

CT 深度学习图像重建技术在肺结节诊断的应用进展

王成¹, 戚聪聪¹, 赵慧²

1 台州市立医院 (浙江台州 317700); 2 浙江省台州医院 (浙江台州 318050)

〔摘要〕肺癌是目前全球死亡率最高的癌症,肺结节的良恶性诊断、鉴别是肺癌早期诊断与治疗、降低患者死亡风险的关键环节。深度学习图像重建(DLIR)技术是当前国内外医学影像领域的研究热点,能够在低辐射剂量条件下降噪、改进图像纹理、减少伪影,生成高质量图像,已广泛应用于多种疾病诊断及辅助分析。随着 DLIR 技术的不断进步及模型泛化性的提升,其基于计算机断层扫描(CT)数据定量分析可在短时间内精准评估肺结节的生物学行为,对 CT 影像进行重建与解读,从而对病变性质等进行预测,且所获得的图像质量、图像可重复性、准确性明显优于传统重建图像,在一定程度上可避免对可疑肺结节的漏诊。本研究旨在介绍 CT 的 DLIR 在肺结节诊断的应用现状,并对其发展趋势进行展望。

〔关键词〕深度学习图像重建;肺结节;计算机断层扫描

〔中图分类号〕R563 **〔文献标识码〕**A **〔文章编号〕**1002-2376(2025)09-0161-04

〔DOI〕10.3969/j.issn.1002-2376.2025.09.047

肺结节是指肺内直径 ≤ 3 cm 的类圆形或不规则病灶,在计算机断层扫描(computed tomography, CT)上表现为高亮与阴影,边缘不规则或光滑^[1]。肺结节多呈良性,但少数可能为早期肺癌表现,因此早期肺结节的鉴别诊断和治疗肺癌、改善患者预后意义重大。目前临床多以胸部 CT 进行肺结节筛查及诊断^[2]。但常规影像诊断凭借医师自身经验,需要人工阅片及勾勒病灶区域,存在主观性强、重复性低及定量分析不足等问题,且重建的 CT 噪声严重、图像质量不佳,对于恶性征象不明显的微小结节,有一定的漏诊和误诊风险^[3-5]。随着人工智能技术的进步,深度学习图像重建(deep learning image reconstruction, DLIR)技术在肺癌的诊断与筛查中表现出良好效能^[6]。DLIR 基于卷积神经网络(convolutional neural network, CNN),可模拟人脑自动学习数据特征的机制,通过训练识别信号、噪声,能够在降低辐射剂量的同时改进图像纹理、减少伪影,生成高质量图像,并自动学习、提取并鉴别图像上的主要特征^[7]。基于此,本研究对 CT DLIR 技术在肺结节诊断中的应用进行综述,并对其面临的挑战与未来发展趋势进行展望,以期为该技术的临床应用与优化提供参考。

1 DLIR 技术

1.1 DLIR 技术定义及优势

LeCun 等^[7]于 2006 年首先提出 DLIR 概念,

其属于机器学习的一个新的分支,旨在通过模拟人脑自动地学习数据各个层次的抽象特征,从而更好地反映数据的本质特征。DLIR 技术采用人工神经网络结构,由多个输入、输出和隐藏层构成,在分类、计算机视觉、物体识别和医学图像分析等方面获得显著成果。DLIR 技术基于 CNN,其中常用的深度学习方法有二维卷积神经网络(two dimension CNN, 2D-CNN)、三维卷积神经网络(three dimension CNN, 3D-CNN)和更快速的区域卷积神经网络(faster regions CNN, Faster R-CNN)。DLIR 算法于 2019 年推出,已获得美国食品药品监督管理局批准,并在全球范围内投入临床使用^[8]。在 CT 影像重建领域,DLIR 技术实现了从噪声严重的低剂量 CT 数据中重建高质量图像的重大突破^[9]。与传统算法相比,DLIR 技术具有 3 大核心优势:(1)通过端到端的训练方式,DLIR 技术能够更有效地分离真实信号与噪声,在相同辐射剂量下可获得显著更优的图像质量;(2)DLIR 技术采用特殊的网络结构设计(如跳跃连接、注意力机制等),能够更好地保留图像纹理细节和微小结构特征,CNN 通过分层特征提取从 CT 图像中识别结节恶性征象,为诊断提供形态学依据;(3)DLIR 技术具备自动特征提取和学习能力,可以从海量临床数据中学习肺结节的形态学特征和演变规律,为临床诊断提供客观、量化的决策支持。DLIR 技术不仅可以缩短诊断时间,提高影像医师的工作效率,而且可以进

收稿日期:2024-10-31

行自我学习,不断地优化读片的效率,减少对可疑肺结节的漏诊。例如,在冠状动脉钙化评分研究中,DLIR-H(高等级重建)在管电流增加时,标准偏差(HU)较传统滤波反投影(FBP)降低40%~60%,尤其在低剂量条件下优势更为显著^[10]。

1.2 DLIR 技术发展的关键数据集

近年来,肺部图像数据库联盟与图像数据库资源计划(lung image database consortium and image database resource initiative, LIDC-IDRI)、2017 年数据科学杯(data science bowl 2017, DSB)的举办和举办为 DLIR 技术在肺部疾病诊断领域的研究提供了大量专家标注的肺部 CT 影像数据,为推动肺结节检测和分类研究的发展奠定了坚实的基础。LIDC-IDRI 是最具代表性的公用肺结节数据库,共计 244 527 张影像,包括 1 010 名患者的 1 018 次 CT 影像扫描^[11]。该数据集可从患者和结节两个层面诊断肺部病变,研究者可通过此数据集中进行 CNN 及其改进模型的训练与测试。但由于 LIDC-IDRI 数据来源由多个厂家共同合作提供,不同仪器扫描参数不同,因此影像中切片厚度和像素间距不一致。DSB 数据集由 2 101 例高风险患者胸腔的轴向低剂量 CT 扫描图像组成,图像数据以高分辨率 DICOM 格式储存^[12]。DSB 数据集没有对结节位置、大小等信息的标注,仅提供了 CT 扫描图像具体参数、受试者是否为肺癌的二元标签等信息。该数据集旨在提示患者扫描后 1 年内是否被诊断为癌症,目前该数据集因使用限制并未公开使用。

1.3 DLIR 技术性能评估指标

科学评估 DLIR 技术性能需借助多维度评测指标。灵敏度(真阳性率)与特异度(真阴性率)用于衡量算法识别阳性病例与排除阴性病例的能力,量化模型区分良恶性结节的能力,二者的平衡是提升诊断准确度的关键。受试者工作特征(receiver operating characteristic, ROC)曲线可直观呈现算法性能,ROC 曲线下面积(area under the curve, AUC)值越接近 1 表明算法诊断效能越高,而 3D-CNN 模型 AUC 为 0.92~0.97,表明其诊断效能较高^[13]。F1 值为综合考虑精确率和召回率的综合评估指标,可有效避免数据不平衡导致的评估偏差。在肺炎分类任务中,结合注意力机制的 CNN 模型 F1 分数为 0.91,但 ROC 曲线表示其在微小结节检测中仍存在假阳性瓶颈^[14]。这些指标从不同角度全面评估 DLIR 技术,为其改进与临床应用提供可靠依据。

2 基于 CT 的 DLIR 技术在肺结节诊断中的应用

2.1 DLIR 技术在肺结节检出与分割中的应用

医学图像分割是图像分析和解译的重要前提,

但是由于肺结节形状特征多样,周围结构和纹理特征复杂、图像噪声干扰等问题,难以实现自动、精准的医学图像分割。随着 Kaggle 提供了一个公开的数据集,研究人员据此进行大量相关实验,提出了多种深度学习算法,均取得一定成果。深度学习具有自动学习、提取并鉴别图像上肺结节主要特征的能力,和传统图像分割方法比较,其分割性能更显著。CNN 算法被认为是深度学习的领先模型,从单网络分割方法中的 2D-CNN、3D-CNN 发展到多网络分割中的级联路径 CNN、双路径 CNN,再发展到更快速的 Faster R-CNN、无监督学习算法等^[15]。随着 DLIR 技术的持续改进与发展,在肺结节检测与分割、假阳性降低、肺结节分类等方面均取得了一定成果。

CNN 是 DLIR 技术应用于 CT 诊断肺结节的典型技术,主要由池化层、卷积层、全连接层构成,通过重复地对图像自动进行特征提取,不断改进所提取的特征,并对特征加以分类,从而实现自动识别出肺结节,该技术的引入能够提高肺结节的检出率^[16]。肺结节分割方法发展过程中,单网络、多网络及 Faster R-CNN 是肺结节主要的分割方法。2D-CNN 及 3D-CNN 单网络分割方法是早期肺结节分割的常用深度学习方法。相较于 2D-CNN,3D-CNN 具有能够利用 CT 图像的空间特征信息优势,分割效果更为明显。多网络肺结节分割方法是一类通过级联路径和双路径的 CNN,将多个基础网络进行串联或并行,以提取更多肺结节特征,从而实现肺结节的精准分割。Faster R-CNN 是在端对端目标检测框架基础上,通过改进原来目标检测的网络结构获得,检测速度快、精度高^[17]。

YU 等^[18]在残差学习和 U-Net 结构基础上,构建三维 Res U-Net 网络模型,更有效地识别小结核,并提高了大结核的分割精度。YUAN 等^[19]建立了 3D-CNN 模型,通过分层结构有效地提取空间信息,精确识别肺结节的形状、大小及背景信息,有效减少假阳性肺结节。孟祥鹿等^[20]建构了 3D-CNN 和递归神经网络的 DLIR 技术相结合的模型,在 LIDC-IDRI 数据集上进行测试,对三种 CT 重建算法(肺重建、纵膈重建和骨重建)图像均表现出稳定的分割与分类效果。ZHAO 等^[20]提出了 3D-CNN 肺结节检测网络,以提取不同尺度的相应特征,挖掘空间和通道特征间的关联信息,对特征进行加强,显著提高了检测灵敏度,有利于目标定位与分类。王梦南等^[21]提出一种基于可变形 CNN,在 LUNA16 数据集和合作医院临床数据集进行测试,和 2D-CNN、单尺度及多尺度 3D-CNN 等

方法比较, CPM 评分更高。肺结节假阳性降低框架, 有很好的泛化能力, 能有效降低结节假阳性。尽管肺结节检测模型不断优化, 但仍存在局限性, 对于直径较大或较小、与周围肺实质密度接近、形状不规则、背景复杂的肺结节以及不同种类肺结节检出与分割有待提升。

2.2 DLIR 技术在肺结节分类中的应用

在完成肺结节的检出与分割后, 仍需进一步判断其良恶性进行分类, 基于 CAD 系统对肺结节良恶性分类是早期诊断肺癌的关键步骤, 常用 DLIR 方法包括无监督学习方法(如栈式去噪自编码器、深度置信网络、深度置信网络等)、有监督学习方法(如 CNN 等)及迁移学习等。临床多以肺结节大小、形状、空洞、钙化程度等形态学特征指标判断其良恶性, 近年来, 研究者为了改善肺结节良恶性分类做出了许多尝试。王传彬等^[22]基于 CT 临床放射组学列线图与 DLIR CNN 对常见的良性(肺错构瘤)和恶性肿瘤(肺腺癌)进行鉴别, 发现后者的鉴别价值更优, 其在训练集和内、外部验证集中的曲线下面积均较高, 但无统计学差异。MIAO 等^[23]研究基于深度学习的 CT 图像对含胸内脂肪的肺结节进行分类, 将精确划定肺结节内和结节周围区域的分割方法和深度学习下胸内脂肪特征相结合, 诊断效能更优, 可精确分类肺结节良性或恶性。AFSHAR 等^[24]研提出了 1 种新的肺肿瘤恶性肿瘤预测模型, 3D 多尺度胶囊网络可提供有关 3D 结节的信息, 捕获结节的局部特征以及周围组织的特征, 并且能够处理少量的训练样本。在 LIDC-IDRI 数据集上进行测试时, 该模型预测肺结节恶性肿瘤的准确率为 93.12%, 灵敏度为 94.94%, *AUC* 为 0.964, 特异度为 90%。MASTOURI 等^[25]提出 1 种新的分类方法, 双线性 CNN, 用于对 CT 图像上的肺结节分类, 该方法在 LUNA16 数据集上进行测试时, 组合模型准确率为 91.99%。DONG 等^[26]提出了 1 种结合语义特征的 CNN 模型, 预测给定的肺结节是否是恶性, 在 LIDC-IDRI 数据集上进行测试时, 模型准确率为 95.45%, 与标准 3D CNN 方法相比提高了肺结节良恶性的分类。目前, 基于 CNN 的方法仍是肺结节良恶性分类中利用率较高的方法, 但仍存在数据集中 CT 图像分辨率不同、网络模型的泛化能力低、可解释性差、目标函数优化困难等局限性, 分类精度有待进一步提高。随着 DLIR 技术的快速发展, 在提高准确率的同时, 不少学者更着重于是否存在淋巴结转移、胸膜转移等更加细化的分类, 对良恶性鉴别具有重要指导作用^[27]。

2.3 DLIR 技术在评价肺结节发展与恶性程度中的应用

肺结节呈动态化发展, 不同的肺结节转归有所不同。对于部分因炎症、嗜酸性粒细胞增多导致的亚实性结节而言, 经激素治疗后结节可缩小或消失。HUANG 等^[28]通过从性能良好的肺结节分类 DLIR 模型迁移构建学习, 以在基线 CT 上区分短暂性和持续性亚实性结节, 在验证集上的 *AUC* 为 0.926, 准确度为 0.859, 灵敏度为 0.863, 特异度为 0.858, 借助 DLIR 迁移模型可以在基线 CT 上实现对结节持续性的可靠诊断。由于恶性结节并非确定是癌症, 故需对其进一步分类, 预测患癌概率。LIAO^[29]构建了改进型 U-Net 模型解决此问题, 该模型可用于识别输出对象的所有可疑结节, 并根据检测置信度选择前 5 个结节, 将其与噪声等相结合, 通过设置阈值评估癌症概率, 当预测概率高于设置阈值, 则分类为癌症。

3 讨论

DLIR 技术在提高肺结节诊断、假阳性减少和结节良恶性分类方面均表现出突出优势, 在医学图像诊断领域具有良好的应用前景。随着 DLIR 技术的快速发展, 有关肺结节检测与分割、假阳性降低、肺结节分类的各项技术指标和诊断性能都在不断提升。然而, 与传统的肺结节检测模型对比, 虽然 DLIR 模型在灵敏度、准确度、处理数据的速度上表现更卓越, 但由于 DLIR 技术要求大量带有金标准的数据, 花费大量时间与精力, 同时肺癌公共数据集的样本有限, 并且数据集内部类别不平衡, DLIR 技术在肺结节的诊断中仍面临着许多挑战, 假阳性高与模型可解释性差等问题仍有待解决。开发基于半监督和无监督的 DLIR 技术, 或模型在训练及验证中应适当增加不同机构样本以及均衡不同种类肺结节比例可能是未来解决此类问题的有效途径。随着迁移学习、生成对抗网络的发展, 若能对肺部图像数据进行有效扩增, 进一步解决数据不足与样本不平衡问题, 可降低肺结节数据的标注成本。

[参考文献]

- [1] 林佳, 王龙飞, 吴安乐, 等. CT 引导下注射吡咯菁绿在肺磨玻璃结节术前定位中的应用[J]. 介入放射学杂志, 2023, 32(6): 556-559.
- [2] 谷宇, 迟靖千, 张宝华, 等. 基于改进残差和注意力的 CT 肺癌辅助诊断[J]. 传感器与微系统, 2024, 43(9): 30-34.
- [3] 杨金生, 李聪. 人工智能技术在胸部高分辨率 CT 中对肺结节诊断的应用[J]. 中国临床研究, 2022, 35(3):

- 343–346.
- [4] JO G D, AHN C, HONG J H, et al. 75% radiation dose reduction using deep learning reconstruction on low-dose chest CT[J]. BMC Med Imaging, 2023, 23(1): 121.
- [5] PARK H J, CHOI S Y, LEE J E, et al. Deep learning image reconstruction algorithm for abdominal multidetector CT at different tube voltages: Assessment of image quality and radiation dose in a phantom study[J]. Eur Radiol, 2022, 32(6): 3974–3984.
- [6] 林泽, 李晶, 彭志伟, 等. AI 辅助系统评估双层探测器光谱 CT 虚拟平扫肺结节检出的价值探究 [J]. 临床放射学杂志, 2024, 43 (8) : 1404–1409.
- [7] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436–444.
- [8] MCLEAVY C M, CHUNARA M H, GRAVELL R J, et al. The future of CT: deep learning reconstruction[J]. Clin Radiol, 2021, 76(6): 407–415.
- [9] PARK S B. Advances in deep learning for computed tomography denoising[J]. World J Clin Cases, 2021, 9(26): 7614–7619.
- [10] GENNARI A G, ROSSI A, DE CECCO C N, et al. Artificial intelligence in coronary artery calcium score: Rationale, different approaches, and outcomes[J]. Int J Cardiovasc Imaging, 2024, 40(5): 951–966.
- [11] 杨萍, 张鑫, 温帆, 等. 基于双路径交叉融合网络的肺结节 CT 图像分类方法 [J]. 激光与光电子学进展, 2024, 61 (8) : 353–362.
- [12] URREHMAN Z, QIANG Y, WANG L, et al. Effective lung nodule detection using deep CNN with dual attention mechanisms[J]. Sci Rep, 2024, 14(1): 3934.
- [13] DONG Y, LI X, YANG Y, et al. A synthesizing semantic characteristics lung nodules classification method based on 3D convolutional neural network[J]. Bioengineering (Basel), 2023, 10(11): 1245.
- [14] GOWRI L, PRADEEPA S, PANCHADA V, et al. Enhancing pneumonia detection with masked neural networks: A deep learning approach[J]. Neural Comput Appl, 2024, 36(29): 18433–18444.
- [15] YU H, LI J, ZHANG L, et al. Design of lung nodules segmentation and recognition algorithm based on deep learning[J]. BMC Bioinformatics, 2021, 22(S5): 314.
- [16] 曹斌, 杨锋, 马金刚. 深度学习方法在肺结节诊断中的应用 [J]. 激光与光电子学进展, 2021, 58 (16) : 104–117.
- [17] 赵清一, 孔平, 闵建中, 等. 肺结节检测与分类的深度学习方法综述 [J]. 生物医学工程学杂志, 2019, 36 (6) : 1060–1068.
- [18] Setio A A, Ciompi F, Litjens G, et al. Pulmonary nodule detection in ct images: False positive reduction using multi-view convolutional networks[J]. IEEE Trans Med Imaging, 2016, 35(5): 1160–1169.
- [19] YUAN H, FAN Z, WU Y, et al. An efficient multi-path 3D convolutional neural network for false-positive reduction of pulmonary nodule detection[J]. Int J Comput Assist Radiol Surg, 2021, 16(12): 2269–2277.
- [20] 孟祥鹿, 幸子健, 卢山. 基于深度学习的肺结节分类分割算法及其在不同 CT 重建算法下的效能评估 [J]. 中华医学杂志, 2021, 101 (7) : 476–480.
- [21] ZHAO Y D, PENG Z W, MA J, et al. A three dimensional convolutional neural network pulmonary nodule detection algorithm based on the multi-scale attention mechanism[J]. Sheng Wu Yi Xue Gong Cheng Xue Za Zhi, 2022, 39(2): 320–328.
- [22] 王传彬, 李翠平, 曹锋, 等. 基于 CT 临床放射组学列线图与深度学习鉴别非典型肺错构瘤和肺腺癌 [J]. 安徽医科大学学报, 2024, 59 (2) : 344–350.
- [23] MIAO S, XUAN Q, JIA Q, et al. Deep learning-based CT image for pulmonary nodule classification with intrathoracic fat: A multicenter study[J]. Biomed Signal Proces, 2025, 100(PA): 106938.
- [24] AFSHAR P, OIKONOMOU A, NADERKHANI F, et al. 3D-MCN: A 3D Multi-scale capsule network for lung nodule malignancy prediction[J]. Sci Rep, 2020, 10(1): 7948.
- [25] MASTOURI R, KHLIFA N, NEJI H, et al. A bilinear convolutional neural network for lung nodules classification on CT images[J]. Int J Comput Assist Radiol Surg, 2021, 16(1): 91–11.
- [26] DONG Y, LI X, YANG Y, et al. A synthesizing semantic characteristics lung nodules classification method based on 3D convolutional neural network[J]. Bioengineering (Basel), 2023, 10(11): 1245.
- [27] KHAN O F, SALLUZZI M, BRIDGES R, et al. 1362P Evaluation of imaging-based prognostication (IPRO) for advanced non-small cell lung cancer (aNSCLC) using deep learning applied to computed tomography (CT)[J]. Annals of Oncology, 2024, 35(S2): S858.
- [28] HUANG C, LV W, ZHOU C, et al. Discrimination between transient and persistent subsolid pulmonary nodules on baseline CT using deep transfer learning[J]. Eur Radiol, 2020, 30(12): 6913–6923.
- [29] LIAO F, LIANG M, LI Z, et al. Evaluate the malignancy of pulmonary nodules using the 3-d deep leaky noisy-or-network[J]. IEEE Trans Neural Netw Learn Syst, 2019, 30(11): 3484–3495.