

基于改进YOLOv9的肺结节检测研究

邵锦雷¹, 张正¹, 邹丽^{1,2,3}

(1. 大连交通大学 轨道智能工程学院; 2. 辽宁省轨道交通装备焊接与可靠性重点实验室;
3. 大连市区块链技术与应用重点实验室, 辽宁 大连 116028)

摘要: 肺部结节的早期诊断对于提高患者生存率至关重要, 但传统检测方法存在易丢失小目标特征、难以抵抗复杂背景干扰以及轻量化与性能失衡等问题。为此, 提出一种基于改进YOLOv9的肺结节检测算法。首先, 引入损失函数Shape-IoU, 通过优化传统交并比的计算方式来增强模型对复杂背景和小目标的关注度; 其次, 设计空间—通道协同注意力模块, 采用多尺度空间特征融合与渐进式通道压缩策略来强化算法的特征表达能力; 最后, 设计轻量化动态卷积模块, 通过专家卷积核库动态选择策略, 在保持模型轻量化的同时提升其特征提取灵活性。实验结果表明, 改进算法的平均精度达82.7%, 相较原始YOLOv9模型提升了2.4%, 精确率、召回率分别提升了2.8%、0.6%, 参数量减少了 5×10^6 。该算法实现了检测精度与轻量化的平衡, 为肺结节的检测提供了高效解决方案。

关键词: 肺结节检测; YOLOv9; 轻量化动态卷积; Shape-IoU; 空间—通道协同注意力

DOI: 10.11907/tj.251337

扫描二维码阅读全文:



中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2026)007-0179-07

Research on Pulmonary Nodule Detection Based on Improved YOLOv9

SHAO Jinlei¹, ZHANG Zheng¹, ZOU Li^{1,2,3}

(1. School of Rail Intelligent Engineering, Dalian Jiaotong University; 2. Liaoning Key Laboratory of Welding and Reliability of Rail Transportation Equipment; 3. Dalian Key Laboratory of Blockchain Technology and Application, Dalian 116028, China)

Abstract: The early diagnosis of pulmonary nodules is essential to improve the survival rate of patients. However, traditional detection methods are prone to lose small target features, difficult to resist complex background interference, and lightweight and performance imbalance. Therefore, a lung nodule detection algorithm based on improved YOLOv9 is proposed. Firstly, the loss function Shape IoU is introduced to enhance the model's attention to complex backgrounds and small targets by optimizing the traditional calculation method of intersection and merger ratio; Secondly, the space channel collaborative attention module is designed, and multi-scale spatial feature fusion and progressive channel compression strategy are used to enhance the feature expression ability of the algorithm; Finally, the lightweight dynamic convolution module is designed. Through the dynamic selection strategy of expert convolution core library, the flexibility of feature extraction is improved while maintaining the lightweight of the model. The experimental results show that the average accuracy (AP) of the improved algorithm is 82.7%, which is 2.4% higher than the original YOLOv9 model. The accuracy and recall rates are 2.8% and 0.6% higher respectively, and the number of parameters is reduced by 5×10^6 . This algorithm realizes the balance between detection accuracy and lightweight, and provides an efficient solution for the detection of pulmonary nodules.

Key Words: lung nodule detection; YOLOv9; lightweight dynamic convolution; Shape-IoU; spatial-channel collaborative attention

0 引言

计算机技术的持续革新有力推动了人工智能在各个

领域的广泛应用, 其中在医学影像学领域的应用成效尤为突出。以肺结节检测为例, 传统检测技术遭遇了精准诊断的瓶颈, 而人工筛查方式则因不同医生主观判断的差异, 极易造成较高的误诊率和漏诊率。得益于当前人工智能

收稿日期: 2025-05-12

基金项目: 辽宁省应用基础研究计划项目(2023JH2/101300236)

作者简介: 邵锦雷(2001-), 男, CCF 学生会会员, 大连交通大学轨道智能工程学院硕士研究生, 研究方向为计算机视觉、图像处理; 张正(2001-), 男, CCF 学生会会员, 大连交通大学轨道智能工程学院硕士研究生, 研究方向为智能信息处理; 邹丽(1980-), 女, 博士, CCF 会员, 大连交通大学轨道智能工程学院教授、博士生导师, 研究方向为智能信息处理。本文通讯作者: 邹丽。

图像识别技术的重大突破,基于该技术构建的计算机辅助诊断(Computer-Aided Diagnosis, CAD)系统能切实弥补传统方法和人工筛查的不足,其通过自动化分析技术对CT影像进行初筛,可快速定位可疑病灶,并以预标注异常征象的形式为放射科医生提供诊断决策支持,在提升影像判读效率的同时大幅降低了漏诊概率,进而有效改善患者的生存质量,降低肺癌死亡率^[1-3]。随着医学大数据的规模化应用以及深度学习算法的持续演进,CAD系统正凭借端到端的特征自主学习能力,加速实现从传统人工模式向数据驱动范式的转型。

目前,国内外学者在肺结节检测方面取得了较多成果。例如,尹智贤等^[4-5]提出一种双路径的特征提取网络用于肺结节良恶性分类,将上下文信息融入两阶段生成对抗网络,从而更好地提取图像特征。陈亚浩等^[6]在改进U-Net网络的基础上提出一种高精度的肺结节分割方法。王聪等^[7]提出一种基于双路径特征融合机制的LCT-YOLO模型进行肺结节检测,其中一路保留高分辨率浅层特征以捕捉小病灶细节,另一路整合深层语义信息以抑制血管干扰,在保持检测效率的同时提升了对小结节的敏感度,但其双路径结构在轻量化部署方面存在优化空间。Ren等^[8]采用集成Swin Transformer模块与自适应空间特征融合策略的SwiF-YOLO模型进行肺结节检测,显著提升了检测精度与鲁棒性,但模型的计算复杂度和参数量有所增加,对硬件资源要求更高。Song等^[9]采用一种多尺度3D无锚点深度学习网络进行肺结节检测,利用三维体数据的空间连续性和无锚点设计提高了检测准确率,然而3D网络计算开销巨大,且在训练数据量有限时存在过拟合风险。包强强等^[10]对YOLOv8算法中的特征提取和损失函数进行针对性改进,实现了多类型肺结节的准确检测,但这些复杂模块通常需要大量高质量的标注数据才能充分学习有效的特征表示,在小规模、标注质量不均的数据集上,其优势可能无法发挥,甚至引入噪声。

国外研究则主要集中在深度学习算法的应用与优化上。例如,Hwang等^[11]提出基于YOLOv3架构的肺结节检测算法,通过构建多尺度特征图有效增强了模型对不同大小结节的特征表达能力,但模型主要基于早期YOLO架构,在检测精度提升和复杂背景抑制方面仍有较大提升空间。Ahmadyar等^[12]提出一种基于YOLO模型与3D神经网络分类器的肺结节分层检测方法,在公开数据集上实现了高灵敏度与低假阳性率的平衡,然而其级联结构存在误差传递风险,且三维分类模块对计算资源要求较高,不利于临床实时应用。

综上所述,肺结节检测方法中仍存在小目标特征易丢失、复杂背景干扰以及轻量化与性能失衡等问题。为此,本文提出一种基于YOLOv9模型的肺结节检测方法^[13]。主要创新点为:①设计Shape-IoU损失函数,通过引入边界框形状敏感度权重和形状相似性约束来优化复杂背景下

的定位精度;②构建空间—通道协同注意力模块(Spatial and Channel Squeeze & Excitation Attention, SCSA),融合多尺度一维卷积与渐进式通道压缩机制,强化小目标的特征表达能力;③设计轻量化动态卷积架构,基于专家核库动态激活最优卷积核,在减少模型参数数量的同时保持检测精度。在Lung Nodule Detection数据集上的实验结果表明,该算法实现了检测精度与效率的平衡,为肺结节的智能化检测提供了一条有效途径。

1 方法构建

原始YOLOv9采用的小尺寸卷积核(如3×3)局部感受野较小,导致浅层网络的整体感受野受限,在检测小目标或处于复杂背景中的目标时难以准确捕捉特征并定位,容易导致漏检或误检现象。考虑到动态卷积设计在兼顾模型轻量化与建模表征力方面的优势,本文将其应用于Backbone网络优化。Neck网络需对Backbone提取的多层级特征进行融合,以提供检测目标的精准空间位置信息。然而,原始YOLOv9采用Concat或Add等简单融合方式,易导致特征被掩盖或丢失,尤其在小目标或被遮挡目标的检测中劣势明显。为此,本文引入SCSA模块,通过捕捉肺结节的多尺度特征变化来增强模型对不同大小结节的特征表达能力,进而提升平均检测精度。同时,采用Shape-IoU损失函数替代原始损失函数,以更精准地刻画预测框与真实框之间的几何匹配程度。改进后的YOLOv9网络结构见图1(彩图扫二维码可见,下同)。

1.1 Shape-IoU 损失函数

原始损失函数将预测框与真实框的IoU值作为优化对象,难以解决肺结节这类检测背景较复杂的小目标识别问题。因此,本文引入动态调整损失权重的Shape-IoU损失函数。首先,引入长宽比敏感因子,对形状偏差大的预测框施加更高惩罚,强制模型优先修正严重形变的检测框;其次,针对小目标设计尺度归一化策略,降低其位置偏差的敏感性,避免因微小误差导致梯度剧烈波动;最后,通过几何约束使边界框回归时同时优化重叠面积和形状匹配度,相较于仅优化IoU的损失函数能更稳定地应对复杂场景。Shape-IoU根据真实框的形状和尺度计算权重系数 w 和 h ,用于调整预测框与真实框在水平和垂直方向上的距离损失和形状损失。计算公式为:

$$w = \frac{2 \times (w^{gt})^{scale}}{(w^{gt})^{scale} + (h^{gt})^{scale}} \quad (1)$$

$$h = \frac{2 \times (h^{gt})^{scale}}{(w^{gt})^{scale} + (h^{gt})^{scale}} \quad (2)$$

式中: w^{gt} 和 h^{gt} 分别为真实框的宽度和高度; $scale$ 为控制形状敏感度的超参数(默认为1)。

IoU损失通过计算预测框与真实框的IoU,直接反映检测框的定位精度。计算公式为:




Fig. 1 Improved YOLOv9 network structure

图 1 改进后的 YOLOv9 网络结构

$$IoU(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (3)$$

式中: A 和 B 分别表示预测框和真实框。

在此基础上, Shape-IoU 通过引入形状距离损失 $distance^{shape}$ 来调整预测框与真实框在水平和垂直方向上的距离损失。形状距离损失的计算公式为:

$$distance^{shape} = hh \times \frac{(x_c - x_c^{gt})^2}{c^2} + ww \times \frac{(y_c - y_c^{gt})^2}{c^2} \quad (4)$$

式中: x_c, y_c 表示预测框的中心点坐标; x_c^{gt}, y_c^{gt} 表示真实框的中心点坐标; c 为最小外接框的对角线长度。

此外, Shape-IoU 还引入形状相似性损失 Ω^{shape} , 用于衡量预测框与真实框在形状上的差异。计算公式为:

$$\Omega^{shape} = \sum_{t=w, h} (1 - e^{-w_t})^\theta \quad (5)$$

式中: w_w 和 w_h 分别表示预测框与真实框在宽度和高度上的形状差异。

最终, Shape-IoU 损失函数由 IoU 损失、形状距离损失和形状相似性损失 3 部分组成。计算公式为:

$$L_{Shape-IoU} = 1 - IoU + distance^{shape} + 0.5 \times \Omega^{shape} \quad (6)$$

通过加入形状和尺度权重, Shape-IoU 可以更好地匹配各种不同形状和尺度的边界框, 在小目标检测中效果优异。

1.2 SCSA 模块

尽管 YOLOv9 通过特征金字塔网络与路径聚合网络的多尺度融合机制增强了浅层特征的语义信息, 并提升了深层特征的定位能力, 但其在肺结节检测任务中仍存在小目标细节易丢失和特征捕捉困难的问题。对此, 本文在 YOLOv9 中引入 SCSA 模块, 通过并行建模空间位置与通道特征的交互关系, 动态增强关键区域的显著性^[14]。首先, 将输入特征分解为空间和通道两个分支, 空间分支通过卷积

提取像素级位置权重, 通道分支通过压缩-激励机制学习通道间的依赖关系; 其次, 通过双向交叉调制, 即空间权重指导通道特征增强、通道权重细化空间注意力, 融合输出具有位置敏感性和通道判别性的特征图, 从而在复杂场景中更精准地聚焦目标关键区域。图 2 为 SCSA 模块结构。

本文设计了多个并行的一维卷积核, 分别对应不同的感受野大小, 从而在不同尺度上提取特征。设输入特征图 F 的尺寸为 $H \times W \times C$, 其中 H 和 W 分别表示特征图的高度和宽度, C 表示通道数。多尺度一维卷积操作可表示为:

$$F_{scale} = \sum_{k \in K} \text{Conv}_k(F) \quad (7)$$

式中: K 表示不同尺度的一维卷积核集合; Conv_k 表示第 k 个尺度的一维卷积操作。通过这种方式, 模型能获得多个尺度的特征图 F_{scale} , 并将其融合为最终的多尺度特征表示。

为进一步强化特征的表达能力, 本文在每个尺度的一维卷积后引入分组归一化和通道注意力机制。其中, 分组归一化能有效减少批量大小对模型性能的影响; 通道注意力机制通过对不同通道的特征进行加权来突出重要特征, 抑制冗余信息, 计算公式为:

$$A_c = \sigma(\text{Conv}_1(\text{AvgPool}(F_{scale}))) \odot F_{scale} \quad (8)$$

式中: σ 表示 Sigmoid 激活函数; AvgPool 表示全局平均池化操作; $\odot$ 表示逐元素相乘。这种方式能动态调整每个通道的特征权重, 增强模型对肺结节特征的敏感度。

空间分支通过结合多尺度一维卷积、分组归一化和通道注意力机制, 有效提升了模型在肺结节检测任务中的特征提取能力, 为后续的高精度检测奠定了坚实基础。

渐进式通道压缩是本文提出的一种增强通道特征表达能力的方法, 其通过分组归一化以及通道注意力的渐进




Fig. 2 SCSA module structure

图2 SCSA模块结构

融合来不断降低通道维度,提高模型对肺结节特征的敏感度,以及复杂背景下的抗干扰能力^[14]。对于输入的特征图,首先通过分组归一化将通道划分为若干个组;其次对每一组通道进行独立的归一化,使通道之间相对独立,实现通道去冗余化;最后引入通道注意力,对每个分组归一化后的特征进行加权选择,保留比较重要的通道。

在通道注意力模块中,采用全局平均池化与全局最大池化相结合的方式提取通道的全局统计信息,并通过多层感知机(Multilayer Perceptron, MLP)进行特征融合与非线性变换,生成通道权重。具体公式为:

$$\alpha_c = \sigma(W_2 \delta(W_1 X_c)) \quad (9)$$

式中: X_c 为第 c 个通道的特征图; W_1 和 W_2 为MLP的权重矩阵; δ 为ReLU激活函数; σ 为Sigmoid激活函数; α_c 为第 c 个通道的权重。

通过对生成的通道权重图与经分组归一化处理的特征图进行逐元素相乘来完成通道特征的加权融合。逐层压缩通道维数,不断减少特征图的通道数,以便在降低模型计算量的同时尽可能保持特征的表达能力。渐进式选择性通道压缩的优点在于其通过在不同层次上差异化地压缩次要通道,避免了单一压缩层可能造成的关键信息丢失,从而更稳健地强化了主干通道的特征表达能力。将通道注意力与空间注意力相结合的SCSA模块可有效发掘图像中最重要的部分,并去除无用信息。

1.3 轻量化动态卷积

与YOLOv8、YOLOv7相比,YOLOv9的检测精度显著提升,但参数量也大幅增加。为在模型轻量化与特征表达能力之间达到平衡,本文采用动态卷积层设计,将模型中

原有的卷积层替换为动态卷积层^[15]。动态卷积的工作原理为通过动态调整卷积核参数来适应不同输入特征。具体来说:预先设计一组基础卷积核(专家核库),在处理每个输入时,首先采用一个轻量级网络分析当前图像特征,生成一组权重值;其次采用这些权重对基础卷积核进行加权组合,形成针对当前输入特制的动态卷积核。该种机制能使模型自动为不同大小、形状的肺结节生成最合适的特征提取器,提升对多尺度目标的检测精度。动态卷积网络结构见图3。

假设输入特征图为 $X \in \mathbb{R}^{H \times W \times C}$,其中 H 、 W 和 C 分别表示特征图的高度、宽度和通道数。专家卷积核库中的每个卷积核可以表示为 $K_i \in \mathbb{R}^{k \times k \times C \times C'}$,其中 i 为卷积核的索引, k 为卷积核的大小, C' 为输出通道数。动态参数激活的过程为:采用一个轻量级网络对输入特征图 X 进行特征提取,生成一个权重向量 $W \in \mathbb{R}^N$,其中 N 为专家卷积核的数量。该权重向量反映了每个卷积核在当前输入下的重要性。权重向量 W 的计算公式为:

$$W = \sigma(f(X)) \quad (10)$$

采用向量对专家卷积核库中的卷积核进行加权组合,得到最后的动态卷积核。表示为:

$$K_{\text{dynamic}} = \sum_{i=1}^N W_i \cdot K_i \quad (11)$$

2 实验方法与结果分析

2.1 实验环境与参数设置

硬件环境:显卡为RTX3060,显存为24 GB,CPU为In-




Fig. 3 Dynamic convolutional network structure
图3 动态卷积网络结构

tel(R) Core(TM) i7-12700。软件环境:编程语言为Python3.8,Pytorch版本为1.8.1,编程模型为CUDA11.8。参数设置:采用Mosaic方式增强数据,迭代批量为8,优化器为SGD,初始学习率为0.01,学习算法为余弦退火,训练轮数为200。

2.2 数据集

Lung Nodule Detection 数据集 (<https://universe.roboflow.com/college-xsgmz/lung-nodule-detection-using-yolo-v8/dataset/1>)是由Roboflow发布的一个公开肺结节检测数据集。该数据集包含3 631例患者的低剂量CT扫描图像,像素为512×512,其中大部分结节直径在3~30 mm之间。每个结节均由经验丰富的放射科医生标注,提供了结节的位置和直径信息。从中随机选择78%作为训练集,12%作为测试集,10%作为验证集。

为增强模型对不同尺度肺结节的检测能力,采用随机裁剪、水平翻转、随机缩放等数据增强手段增加数据集的多样性。

2.3 评价指标

采用精确率(Precision)、召回率(Recall)、F1值(F1-Score)和平均精度(Average Precision, AP)评价模型性能。计算公式分别为:

Precision = TP / (TP + FP) (12)

Recall = TP / (TP + FN) (13)

F1 Score = 2 * (Precision * Recall) / (Precision + Recall) (14)

式中:TP(True Positive)表示正确检测到的肺结节数量;FP(False Positive)表示误检为肺结节的其他组织数量;FN(False Negative)表示漏检的肺结节数量。

AP通过计算 Precision-Recall 曲线下面积得到。

2.4 实验结果分析

2.4.1 比较实验

将本文算法与原始YOLOv9、YOLOv5-n、Faster R-CNN^[16]、SSD^[17]、YOLOv8-n、YOLOv7、YOLOX^[18]、RetinaNet^[19]、YOLOv11-n、Gold-YOLO^[20]、YOLOv12-n^[21]、RT-DERT^[22]模型进行比较。结果见表1。本文算法以82.7%的AP、83.6%的精确率、78.6%的召回率和0.81的F1-score展现出较为明显的整体优势。

Table 1 Comparison experiment results				
表1 比较实验结果				
模型	AP/%	Precision/%	Recall/%	F1-score
原始YOLOv9	80.3	80.8	78.1	0.78
本文算法	82.7	83.6	78.6	0.81
YOLOv5-n	68.8	71.9	69.2	0.70
Faster R-CNN	79.6	81.7	78.9	0.80
SSD	48.6	82.3	3.9	0.07
YOLOv8-n	78.5	79.6	77.2	0.78
YOLOv7	64.3	70.1	61.9	0.66
YOLOX	79.9	83.1	81.5	0.82
RetinaNet	53.9	83.9	32.3	0.47
YOLOv11-n	75.1	79.5	72.3	0.75
Gold-YOLO	76.2	74.4	40.9	0.53
YOLOv12-n	74.0	77.3	69.0	0.73
RT-DERT	78.4	81.9	73.9	0.78

图4为原始YOLOv9和本文算法的可视化检测效果比较。可以看出,本文算法对肺结节预测框所附的置信度分数显著高于原始算法,说明改进策略有效增强了算法对结节特征的表征确定性,提升了检测结果的可靠性。

图5为原始YOLOv9和本文算法的AP与精确率变化曲线。可以看出,本文算法的性能收敛曲线趋势更优。具体来说,在训练初期,本文算法的AP与精确率曲线均呈现出更陡峭的上升斜率,迅速超过原始模型,表明改进方案有效优化了网络梯度流与特征学习过程,提升了训练效率。相较于原始算法曲线后期出现的波动或平台期,本文




Fig. 4 Comparison of detection performance between original YOLOv9 and proposed algorithm

图4 原始YOLOv9和本文算法检测效果比较


算法的AP与精确率曲线在训练中后期上升更为平稳,且最终收敛至更稳定、更高的平台,表明其在应对复杂样本时表现出更强的鲁棒性与泛化能力。值得注意的是,本文算法的AP与精确率曲线呈现出高度一致的优化趋势,均在相同阶段快速提升并同步趋于稳定,这从侧面验证了其在提升召回与控制误检两个目标上取得了均衡的进步,而非以牺牲一方来换取另一方。上述曲线趋势分析表明,改进方案不仅提升了模型的最终性能,而且从优化过程上增强了其学习效率与稳定性。

2.4.2 消融实验

本文设计了8组消融实验来验证轻量化动态卷积、SCSA模块和Shape-IoU损失函数对模型性能的独立贡献以及协同作用。结果见表2。可以看出,当在原始YOLOv9模型的基础上仅添加轻量化动态卷积时,参数量减少至 5.02×10^8 ,AP提高0.9%,精确率提高3.2%,召回率提高1.3%。仅添加SCSA模块时,模型参数量增加至 5.12×10^8 ,AP提高0.6%,精确率提高0.1%,召回率提升1.3%,验证了其通过多尺度特征融合缓解小目标特征丢失的能力。仅添加Shape-IoU时,模型AP提高2.6%,精确率提高6.2%,但召回率下降1.0%,说明其对边界框形状的严格约束可能抑制低置信度目标。同时添加3个模块时,模型AP为82.7%,参数量减少 5×10^6 ,精确率与召回率分别提升2.8%和0.5%。综上所述,动态卷积优化参数效率,SCSA提升特征表达能力,Shape-IoU强化定位精度,三者协同最终实现精度与效率的平衡。


3 结语

本文针对肺结节检测中的特征丢失、复杂背景干扰以及轻量化与性能失衡等问题,提出一种基于改进YOLOv9的检测方法。通过在原始YOLOv9模型中引入Shape-IoU损失函数,有效提升了模型在复杂医学影像背景下的定位



(a) Comparison of AP

(a) AP比较



(b) Comparison of precision

(b) 精确率比较

Fig. 5 Comparison of AP and accuracy curves between original YOLOv9 and the proposed algorithm

图5 原始YOLOv9和本文算法的AP与精确率曲线比较

Table 2 Ablation experiment result

表2 消融实验结果

动态卷积	SCSA	Shape-IoU	AP/%	Precision/%	Recall/%	Parameters/ $\times 10^8$
			80.3	80.8	78.1	5.09
√			81.2	84.0	79.4	5.02
	√		80.9	80.9	79.4	5.12
		√	82.9	87.0	77.1	5.12
√	√		82.4	85.7	77.8	5.04
	√	√	82.9	85.2	79.1	5.12
√		√	80.2	81.2	78.5	5.04
√	√	√	82.7	83.6	78.6	5.04

精度;通过引入SCSA模块,显著增强了模型的多尺度特征提取能力;通过引入轻量化动态卷积,在保证计算效率的同时提升了特征表达的灵活性。然而,本研究仍存在数据不均衡、检测性能提升有限等不足。未来需构建更大规模的数据集,并结合元学习策略增强模型对新数据的适应性;同时进一步优化网络结构与训练方法以提升计算效率。

参考文献:

- [1] LIU A L, WANG Z H, YANG Y C, et al. Preoperative diagnosis of malignant pulmonary nodules using radiomics nomogram in lung cancer screen-

- ing[J]. Chinese Journal of Cancer, 2020, 39(6):261-270.
- 刘爱玲,王志恒,杨亚超,等. 在肺癌筛查中使用影像组学诺模图术前诊断恶性肺结节[J]. 癌症, 2020, 39(6):261-270.
- [2] SIEGEL R L, MILLER K D, FUCHS H E, et al. Cancer statistics, 2022[J]. CA: A Cancer Journal for Clinicians, 2022, 72(1): 7-33.
- [3] LEE E, KAZEROONI E A. Lung cancer screening[J]. Seminars in Respiratory and Critical Care Medicine, 2022, 43(6):839-850.
- [4] YIN Z X, XIA K W, WU P P. Classification method for benign and malignant pulmonary nodules based on multimodal feature fusion network[J]. Computer Engineering and Applications, 2023, 59(23):228-236.
- 尹智贤,夏克文,武盼盼. 多模式特征融合网络肺结节良恶性分类方法[J]. 计算机工程与应用, 2023, 59(23): 228-236.
- [5] YIN Z X, XIA K W, ZHANG Z, et al. Image generation and classification of pulmonary nodules using two-stage generative adversarial network with contextual attention fusion [J]. Chinese Journal of Medical Physics, 2024, 41(12): 1517-1531.
- 尹智贤,夏克文,张昭,等. 融合上下文注意力的两段式生成对抗网络的肺结节图像生成与分类[J]. 中国医学物理学杂志, 2024, 41(12): 1517-1531.
- [6] CHEN Y H, HAN L, LIU Y Q, et al. Research on lung CT segmentation algorithm based on RDU-Net network [J]. Computer Applications and Software, 2024, 41(7): 177-183.
- 陈亚浩,韩林,刘艳青,等. 基于RDU-Net网络的肺部CT分割算法研究[J]. 计算机应用与软件, 2024, 41(7):177-183.
- [7] WANG C, YIN H P, CHEN B. Lightweight lung nodule detection method based on improved YOLOv5 [J]. Acta Automatica Sinica, 2022, 48 (5): 1342-1351.
- 王聪,尹宏鹏,陈波. 基于改进YOLOv5的轻量化肺结节检测方法[J]. 自动化学报, 2022, 48(5):1342-1351.
- [8] REN C, HOU S, HOU J, et al. SwiF-YOLO: a deep learning method for lung nodule detection[J]. International Journal of Biology and Life Sciences, 2024, 5(2): 20-27.
- [9] SONG W, TANG F, MARSHALL H, et al. A multiscale 3D network for lung nodule detection using flexible nodule modeling [J]. Medical Physics, 2024, 51(10): 7356-7368.
- [10] BAO Q Q, TANG S Y, LI Q Q, et al. Improved YOLOv8 model for multi-type pulmonary nodule detection [J]. Journal of Frontiers of Computer Science and Technology, 2025, 19(2): 429-442.
- 包强强,唐思源,李擎乾,等. 改进YOLOv8模型实现多类型肺结节检测[J]. 计算机科学与探索, 2025, 19(2): 429-442.
- [11] HWANG E J, LEE J S, LEE J H, et al. Deep learning for detection of pulmonary metastasis on chest radiographs [J]. Radiology, 2021, 301 (2): 455-463.
- [12] AHMADYAR Y, KAMALI-ASL A, ARABI H, et al. Hierarchical approach for pulmonary-nodule identification from CT images using YOLO model and a 3D neural network classifier [J]. Radiological Physics and Technology, 2024, 17: 124-134.
- [13] WANG C Y, YE H I, MARK L H Y. Yolov9: learning what you want to learn using programmable gradient information [C]//European Conference on Computer Vision, 2024: 1-21.
- [14] SI Y, XU H, ZHU X, et al. SCSA: exploring the synergistic effects between spatial and channel attention [J]. Neurocomputing, 2025, 634: 1-11.
- [15] HAN K, WANG Y, GUO J, et al. ParameterNet: parameters are all you need for large-scale visual pretraining of mobile networks [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 15751-15761.
- [16] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.
- [17] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C]//Proceedings of the 14th European Conference on Computer Vision, 2016: 21-37.
- [18] GE Z, LIU S, WANG F, et al. YoloX: exceeding yolo series in 2021 [DB/OL]. <https://arxiv.org/abs/2107.08430>.
- [19] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [20] WANG C, HE W, NIE Y, et al. Gold-YOLO: efficient object detector via gather-and-distribute mechanism [DB/OL]. <https://arxiv.org/abs/2309.11331>.
- [21] TIAN Y, YE Q, DOERMANN D. Yolov12: attention-centric real-time object detectors [DB/OL]. <https://arxiv.org/abs/2502.12524>.
- [22] ZHAO Y, LV W, XU S, et al. Detrs beat yolos on real-time object detection [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.

(责任编辑:尹晨茹)