

一种改进YOLOv5的CT图像肺结节检测方法

邬春明, 刘亚丽

引用本文

邬春明, 刘亚丽. 一种改进YOLOv5的CT图像肺结节检测方法[J]. 计算机科学, 2024, 51(6A): 230500019-6.

WU Chunming, LIU Yali. Method for Lung Nodule Detection on CT Images Using Improved YOLOv5[J]. Computer Science, 2024, 51(6A): 230500019-6.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[面向产线AI质检的少样本评测方法研究和验证](#)

Study and Verification on Few-shot Evaluation Methods for AI-based Quality Inspection in Production Lines

计算机科学, 2024, 51(6A): 230700086-8. <https://doi.org/10.11896/jsjcx.230700086>

[基于SAMNV3的滚动轴承智能故障诊断方法](#)

Intelligent Fault Diagnosis Method for Rolling Bearing Based on SAMNV3

计算机科学, 2024, 51(6A): 230700167-6. <https://doi.org/10.11896/jsjcx.230700167>

[基于BERT和CNN的药物不良反应个案报道文献分类方法](#)

Literature Classification of Individual Reports of Adverse Drug Reactions Based on BERT and CNN

计算机科学, 2024, 51(6A): 230400049-6. <https://doi.org/10.11896/jsjcx.230400049>

[基于LSTM和注意力机制的远程会诊需求预测](#)

Forecasting Teleconsultation Demand Based on LSTM and Attention Mechanism

计算机科学, 2024, 51(6A): 230800119-7. <https://doi.org/10.11896/jsjcx.230800119>

[DUWe:动态未知词嵌入方法在Web异常检测中的应用](#)

DUWe:Dynamic Unknown Word Embedding Approach for Web Anomaly Detection

计算机科学, 2024, 51(6A): 230300191-5. <https://doi.org/10.11896/jsjcx.230300191>

一种改进 YOLOv5 的 CT 图像肺结节检测方法

邬春明 刘亚丽

东北电力大学电气工程学院 吉林 吉林 132000

(wuchunming@neepu.edu.cn)

摘要 针对 YOLOv5 算法对 CT 图像中的肺结节检测效果较差的问题,提出基于改进 YOLOv5 的肺结节检测方法。将 YOLOv5 网络中 Neck 部分的特征金字塔改进为加权双向特征金字塔网络;在 YOLOv5 网络中的 Backbone 部分加入高效通道注意力机制与坐标注意力机制。在 LIDC-IDRI 数据集上进行实验,结果表明,检测的平均精度可达 80.2%,召回率可达 90.75%,因此该方法能够有效检测肺结节。相较于 YOLOv5 算法,改进后的算法在 mAP 上提高了 7.7%,在召回率上提高了 5.5%。

关键词 肺结节检测;深度学习;特征金字塔;注意力机制

中图分类号 TP391

Method for Lung Nodule Detection on CT Images Using Improved YOLOv5

WU Chunming and LIU Yali

College of Electrical Engineering, Northeast Electric Power University, Jilin, Jilin 132000, China

Abstract To address the problem of poor detection results of lung nodules in CT images by YOLOv5 algorithm, an improved YOLOv5-based lung nodule detection method is proposed. The feature pyramid of the Neck part of the YOLOv5 network is improved to weighted bidirectional feature pyramid network. In the YOLOv5 network, the Backbone part adds an efficient channel attention mechanism and a coordinate attention mechanism. Experiments are conducted on the LIDC-IDRI dataset and the results show that the average detection accuracy id up to 80.2%, and the recall is up to 90.75%, so this method can effectively detect lung nodules. Compared with the YOLOv5 algorithm, the improved algorithm improves 7.7% in mAP and 5.5% in recall.

Keywords Pulmonary nodules detection, Deep learning, Feature pyramid, Attention mechanism

1 引言

肺癌是一种恶性肿瘤,大部分患者在发现时已经是中晚期,导致后续的治愈率不高。目前,肺癌的发病率仍然居高不下。肺癌的早期临床诊断主要是通过肺结节的形状进行判定^[1],但由于肺部中的肺结节形状各异,且分布十分不均匀,如果单纯依靠医生进行诊断,会因医生经验不足或先入为主的主观判断而造成对结节的错检、漏检情况^[2],从而影响检测的结果和后续的治疗。因此,研究通过计算机来辅助医生进行肺结节检测的方法,不仅可以减轻影像科医生的负担,而且能够提高肺结节的检测精度。各种深度神经网络(Deep Neural Networks, DNN)随着各类应用场景的需求横空出世。其中,卷积神经网络(Convolutional Neural Network, CNN)是目前医学影像中最常用的模型类型^[3-4],在肺结节检测中也得到了广泛应用^[5-6]。YOLO(You Only Look Once)系列^[7-10]网络在其中展现出了比其他 CNN 网络更快的检测速度。在肺结节的检测中使用基于改进 YOLO 系列的目标检测网络,到目前已经取得了不少成果^[11-15]。作为 YOLO 系列的代表算法,YOLOv5 在各种场景都表现出了良好的性能,但用于 CT

图像中肺结节的检测时,还是存在精度不高的问题。针对上述问题,提出改进的 BiFPN-ECA-CA-YOLOv5 算法并将其应用于肺结节检测,以获取更准确、稳定的检测效果。

2 改进算法

YOLO 是经典的单阶段(one-stage)目标检测算法,其计算速度快且模型结构简单,使得目标检测变得高效且灵活。与两阶段(two-stage)的目标检测算法相比,YOLO 虽然在准确率方面稍有欠缺,但在检测速度和实时性等方面优势显著。

在 YOLOv5 的多个版本中,YOLOv5s 虽然精确度略低,但其体积小,速度快。本文综合考虑训练速度与检测精度后,选定其作为基准网络,对其进行改进来进行肺结节检测。YOLOv5s 的网络结构如图 1 所示。

BiFPN-ECA-CA-YOLOv5 算法是用加权双向特征金字塔网络(Bidirectional Feature Pyramid Network, BiFPN)来替换 YOLOv5 网络中 Neck 部分的特征金字塔;将高效通道注意力机制(Efficient Channel Attention, ECA)与坐标注意力机制(Coordinate Attention, CA)加到 YOLOv5 网络的 Backbone 部分。

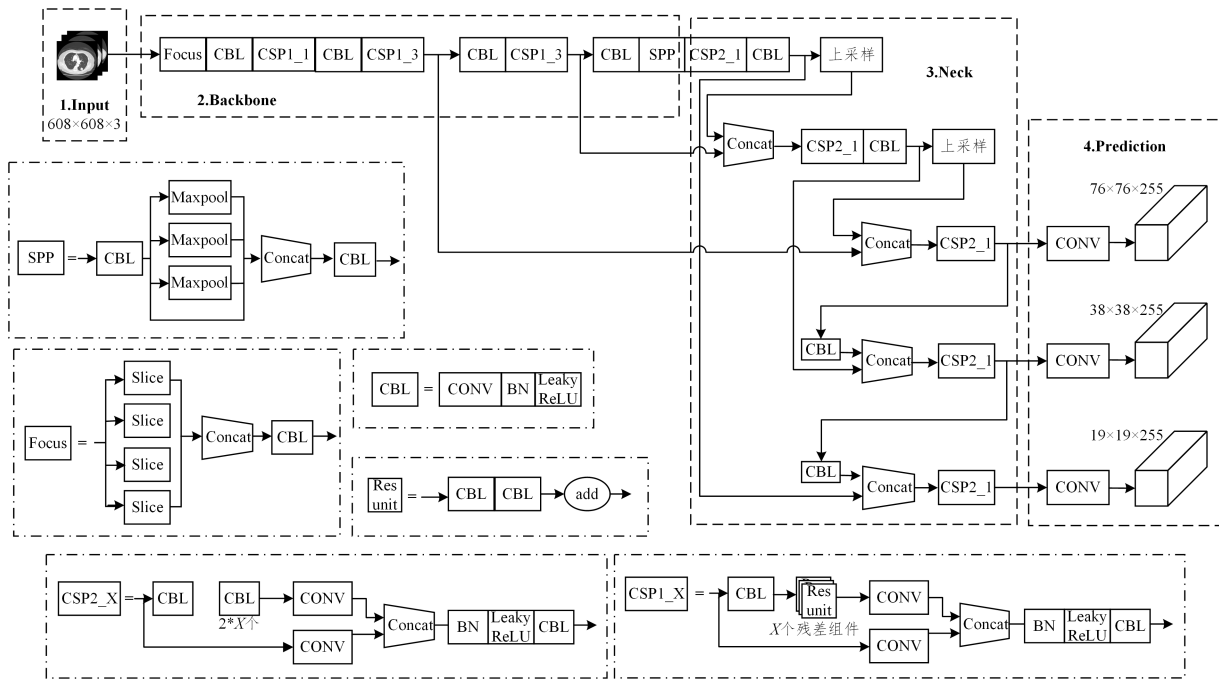


图 1 YOLOv5s 网络结构

Fig. 1 YOLOv5s network structure

2.1 加权双向特征金字塔 BiFPN

BiFPN^[16]是一种特征融合的新方法,其中的双向是指自顶向下与自底向上的特征融合。其思想是高效的双向跨尺度连接及加权特征融合,即在路径增强的基础上,先进行自顶向下的特征融合,再进行自底向上的特征融合。图 2 展示了 3 种典型的特征融合网络的设计形式,这 3 种结构在某种程度上也代表了特征融合网络的发展过程。




图 2 3 种典型的特征融合网络

Fig. 2 Three typical feature fusion networks

最早的 Neck 部分是从 Backbone 中提取高层金字塔特征直接预测,但是这种结构没有进行特征融合,所以精度都比较低。Tsung 等提出特征金字塔 (Feature Pyramid Network, FPN)^[17]对其进行改善。如图 2(a)所示,FPN 进行自顶向下的特征融合,融合后获得的语义信息较高的特征层用来进行预测,但其会受限与单向信息流。路径聚合网络 (Path Aggregation Network, PAN)^[18]解决了这个问题,如图 2(b)所示,在 FPN 的基础上建立新路径,实现自底向上的特征融合,这样就使得底层位置信息能够被送到预测特征层。预测特征层同时得到顶层的语义信息与底层的位置信息,从而提高检测精度。如图 2(c)所示,与 PAN 不同,BiFPN 在 FPN 的基础上增加了一个自底向上的集成路径 (repeated blocks)。一般情况下,网络首先将深层特征图与浅层特征图逐渐合并,使每一层的特征图同时包含浅层特征和深层特征。然后将特定的融合操作连接起来,再加入卷积操作来调整信道数。从而

使得模型在小目标和闭塞目标上的检测性能得到提升。

本文采用 BiFPN 来替换 YOLOv5 结构中的 PANet 层,实现自上而下与自下而上的深层次特征双向融合,加强不同网络层之间特征信息的传递,提高 YOLOv5 算法的检测精度,优化其检测性能。

2.2 注意力机制

在 YOLOv5 网络中,Backbone 结构提取特征是十分重要的步骤,所以将注意力机制引入 Backbone 以优化性能。

2.2.1 高效通道注意力机制 ECA

通过对 SENet^[19]的缺陷进行研究,发现避免降维以及有适当的通道交互是十分重要的,因此提出一种局部的跨通道交互策略 (ECA-Module)^[20],通过一维卷积就可快速实现,此外还设计了一种自适应的一维卷积函数加速训练收敛,实现检测网络的性能优化。图 3 为 ECA 模块结构图。




图 3 ECA 模块结构图

Fig. 3 Structure of ECA module

ECA 模块捕获通道间交互和多通道交互,同时避免降维。如图 3 所示,在不降维的情况下进行全局平均池化运算 (Global Average Pooling, GAP),然后进行一维卷积操作,接着利用 Sigmoid 激活函数归一化,得到各个通道的权重。由于一维卷积的权重以组合跨通道的形式存储,因此权重的数量由卷积核 k 的大小决定。为了进一步提升网络性能,ECA 模块采用了卷积网络权重共享的理念,使每组权重都完全相同。参数量因此而锐减,权重数也由 $k \times C$ (其中 C 为通道数) 个减为 k 个。然而,对于不同的通道数 C, k 也有不同的尺寸变化,所以 ECA 机制提出了一种可以自适应确定一维卷积核

大小的方法,一旦明确了通道维度 C ,则可计算自适应的卷积核大小 k 。

ECA 模块便于集成到现有 CNN 的框架中,因此本文将引入 YOLOv5 来实现性能优化。

2.2.2 坐标注意力机制 CA

在通道注意力中加入位置信息得到坐标注意力机制^[21],扩大网络的注意范围。之前的注意力机制,如 SENet 和 CBAM^[22]等,虽然能够提高检测精度,但依然存在一些问题。SENet 考虑了通道信息,但忽略了位置信息;CBAM 利用了位置信息,但无法获得长程依赖关系。CA 注意力机制不仅获取了通道间信息,还考虑了方向相关的位置信息,有助于模型更好地定位和识别目标。而且 CA 足够灵活和轻量,能够简单地插入移动网络的核心结构中,还可以作为预训练模型用于多种任务中,如检测和分割,均有不错的性能提升。图 4 为 CA 模块结构图。




图 4 CA 模块结构图

Fig. 4 Structure of CA module

图 4 中, X Avg Pool 是对 W 方向做平均池化,同样 Y Avg Pool 是对 H 方向做平均池化。对两个多通道的 1D 向量再做空间维度的级联,然后用 1×1 卷积压缩通道数,接着通过 BN 和 Non-linear 来编码垂直方向和水平方向的空间信息,再进行 split 分离(即将完整的特征向量重新分为两个方向的向量),通过 1×1 卷积重新调整两个方向特征向量的通道数,然后经过 Sigmoid 函数,最后再与原输入信息进行两个方向的加权。

CA 机制能够在提升网络精度的同时不增加开销。本文将将其加入到 YOLOv5 模型中的 Backbone 部分,以此来提升算法精度。

2.3 改进网络整体结构

本文以 YOLOv5 的主体结构为基准,在 Backbone 中加入注意力机制 ECA 和 CA,使得网络能够更加关注待检测目标,以此来提升网络的特征处理能力,提高检测效果;将特征金字塔上网络中的 PAN 改进为 BiFPN,使网络能够实现深浅层特征的双向融合,加强不同网络层之间特征信息的传递,优化检测性能。改进网络的整体结构及各部分主要功能如图 5 所示。




图 5 改进网络的整体结构图

Fig. 5 Overall structure of the improved network

3 实验结果与分析

为了验证本文所提方法的有效性,在公共数据集 LIDC-

IDRI(The Lung Image Database Consortium)上进行消融实验,对各方法性能进行对比,以验证本文所提方法的优越性。

3.1 数据集

LIDC-IDRI 是由美国癌症研究院发起收集的,目的是给医学影像数据的研究人员建立一个公开的参考,进行肺癌早期检测的研究。该数据集由胸部医学影像和对应的诊断信息构成,其中包括 1018 个病例,并且每个病例的诊断信息都由 4 位经验丰富的专家进行诊断和标注。首先,每位专家独立对肺部 CT 图像进行标注,即 ≥ 3 mm 的结节、 < 3 mm 的结节、 ≥ 3 mm 的非结节;然后,每位专家对比另外 3 位专家的匿名标注信息,再次观察肺部 CT 图像,并给出最终的标注结果。这种两阶段的标注方式能够使每位专家都充分考虑到结节的实际情况,减少因个人想法造成的错误,从而得到更准确有效的标注信息。该数据集的主要信息如表 1 所列。

表 1 LIDC-IDRI 数据集的主要信息

Table 1 Main information of LIDC-IDRI

项目	详情
患者数量	1010
图片格式	DICOM
图片数量	244527
扫描层厚	1.25 mm~3 mm
图片尺寸	512 * 512
图片类型	CT(computed tomography);243958 张 DX(digital radiography) CR(computed radiography)
研究数量	1308
系列数量	1018 CT 290 DX/CR

由于 LIDC-IDRI 数据库中的 CT 原始图像为 DICOM 格式,而本实验中用的是 jpg 格式的图像,因此首先从该数据集中挑选出比较有代表性的一部分(约 2000 张切片)并对其进行处理格式转换;然后使用 Label Img 对得到的 jpg 格式的图像进行标注,类别“0”表示有结节,检测结果包括有结节和无结节两种情况。

3.2 参数设置与硬件设备

网络模型训练阶段,参数设置如下:输入图像大小为 640×640 ,置信度设置为 0.5,IOU 阈值设置为 0.5,衰减权重系数设置为 0.0005,将数据的 80% 用于训练,10% 用于验证,10% 用于测试。学习率设置为 0.001,训练批次大小为 16,最大迭代次数为 200,如此可以减少重复计算,加速模型收敛。搭建好网络,准备好数据集,设置好服务器,然后进行网络训练。本文实验所需的软硬件以及环境配置如表 2 所列。

表 2 软硬件配置表

Table 2 Software/hardware configuration

参数	配置
系统环境	Ubuntu18.04
训练框架	PyTorch 1.8.1
语言	Python 3.8
CPU	15 vCPU Intel © Xeon © Platinum 8338C CPU @2.60 GHz
GPU	RTX 3090(24GB)
GPU 加速	CUDA 11.1

3.3 评价指标

本文采用准确率(Precision, P)、召回率(Recall, R)以及平均精度均值(mean Average Precision, mAP)作为评估指标,评估算法对 CT 图像中肺结节的检测性能。

准确率是精度的度量,表示被检测为有结节的样本中实际有结节的比例。召回率是覆盖率的衡量标准,计算有结节的样本中被正确检测为有结节的比例。

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (2)$$

其中, TP 表示被判断为有结节实际也有结节的样本数, FP 表示被判断为有结节但实际无结节的样本数, FN 表示被判断为无结节但实际上有结节的样本数。

mAP 是识别准确性的度量,通过对所有类别的 AP 值求均值得到。通过计算不同召回率下的最高精度,可以绘制出 P-R 曲线,曲线包围的区域即该类的 AP 值。因为本实验中检测目标只有肺结节一类,故本文的 mAP 即 AP 值。

$$mAP = \int_0^1 \frac{TP}{TP + FP}(S) dS \quad (3)$$

3.4 实验结果分析


按照上述设定的网络训练参数进行模型的训练,分别对 YOLOv5 网络和 BiFPN-ECA-CA-YOLOv5 网络进行训练,对实验结果分析如下。

3.4.1 损失值分析


YOLOv5 的损失值由 3 类损失组成,即表征对象位置的损失、对象类别以及是否包含目标对象的损失,如式(4)所示。本实验所检测的目标仅有肺结节一种,故 cls_loss 为 0。

$$Loss = box_loss + cls_loss + obj_loss \quad (4)$$

迭代批次 $epoch$ 设为 200,实验得到的模型的损失变化如图 6 所示,图形中横坐标代表模型的迭代批次,纵坐标表示损失值。



(a) box_loss 收敛效果



(b) obj_loss 收敛效果


图 6 损失函数对比

Fig. 6 Comparison of loss functions


由图 6 可知,改进的 BiFPN-ECA-CA-YOLOv5 的 box_loss 与 YOLOv5 相差不多,而且都基本接近于 0,但是 BiFPN-ECA-CA-YOLOv5 算法收敛明显更平缓。置信度损失收敛后的值,改进前的算法收敛更快,且收敛值更小,这表示改进后的算法对是否包含结节存在更多误判。模型训练效果相对较理想。

3.4.2 精度分析


图 7 对比了 YOLOv5 与 BiFPN-ECA-CA-YOLOv5 的性能度量指标收敛曲线。观察两个模型的 mAP 曲线可知,改进后的 BiFPN-ECA-CA-YOLOv5 更加稳定,性能更好。




(a) 准确率曲线对比



(b) 召回率曲线对比



(c) mAP@0.5 曲线对比



(d) mAP@0.5:0.95 曲线对比

图 7 性能度量指标收敛曲线

Fig. 7 Convergence curves of performance metrics

由图 7 可知,YOLOv5 的精确率只有 60% 左右,而 BiFPN-ECA-CA-YOLOv5 的精确率接近 80%,同时, BiFPN-ECA-CA-YOLOv5 的召回率最高时达到 90% 多, $mAP@0.5$ 大约由 75% 增长到 80%, $mAP@0.5:0.95$ 大约由 40% 增长到 50%。由此可见,改进后的 BiFPN-ECA-CA-YOLOv5 算法收敛后的各项性能指标值更高,模型对 CT 图像中肺结节的检测能力更强。

3.4.3 消融实验

为了验证所提 BiFPN-ECA-CA-YOLOv5 算法的有效性,分析提出的检测方法中各成分的重要性,逐步将 BiFPN, ECA 和 CA 应用到模型中进行消融实验。所有消融实验的基准网络是 YOLOv5。在测试集上的消融实验结果如表 3 所列,表中加粗的数值为最优值。

表 3 算法性能对比

Table 3 Algorithm performance comparison

算法	准确率	召回率	mAP
YOLOv5	63.85	85.25	72.5
YOLOv5+BiFPN	73.94	88.00	73.2
YOLOv5+ECA+CA	73.92	89.00	74.0
BiFPN-ECA-CA-YOLOv5	75.33	90.75	80.2

根据实验结果得出,相同的实验环境下,改进特征金字塔和加入注意力机制对检测性能都提供了一定的帮助,性能指标都得到提升。由表 3 可以看出,相较于 YOLOv5 算法,BiFPN-ECA-CA-YOLOv5 算法在准确率、召回率和平均精度上分别提高了 11.48%,5.5%和 7.7%。对于肺结节检测来说,

查全的重要性要大于查准,而召回率越高即模型对肺结节的查全率越高,因此改进的 BiFPN-ECA-CA-YOLOv5 性能比较优越。

3.4.4 检测结果

为了验证基于 YOLOv5 改进的模型对肺结节的检测性能,将模型在 LIDC-IDRI 数据集上分别进行训练和测试,得到的检测结果如图 8 所示。图中目标框表示检测到的肺结节,目标框上的数值是类别标签的置信度。为了增强图像可视化效果,对标签进行了简化,“0”表示结节。观察检测结果图可以得出,BiFPN-ECA-CA-YOLOv5 算法能够有效地检测出肺结节,对于难检测的小结节也有较好的检测效果。

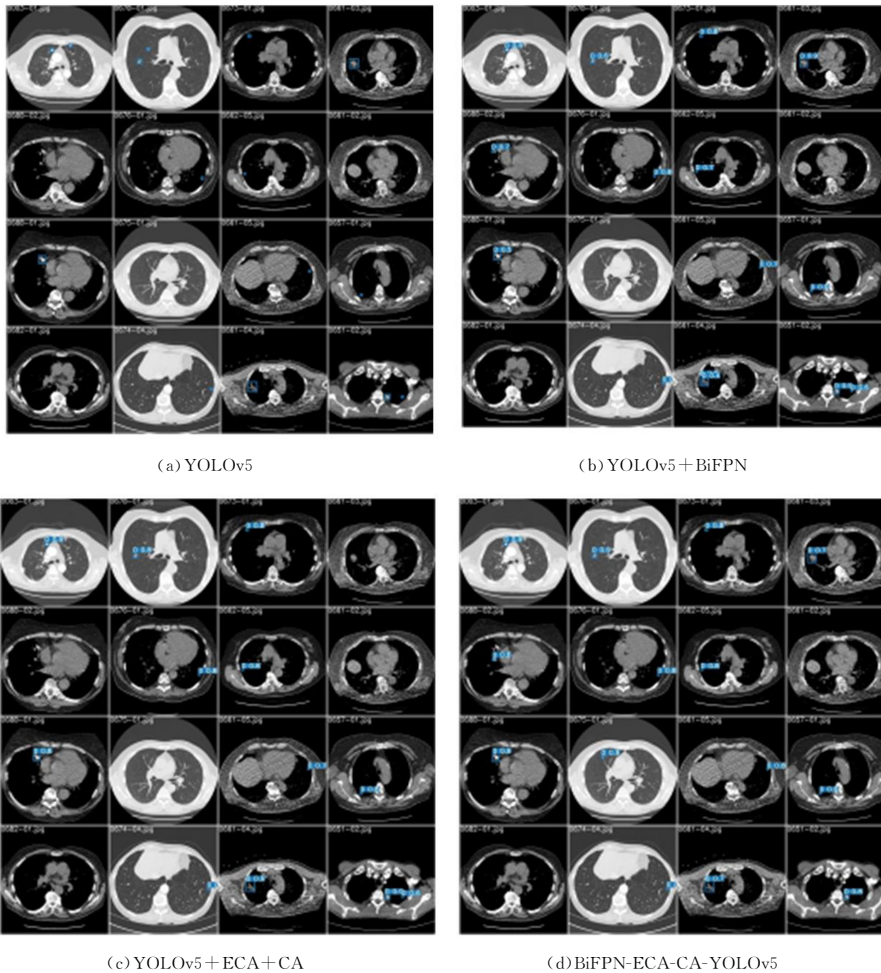


图 8 检测结果

Fig. 8 Detection results

从检测结果图中可以观察到,改进前的检测结果中存在漏检的情况,而改进后的检测结果中大部分结节能够被正确检出,但依然存在部分漏检的情况,这是因为肺部小结节容易隐匿于其它组织,提取特征比较困难,且其特征不够明显,在预处理环节容易造成特征信息丢失。在后续工作中,可以针对该问题做出改进,充分利用小结节的三维特征,提高其检出率。

结束语 综上所述,为了减轻影像科医生的工作负担,并实现更准确且实时的肺结节检测,提出一种基于 YOLOv5 的肺部 CT 图像肺结节检测算法 BiFPN-ECA-CA-YOLOv5。经过实验验证,所提方法的检测精度与召回率较 YOLOv5 算法

均有所提高,因此本文方法具有一定的优势。但同时,本方法仍然存在一定的局限性,对特征信息不明显的小结节有一定程度的漏检。因此,接下来将在这些方面做进一步研究和改进。

参考文献

[1] ZHANG J,XIA Y,CUI H,et al. Pulmonary nodule detection in medical images: A survey[J]. Biomedical Signal Processing and Control,2018,43:138-147.
 [2] ZHANG Z H,CAI Y Q,HAN D, et al. Artificial intelligence and various levels of physicians in detection of pulmonary nodules:a

- comparative study [J]. Chinese Journal of Medical Imaging, 2020, 28(9): 662-665.
- [3] KIM Y G, CHO Y, WU C J, et al. Short-term reproducibility of pulmonary nodule and mass detection in chest radiographs: comparison among radiologists and four different computer-aided detections with convolutional neural net [J]. Scientific Reports, 2019, 9: 18739.
- [4] XU J, REN H J, CAI S Z, et al. An improved faster R-CNN algorithm for assisted detection of lung nodules [J]. Computers in Biology and Medicine, 2023, 153: 106470.
- [5] ZHAO P F, ZHAO J J, QIANG Y, et al. Study on detection method of pulmonary nodules with multiple input convolutional neural network [J]. Computer Science, 2018, 45(1): 162-166.
- [6] YUE Q, YIN J Y, WANG S. Automatic detection of pulmonary nodules in low-dose CT images based on improved CNN [J]. Computer Science, 2022, 49(S1): 54-59.
- [7] 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. IEEE, 2016: 779-788.
- [8] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 7263-7271.
- [9] REDMON J, FARHADI A. YOLOv3: an incremental improvement [J/OL]. (2018-04-08) [2021-09-08]. arXiv: 1804. 02767, 2018.
- [10] BOCHKOVSKIY A, WANG C Y, LIAO H Y. YOLOv4: optimal speed and accuracy of object detection [J/OL]. (2020-04-23) [2021-09-08]. arXiv: 2004. 10934, 2020.
- [11] JENA S R, GEORGE S T, PONRAJ D N. Modeling an effectual multi-section you only look once for enhancing lung cancer prediction [J]. International Journal of Imaging Systems and Technology, 2021, 31(4): 2144-2157.
- [12] CHO Y, LEE S M, CHO Y H, et al. Deep chest X-ray: detection and classification of lesions based on deep convolutional neural networks [J]. International Journal of Imaging Systems and Technology, 2020, 31(1): 72-81.
- [13] LIU C Y, HU S C, WANG C H, et al. Automatic detection of pulmonary nodules on CT images with YOLOv3: development and evaluation using simulated and patient data [J]. Quantitative Imaging in Medicine and Surgery, 2020, 10(10): 1917-1929.
- [14] HUANG Y S, CHOU P R, CHEN H M, et al. One-stage pulmonary nodule detection using 3-D DCNN with feature fusion and attention mechanism in CT image [J]. Computer Methods and Programs in Biomedicine, 2022, 220: 106786.
- [15] LIU K H. STBi-YOLO: a real-time object detection method for lung nodule recognition [J]. IEEE Access, 2022, 10: 75385-75394.
- [16] TAN M, PANG R, QUOC V. EfficientDet: scalable and efficient object detection [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 10781-10790.
- [17] TSUNG Y, PIOTR D, ROSS G, et al. Feature pyramid networks for object detection [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 2117-2125.
- [18] LIU S, QI L, QIN H F. Path aggregation network for instance segmentation [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 8759-8768.
- [19] HU J, SHEN L, SAMUEL A. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 42(8): 2011-2023.
- [20] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 11534-11542.
- [21] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C] // 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 13713-13722.
- [22] WOO S, PARK J, LEE J Y, et al. CBAM: convolution block attention module [C] // Computer Vision—ECCV 2018: 15th European Conference. Springer, 2018: 3-19.



WU Chunming, born in 1966, professor, master's supervisor. His main research interests include image processing and wireless sensor networks.



LIU Yali, born in 1996, postgraduate. Her main research interest is image processing.