

# CT联合深度学习技术在腹部脂肪定量中的研究进展

李荣荣<sup>1</sup>, 陈海洋<sup>1</sup>, 王鸿轩<sup>1</sup>, 姬明<sup>1</sup>, 张悦<sup>2</sup>, 高春愿<sup>1\*</sup>

<sup>1</sup>临潼康复疗养中心医学影像科, 陕西 西安

<sup>2</sup>核工业417医院检验科, 陕西 西安

收稿日期: 2026年5月25日; 录用日期: 2026年6月18日; 发布日期: 2026年6月29日

## 摘要

随着代谢性疾病负担日益加重以及对肿瘤风险预测指标的重视, 腹部脂肪尤其是内脏脂肪组织和皮下脂肪组织的精准量化已成为疾病风险预测与个体化干预的关键指标。传统CT测量方法受限于主观性强、效率低下和可重复性差等问题, 难以满足临床对高通量和自动化脂肪参数提取的需求。近年来, 深度学习模型与CT的结合, 实现了CT图像中腹部脂肪组织的高精度分割与测量, 并将腹部脂肪作为代谢性疾病和肿瘤独立影像生物标志物。本文就CT联合深度学习技术在腹部脂肪测量中的进展进行综述。

## 关键词

腹部脂肪, CT, 深度学习

# Research Advances in CT Combined with Deep Learning for Abdominal Fat Quantification

Rongrong Li<sup>1</sup>, Haiyang Chen<sup>1</sup>, Hongxuan Wang<sup>1</sup>, Ming Ji<sup>1</sup>, Yue Zhang<sup>2</sup>, Chunyuan Gao<sup>1\*</sup>

<sup>1</sup>Department of Medical Imaging, Lintong Rehabilitation and Convalescent Center, Xi'an Shaanxi

<sup>2</sup>Department of Laboratory Medicine, No. 417 Hospital of Nuclear Industry, Xi'an Shaanxi

Received: May 25, 2026; accepted: June 18, 2026; published: June 29, 2026

## Abstract

With the increasing burden of metabolic diseases and the growing emphasis on tumor risk prediction

\*通讯作者。

文章引用: 李荣荣, 陈海洋, 王鸿轩, 姬明, 张悦, 高春愿. CT联合深度学习技术在腹部脂肪定量中的研究进展[J]. 临床医学进展, 2026, 16(6): 2168-2176. DOI: 10.12677/acm.2026.1662437

indicators, the accurate quantification of abdominal fat, especially visceral adipose tissue and subcutaneous adipose tissue, has become a key indicator for disease risk prediction and individualized intervention. Traditional CT measurement methods are limited by strong subjectivity and low efficiency and poor reproducibility, making it difficult to meet clinical demands for high-throughput, automated extraction of fat parameters. In recent years, the combination of deep learning models and CT has achieved high-precision segmentation and measurement of abdominal adipose tissue in CT images, and has established abdominal fat as an independent imaging biomarker for metabolic diseases and tumors. This article reviews the research progress of CT combined with deep learning technology in abdominal fat measurement.

## Keywords

Abdominal Fat, CT, Deep Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

腹部脂肪不仅是能量储存器官,更是调控代谢稳态的关键内分泌组织,其分布与功能状态与II型糖尿病、心血管疾病及肿瘤预测、治疗、复发等密切相关[1][2]。腹部脂肪主要包括皮下脂肪面积(subcutaneous fat area, SFA)、内脏脂肪面积(visceral fat area, VFA)、总脂肪面积(Total fat area, TFA)及脂肪面积比(VFA/SAT) [3]。近年来, VFA/SAT 被证实为独立于体重指数的代谢风险预测因子[4]。然而,传统基于CT的手动或半自动分割方法受限于操作者主观差异、耗时长和可重复性差等问题,难以满足大规模队列研究或日常诊疗中对高通量、标准化体成分分析的要求[5]。深度学习技术凭借其强大的图像语义理解与空间建模能力,为CT图像中脂肪组织的全自动、高精度分割提供了新范式[6]-[8]。更重要的是,深度学习不仅支持体积测量,还可挖掘各类脂肪参数与代谢综合征、肿瘤等疾病之间的潜在关联。因此,本文综述了CT联合深度学习在腹部脂肪测量中的应用及其在代谢性疾病中的研究进展。

## 2. 深度学习概述

深度学习是一类依托多层非线性神经网络的机器学习技术,其核心在于通过分层特征挖掘与端到端训练模式,直接从原始数据中自动学习复杂的内在表征,从而完成高精度的模式识别与预测任务[9][10]。在医学影像分析领域,卷积神经网络(Convolutional Neural Network, CNN)是应用最为广泛的深度学习结构,其基础架构通常包含卷积层、激活层、池化层与全连接层,卷积层负责提取影像的关键特征,池化层用于数据降维与压缩,全连接层则最终实现分类或预测输出[11]。相较于传统机器学习方法,深度学习具备自动特征学习、高维数据处理能力强和支持端到端建模等突出优势,现已在医学影像的分割、检测、识别与分类等任务中展现出强大性能与广阔应用前景。在病灶检测与早期诊断方面,深度学习模型展现出超越传统方法的灵敏度与效率,近年来,大规模应用于肺结节筛查、骨折识别等,并且显著提升影像医师的工作效率[12]。图像分割是另一核心应用,U-Net及其衍生架构成为医学影像分割的里程碑,可精准勾勒病灶边界、器官轮廓及病变范围[13],尤其是针对脑出血这类急重症患者,深度学习模型不仅能显著缩短影像医师诊断时间,并可以对脑内出血、脑室内出血和血肿周围水肿进行精确体积评估,为诊疗提供精准支撑[14]。此外,深度学习还能通过提取人眼无法量化的深层特征,实现疾病分型、良恶性鉴别

及预后风险分层,尤其是在肿瘤领域中,深度挖掘影像学与病理学、免疫学之间的联系,对肿瘤的早期预测与诊断提供有效诊疗[15][16]。

### 3. CT 图像结合深度学习模型在腹部脂肪定量中的应用

#### 3.1. CT 图像中的脂肪分割

图像分割是将影像图像按解剖结构、病变区域、组织类型等特征,自动或半自动地划分成若干个互不重叠、具有相同属性的子区域,从而实现目标区域的精准提取与边界界定[17]。准确分割腹部肌肉与脂肪是测量腹部脂肪参数的首要任务,稳定的自动分割技术是实现大样本患者队列分析并将腹部脂肪评估纳入常规临床实践的关键。相较于手动分割,CNN的引入彻底改变了腹部脂肪组织的图像分割方式。早期方法多依赖阈值分割或人工手动分割,难以应对脂肪与肌肉、肠腔内容物之间的灰度重叠问题,自2015年U-Net架构提出以来,其编码器-解码器结构配合跳跃连接机制,显著提升了医学图像分割的精度[18]。van Dijk等人基于标准二维U-Net构建了一个用于多标签分割VAT和SAT的深度学习神经网络,采用戴斯相似系数(Dice Similarity Coefficient, DSC)及林氏一致性相关系数(Lin's Concordance Correlation Coefficient, CCC)评估了2535例患者L3腹部CT图像DLNN的分割性能,结果表明该模型在约2秒内完成了单张CT图像的分割,自动分割与手动分割结果具有高度一致性,其中VAT、SAT的DSC分别为0.98及0.95;CCC分别为VAT 0.998、SAT 0.992。随着研究进展,许多研究者将U-Net适配为3D版本,以捕获跨切片的空间连续性信息。Koitka等人[19]利用3D U-Net深度学习模型对肌肉、骨骼、皮下组织、腹腔和胸腔5个身体区域进行全自动分割,在186个测试数据中,该模型平均DSC达0.9553,证明3D U-Net深度学习模型可以实现全腹部三维体成分定量分析,并作为常规临床影像的稳定生物标志物。

此外,绝大多数DL模型通过脊柱进行定位测量腹部脂肪,而对于许多没有完整脊柱CT图像,DL模型的潜力也在一步步挖掘,Dabiri[20]等人通过训练VGG-11定位网络,在1748张CT图像进行定位,L3切片定位的平均误差为 $0.87 \pm 2.54$ 。并且构建五类分割网络的CNN模型,用于分割L3切片上的骨骼肌、皮下脂肪、内脏脂肪和肌间脂肪组织,四者的量化分割精度的核心指标Jaccard系数均高达0.97~0.98。从2D到3D,从完整图像到不完整的演进不仅是技术升级,更是临床需求驱动下CT与深度学习模型的充分结合。

尽管U-Net系列模型在整体分割上表现优异,但在脂肪与肌肉交界区域(如腹壁、腰大肌周围)仍易出现误分割,尤其在肥胖或肌少症患者中更为显著。为此,研究者引入注意力机制与多尺度特征融合策略以增强边界判别能力。通道注意力模块通过学习各特征通道的重要性权重,抑制无关背景响应。例如,为解决临床体成分评估操作繁琐、分割精度不足的问题,几位研究者基于融合注意力门控模块的U-Net深度学习框架构建了AI模型,该模型分割L3段CT影像中皮下脂肪、内脏脂肪、骨骼肌面积的中位DSC系数分别达0.954、0.849、0.920,性能持平甚至优于经典U-Net模型[21][22]。

#### 3.2. 代谢综合征的筛查及预测

代谢综合征(Metabolic Syndrome, MetS)是一组临床综合征,特征包括肥胖、糖尿病、胰岛素抵抗、高血压和血脂异常,这些代谢因子相互作用,可显著增加心血管疾病和2型糖尿病的风险[23]。据统计,代谢综合征患者的死亡风险是无代谢综合征患者的两倍,心脏病或中风的风险是患者的三倍[24]。CT作为目前最常用的检查方式,如何充分利用图像中的信息来挖掘其与代谢性综合征的联系,是目前DL模型构建的方向之一。Pickhardt[25]在研究纳入7785例无症状成人,采用国际糖尿病联盟标准诊断代谢综合

征并以全自动腹部 CT 算法定量脂肪、肌肉、肝脏及主动脉钙化指标,结果显示 L1 水平总腹部脂肪诊断效能最优,以  $460.6 \text{ cm}^2$  为阈值时敏感度和特异度分别为 85.4%和 80.1%,该研究表明全自动腹部 CT 生物标志物可高效对无症状成人进行代谢综合征机会性筛查。VAT 作为代谢活跃的异位脂肪库,其体积已被多项大型前瞻性研究证实与冠状动脉钙化(Coronary Artery Calcification, CAC)进展密切相关。Magudia [26]队列研究利用深度学习算法对超过 40,000 例无症状受试者的腹部 CT 图像进行全自动 VAT 分割,发现 VAT 体积每增加 1 个标准差,5 年内 CAC 评分进展风险升高 28%,该关联独立于 BMI、腰围及传统心血管危险因素。而 Lee [27]等人基于深度学习模型全自动分析 9223 例成人腹部 CT 数据显示,VFA/SAT > 1.53 可使全因死亡风险升高至 3.1 倍,VFS >  $291 \text{ cm}^2$  则使糖尿病风险升高至 6.3 倍,且上述 CT 指标对死亡及代谢疾病的预测效能显著优于 BMI。综上,深度学习模型与 CT 图像的结合可以充分利用图像中的信息,对代谢性疾病进行筛查及预测相关风险。

### 3.3. 肿瘤风险的预测与分型

近年来,越来越多的循证医学证据揭示了腹部脂肪与肿瘤之间的深刻生物学关联。VAT 不仅是能量储存库,更是活跃的内分泌器官,在肥胖状态下可转变为慢性低度炎症的策源地。其分泌的促炎因子如白细胞介素-6 (IL-6)、肿瘤坏死因子- $\alpha$  (TNF- $\alpha$ )及瘦素显著上调,形成有利于肿瘤发生发展的微环境。与内脏脂肪的促炎特性不同,SAT 在生理状态下主要分泌具有抗炎和胰岛素增敏作用的脂肪因子,如脂联素和内脂素的低表达形式。脂联素可通过 AMPK 通路抑制 mTOR 活性,降低肿瘤细胞代谢速率,并增强肿瘤化疗敏感性[28]。因此,腹部脂肪分布与各种肿瘤的侵袭性、治疗、愈后以及复发密切相关,对其进行精确定量,并将其与肿瘤特征相结合进行综合评估,是肿瘤风险分层、预后预测和治疗决策全新方向。近年来,基于术前腹部 CT 平扫图像定量分析 VAT/SAT 比值,已被证实为结直肠癌患者术后复发和总生存期的重要预测因子。例如,一项纳入 327 例 I~III 期结直肠癌患者的队列研究发现,V/S 比值较高的患者复发风险约是低 V/S 比患者的 1.93 倍,且高 V/S 比患者的无病生存期显著低于较低的 V/S 比值患者[29]。该指标独立于 TNM 分期、BMI 等传统预后因素。Miao [30]等人构建多模态多任务深度学习框架 GAST-NET,将胃癌 CT 肿瘤特征、内脏脂肪定量特征与临床信息融合,实现术前同步预测神经侵犯与 5 年预后风险,在内部测试集神经侵犯预测曲线下面积(Area under the Curve, AUC)达 0.923,外部测试集 AUC 分别为 0.868 与 0.871,预后风险预测 AUC 达 0.873,充分证实 CT 定量脂肪特征联合深度学习可高效挖掘非肿瘤影像信息,为胃癌术前精准侵袭风险与预后评估提供支持。

Mantz [31]等人研究采用全自动 CT 量化分析技术,对 87 例老年侵袭性非霍奇金淋巴瘤患者治疗前 L3 水平 CT 进行肌肉与脂肪成分测量,结果显示皮下脂肪指数 z 值越高,治疗毒性风险越高,充分证明了 CT 联合自动化深度学习量化可精准提取身体成分影像标志物,从而为淋巴瘤患者治疗毒性预测提供客观、高效的影像学评估手段。另一项研究表明[31],VAT 值越高,高级别四肢软组织肉瘤患者总生存期越低。Lai 等人[32]采用深度学习 U-Net++模型对 227 例 III 期胃癌患者进行 CT 身体成分自动化量化,结果显示该方法与手动分割一致性极高( $r^2 > 0.85$ ),高 VAT/SAT 值可独立预测不良生存,并揭示其背后的免疫代谢机制,为肿瘤预后预测提供强有力的智能化评估工具。Yu 等人[33]在研究纳入 325 例非肌层浸润性膀胱癌患者,基于 CT 联合深度学习构建(VAT)放射组学模型,结果显示 VAT 模型在多中心验证中 AUC 达 0.808~0.853,显著优于皮下脂肪模型( $P < 0.001$ ),且 VAT 放射组学特征是早期复发最强独立预测因子,融合临床因素后 AUC 最高达 0.938,充分证明 CT 联合深度学习可从内脏脂肪中挖掘高价值放射组学标志物,为膀胱癌术后早期复发提供精准、无创和可推广的预测工具。

简而言之,通过深度学习自动分割和量化腹部脂肪,并将其与肿瘤相关指标结合,可以构建有效的预测模型,从而用于评估肿瘤患者的生存率和疾病进展风险等指标。

## 4. 关键挑战与新兴解决方案

尽管 CT 联合深度学习在腹部脂肪定量领域已取得突破性进展,但从研究走向大规模临床常规应用仍面临多重瓶颈,包括跨中心数据异质性导致的领域偏移、深度学习模型“黑箱”特性引发的临床可信度不足、像素级标注数据稀缺的成本瓶颈以及医疗数据隐私保护的刚性约束。近年来,针对上述问题的新兴技术体系不断完善,为推动技术临床转化提供了关键支撑。

### 4.1. 应对领域偏移的数据增强与归一化技术

腹部 CT 图像的领域偏移是制约模型泛化能力的首要因素,主要源于不同医疗机构使用的 CT 设备品牌(GE、西门子、飞利浦等)、扫描参数(管电压、管电流、重建算法)、扫描层厚及患者体位的差异,导致图像灰度分布、噪声水平和组织对比度存在显著差异,使得单中心训练的模型在跨中心测试时性能下降。针对这一问题,数据增强技术[34]通过对训练数据进行多样化变换扩大分布覆盖范围,基础方法包括几何变换(旋转、平移、缩放、弹性形变)和强度变换(对比度调整、高斯噪声添加、灰度值截断)。生成式对抗网络(GAN)的应用进一步提升了数据增强的效果。此外,基于深度学习的域自适应方法成为研究热点,对抗域自适应通过引入域判别器,引导模型学习域不变特征;自监督域自适应则利用无标注数据预训练通用特征提取器,显著提升模型在未知域的性能。

### 4.2. 提高模型可信度的可解释 AI 方法

深度学习模型的“黑箱”特性是临床转化的核心障碍之一,临床医师无法理解模型的决策依据,难以对分割结果和预测结论建立信任,同时也给医疗责任认定带来困难。可解释人工智能技术通过揭示模型的内部决策过程,为模型的临床应用提供可信度保障。

在腹部脂肪定量领域,类激活图(Class Activation Mapping, CAM)及其衍生方法(Grad-CAM, Grad-CAM++)是应用最广泛的可视化技术[35],可生成热力图直观展示模型在分割和预测任务中关注的图像区域。例如,在直肠癌预测模型中,Grad-CAM 决策区域与逻辑回归分析识别的独立预后因素相符。与已知的生物学机制高度一致,验证了内脏脂肪是腹膜转移早期检测直肠癌患者有意义影像生物标志物。特征重要性分析方法可量化不同脂肪参数(VFA, SFA, VFA/SAT)对疾病预测结果的贡献度,帮助临床医师理解模型的预测逻辑。不确定性估计技术则可评估模型预测结果的置信度,在脂肪与肌肉交界等易误分割区域标记高不确定性,提示临床医师进行人工复核,进一步提升临床应用的安全性。

### 4.3. 减少标注依赖的弱监督与自监督学习范式

全监督深度学习模型的训练依赖大量像素级标注数据,而腹部脂肪的像素级标注需要资深影像医师逐张勾画,观察者间的差异成为制约大规模模型训练的核心瓶颈。弱监督和自监督学习范式通过降低对标注数据的依赖,为解决这一问题提供了有效途径[36]。

弱监督学习利用图像级标注、点标注或框标注等低成本标注信息训练模型,例如仅需标注图像中是否存在内脏脂肪过多,即可通过注意力机制引导模型学习脂肪区域的特征。半监督学习结合少量标注数据和大量无标注数据,通过一致性正则化、伪标签等方法提升模型性能。自监督学习作为当前研究热点,通过设计对比学习、掩码图像建模等预训练任务,从海量无标注医学影像中学习通用的解剖结构和纹理特征,再在少量标注数据上进行微调。

### 4.4. 保护数据隐私的联邦学习

医疗数据包含患者的敏感个人信息,受法律法规的严格约束,多中心数据共享面临巨大的法律和伦

理障碍, 导致传统集中式训练模式难以构建泛化能力强的大规模模型。联邦学习(Federated Learning, FL)作为一种分布式机器学习框架, 实现了“数据不出本地, 模型参数共享”, 在保护数据隐私的前提下完成多中心联合建模。

为解决腹部脂肪定量领域数据隐私问题, 横向联邦学习是最常用的架构[37], 多个参与机构在本地使用自有数据训练模型, 仅将模型参数或梯度更新上传至中央服务器进行聚合, 再将聚合后的全局模型下发至各机构迭代训练。针对多中心数据非独立同分布问题, 联邦平均(Federated Averaging, FedAvg)的改进版本(如 FedProx、FedBN)可有效提升模型性能。此外, 将联邦学习与差分隐私、同态加密技术结合, 可在模型参数传输过程中加入噪声或进行加密处理, 进一步增强数据隐私保护能力。

## 5. 小结与展望

CT 联合深度学习技术正深刻重塑腹部脂肪参数的测量范式, 从传统依赖人工勾画的低效模式迈向全自动、高精度、高通量的智能分析体系。以 3D U-Net 和注意力增强型卷积网络为代表的算法不仅实现了 VAT 与 SAT 的精准分割, 而且可以构建预测模型, 与代谢性疾病、肿瘤等相结合, 形成从图像分割 - 数据测量 - 模型预测一体化的智能 AI 工具, 为影像学领域开辟新的研究途径与方向。然而, 该技术的临床转化仍面临严峻挑战, 如小样本训练导致的模型偏差、跨中心领域偏移、模型可解释性不足、标注数据稀缺以及数据隐私保护等问题, 共同制约其在临床工作中的常规应用。未来, 需通过技术创新与体系建设相结合, 系统推进该技术的临床转化落地。

### 5.1. 构建标准化、多中心、多设备的大规模公共数据集

高质量、标准化的数据集是 AI 模型研发和验证的基础。应推动建立标准的腹部脂肪定量医学影像公共数据集, 纳入不同年龄段、性别、BMI 范围(偏瘦、正常、超重、肥胖)及不同疾病状态(代谢综合征、肿瘤、肌少症等)的人群样本, 覆盖主流 CT 设备品牌、不同扫描参数和重建算法。数据集的标注需制定统一的解剖学标准, 由至少 2 名资深影像医师独立勾画并交叉验证, 建立金标准。同时, 建立数据共享与管理机制, 对数据进行严格的去标识化处理, 符合医疗数据隐私保护法规要求, 为全球研究者提供开放、可复用的研究资源。

### 5.2. 设计前瞻性临床试验以验证 AI 模型临床价值的标准

AI 模型的临床价值需通过严格的前瞻性临床试验进行验证, 应采用多中心、随机对照研究设计, 明确主要研究终点(如脂肪定量的准确性、影像医师工作效率提升、临床决策时间缩短、患者预后改善等)和次要研究终点(如模型的鲁棒性、可重复性、不良事件发生率)。试验需纳入不同层级医疗机构的患者, 评估模型在真实临床场景中的性能。同时, 建立统一的模型评估指标体系, 除传统的分割精度指标(DSC、Jaccard 系数)外, 还应纳入临床相关性指标, 如疾病预测的 AUC、灵敏度、特异度等, 全面评价模型的临床应用价值。

### 5.3. 探讨与现有临床 workflow(PACS/RIS)的无缝整合方案

AI 模型的临床应用需与医院现有的信息系统深度融合, 避免增加临床医师的工作负担。应开发符合 DICOM 标准的 AI 接口, 实现与 PACS/RIS 系统的无缝对接: 患者完成腹部 CT 扫描后, 图像自动传输至 AI 分析服务器, 模型自动定位目标层面(如 L3 椎体层面)、分割脂肪组织、计算 VFA、SFA、TFA 及 VFA/SAT 等关键参数, 生成结构化的定量报告并回传至 PACS/RIS 系统。同时, 提供便捷的手动修正功能, 允许影像医师对分割结果进行调整和确认, 确保报告的准确性。此外, 应支持将脂肪定量参数与患

者的其他临床信息(如血糖、血脂、肿瘤分期)整合,为临床决策提供全面的参考依据。

#### 5.4. 完善医疗器械软件(SaMD)监管审批流程

腹部脂肪定量 AI 软件属于第二类医疗器械软件,需通过国家药品监督管理局的注册审批方可上市。注册申报需提交完整的技术资料,包括软件需求规格说明书、算法设计与验证报告、性能评估报告、临床试验数据、风险管理报告等。对于采用深度学习技术的 AI 软件,还需重点提交算法可解释性、鲁棒性、更新维护机制及数据安全保护的相关资料。监管部门应加快建立针对医学 AI 软件的快速审批通道,鼓励创新技术的临床转化,同时加强上市后监管,确保产品的安全性和有效性。

综上,随着技术的不断进步和临床转化体系的逐步完善,CT 联合深度学习的腹部脂肪定量技术有望在不久的将来纳入常规临床诊疗流程,为代谢性疾病和肿瘤的早期预警、风险分层与个体化干预提供坚实的影像学支撑。

#### 参考文献

- [1] Zhou, H., Li, T., Li, J., Zhuang, X. and Yang, J. (2024) The Association between Visceral Adiposity Index and Risk of Type 2 Diabetes Mellitus. *Scientific Reports*, **14**, Article No. 16634. <https://doi.org/10.1038/s41598-024-67430-x>
- [2] Shuster, A., Patlas, M., Pinthus, J.H. and Mourtzakis, M. (2012) The Clinical Importance of Visceral Adiposity: A Critical Review of Methods for Visceral Adipose Tissue Analysis. *The British Journal of Radiology*, **85**, 1-10. <https://doi.org/10.1259/bjr/38447238>
- [3] Kandi, S.R., Khera, R., Rajagopalan, S. and Neeland, I.J. (2025) AI in Adipose Imaging: Revolutionizing Visceral Adipose Tissue, Ectopic Fat, and Cardiovascular Risk Assessment. *Current Atherosclerosis Reports*, **27**, Article No. 101. <https://doi.org/10.1007/s11883-025-01356-1>
- [4] Lee, M., Wu, Y. and Fried, S.K. (2013) Adipose Tissue Heterogeneity: Implication of Depot Differences in Adipose Tissue for Obesity Complications. *Molecular Aspects of Medicine*, **34**, 1-11. <https://doi.org/10.1016/j.mam.2012.10.001>
- [5] Parikh, A.M., Coletta, A.M., Yu, Z.H., Rauch, G.M., Cheung, J.P., Court, L.E., et al. (2017) Development and Validation of a Rapid and Robust Method to Determine Visceral Adipose Tissue Volume Using Computed Tomography Images. *PLOS ONE*, **12**, e0183515. <https://doi.org/10.1371/journal.pone.0183515>
- [6] van Dijk, D.P.J., Volmer, L.F., Brecheisen, R., et al. (2024) External Validation of a Deep Learning Model for Automatic Segmentation of Skeletal Muscle and Adipose Tissue on Abdominal CT Images. *British Journal of Radiology*, **97**, 2015-2023.
- [7] Lee, Y.S., Hong, N., Witanto, J.N., Choi, Y.R., Park, J., Decazes, P., et al. (2021) Deep Neural Network for Automatic Volumetric Segmentation of Whole-Body CT Images for Body Composition Assessment. *Clinical Nutrition*, **40**, 5038-5046. <https://doi.org/10.1016/j.clnu.2021.06.025>
- [8] Weston, A.D., Korfiatis, P., Kline, T.L., Philbrick, K.A., Kostandy, P., Sakinis, T., et al. (2019) Automated Abdominal Segmentation of CT Scans for Body Composition Analysis Using Deep Learning. *Radiology*, **290**, 669-679. <https://doi.org/10.1148/radiol.2018181432>
- [9] Chen, X., Wang, X., Zhang, K., Fung, K., Thai, T.C., Moore, K., et al. (2022) Recent Advances and Clinical Applications of Deep Learning in Medical Image Analysis. *Medical Image Analysis*, **79**, Article 102444. <https://doi.org/10.1016/j.media.2022.102444>
- [10] Zhou, T., Cheng, Q., Lu, H., Li, Q., Zhang, X. and Qiu, S. (2023) Deep Learning Methods for Medical Image Fusion: A Review. *Computers in Biology and Medicine*, **160**, Article 106959. <https://doi.org/10.1016/j.combiomed.2023.106959>
- [11] Anwar, S.M., Majid, M., Qayyum, A., Awais, M., Alnowami, M. and Khan, M.K. (2018) Medical Image Analysis Using Convolutional Neural Networks: A Review. *Journal of Medical Systems*, **42**, Article No. 226. <https://doi.org/10.1007/s10916-018-1088-1>
- [12] 付姣慧, 常晓丹, 沙俏丽, 等. 2011 年-2020 年深度学习用于医学影像学研究文献分析[J]. *中国介入影像与治疗学*, 2022, 19(1): 53-57.
- [13] Minaee, S., Boykov, Y.Y., Porikli, F., Plaza, A.J., Kehtarnavaz, N. and Terzopoulos, D. (2021) Image Segmentation Using Deep Learning: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **44**, 3523-3542. <https://doi.org/10.1109/tpami.2021.3059968>
- [14] Wilting, F.N.H., Douwes, J.P.J., Patel, A., Schreuder, F.H.B.M., Dammers, R., Hannink, G., et al. (2026) Deep Learning-

- Based Automated Segmentation of Intracerebral Haemorrhage, Intraventricular Haemorrhage and Perihematoma Oedema on Non-Contrast CT. *European Stroke Journal*, **11**, aakag007. <https://doi.org/10.1093/esj/aakag007>
- [15] Li, Z., Cai, R., Qin, Y., Liao, X., Wang, E., Wu, X., *et al.* (2026) Integration of Radiomics, Deep Learning, Transcriptomics, and Metabolomics Reveals Prognostic Risk Stratification and Underlying Biological Mechanisms in Colorectal Cancer. *NPJ Precision Oncology*, **10**, Article No. 155. <https://doi.org/10.1038/s41698-026-01331-2>
- [16] Popescu, D.-C. and Găman, M.-A. (2025) Artificial Intelligence for Risk Stratification in Diffuse Large B-Cell Lymphoma: A Systematic Review of Classification Models and Predictive Performances. *Medical Sciences*, **13**, Article 280. <https://doi.org/10.3390/medsci13040280>
- [17] 孙淑婷, 刘铖彬, 周广茵, 等. 图像分割算法在医学图像中的应用综述[J]. 现代仪器与医疗, 2024, 30(2): 59-68.
- [18] Azad, R., Aghdam, E.K., Rauland, A., Jia, Y., Avval, A.H., Bozorgpour, A., *et al.* (2024) Medical Image Segmentation Review: The Success of U-Net. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **46**, 10076-10095. <https://doi.org/10.1109/tpami.2024.3435571>
- [19] Koitka, S., Kroll, L., Malamutmann, E., Oezcelik, A. and Nensa, F. (2021) Fully Automated Body Composition Analysis in Routine CT Imaging Using 3D Semantic Segmentation Convolutional Neural Networks. *European Radiology*, **31**, 1795-1804. <https://doi.org/10.1007/s00330-020-07147-3>
- [20] Dabiri, S., Popuri, K., Ma, C., Chow, V., Feliciano, E.M.C., Caan, B.J., *et al.* (2020) Deep Learning Method for Localization and Segmentation of Abdominal CT. *Computerized Medical Imaging and Graphics*, **85**, Article 101776. <https://doi.org/10.1016/j.compmedimag.2020.101776>
- [21] Shen, H., He, P., Ren, Y., Huang, Z., Li, S., Wang, G., *et al.* (2023) A Deep Learning Model Based on the Attention Mechanism for Automatic Segmentation of Abdominal Muscle and Fat for Body Composition Assessment. *Quantitative Imaging in Medicine and Surgery*, **13**, 1384-1398. <https://doi.org/10.21037/qims-22-330>
- [22] Zhang, L., Li, J., Yang, Z., Yan, J., Zhang, L. and Gong, L. (2024) The Development of an Attention Mechanism Enhanced Deep Learning Model and Its Application for Body Composition Assessment with L3 CT Images. *Scientific Reports*, **14**, Article No. 28953. <https://doi.org/10.1038/s41598-024-79915-w>
- [23] Zhao, J., An, X., Liu, L., Meng, J., Liu, L. and Mu, Y. (2026) Construction and Validation of a Risk Prediction Model for Metabolic Syndrome: A Cross-Sectional Study Based on Randomized Sampling. *Frontiers in Endocrinology*, **16**, Article 1761342. <https://doi.org/10.3389/fendo.2025.1761342>
- [24] Isomaa, B., Almgren, P., Tuomi, T., Forsén, B., Lahti, K., Nissén, M., *et al.* (2001) Cardiovascular Morbidity and Mortality Associated with the Metabolic Syndrome. *Diabetes Care*, **24**, 683-689. <https://doi.org/10.2337/diacare.24.4.683>
- [25] Pickhardt, P.J., Graffy, P.M., Zea, R., Lee, S.J., Liu, J., Sandfort, V., *et al.* (2021) Utilizing Fully Automated Abdominal CT-Based Biomarkers for Opportunistic Screening for Metabolic Syndrome in Adults without Symptoms. *American Journal of Roentgenology*, **216**, 85-92. <https://doi.org/10.2214/ajr.20.23049>
- [26] Magudia, K., Bridge, C.P., Bay, C.P., Farah, S., Babic, A., Fintelmann, F.J., *et al.* (2023) Utility of Normalized Body Composition Areas, Derived from Outpatient Abdominal CT Using a Fully Automated Deep Learning Method, for Predicting Subsequent Cardiovascular Events. *American Journal of Roentgenology*, **220**, 236-244. <https://doi.org/10.2214/ajr.22.27977>
- [27] Lee, M.H., Zea, R., Garrett, J.W., Summers, R.M. and Pickhardt, P.J. (2024) AI-Based Abdominal CT Measurements of Orthotopic and Ectopic Fat Predict Mortality and Cardiometabolic Disease Risk in Adults. *European Radiology*, **35**, 520-531. <https://doi.org/10.1007/s00330-024-10935-w>
- [28] Yan, S.Y., Yang, Y.W., Jiang, X.Y., Hu, S., Su, Y.Y., Yao, H., *et al.* (2023) Fat Quantification: Imaging Methods and Clinical Applications in Cancer. *European Journal of Radiology*, **164**, Article 110851. <https://doi.org/10.1016/j.ejrad.2023.110851>
- [29] Zhou, H., Tian, L., Wu, Y. and Liu, S. (2024) Computed Tomography-Measured Body Composition Can Predict Long-Term Outcomes for Stage I-III Colorectal Cancer Patients. *Frontiers in Oncology*, **14**, Article ID: 1420917. <https://doi.org/10.3389/fonc.2024.1420917>
- [30] Miao, S., Dong, H., Feng, J., Jiang, Y., Sun, M., Liu, Z., *et al.* (2026) GAST-NET: A Multi-Modal and Multi-Task Deep Learning Framework for Preoperative Prediction of Perineural Invasion and Prognostic Risk in Gastric Cancer. *International Journal of Medical Informatics*, **212**, Article 106348. <https://doi.org/10.1016/j.ijmedinf.2026.106348>
- [31] Mantz, L., Johnson, P.C., Lei, M., Newcomb, R.A., Stacey, J., Yang, D., *et al.* (2026) Exploratory Association of Muscle and Adipose Tissue Indices with Clinical Outcomes in Aggressive Lymphomas. *Cancer*, **132**, e70313. <https://doi.org/10.1002/cncr.70313>
- [32] Lai, Y.-C., Lin, Y.-C., Tai, T.-S., *et al.* (2026) Deep Learning-Derived CT Body Composition Enhances Survival Risk Stratification beyond the TNM System in Locally Advanced Gastric Cancer: A Multi-Modality Cohort Study. *International Journal of Surgery*.
- [33] Yu, N., Li, J., Cao, D., Chen, X., Yang, D., Jiang, N., *et al.* (2025) CT-Based Radiomics Signature of Visceral Adipose

Tissue for Prediction of Early Recurrence in Patients with NMIBC: A Multicentre Cohort Study. *International Journal of Surgery*, **111**, 9457-9470. <https://doi.org/10.1097/js9.0000000000003140>

- [34] 赵阳. 基于深度学习的三维医学影像分割方法研究[D]: [博士学位论文]. 北京: 中国科学院大学(中国科学院大学工程科学学院), 2024.
- [35] Miao, S., Sun, M., Zhang, B., Jiang, Y., Xuan, Q., Wang, G., *et al.* (2025) Multimodal Deep Learning: Tumor and Visceral Fat Impact on Colorectal Cancer Occult Peritoneal Metastasis. *European Radiology*, **35**, 4522-4532. <https://doi.org/10.1007/s00330-025-11450-2>
- [36] 仙同胜, 肖晴. 基于跨模态自监督预训练的 U-Net 弱监督分割性能提升[J]. 信息记录材料, 2026, 27(7): 45-47.
- [37] 张畅. 横向联邦学习性能优化研究及其在医疗健康领域的应用[D]: [博士学位论文]. 北京: 北京科技大学, 2024.