nechaev — writing the text of the article; D.W. Shikhmuradov, A.V. Pankratov, I.V. Ulyanov — data analysis.

REFERENCES

1. Iliashenko OY, Lukyanchenko EL. Possibilities of using computer vision for data analytics in medicine. *Izvestiya of Saratov University. Mathematics. Mechanics. Informatics.* 2022;22(2):224–232. EDN: MCSLKQ doi: 10.18500/1816-9791-2022-22-2-224-232
2. Alekseeva MG, Zubov AI, Novikov MYu. Artificial intelligence in medicine. *Meždunarodnyj naučno-issledovatel'skij žurnal.* 2022;7(121):10–13. EDN: JMMMDF doi: 10.23670/IRJ.2022.121.7.038
3. Gusev AV, Vladzimyrskyy AV, Sharova DE, Arzamasov KM, Khramov AE. Evolution of research and development in the field of artificial intelligence technologies for healthcare in the Russian Federation: results of 2021. *Digital Diagnostics.* 2022;3(3):178–194. EDN: KHWQWZ doi: 10.17816/DD107367
4. Wang L, Wang H, Huang Y, et al. Trends in the application of deep learning networks in medical image analysis: Evolution between 2012 and 2020. *Eur J Radiol.* 2022;146:110069. doi: 10.1016/j.ejrad.2021.110069
5. Alrefai N, Ibrahim O. AI Deep learning-based cancer classification for microarray data: A systematic review. *Journal of Theoretical and Applied Information Technology.* 2021;99:2312–2332. doi: 10.5281/zenodo.6126510
6. Clinical trials of artificial intelligence systems (radiation diagnostics). Vasil'ev YuA, Vladzimyrskyy AV, Sharova DE, editors. Moscow: GBUZ «NPKTS DiT DZM»; 2023. EDN: PUIJLD
7. Lee J, Kim KW, Kim SY, et al. Automatic detection method of hepatocellular carcinomas using the non-rigid registration method of multi-phase liver CT images. *J Xray Sci Technol.* 2015;23(3):275–288. doi: 10.3233/XST-150487
8. Patel BN, Boltyenkov AT, Martinez MG, et al. Cost-effectiveness of dual-energy CT versus multiphasic single-energy CT and MRI for characterization of incidental indeterminate renal lesions. *Abdom Radiol (NY).* 2020;45(6):1896–1906. doi: 10.1007/s00261-019-02380-x
9. Marrero JA, Kulik LM, Sirlin CB, et al. Diagnosis, Staging, and Management of Hepatocellular Carcinoma: 2018 Practice Guidance by the American Association for the Study of Liver Diseases. *Hepatology.* 2018;68(2):723–750. doi: 10.1002/hep.29913
10. Ayuso C, Rimola J, Vilana R, et al. Diagnosis and staging of hepatocellular carcinoma (HCC): current guidelines. *Eur J Radiol.* 2018;101:72–81. doi: 10.1016/j.ejrad.2018.01.025
11. Liver cancer (hepatocellular). Clinical guidelines. ID 1. Approved by the Scientific and Practical Council of the Ministry of Health of the Russian Federation. 2022. Available from: https://cr.menzdrav.gov.ru/schema/1_3 (In Russ)
12. Rahman H, Bukht TFN, Imran A, et al. A Deep Learning Approach for Liver and Tumor Segmentation in CT Images Using ResUNet. *Bioengineering (Basel).* 2022;9(8):368. doi: 10.3390/bioengineering9080368
13. Maqsood M, Bukhari M, Ali Z, et al. A Residual-Learning-Based Multi-Scale Parallel-Convolutions- Assisted Efficient CAD System for Liver Tumor Detection. *Mathematics.* 2021;9(10):1133. doi: 10.3390/math9101133
14. Khan RA, Luo Y, Wu FX. RMS-UNet: Residual multi-scale UNet for liver and lesion segmentation. *Artif Intell Med.* 2022;124:102231. doi: 10.1016/j.artmed.2021.102231
15. Affane A, Kucharski A, Chapuis P, et al. Segmentation of Liver Anatomy by Combining 3D U-Net Approaches. *Applied Sciences.* 2021;11(11):4895. doi: 10.3390/app11114895
16. Han X, Wu X, Wang S, et al. Automated segmentation of liver segment on portal venous phase MR images using a 3D convolutional neural network. *Insights Imaging.* 2022;13(1):26. doi: 10.1186/s13244-022-01163-1
17. Wang J, Zhang X, Guo L, et al. Multi-scale attention and deep supervision-based 3D UNet for automatic liver segmentation from CT. *Math Biosci Eng.* 2023;20(1):1297–1316. doi: 10.3934/mbe.2023059
18. Kashala KG, Song Y, Liu Z. Optimization of FireNet for Liver Lesion Classification. *Electronics.* 2020;9(8):1237. doi: 10.3390/electronics9081237
19. Trivizakis E, Manikis GC, Nikiforaki K, et al. Extending 2-D Convolutional Neural Networks to 3-D for Advancing Deep Learning Cancer Classification With Application to MRI Liver Tumor Differentiation. *IEEE J Biomed Health Inform.* 2019;23(3):923–930. doi: 10.1109/JBHI.2018.2886276
20. Zhou J, Wang W, Lei B, et al. Automatic Detection and Classification of Focal Liver Lesions Based on Deep Convolutional Neural Networks: A Preliminary Study. *Front Oncol.* 2021;10:581210. doi: 10.3389/fonc.2020.581210
21. Rela M, Rao SN, Patil RR. Performance analysis of liver tumor classification using machine learning algorithms. *International Journal of Advanced Technology and Engineering Exploration.* 2022;9(86):143–154. doi: 10.19101/IJATEE.2021.87465
22. Oberai A, Varghese B, Cen S, et al. Deep learning based classification of solid lipid-poor contrast enhancing renal masses using contrast enhanced CT. *Br J Radiol.* 2020;93(1111):20200002. doi: 10.1259/bjr.20200002
23. Lin Z, Cui Y, Liu J, et al. Automated segmentation of kidney and renal mass and automated detection of renal mass in CT urography using 3D U-Net-based deep convolutional neural network. *Eur Radiol.* 2021;31(7):5021–5031. doi: 10.1007/s00330-020-07608-9
24. Toda N, Hashimoto M, Arita Y, et al. Deep Learning Algorithm for Fully Automated Detection of Small (<4 cm) Renal Cell Carcinoma in Contrast-Enhanced Computed Tomography Using a Multicenter Database. *Invest Radiol.* 2022;57(5):327–333. doi: 10.1097/RLI.0000000000000842

- 25.** Ding Y, Chen Z, Wang Z, et al. Three-dimensional deep neural network for automatic delineation of cervical cancer in planning computed tomography images. *J Appl Clin Med Phys.* 2022;23(4):e13566. doi: 10.1002/acm2.13566
- 26.** Zhu XL, Shen HB, Sun H, et al. Improving segmentation and classification of renal tumors in small sample 3D CT images using transfer learning with convolutional neural networks. *Int J Comput Assist Radiol Surg.* 2022;17(7):1303–1311. doi: 10.1007/s11548-022-02587-2
- 27.** Hsiao CH, Sun TL, Lin PC, et al. A deep learning-based precision volume calculation approach for kidney and tumor segmentation on computed tomography images. *Comput Methods Programs Biomed.* 2022;221:106861. doi: 10.1016/j.cmpb.2022.106861
- 28.** Hsiao CH, Lin PC, Chung LA, et al. A deep learning-based precision and automatic kidney segmentation system using efficient feature pyramid networks in computed tomography images. *Comput Methods Programs Biomed.* 2022;221:106854. doi: 10.1016/j.cmpb.2022.106854
- 29.** Islam MN, Hasan M, Hossain MK, et al. Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography. *Sci Rep.* 2022;12(1):11440. doi: 10.1038/s41598-022-15634-4
- 30.** Yang L, Gao L, Arefan D, et al. A CT-based radiomics model for predicting renal capsule invasion in renal cell carcinoma. *BMC Med Imaging.* 2022;22(1):15. doi: 10.1186/s12880-022-00741-5
- 31.** Shehata M, Alksas A, Abouelkheir RT, et al. A Comprehensive Computer-Assisted Diagnosis System for Early Assessment of Renal Cancer Tumors. *Sensors (Basel).* 2021;21(14):4928. doi: 10.3390/s21144928
- 32.** Kulikovskiy VF, Shkodkin SV, Batishchev SA, et al. Modern research and thinking about the epidemiology and pathogenesis of urolithiasis. *Nauchnyi rezul'tat. Meditsina i farmatsiya.* 2016;2(4):4–12. EDN: NSGAXL doi: 10.18413/2313-8955-2016-2-4-4-12
- 33.** Gadzhiev N, Prosyannikov M, Malkhasyan V, et al. Urolithiasis prevalence in the Russian Federation: analysis of trends over a 15-year period. *World J Urol.* 2021. Vol. 39(10):3939–3944. doi: 10.1007/s00345-021-03729-y
- 34.** *Urology. Russian Clinical Recommendations.* Alyaev YuG, Glybochko PV, Pushkar' DYu, editors. Moscow: GEOTARMedia; 2016. (In Russ).
- 35.** Caglayan A, Horsanali MO, Kocadurdu K, et al. Deep learning model-assisted detection of kidney stones on computed tomography. *Int Braz J Urol.* 2022;48(5):830–839. doi: 10.1590/S1677-5538.IBJU.2022.0132
- 36.** Elton DC, Turkbey EB, Pickhardt PJ, Summers RM. A deep learning system for automated kidney stone detection and volumetric segmentation on noncontrast CT scans. *Med Phys.* 2022;49(4):2545–2554. doi: 10.1002/mp.15518
- 37.** He Z, An L, Chang Z, Wu W. Comment on “Deep learning computer vision algorithm for detecting kidney stone composition”. *World J Urol.* 2021;39(1):291. doi: 10.1007/s00345-020-03181-4
- 38.** Doyle PW, Kavoussi NL. Machine learning applications to enhance patient specific care for urologic surgery. *World J Urol.* 2022;40(3):679–686. doi: 10.1007/s00345-021-03738-x
- 39.** Neymark AI, Neymark BA, Ershov AV, et al. The use of intelligent analysis (IA) in determining the tactics of treating patients with nephrolithiasis. *Urologia Journal.* 2023;(3915603231162881). doi: 10.1177/03915603231162881
- 40.** Kadlec AO, Ohlander S, Hotaling J, et al. Nonlinear logistic regression model for outcomes after endourologic procedures: a novel predictor. *Urolithiasis.* 2014;42(4):323–330. doi: 10.1007/s00240-014-0656-1
- 41.** Black KM, Law H, Aldoukhia A, et al. Deep learning computer vision algorithm for detecting kidney stone composition. *BJU Int.* 2020;125(6):920–924. doi: 10.1111/bju.15035
- 42.** Zhang GM, Sun H, Xue HD, et al. Prospective prediction of the major component of urinary stone composition with dual-source dual-energy CT in vivo. *Clin Radiol.* 2016;71(11):1178–1183. doi: 10.1016/j.crad.2016.07.012
- 43.** Chaytor RJ, Rajabu K, Jones PA, McKnight L. Determining the composition of urinary tract calculi using stone-targeted dual-energy CT: evaluation of a low-dose scanning protocol in a clinical environment. *Br J Radiol.* 2016;89(1067):20160408. doi: 10.1259/bjr.20160408
- 44.** Kapanadze LB, Serova NS, Rudenko VI. Application of dual-energy computer tomography in diagnostics of urolithiasis. *REJR.* 2017;7(3):165–173. EDN: ZWBLYL doi: 10.21569/2222-7415-2017-7-3-165-173
- 45.** Cui Y, Sun Z, Ma S, et al. Automatic Detection and Scoring of Kidney Stones on Noncontrast CT Images Using S.T.O.N.E. Nephrolithometry: Combined Deep Learning and Thresholding Methods. *Mol Imaging Biol.* 2021;23(3):436–445. doi: 10.1007/s11307-020-01554-0
- 46.** Okhunov Z, Friedlander JL, George AK, et al. S.T.O.N.E. nephrolithometry: novel surgical classification system for kidney calculi. *Urology.* 2013;81(6):1154–1159. doi: 10.1016/j.urology.2012.10.083
- 47.** Yildirim K, Bozdag PG, Talo M, et al. Deep learning model for automated kidney stone detection using coronal CT images. *Comput Biol Med.* 2021;135:104569. doi: 10.1016/j.combiomed.2021.104569
- 48.** Kodenko MR, Reshetnikov RV, Makarova TA. Modification of quality assessment tool for artificial intelligence diagnostic test accuracy studies (QUADAS-CAD). *Digital Diagnostics.* 2022;3(1S):4–5. EDN: KNBHOJ doi: 10.17816/DD105567
- 49.** Schwartz FR, Clark DP, Ding Y, Ramirez-Giraldo JC. Evaluating renal lesions using deep-learning based extension of dual-energy FoV in dual-source CT-A retrospective pilot study. *Eur J Radiol.* 2021;139:109734. doi: 10.1016/j.ejrad.2021.109734
- 50.** Li W, Diao K, Wen Y, et al. High-strength deep learning image reconstruction in coronary CT angiography at 70-kVp tube voltage significantly improves image quality and reduces both radiation and contrast doses. *Eur Radiol.* 2022;32(5):2912–2920. doi: 10.1007/s00330-021-08424-5
- 51.** Bae JS, Lee JM, Kim SW, et al. Low-contrast-dose liver CT using low monoenergetic images with deep learning-based denoising for assessing hepatocellular carcinoma: a randomized controlled noninferiority trial. *Eur Radiol.* 2023;33(6):4344–4354. doi: 10.1007/s00330-022-09298-x

СПИСОК ЛИТЕРАТУРЫ

1. Ильяшенко О.Ю., Лукьянченко Е.Л. Возможности применения компьютерного зрения для аналистики данных в медицине // Известия Саратовского университета. Новая серия. Серия : Математика. Механика. Информатика. 2022. Т. 22, № 2. С. 224–232. EDN: MCSLKQ doi: 10.18500/1816-9791-2022-22-2-224-232
2. Алексеева М.Г., Зубов А.И., Новиков М.Ю. Искусственный интеллект в медицине // Международный научно-исследовательский журнал. 2022. Т. 7, № 121. С. 10–13. EDN: JMMMDF doi: 10.23670/IRJ.2022.121.7.038
3. Гусев А.В., Владзимирский А.В., Шарова Д.Е., Арзамасов К.М., Храмов А.Е. Развитие исследований и разработок в сфере технологий искусственного интеллекта для здравоохранения в Российской Федерации: итоги 2021 года // Digital Diagnostics. 2022. Т. 3, № 3. С. 178–194. EDN: KHWQWZ doi: 10.17816/DD107367
4. Wang L., Wang H., Huang Y., et al. Trends in the application of deep learning networks in medical image analysis: Evolution between 2012 and 2020 // Eur J Radiol. 2022. Vol. 146. P. 110069. doi: 10.1016/j.ejrad.2021.110069
5. Alrefai N., Ibrahim O. AI Deep learning-based cancer classification for microarray data: A systematic review // Journal of Theoretical and Applied Information Technology. 2021. Vol. 99. P. 2312–2332. doi: 10.5281/zenodo.6126510
6. Клинические испытания систем искусственного интеллекта (лучевая диагностика) / под ред. Ю.А. Васильева, А.В. Владзимирского, Д.Е. Шаровой, и др. Москва : ГБУЗ «НПКЦ ДИТ ДЗМ», 2023. EDN: PUIJLD
7. Lee J., Kim K.W., Kim S.Y., et al. Automatic detection method of hepatocellular carcinomas using the non-rigid registration method of multi-phase liver CT images // J Xray Sci Technol. 2015. Vol. 23, N 3. P. 275–288. doi: 10.3233/XST-150487
8. Patel B.N., Boltyenkov A.T., Martinez M.G., et al. Cost-effectiveness of dual-energy CT versus multiphasic single-energy CT and MRI for characterization of incidental indeterminate renal lesions // Abdom Radiol (NY). 2020. Vol. 45, N 6. P. 1896–1906. doi: 10.1007/s00261-019-02380-x
9. Marrero J.A., Kulik L.M., Sirlin C.B., et al. Diagnosis, Staging, and Management of Hepatocellular Carcinoma: 2018 Practice Guidance by the American Association for the Study of Liver Diseases // Hepatology. 2018. Vol. 68, N 2. P. 723–750. doi: 10.1002/hep.29913
10. Ayuso C., Rimola J., Vilana R., et al. Diagnosis and staging of hepatocellular carcinoma (HCC): current guidelines // Eur J Radiol. 2018. Vol. 101. P. 72–81. doi: 10.1016/j.ejrad.2018.01.025
11. Клинические рекомендации — Рак печени (гепатоцеллюлярный). ID 1. Одобрено Научно-практическим Советом Минздрава РФ. 2022. Режим доступа: https://cr.minsdrav.gov.ru/schema/1_3 Дата обращения: 03.04.2023
12. Rahman H., Bukht T.F.N., Imran A., et al. A Deep Learning Approach for Liver and Tumor Segmentation in CT Images Using ResUNet // Bioengineering (Basel). 2022. Vol. 9, N 8. P. 368. doi: 10.3390/bioengineering9080368
13. Maqsood M., Bukhari M., Ali Z., et al. A Residual-Learning-Based Multi-Scale Parallel-Convolutions- Assisted Efficient CAD System for Liver Tumor Detection // Mathematics. 2021. Vol. 9, N 10. P. 1133. doi: 10.3390/math9101133
14. Khan R.A., Luo Y., Wu F.X. RMS-UNet: Residual multi-scale UNet for liver and lesion segmentation // Artif Intell Med. 2022. Vol. 124. P. 102231. doi: 10.1016/j.artmed.2021.102231
15. Affane A., Kucharski A., Chapuis P., et al. Segmentation of Liver Anatomy by Combining 3D U-Net Approaches // Applied Sciences. 2021. Vol. 11, N 11. P. 4895. doi: 10.3390/app11114895
16. Han X., Wu X., Wang S., et al. Automated segmentation of liver segment on portal venous phase MR images using a 3D convolutional neural network // Insights Imaging. 2022. Vol. 13, N 1. P. 26. doi: 10.1186/s13244-022-01163-1
17. Wang J., Zhang X., Guo L., et al. Multi-scale attention and deep supervision-based 3D UNet for automatic liver segmentation from CT // Math Biosci Eng. 2023. Vol. 20, N 1. P. 1297–1316. doi: 10.3934/mbe.2023059
18. Kashala K.G., Song Y., Liu Z. Optimization of FireNet for Liver Lesion Classification // Electronics. 2020. Vol. 9, N 8. P. 1237. doi: 10.3390/electronics9081237
19. Trivizakis E., Manikis G.C., Nikiforaki K., et al. Extending 2-D Convolutional Neural Networks to 3-D for Advancing Deep Learning Cancer Classification With Application to MRI Liver Tumor Differentiation // IEEE J Biomed Health Inform. 2019. Vol. 23, N 3. P. 923–930. doi: 10.1109/JBHI.2018.2886276
20. Zhou J., Wang W., Lei B., et al. Automatic Detection and Classification of Focal Liver Lesions Based on Deep Convolutional Neural Networks: A Preliminary Study // Front Oncol. 2021. Vol. 10. P. 581210. doi: 10.3389/fonc.2020.581210
21. Rela M., Rao S.N., Patil R.R. Performance analysis of liver tumor classification using machine learning algorithms // International Journal of Advanced Technology and Engineering Exploration. 2022. Vol. 9, N 86. P. 143–154. doi: 10.19101/IJATEE.2021.87465
22. Oberai A., Varghese B., Cen S., et al. Deep learning based classification of solid lipid-poor contrast enhancing renal masses using contrast enhanced CT // Br J Radiol. 2020. Vol. 93, N 1111. P. 20200002. doi: 10.1259/bjr.20200002
23. Lin Z., Cui Y., Liu J., et al. Automated segmentation of kidney and renal mass and automated detection of renal mass in CT urography using 3D U-Net-based deep convolutional neural network // Eur Radiol. 2021. Vol. 31, N 7. P. 5021–5031. doi: 10.1007/s00330-020-07608-9
24. Toda N., Hashimoto M., Arita Y., et al. Deep Learning Algorithm for Fully Automated Detection of Small (<4 cm) Renal Cell Carcinoma in Contrast-Enhanced Computed Tomography Using a Multicenter Database // Invest Radiol. 2022. Vol. 57, N 5. P. 327–333. doi: 10.1097/RLI.0000000000000842
25. Ding Y., Chen Z., Wang Z., et al. Three-dimensional deep neural network for automatic delineation of cervical cancer in planning computed tomography images // J Appl Clin Med Phys. 2022. Vol. 23, N 4. P. e13566. doi: 10.1002/acm2.13566

- 26.** Zhu X.L., Shen H.B., Sun H., et al. Improving segmentation and classification of renal tumors in small sample 3D CT images using transfer learning with convolutional neural networks // *Int J Comput Assist Radiol Surg.* 2022. Vol. 17, N 7. P. 1303–1311. doi: 10.1007/s11548-022-02587-2
- 27.** Hsiao C.H., Sun T.L., Lin P.C., et al. A deep learning-based precision volume calculation approach for kidney and tumor segmentation on computed tomography images // *Comput Methods Programs Biomed.* 2022. Vol. 221. P. 106861. doi: 10.1016/j.cmpb.2022.106861
- 28.** Hsiao C.H., Lin P.C., Chung L.A., et al. A deep learning-based precision and automatic kidney segmentation system using efficient feature pyramid networks in computed tomography images // *Comput Methods Programs Biomed.* 2022. Vol. 221. P. 106854. doi: 10.1016/j.cmpb.2022.106854
- 29.** Islam M.N., Hasan M., Hossain M.K., et al. Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography // *Sci Rep.* 2022. Vol. 12, N 1. P. 11440. doi: 10.1038/s41598-022-15634-4
- 30.** Yang L., Gao L., Arefan D., et al. A CT-based radiomics model for predicting renal capsule invasion in renal cell carcinoma // *BMC Med Imaging.* 2022. Vol. 22, N 1. P. 15. doi: 10.1186/s12880-022-00741-5
- 31.** Shehata M., Alksas A., Abouelkheir R.T., et al. A Comprehensive Computer-Assisted Diagnosis System for Early Assessment of Renal Cancer Tumors // *Sensors (Basel).* 2021. Vol. 21, N 14. P. 4928. doi: 10.3390/s21144928
- 32.** Куликовский В.Ф., Шкодкин С.В., Батищев С.А., и др. Современные представления о эпидемиологии и патогенезе уrolитиаза // Научный результат. Медицина и фармация. 2016. Т. 2, № 4. С. 4–12. EDN: NSGAXL doi: 10.18413/2313-8955-2016-2-4-4-12
- 33.** Gadzhiev N., Prosyannikov M., Malkhasyan V., et al. Urolithiasis prevalence in the Russian Federation: analysis of trends over a 15-year period // *World J Urol.* 2021. Vol. 39, N 10. P. 3939–3944. doi: 10.1007/s00345-021-03729-y
- 34.** Урология. Российские клинические рекомендации / под ред. Ю.Г. Аляева, П.В. Глыбочки, Д.Ю. Пушкаря. Москва : ГЭОТАРМедиа, 2016.
- 35.** Caglayan A., Horsanali M.O., Kocadurdu K., et al. Deep learning model-assisted detection of kidney stones on computed tomography // *Int Braz J Urol.* 2022. Vol. 48, N 5. P. 830–839. doi: 10.1590/S1677-5538.IBJU.2022.0132
- 36.** Elton D.C., Turkbey E.B., Pickhardt P.J., Summers R.M. A deep learning system for automated kidney stone detection and volumetric segmentation on noncontrast CT scans // *Med Phys.* 2022. Vol. 49, N 4. P. 2545–2554. doi: 10.1002/mp.15518
- 37.** He Z., An L., Chang Z., Wu W. Comment on “Deep learning computer vision algorithm for detecting kidney stone composition” // *World J Urol.* 2021. Vol. 39, N 1. P. 291. doi: 10.1007/s00345-020-03181-4
- 38.** Doyle P.W., Kavoussi N.L. Machine learning applications to enhance patient specific care for urologic surgery // *World J Urol.* 2022. Vol. 40, N 3. P. 679–686. doi: 10.1007/s00345-021-03738-x
- 39.** Neymark A.I., Neymark B.A., Ershov A.V., et al. The use of intelligent analysis (IA) in determining the tactics of treating patients with nephrolithiasis // *Urologia Journal.* 2023. N 3915603231162881. doi: 10.1177/03915603231162881
- 40.** Kadlec A.O., Ohlander S., Hotaling J., et al. Nonlinear logistic regression model for outcomes after endourologic procedures: a novel predictor // *Urolithiasis.* 2014. Vol. 42, N 4. P. 323–330. doi: 10.1007/s00240-014-0656-1
- 41.** Black K.M., Law H., Aldoukh A., et al. Deep learning computer vision algorithm for detecting kidney stone composition // *BJU Int.* 2020. Vol. 125, N 6. P. 920–924. doi: 10.1111/bju.15035
- 42.** Zhang G.M., Sun H., Xue H.D., et al. Prospective prediction of the major component of urinary stone composition with dual-source dual-energy CT in vivo // *Clin Radiol.* 2016. Vol. 71, N 11. P. 1178–1183. doi: 10.1016/j.crad.2016.07.012
- 43.** Chaytor R.J., Rajabu K., Jones P.A., McKnight L. Determining the composition of urinary tract calculi using stone-targeted dual-energy CT: evaluation of a low-dose scanning protocol in a clinical environment // *Br J Radiol.* 2016. Vol. 89, N 1067. P. 20160408. doi: 10.1259/bjr.20160408
- 44.** Капанадзе Л.Б., Серова Н.С., Руденко В.И. Аспекты применения двухэнергетической компьютерной томографии в диагностике мочекаменной болезни // *REJR.* 2017. Т. 7, № 3. С. 165–173. EDN: ZWBLYL doi: 10.21569/2222-7415-2017-7-3-165-173
- 45.** Cui Y., Sun Z., Ma S., et al. Automatic Detection and Scoring of Kidney Stones on Noncontrast CT Images Using S.T.O.N.E. Nephrolithometry: Combined Deep Learning and Thresholding Methods // *Mol Imaging Biol.* 2021. Vol. 23, N 3. P. 436–445. doi: 10.1007/s11307-020-01554-0
- 46.** Okhunov Z., Friedlander J.I., George A.K., et al. S.T.O.N.E. nephrolithometry: novel surgical classification system for kidney calculi // *Urology.* 2013. Vol. 81, N 6. P. 1154–1159. doi: 10.1016/j.urology.2012.10.083
- 47.** Yildirim K., Bozdag P.G., Talo M., et al. Deep learning model for automated kidney stone detection using coronal CT images // *Comput Biol Med.* 2021. Vol. 135. P. 104569. doi: 10.1016/j.compbioimed.2021.104569
- 48.** Коденко М.Р., Решетников Р.В., Макарова Т.А. Инструмент оценки качества исследований диагностической точности алгоритмов искусственного интеллекта (QUADAS-CAD) // *Digital Diagnostics.* 2022. Т. 3, № 1S. С. 4–5. EDN: KNBHOJ doi: 10.17816/DD105567
- 49.** Schwartz F.R., Clark D.P., Ding Y., Ramirez-Giraldo J.C. Evaluating renal lesions using deep-learning based extension of dual-energy FoV in dual-source CT-A retrospective pilot study // *Eur J Radiol.* 2021. Vol. 139. P. 109734. doi: 10.1016/j.ejrad.2021.109734
- 50.** Li W., Diao K., Wen Y., et al. High-strength deep learning image reconstruction in coronary CT angiography at 70-kVp tube voltage significantly improves image quality and reduces both radiation and contrast doses // *Eur Radiol.* 2022. Vol. 32, N 5. P. 2912–2920. doi: 10.1007/s00330-021-08424-5
- 51.** Bae J.S., Lee J.M., Kim S.W., et al. Low-contrast-dose liver CT using low monoenergetic images with deep learning-based denoising for assessing hepatocellular carcinoma: a randomized controlled noninferiority trial // *Eur Radiol.* 2023. Vol. 33, N 6. P. 4344–4354. doi: 10.1007/s00330-022-09298-x

AUTHORS' INFO

* **Nikolay B. Nechaev**, MD, Cand. Sci. (Medicine);
address: 24-1 Petrovka Str., Moscow, 127051, Russia;
ORCID: 0009-0007-9219-7726;
eLibrary SPIN: 3232-1545;
e-mail: NechaevNB@zdrav.mos.ru

Yuriy A. Vasilev, MD, Cand. Sci. (Medicine);
ORCID: 0000-0002-0208-5218;
eLibrary SPIN: 4458-5608;
e-mail: npcmr@zdrav.mos.ru

Anton V. Vladzymyrskyy, MD, Dr. Sci. (Medicine),
Professor;
ORCID: 0000-0002-2990-7736;
eLibrary SPIN: 3602-7120;
e-mail: VladzimirskijAV@zdrav.mos.ru

Kirill M. Arzamasov, MD, Cand. Sci. (Medicine);
ORCID: 0000-0001-7786-0349;
eLibrary SPIN: 3160-8062;
e-mail: ArzamasovKM@zdrav.mos.ru

David U. Shikhmuradov, MD;
ORCID: 0000-0003-1597-5786;
eLibrary SPIN: 9641-0913;
e-mail: ShikhmuradovDU@zdrav.mos.ru

Andrey V. Pankratov, MD;
ORCID: 0009-0008-4741-4530;
e-mail: PankratovAV3@zdrav.mos.ru

Iliya V. Ulyanov, MD;
ORCID: 0000-0002-8330-6069;
eLibrary SPIN: 5898-3242;
e-mail: UlyanovIV2@zdrav.mos.ru

Nikolay B. Nechaev, MD, Cand. Sci. (Medicine);
ORCID: 0009-0007-9219-7726;
eLibrary SPIN: 3232-1545;
e-mail: NechaevNB@zdrav.mos.ru

ОБ АВТОРАХ

* **Нечаев Николай Борисович**, канд. мед. наук;
адрес: Россия, 127051, г. Москва, ул. Петровка, д. 24, стр. 1;
ORCID: 0009-0007-9219-7726;
eLibrary SPIN: 3232-1545;
e-mail: NechaevNB@zdrav.mos.ru

Васильев Юрий Александрович, канд. мед. наук;
ORCID: 0000-0002-0208-5218;
eLibrary SPIN: 4458-5608;
e-mail: npcmr@zdrav.mos.ru

Владзимирский Антон Вячеславович, д-р мед. наук,
профессор;
ORCID: 0000-0002-2990-7736;
eLibrary SPIN: 3602-7120;
e-mail: VladzimirskijAV@zdrav.mos.ru

Арзамасов Кирилл Михайлович, канд. мед. наук;
ORCID: 0000-0001-7786-0349;
eLibrary SPIN: 3160-8062;
e-mail: ArzamasovKM@zdrav.mos.ru

Шихмурадов Давид Уружбекович,
ORCID: 0000-0003-1597-5786;
eLibrary SPIN: 9641-0913;
e-mail: ShikhmuradovDU@zdrav.mos.ru

Панкратов Андрей Вячеславович,
ORCID: 0009-0008-4741-4530;
e-mail: PankratovAV3@zdrav.mos.ru

Ульянов Илья Владимирович,
ORCID: 0000-0002-8330-6069;
eLibrary SPIN: 5898-3242;
e-mail: UlyanovIV2@zdrav.mos.ru

Нечаев Николай Борисович, канд. мед. наук;
ORCID: 0009-0007-9219-7726;
eLibrary SPIN: 3232-1545;
e-mail: NechaevNB@zdrav.mos.ru

* Corresponding author / Автор, ответственный за переписку

附录1

表1. 通过成像方法检测腹部病理的深度机器学习算法的架构和诊断指标

临床任务	作者, 年份	测试样本量	所用架构	宣布的诊断准确性指标
1	2	3	4	5
M. Maqsood等 人, 2021年[13]	4个检查	Res blocks后使用Multi-scale parallel convolution blocks的ResUNet	肝脏分割: - 戴斯相似性系数: 0.77; - 准确率: 93%	
R. Z. Khan等 人, 2022年[14]	3个检查 (Dicadb) 19个检查 (LiTS) 4个检查 (Silver07) 1个检查 (Chaos)	ResUNet。基本块有三个Conv2D串行层, 可扩展卷积核 (三种扩展速度, 即1、2和4)	1、肝脏分割, 戴斯相似性系数: - 在Dicadb数据集上: 0.97; - 在LiTS数据集上: 0.97; - 在Silver07数据集上: 0.97; - 在Chaos数据集上: 0.95。 2、肝脏肿块的分割, 戴斯相似性系数: - 在Dicadb数据集上: 0.92; - 在LiTS数据集上: 0.87	
H. Rahman等 人, 2022年[12]	4个检查	依次使用ResUNet对肝脏进行分割, 然后使用另一个ResUNet获取的数据对肿块进行分割	肝脏及其肿块的分割: - 戴斯相似性系数: 0.99; - 准确率: 99.6%	
肝脏肿块及其结构的分割				
A. Affane等 人, 2021年[15]	1个检查	3D U-Net的三种修改: 1、3D U-Net, 经典网络 2、3D MultiRes U-Net。在Skip Connection之前使用Resolution Path块。在Conv块内: 三个大小为 $3 \times 3 \times 3$ 的链接3D卷积 (第一个有32个滤波器, 后两个各有16个滤波器), 与通过Conv3D (大小为 $1 \times 1 \times 1$, 64个滤波器) 的输入数据进行合并、归一化和求和。 3、3D Dense U-Net: 在每个Conv层之后进行残差连接式合并	肝脏分割, 戴斯相似性系数: - 0.86 - 3D MultiRes U-Net; - 0.84 - 3D Dense U-Net; - 0.73 - 3D U-Net	
J. Wang等 人, 2023年[17]	8个检查 (Dicadb) 15个检查 (LiTS)	肝肿块的分割, 戴斯相似性系数: - 0.96 - LiTS数据集上的3D U-Net+LSSC+MA网络; - 0.96 - Dicadb数据集上的3D U-Net+LSSC+MA网络; - 0.92 - LiTS数据集上的3D U-Net网络; - 0.89 - Dicadb数据集上的3D U-Net网络		

续表1

	1	2	3	4	5
K. G. Kashala等人, 2020年[18]	250个检查	修改后的SqueezeNet, 是指在第2、4、6和8个块之后添加遍历, 并在expand合并之前使用Conv2D (1×1) 的模型	根据疾病分类学的肝脏肿块分类人, 2021年[20]	J. Zhou等人, 2021年[21]	154个检查
Y. Ding等人, 2022年[25]	30个检查	使用2.5D Faster R-CNN进行分割; 使用3D ResNet-18 (基于Conv3D的修改) 进行分类	M. ReLa等人, 2022年[21]	14个检查	支持向量机、k-近邻算法
Z. Lin等人, 2021年[23]	66个检查	肾脏和肿块的分割			

修改后的SqueezeNet, 是指在第2、4、6和8个块之后添加遍历, 并在expand合并之前使用Conv2D (1×1) 的模型

根据疾病分类学的肝脏肿块分类人, 2021年[20]

Y. Ding等人, 2022年[25]

Z. Lin等人, 2021年[23]

J. Zhou等人, 2021年[21]

M. ReLa等人, 2022年[21]

K. G. Kashala等人, 2020年[18]

使用2.5D Faster R-CNN进行分割; 使用3D ResNet-18 (基于Conv3D的修改) 进行分类

支持向量机、k-近邻算法

肾脏和肿块的分割

修改后的SqueezeNet, 是指在第2、4、6和8个块之后添加遍历, 并在expand合并之前使用Conv2D (1×1) 的模型

根据疾病分类学的肝脏肿块分类人, 2021年[20]

Y. Ding等人, 2022年[25]

Z. Lin等人, 2021年[23]

J. Zhou等人, 2021年[21]

M. ReLa等人, 2022年[21]

K. G. Kashala等人, 2020年[18]

支持向量机、k-近邻算法

肾脏和肿块的分割

1、支持向量机:
- 准确率: 82.5% (确定良性/恶性肿瘤时);
- 准确率: 73.4% (确定6种病理之一, 即肝细胞癌、胆管癌、转移瘤、血管瘤、增生、囊肿)
2、k-近邻算法:
- 准确率: 76.92%;
- F1分数: 0.76

1、左肾的戴斯相似性系数:
- U-Net: 0.93 - U-Net_{修改}: 0.92
2、右肾的戴斯相似性系数:
- V-Net: 0.91 - U-Net_{修改}: 0.92 - V-Net_{修改}

1、肾脏分割:
1、肾脏分割:
- 戴斯相似性系数: 0.97
2、肾脏块分割:
- 戴斯相似性系数: 0.84
3、肾囊肿分割:
- 戴斯相似性系数: 0.54

续表1

	1	2	3	4	5
肾脏和肿块的分割	C. H. Hsiao等人, 2022年[27]	90个检查	U-Net, 其中ResNet-41或EffectiveNet的架构被用作编码器模块	1、戴斯相似性系数（数据经预处理, U-Net带有编码器）： - 0.96 - EfficientNet-B7; - 0.95 - ResNet-41; - 0.95 - EfficientNet-B4; 2、戴斯相似性系数（数据未经预处理, U-Net带有编码器）： - 0.95 - EfficientNet-B4, 预训练: - 0.93 - ResNet-41; - 0.29 - EfficientNet-B4; - 0.27 - EfficientNet-B7 3、肾脏肿块的分割： 戴斯相似性系数 - 0.41 (EfficientNet-B5)	肾脏分割： 1、戴斯相似性系数（数据经预处理, U-Net带有编码器）： - 0.96 - EfficientNet-B7; - 0.95 - ResNet-41; - 0.95 - EfficientNet-B4; 2、戴斯相似性系数（数据未经预处理, U-Net带有编码器）： - 0.95 - EfficientNet-B4, 预训练: - 0.93 - ResNet-41; - 0.29 - EfficientNet-B4; - 0.27 - EfficientNet-B7 3、肾脏肿块的分割： 戴斯相似性系数 - 0.41 (EfficientNet-B5)
根据疾病分类学的肾脏和肿块的分割和分类	M. H. Islam等人, 2022年[29]	~1000张图片	C. H. Hsiao等人, 2022年[28]	56个检查 (KITTS19) EfficientNet-B5 (编码器) : Feature pyramid network (解码器)	肾脏肿块的分类： 1、VGG16结构： - 准确率: 98.2%; - F1分数平均值: 0.98; - AUC平均值: 0.99 2、Inception v3架构： - 准确率: 61.6%; - F1分数平均值: 0.59; - AUC平均值 - 0.85 3、ResNet50架构： - 准确率: 73.8%; - F1分数平均值: 0.74; - AUC平均值: 0.93 4、EANet架构： - 准确率: 77.0%; - F1分数平均值: 0.77; - AUC平均值: 0.96 5、Swin Transformers架构： - 准确率: 99.3%; - F1分数平均值: 0.99; - AUC平均值: 0.99 6、CCT架构： - 准确率: 96.5%; - F1分数平均值: 0.97; - AUC平均值: 0.99
					DOI: https://doi.org/10.17816/DD515814

续表1

	1	2	3	4	5
根据疾病分类学的肾脏和肿块的分割和分类	N. Toda等人, 2022年[24]	132个检查	用于肾脏分割的2D U-Net; 用于肿块分割和分类的3D U-Net		
X. L. Zhu等人, 2022年[26]	20个检查				
肾脏肿块及其特点的分类	M. Shehata等人, 2021年[31]	-			
在CT图片上的的尿石确定	A. Caglayan等人, 2022年[35]	-			
肾脏肿块分类:					
- 准确率: 87. 5%;					
- AUC: 0. 93					
FS-Net: 原始数据通过预训练的3D U-Net运行, 得到的掩码与原始数据相结合, 再通过预训练的3D U-Net运行。根据得到的掩码, 制作出肾脏和肾脏区域的分割数据。对分割后的数据进行纹理分析, 以提取特征。肾脏区域通过预训练的3D ResNet来提取特征。获得的特征被用于支持向量机					
1、肾脏分割: - 戴斯相似性系数: 0. 97 (KITs19); - 戴斯相似性系数: 0. 97 (自有数据集)					
2、肾脏肿块分割: - 戴斯相似性系数: 0. 79 (KITs19); - 戴斯相似性系数: 0. 77 (自有数据集)					
肾脏肿块分类, AUC:					
- 0. 76 - 在原生期; - 0. 79 - 在皮质髓质期; - 0. 77 - 在肾造影期					
使用pyradiomics库从人工分割的有肿块的肾脏中提取特征。特征通过前向传播网络运行					
从人工分割的有肿块的肾脏中区分出形态(形状评估)、纹理和功能特征。这些特征通过前向传播网络分为良性和恶性。对于恶性肿瘤, 特征通过前向传播网络来确定透明细胞癌和非透明细胞癌					
结石小于1cm: - 准确率: 85%; - F1分數: 0. 85					
结石为1-2cm: - 准确率: 89%; - F1分數: 0. 89					
结石大于2cm: - 准确率: 93%; - F1分數: 0. 93					
xResNet50					

表1结束

1	2	3	4	5
C. Daniel等人, 2022年[36]	90个检查	用于肾脏分割的3D U-Net、噪声抑制程序、 感兴趣区域剪切、用于分类的13层3D CNN	- AUC: 0.95; - 特异性: 0.91	
在CT图片上的约 尿石确定 Y. Cui等人 人, 2021年[45]	117个检查	连续使用3D U-Net架构进行肾脏分割。获得 的数据用于五个3D EU-Net架构，每个架构负 责根据S. T. O. N. E. 标度参数之一进行分类	- 戴斯相似性系数: 0.93 - 石检测: - 准确率: 90.3%; - AUC: 0.96	肾脏和静脉窦的分割:
K. Yildirim等 人, 2021年[47]	100个检查	xResNet50	- 准确率: 97% - F1分数: 0.97	