

基于深度学习的肺结核检测综述

谢浩杰¹, 鲁明丽², 张陈¹, 周理想³, 滕诣迪⁴, 王明明¹

1. 盐城工学院电气工程学院, 江苏 盐城 221051; 2. 常熟理工学院电气与自动化工程学院, 江苏 常熟 215500; 3. 苏州大学机电工程学院, 江苏 苏州 215031; 4. 常熟理工学院电子信息工程学院, 江苏 常熟 215500

【摘要】基于医学影像的肺结核病灶自动检测技术成为医学图像处理领域的研究热点。本研究围绕深度学习在肺结核病灶检测方面的相关研究与应用展开综述, 首先阐述用于肺结核检测的实验基准, 涵盖肺部医学影像的相关公开数据库和肺结核检测与分类竞赛的相关研究进展, 然后提出肺结核检测领域中深度学习方法与应用的发展趋势, 最后分析深度学习在肺结核诊断中面临的挑战。本研究从技术特性、性能优势、应用前景等方面对这些技术的研究进展以及面临的挑战进行总结和展望。

【关键词】肺结核; 医学影像; 自动检测; 深度学习; 综述

【中图分类号】R318; TP391.7

【文献标志码】A

【文章编号】1005-202X(2024)07-0918-07

Review on tuberculosis detection using deep learning

XIE Haojie¹, LU Mingli², ZHANG Chen¹, ZHOU Lixiang³, TENG Yidi⁴, WANG Mingming¹

1. School of Electrical Engineering, Yancheng Institute of Technology, Yancheng 221051, China; 2. School of Electrical and Automation Engineering, Changshu Institute of Technology, Changshu 215500, China; 3. School of Mechanical and Electrical Engineering, Soochow University, Suzhou 215031, China; 4. School of Electronic and Information Engineering, Changshu Institute of Technology, Changshu 215500, China

Abstract: The automatic detection of tuberculosis lesions based on medical imaging has become a research hotspot in medical image processing. A comprehensive review of relevant researches and applications pertaining to deep learning in tuberculosis lesion detection is provided, which elucidates the experimental benchmarks in tuberculosis analysis, covering public datasets of pulmonary medical images and recent research advancements in tuberculosis detection and classification competitions, introduces emerging trends in deep learning methods and applications in tuberculosis detection, and analyzes the challenges existing in tuberculosis diagnosis using deep learning. The review summarizes and provides insights into the research advances and challenges of these technologies from the aspects of technical characteristics, performance advantages, and application prospects.

Keywords: pulmonary tuberculosis; medical image; automatic detection; deep learning; review

前言

肺结核是由结核分枝杆菌引起的一种慢性传染病, 其感染途径为呼吸道感染, 可通过空气、尘埃及气溶胶传播结核菌, 传染性较强^[1]。中国是世界上30

个结核病高发的国家之一, 发病率为世界第2^[2]。目前肺结核的主要诊断方法为计算机断层成像(Computed Tomography, CT)及X线检查等影像学检查、抗酸染色、结核菌素皮肤试验及纤维支气管镜等^[3]。在肺结核病灶特征的表现上, CT和X光片有着明显的优势^[4-5]。由于肺结核形态复杂, 且与人体部分组织及其它病灶相似而难于识别, 因此, 肺结核诊断与鉴别成为影像学研究的重点与难点^[6]; 同时, 医疗数据中超过90%的数据来自于医学影像^[7], 放射科医生需要阅读医学影像并找出肺结核病灶的具体位置和病灶种类。长时间以及巨大的工作量使医护人员更容易因疲劳而误诊。深度学习的方法擅长从

【收稿日期】2024-02-21

【基金项目】苏州市科技计划项目(SYG202129)

【作者简介】谢浩杰, 硕士, 研究方向: 医学图像处理、计算机视觉、深度学习, E-mail: xiehaojie02@126.com

【通信作者】鲁明丽, 博士, 教授, 研究方向: 医学图像处理、多目标分割与跟踪、人工智能技术与应用等, E-mail: luml@cslg.edu.cn

复杂的图像中提取特征,并通过训练特征参数不断地优化网络对某一特征的检测性能,因此,深度学习方法与常规医学影像诊断方法的融合将在一定的程度上促进两个学科更进一步发展,在应用中不仅可以极大地缓解医生对肺结核病灶的诊断压力^[8],而且可以提升放射科医生诊断的准确性和效率。

本综述主要介绍了基于深度学习的肺结核检测实验基准、检测网络和研究进展。首先,介绍肺结核检测的实验基准,包括肺结核涉及的相关公开数据库及 ImageCLEF (Image of the Cross Language Evaluation Forum) 竞赛肺结核组的相关信息;然后,给出肺结核检测方法的研究进展,在研究进展中介绍用于肺结核检测的深度学习框架;接着,总结基于深度学习的肺结核检测应用进展;最后,基于深度学习方法在实际应用中面临的一些挑战做具体分析。

1 实验基准

1.1 公开数据库

基于深度学习的肺结核辅助诊断系统在进行训练、验证和测试时往往需要大量的医学影像,收集和 处理图像需要耗费大量的时间和资源,因此,研究人员依赖于使用公开数据库进行肺结核检测和分类的研究工作。目前大多数肺结核研究常用的肺结核病 灶公开数据库简介如下。

(1)深圳数据集^[9]:该数据集由中国深圳广东医 学院深圳市第三人民医院编制。记录的正面 X 射线 图像分为正常类和结核类。在 1 个月的时间里,门诊 记录 326 例正常病例和 336 例结核病病例,该数据 集共包含 662 例胸部 X 射线图像,还提供每个 X 射 线图像的临床读数。所有 X 射线图像的分辨率均 为 3 000×3 000 像素。

(2)蒙哥马利数据集(Montgomery County X-ray Set, MC)^[9]:该数据集是从美国蒙哥马利县的结核病预防项 目中收集的。数据集共包含 80 个正常的 X 射线图像, 以及 58 个结核病表现的 X 射线图像。所述 X 射线图像 有两种尺寸:4 020×4 892 像素和 4 892×4 020 像素。

(3) JSRT 数 据 集 (Japanese Society of Radiological Technology Dataset)^[10]:该数据集由日本 放射技术学会和日本放射学会收集。共包含 247 张 胸部 X 射线图像,其中 154 张有肺结节(100 例恶性、 54 例良性),93 张无肺结节。所有 X 射线图像的分辨 率均为 2 048×2 048 像素。

(4)TBX11K数据集(Tuberculosis X-ray Dataset)^[11]: 该数据集共包含 11 200 张 X 射线图像,包括 1 200 张 具有结核病表现的图像、5 000 张患病但非结核病的 图像和 5 000 张健康图像。所有 X 射线图像的分辨率

均为 3 000×3 000 像素。

(5)印度数据集^[12]:该数据集收集自新德里国家 结核病和呼吸道疾病研究所的两台不同的 X 光机,共 有两个数据集:Dataset A 和 Dataset B。其中,Dataset A 的训练集包含 52 张非结核病和 52 张结核病的胸部 X 射线图像,测试集包含 26 张非结核病和 26 张结核病的 胸部 X 射线图像;Dataset B 的训练集包含 50 张非 结核病和 50 张结核病的胸部 X 射线图像,测试集包 含 25 张非结核病和 25 张结核病的胸部 X 射线图像。

(6)印第安纳数据集^[13]:该数据集收集自印第安 纳大学医学院附属的多家医院。共有 7 470 张胸部 X 射线图像,包括带有注释的正面和侧面视图,如心脏 肥大、肺水肿、浸润或胸腔积液等,该数据集通过 NLM(National Library of Medicine)平台的图像检索 服务(Open-i)公开提供。

(7)白俄罗斯数据集^[14]:该数据集是由白俄罗斯 共和国卫生部国家过敏和传染病研究所发起的一项 耐药性研究而收集的。共包含 169 名患者的 306 张 胸部 X 射线图像。X 射线图像使用 Kodak Point-of-Care 260 系统拍摄,图像分辨率为 2 248×2 248 像素。 该数据库中的所有图像均为结核感染影像。

1.2 相关竞赛

随着众多算法与技术在肺部病灶检测领域的深 入发展,与肺部病灶相关的竞赛在一定程度上为研 究者创造了一个重要的学习和交流平台。比赛为研 究人员提供高质量的数据集、标注文件及评估方法, 极大地促进诸多算法在肺结核检测和分类方面的评 估和应用。本研究将着重介绍 ImageCLEF 竞赛,因 为这是一个年度竞赛,代表着最新最全的肺结核研 究资料和算法荟萃。自 2017 年首次在赛题中加入肺 结核的检测和分类任务后一直延续至今,吸引了很 多研究人员的参与,并极大地促进深度学习在肺结 核检测领域的评估和应用,虽然大赛并未限制算法 范围,但大部分获奖者都使用了至少一种深度学习 方法。其中,2019 年的 12 个小组中至少 10 个在一次 实验中使用了深度学习方法,到 2020 年所有的小组 都在提交的材料中使用深度学习方法^[15]。表 1 显示 了 2017~2022 年 ImageCLEF 竞赛肺结核组^[15-20]的详 细信息,包含数据描述、任务描述、评估标准和最佳 结果等。

ImageCLEF 竞赛的肺结核任务推动了肺结核检 测技术不断前进,不仅使大量优秀的深度神经网络 不断应用于肺结核的检测工作,而且推动了医学事 业的前进,诸多优秀的算法在比赛上成功应用,为许 多研究者带来了理论依据和实践支撑。

表1 ImageCLEF肺结核组 2017~2022年竞赛信息
Table 1 Competition information for ImageCLEF tuberculosis group from 2017 to 2022

竞赛名称	数据描述	任务描述	评估标准	最佳结果
ImageCLEF 2017	训练集:230名患者	多重耐药性检测	ROC曲线	0.582 5
	测试集:214名患者			
	训练集:500名患者	结核病类型分类	Cohen's Kappa	0.243 8
	测试集:300名患者			
ImageCLEF 2018	训练集:259名患者	多重耐药性检测	ROC曲线	0.617 8
	测试集:236名患者			
	训练集:677名患者	结核病类型分类	Cohen's Kappa	0.231 2
	测试集:317名患者			
	训练集:170名患者	严重性评分	ROC-AUC	0.770 8
			均方误差	0.784 0
ImageCLEF 2019	训练集:218名患者	SVR-严重程度评分	AUC	0.787 7
			准确性	0.717 9
	测试集:117名患者	CTR-自动生成肺部报告	平均AUC	0.796 8
			最小AUC	0.686 0
ImageCLEF 2020	训练集:283名患者	自动生成肺部报告	平均AUC	0.924 0
	测试集:120名患者		最小AUC	0.885 0
ImageCLEF 2021	训练集:917张图像 测试集:421张图像	结核病类型分类	Cohen's Kappa	0.221 0
ImageCLEF 2022	训练集:559个用例	空洞检测	IoU	0.504 0
	测试集:140个用例		平均精度	
	训练集:60个用例	空洞报告	平均AUC	0.687 0
	测试集:16个用例		最小AUC	0.513 0

2 基于深度学习的肺结核检测进展

目标检测是从图像或视频中找出所有感兴趣的目标并确定它们的类别和位置的任务,是计算机视觉领域的热点研究方向之一。随着神经网络的突破性发展,基于深度学习的目标检测逐渐成为主流。为提高肺结核的检测效率,研究人员已经进行了大量的研究,目标检测逐步应用到各类医学图像领域。

2.1 检测框架

基于深度神经网络的技术在医学图像处理领域的快速应用,深度卷积神经网络在肺结核病灶检测

系统开发上产生了巨大的影响,并显著提高肺结核病灶自动检测的准确性。深度卷积神经网络主要通过3种类型的层,即卷积层、池化层、全连接层和相应的激活函数构建。卷积层和池化层主要用于提取图像中的特征,全连接层根据提取的特征信息映射到最终的输出。每个全连接层之后都会连接特定的激活函数,如sigmoid、softmax和ReLU或相关变体等模块,并根据不同的处理任务选择激活功能。图1展示了应用典型深度卷积神经网络方法进行肺结核检测的工作流程。




图1 基于深度学习方法的工作流程图
Figure 1 Workflow diagram of deep learning-based methods

由于网络变体和计算机硬件的高速发展,深度学习技术近几年在医学领域的应用受到极大的关注。先进的计算资源为更深更复杂网络的训练提供强大的支撑。目前在目标检测领域的深度学习网络主要分为两类:单阶段检测器和两阶段检测器。

单阶段检测器遵循在一次推理中直接检测所有对象。Redmon等^[21]发布YOLO(You Only Look Once)算法。作为深度学习时代的第一个单阶段探测器,YOLO统一了对象检测步骤,图像输入网络后被划分为多个区域,最终输出每个区域的边界框和概率。尽管YOLO在速度上与两阶段检测器相比表现出了很大的提升,但其检测精度较低,尤其针对小目标。因此后来的YOLO版本致力于保证检测速度的同时提升检测精度。最新的YOLOv8网络在MS COCO(Microsoft Common Objects in Context)数据集test-dev 2017进行评估,以280 FPS(Frames Per Second)的速度实现了53.9%的平均精度,其在速度和精度上已经优于大多数现有的检测器。Liu等^[22]提出单步多框目标检测(Single Shot MultiBox Detector, SSD),其主要贡献是引入多参考和多分辨率检测技术,大大提高了检测精度,特别是针对一些小目标。且SSD均衡了检测精度和速度两方面的优势。尽管单阶段检测器检测速度快,但其精度一直落后于两阶段检测器。Lin等^[23]提出RetinaNet,其网络结构通过特征金字塔网络提取多尺度的特征,之后在多尺度特征上连接多个检测头进行预测,这使得RetinaNet能达到与两阶段检测器相当的精度,同时保持较高的检测速度。近年来,基于Transformer的方法影响了深度学习的整个领域,尤其是计算机视觉领域。Carion等^[24]提出的DETR(Detection Transformer)融合了卷积神经网络(Convolutional Neural Networks, CNN)和Transformer方法,网络不再需要非极大值抑制和生成Anchor,实现了端到端的目标检测。

两阶段检测器分为两个过程:一是提取候选区域,二是根据候选区域对目标进行识别和分类。其中,最经典的网络为Girshick等^[25]提出的R-CNN,其主要思想是通过选择性搜索生成候选区域,之后将区域缩放到固定大小后输入到预训练网络(如VGG16)中重新训练全连接层,最后,用支持向量机分类器对目标进行识别和分类,由于网络需要计算大量重叠区域的冗余特征,导致R-CNN的检测速度极慢。为解决这个问题,He等^[26]提出具有空间金字塔池化层的SPPNet,该网络能在输入尺寸任意的情况下输出固定大小,无需重新缩放区域,避免重复计算卷积特征。但该网络仍需要多阶段训练,且特征需要写入硬盘,直接导致网络效率低下。为解决这些问题,Girshick等^[27]提出Fast RCNN检测器,进一

步改进R-CNN和SPPNet。Fast RCNN能在相同的网络配置下同时训练检测器和边界盒回归器,进一步提升整体训练效率。尽管Fast RCNN成功地整合了R-CNN和SPPNet的优点,但没有真正实现端到端的训练,检测速度依然受到限制。基于这些问题,Ren等^[28]提出Faster RCNN,该网络引入区域生成网络(Region Proposal Network, RPN),进一步提升网络的整体性能,真正实现端到端的训练。尽管RCNN系列网络不断优化,但仍存在如计算冗余等诸多问题,在后续版本中提出了许多优化方案,如R-FCN^[29]、Mask RCNN^[30]等。

深度学习技术的发展为研究人员提供可供参考的检测框架,基于这些检测框架,在肺结核领域涌现了许多针对肺结核病灶特点的网络改进版本。

2.2 肺结核检测

目标检测技术的发展为肺结核检测工作提供强大的理论支撑和实践引导,基于深度学习的肺结核检测方案已成为肺结核自动检测的主要方向,并逐渐发展起来。目前主流的方法也从直接应用深度学习网络到基于医学影像特征改进或组合现有深度学习网络的趋势发展。Hwang等^[31]基于当时著名的AlexNet设计了深度卷积神经网络,使用KIT(Korean Institute of Tuberculosis)、MC和深圳数据集进行实验,验证了深度学习在肺结核诊断方面的有效性。Hooda等^[32]通过组合AlexNet、GoogleNet和ResNet这3种标准架构,提出一种基于深度学习的结核病检测系统,并从零开始训练,最终在4个公开数据库上获得了88.24%的准确性和0.93的AUC。Raju等^[33]基于深度残差网络和OxfordNet的变体网络建立结核病自动诊断的模型,最终取得84.1%的敏感度和93.02%的特异度,证明神经网络应用于胸部疾病检测的潜力。Yang等^[34]构建一个U-Net和Faster-RCNN组合的改进模型,并使用残差块进行优化,实验获得87.7%、86.5%和88.5%的敏感度、特异度和准确性,相较于其它机器学习模型,该网络在当时取得更好的效果。UI Abideen等^[35]提出基于贝叶斯的卷积神经网络(B-CNN)用于结核病的识别,在两个公开数据库上分别实现96.42%和86.46%的准确性。表2总结了2021年到近期最新的肺结核检测主要方法、评估措施和结果^[36-46]。

然而,除基于医学影像的肺结核病灶检测方法外,许多研究者也在探索其他可参考领域的诊断方案,如基于患者的咳嗽数据辨别肺结核^[47]和基于患者的痰涂片图像辨别肺结核^[48-52]。这些方法共同构建了基于深度学习技术进行肺结核检测的研究方法,并为后续研究者提供重要的实践参考。

表2 深度学习方法下肺结核检测相关研究进展

Table 2 Advances in tuberculosis detection using deep learning methods

数据集	作者	模型(基础框架)	准确性/%	敏感度/查全率/%	查准率/%	特异度/%	AUC
NLM数据集	Rahman等 ^[36]	ResNet101-XGBoost	98.85±0.55	98.03±0.72	99.71±0.28	99.70±0.28	
Belarus数据集		VGG19-XGBoost	99.42±0.39	99.28±0.44	99.57±0.34	99.57±0.34	-
RSNA数据集		DenseNet201-XGBoost	99.92±0.14	100.00±0.10	99.85±0.20	99.85±0.20	
TBX11K数据集	安乐等 ^[37]	TDT-Net	-	80.7	87.5	-	-
MC和深圳数据集	Dasanayaka等 ^[38]	组合网络(VGG16、Inception V3)	97.1	97.9	-	96.2	-
	Nijjati等 ^[39]	TB-UNet(ResNeXt、U-Net)	90.0	74.5	-	97.9	0.968
	刘学思等 ^[40]	SwinT-Base	98.60	99.23	97.99	-	-
		SwinT-Large	98.85	99.49	98.24	-	-
	安超等 ^[41]	改进RetinaNet	91.39	88.39	-	94.48	0.95
		(深圳)	(深圳)	(深圳)	(深圳)	(深圳)	(深圳)
		(RetinaNet)	86.23	75.86	-	93.75	0.93
		(MC)	(MC)	(MC)	(MC)	(MC)	(MC)
自建数据库	Wang等 ^[42]	3D-ResNet	83(test)	92(test)	-	57(test)	0.86(test)
	Guo等 ^[43]	MIP-MY	-	85.50	96.59	-	-
		(YOLOv4)	-	-	-	-	-
	王佳浩等 ^[44]	MIP-RY	-	87.50	98.42	-	-
		(YOLOv4)	-	-	-	-	-
	王京华等 ^[45]	改进YOLOv4	-	95.14	95.65	-	-
	马依迪丽·尼加提等 ^[46]	3D-ResNet50	0.975(test)	0.951(test)	-	-	0.933(test)

3 肺结核检测挑战

3.1 数据集挑战

大型且高质量的数据集是成功应用深度学习至关重要的先决条件。目前对于数据集的收集和构建主要包括两大障碍:(1)患者隐私,由于一些医院的规章制度和国家的相关政策涉及到个人的隐私保护,这使得数据的收集变得困难。(2)图像注释,非专业人员无法识别和区分结核病灶,需在专业放射科医生的指导下完成,这将花费大量的时间和精力。为缓解数据的稀缺问题,采取合适的数据增强策略可以增加样本的数量和多样性。此外,可使用生成对抗网络来合成对抗图像作为附加数据^[53]。当有足够多的无标签数据时,可采用半监督或无监督的方式进行网络训练,这将达到比监督学习更好的性能。使用迁移学习算法在其他大规模数据集(如ImageNet或MS COCO)上训练的预训练模型,可以在数据不足时进一步提高肺结核检测和分类的准确性^[31, 54-57]。

3.2 技术挑战

研究希望使用计算机辅助系统能帮助医生在肺结核诊断中做出正确的临床决策,然而,目前的检测方法通常使用固定的数据集和深度学习模型开发和

验证,这意味着这项技术只能在固定的场景中使用,在动态场景中无法实现持续学习,以提升模型性能。这些系统往往不能正确识别一些未经训练的独特样本,进而出现错误的诊断结果^[58]。构建一个具有持续学习能力的深度学习技术将在很大程度上提升肺结核检测的整体效率。未来可能会基于这种技术进一步开发云端数据平台,并从诊断记录中提取数据,不断优化深度神经网络,从而持续提升肺结核检测系统的整体性能,以适应持续变化的场景^[59-60]。

3.3 诊断结果的可解释性挑战

基于深度学习的训练模型可以轻易地实现对肺结核的检测和分类,但却无法解释肺结核病灶的发病机制。然而,训练模型对于识别病灶的解读又极其重要,这将帮助放射科医生进一步找出发病原因并作出最终判断,确定疾病后制定相应的治疗方案。因此,在深度学习预测和分类的结果中提供如结核的位置统计以及哪些特征病灶属于肺结核等信息,将是一个值得关注的话题。为提高肺结核诊断系统的可解释性,ImageCLEF多次在竞赛中推出自动生成肺部报告的子任务^[17-18, 20],以解释肺部具体病理特性。此外,还有研究者对深度学习系统诊断结果进行定量分析,用以生成类似医院出具的肺结核诊断报告^[61]。

4 总结与讨论

本研究对基于深度学习的肺结核检测方法和研究进展进行全面的综述。首先,总结肺结核影像涉及的公开数据库和ImageCLEF年度竞赛肺结核组信息;然后,详细介绍肺结核检测的方法和研究应用进展;最后,基于深度学习在肺结核诊断的相关工作,讨论深度学习应用于肺结核检测面临的挑战,为未来的研究工作提供一些方向。基于本综述,可以得出结论,一方面,基于深度学习的方法应用于肺结核诊断已取得超越人类的良好性能,在未来的应用和评估上具有巨大的潜力;另一方面,针对目前所面临的挑战,基于深度学习的肺结核检测方法还应在数据集、技术和可解释性等方面进一步做改进和优化。

【参考文献】

- [1] Rangaka MX, Cavalcante SC, Marais BJ, et al. Controlling the seedbeds of tuberculosis: diagnosis and treatment of tuberculosis infection[J]. *Lancet*, 2015, 386(10010): 2344-2353.
- [2] Chakaya J, Khan M, Ntouni F, et al. Global tuberculosis report 2020-reflections on the global TB burden, treatment and prevention efforts[J]. *Int J Infect Dis*, 2021, 113(S1): S7-S12.
- [3] Wallis RS, Pai M, Menzies D, et al. Biomarkers and diagnostics for tuberculosis: progress, needs, and translation into practice[J]. *Lancet*, 2010, 375(9729): 1920-1937.
- [4] Bhalla AS, Goyal A, Guleria R, et al. Chest tuberculosis: radiological review and imaging recommendations[J]. *Indian J Radiol Imaging*, 2015, 25(3): 213-225.
- [5] Lee SW, Jang YS, Park CM, et al. The role of chest CT scanning in TB outbreak investigation[J]. *Chest*, 2010, 137(5): 1057-1064.
- [6] 周新华. 从建立影像分析思路入手把握结核病影像诊断与鉴别要点[J]. *中国防痨杂志*, 2020, 42(3): 191-194.
- [7] 金征宇. 人工智能医学影像应用: 现实与挑战[J]. *放射学实践*, 2018, 33(10): 989-991.
- [8] Jin ZY. Artificial intelligence in medical imaging: realities and challenges[J]. *Radiologic Practice*, 2018, 33(10): 989-991.
- [9] Singh R, Kalra MK, Nitiwarangkul C, et al. Deep learning in chest radiography: detection of findings and presence of change[J]. *PLoS One*, 2018, 13(10): e0204155.
- [10] Jaeger S, Candemir S, Antani S, et al. Two public chest X-ray datasets for computer-aided screening of pulmonary diseases[J]. *Quant Imaging Med Surg*, 2014, 4(6): 475-477.
- [11] Shiraishi J, Katsuragawa S, Ikezoe J, et al. Development of a digital image database for chest radiographs with and without a lung nodule: receiver operating characteristic analysis of radiologists' detection of pulmonary nodules[J]. *Am J Roentgenol*, 2000, 174(1): 71-74.
- [12] Liu Y, Wu YH, Ban YF, et al. Rethinking computer-aided tuberculosis diagnosis[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2020: 2643-2652.
- [13] Chauhan A, Chauhan D, Rout C. Role of gist and PHOG features in computer-aided diagnosis of tuberculosis without segmentation[J]. *PLoS One*, 2014, 9(11): e112980.
- [14] Demner-Fushman D, Kohli MD, Rosenman MB, et al. Preparing a collection of radiology examinations for distribution and retrieval[J]. *J Am Med Inform Assoc*, 2016, 23(2): 304-310.
- [15] Rahman T, Khandakar A, Kadir MA, et al. Reliable tuberculosis detection using chest X-ray with deep learning, segmentation and visualization[J]. *IEEE Access*, 2020, 8: 191586-191601.
- [16] Cid YD, Liauchuk V, Kovalev V, et al. Overview of the ImageCLEFtuberculosis 2018-detecting multi-drug resistance, classifying tuberculosis types and assessing severity scores[EB/OL]. [2023-10-10]. https://ceur-ws.org/Vol-1866/invited_paper_1.pdf.
- [17] Cid YD, Liauchuk V, Klimuk D, et al. Overview of the ImageCLEFtuberculosis 2019-automatic CT-based report generation and tuberculosis severity assessment[EB/OL]. [2023-10-10]. https://ceur-ws.org/Vol-2380/paper_138.pdf.
- [18] Kozlovski S, Liauchuk V, Cid YD, et al. Overview of the ImageCLEFtuberculosis 2020-automatic CT-based report generation[EB/OL]. [2023-10-10]. https://ceur-ws.org/Vol-2696/paper_252.pdf.
- [19] Kozlovski S, Liauchuk V, Cid YD, et al. Overview of the ImageCLEFtuberculosis 2021-CT-based tuberculosis type classification[EB/OL]. [2023-10-10]. <https://ceur-ws.org/Vol-2936/paper-90.pdf>.
- [20] Kozlovski S, Cid YD, Kovalev V, et al. Overview of the ImageCLEFtuberculosis 2022-CT-based cavern detection and report[EB/OL]. [2023-10-10]. <https://ceur-ws.org/Vol-3180/paper-96.pdf>.
- [21] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 779-788.
- [22] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[C]//Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [23] Lin TY, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2017: 2999-3007.
- [24] Carion N, Massa F, Synnaeve G, et al. End-to-end object detection with transformers[C]//Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 213-229.
- [25] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2014: 580-587.
- [26] He KM, Zhang XY, Ren SQ, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. *IEEE Trans Pattern Anal Mach Intell*, 2015, 37(9): 1904-1916.
- [27] Girshick R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2015: 1440-1448.
- [28] Ren SQ, He KM, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems. Cambridge, MA, USA: MIT Press, 2015: 91-99.
- [29] Dai JF, Li Y, He KM, et al. R-FCN: object detection via region-based fully convolutional networks[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2016: 379-387.
- [30] He KM, Gkioxari G, Dollár P, et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2017: 2980-2988.
- [31] Hwang S, Kim HE, Jeong J, et al. A novel approach for tuberculosis screening based on deep convolutional neural networks[C]//Proceedings Volume 9785, Medical Imaging 2016: Computer-Aided Diagnosis. Bellingham, WA, USA: SPIE, 2016: 97852W.
- [32] Hooda R, Mittal A, Sofat S. Automated TB classification using ensemble of deep architectures[J]. *Multimed Tools Appl*, 2019, 78(22): 31515-31532.
- [33] Raju M, Aswath A, Kadam A, et al. Automatic detection of tuberculosis using deep learning methods[M]//Laha AK. *Advances in Analytics and Applications*. Singapore: Springer Singapore, 2019: 119-129.
- [34] Yang A, Jin XY, Li LJ. CT images recognition of pulmonary tuberculosis based on improved faster RCNN and U-net[C]//2019 10th International Conference on Information Technology in Medicine and Education (ITME). Piscataway, NJ, USA: IEEE, 2019: 93-97.
- [35] Ul Abideen Z, Ghafoor M, Munir K, et al. Uncertainty assisted robust tuberculosis identification with Bayesian convolutional neural networks[J]. *IEEE Access*, 2020, 8: 22812-22825.
- [36] Rahman M, Cao YZ, Sun XB, et al. Deep pre-trained networks as a feature extractor with XGBoost to detect tuberculosis from chest X-ray

- [J]. Comput Electr Eng, 2021, 93: 107252.
- [37] 安乐, 彭柯鑫, 杨兴, 等. 一种融合肺炎影像特征的肺结核病灶检测迁移网络[J]. 光学技术, 2023, 49(1): 120-128.
An L, Peng KX, Yang X, et al. A transfer network for pulmonary tuberculosis lesions detection on the fusion of image features of pneumonia[J]. Optical Technique, 2023, 49(1): 120-128.
- [38] Dasanayaka C, Dissanayake MB. Deep learning methods for screening pulmonary tuberculosis using chest X-rays[J]. Comput Methods Biomech Biomed Eng Imaging Vis, 2021, 9(1): 39-49.
- [39] Nijati M, Zhang ZQ, Abulizi A, et al. Deep learning assistance for tuberculosis diagnosis with chest radiography in low-resource settings[J]. J Xray Sci Technol, 2021, 29(5): 785-796.
- [40] 刘学思, 聂瑞, 张和华, 等. 基于 Swin Transformer 网络的肺结核影像自动分类效果评价[J]. 中国医疗设备, 2022, 37(8): 25-31.
Liu XS, Nie R, Zhang HH, et al. Effect evaluation of automatic classification of pulmonary tuberculosis images based on Swin Transformer network[J]. China Medical Devices, 2022, 37(8): 25-31.
- [41] 安超, 张晨, 郑广平, 等. 基于深度学习的胸部X线肺结核检测研究及多中心临床验证[J]. 放射学实践, 2022, 37(6): 704-709.
An C, Zhang C, Zheng GP, et al. Development of a deep learning-based algorithm for pulmonary tuberculosis detection on chest radiograph: a multi-center study[J]. Radiologic Practice, 2022, 37(6): 704-709.
- [42] Wang L, Ding WL, Mo Y, et al. Distinguishing nontuberculous *Mycobacteria* from *Mycobacterium tuberculosis* lung disease from CT images using a deep learning framework[J]. Eur J Nucl Med Mol Imaging, 2021, 48(13): 4293-4306.
- [43] Guo ZT, Wang JH, Wang JH, et al. Lightweight YOLOv4 with multiple receptive fields for detection of pulmonary tuberculosis[J]. Comput Intell Neurosci, 2022, 2022: 9465646.
- [44] 王佳浩, 王宝珠, 郭志涛, 等. 多感受野的轻量化YOLOv4用于检测肺结核[J]. 中国医学物理学杂志, 2022, 39(9): 1119-1127.
Wang JH, Wang BZ, Guo ZT, et al. Lightweight YOLOv4 with multi-receptive fields for detection of pulmonary tuberculosis[J]. Chinese Journal of Medical Physics, 2022, 39(9): 1119-1127.
- [45] 王京华, 袁金丽, 郭志涛, 等. 改进的YOLOv4算法在肺结核检测中的应用研究[J]. 中国医学物理学杂志, 2023, 40(1): 113-119.
Wang JH, Yuan JL, Guo ZT, et al. Application of improved YOLOv4 algorithm in the detection of pulmonary tuberculosis[J]. Chinese Journal of Medical Physics, 2023, 40(1): 113-119.
- [46] 马依迪丽·尼加提, 米日古丽·达毛拉, 张斌, 等. 基于CT深度学习的活动性/非活动性肺结核分类模型构建及验证[J]. 暨南大学学报(自然科学与医学版), 2023, 44(1): 69-77.
Nijati M, Damaola M, Zhang B, et al. Establishment and verification of active/non-active tuberculosis classification model based on CT deep learning[J]. Journal of Jinan University (Natural Science & Medicine Edition), 2023, 44(1): 69-77.
- [47] Pahar M, Klopper M, Reeve B, et al. Automatic cough classification for tuberculosis screening in a real-world environment[J]. Physiol Meas, 2021, 42(10): 105014.
- [48] Shah MI, Mishra S, Yadav VK, et al. Ziehl-Neelsen sputum smear microscopy image database: a resource to facilitate automated bacilli detection for tuberculosis diagnosis[J]. J Med Imaging (Bellingham), 2017, 4(2): 027503.
- [49] Panicker RO, Kalmady KS, Rajan J, et al. Automatic detection of tuberculosis bacilli from microscopic sputum smear images using deep learning methods[J]. Biocybern Biomed Eng, 2018, 38(3): 691-699.
- [50] Mithra KS, Sam Emmanuel WR. Automated identification of *Mycobacterium* bacillus from sputum images for tuberculosis diagnosis[J]. Signal Image Video Process, 2019, 13(8): 1585-1592.
- [51] El-Melegy M, Mohamed D, ElMelegy T, et al. Identification of tuberculosis bacilli in ZN-stained sputum smear images: a deep learning approach[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway, NJ, USA: IEEE, 2019: 1131-1137.
- [52] Mithra KS, Sam Emmanuel WR. GFNN: gaussian-fuzzy-neural network for diagnosis of tuberculosis using sputum smear microscopic images[J]. J King Saud Univ Comput Inf Sci, 2021, 33(9): 1084-1095.
- [53] Zhang Y, He SP, Wa SY, et al. Symmetry GAN detection network: an automatic one-stage high-accuracy detection network for various types of lesions on CT images[J]. Symmetry, 2022, 14(2): 234.
- [54] Tajbakhsh N, Shin JY, Gurudu SR, et al. Convolutional neural networks for medical image analysis: full training or fine tuning?[J]. IEEE Trans Med Imaging, 2016, 35(5): 1299-1312.
- [55] Lakhani P, Sundaram B. Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks[J]. Radiology, 2017, 284(2): 574-582.
- [56] Lopes UK, Valiati JF. Pre-trained convolutional neural networks as feature extractors for tuberculosis detection[J]. Comput Biol Med, 2017, 89(C): 135-143.
- [57] Mizan MB, Hasan MA, Hassan SR. A comparative study of tuberculosis detection using deep convolutional neural network[C]//2020 2nd International Conference on Advanced Information and Communication Technology (ICAICT). Piscataway, NJ, USA: IEEE, 2020: 157-161.
- [58] Liu B, Chi WH, Li XR, et al. Evolving the pulmonary nodules diagnosis from classical approaches to deep learning-aided decision support: three decades' development course and future prospect[J]. J Cancer Res Clin Oncol, 2020, 146(1): 153-185.
- [59] Masood A, Yang P, Sheng B, et al. Cloud-based automated clinical decision support system for detection and diagnosis of lung cancer in chest CT[J]. IEEE J Transl Eng Health Med, 2020, 8: 4300113.
- [60] Oyenuga SO, Garg L, Bhardwaj AK, et al. Cloud-based clinical decision support system[C]//Conference Proceedings of ICDLAIR 2019. Cham: Springer International Publishing, 2021: 220-234.
- [61] Li XK, Zhou YK, Du P, et al. A deep learning system that generates quantitative CT reports for diagnosing pulmonary tuberculosis[J]. Appl Intell, 2021, 51(6): 4082-4093.

(编辑:谭斯允)