

基于跨路径特征聚合的改进型 YOLOv3 乳腺肿块识别算法

王杉¹, 胡艺莹^{1*}, 丰亮², 郭林英²

¹华东交通大学信息工程学院, 江西 南昌 330013;

²南昌市第三医院乳腺肿瘤科, 江西 南昌 330009

摘要 针对基于深度学习的乳腺癌诊断中小肿块和互相遮挡肿块易被漏诊的问题,提出了一种用于乳腺肿块检测的改进型 YOLOv3 算法。首先,在特征融合模块中添加了自底向上的路径,并采用级联和跨层连接的方式充分利用底层特征信息,提高了小肿块的识别精度;其次,为了筛选出更精确的预测框,避免互相遮挡的肿块出现漏检的情况,在软非极大值抑制(Soft-NMS)算法中引入了距离交并比(DIoU)来抑制冗余的预测框。实验结果表明,所提乳腺肿块检测算法在检测小肿块和互相遮挡的肿块方面有较高的准确率和速度,平均均值精度(mAP@0.5)达到了 96.1%,相比于 YOLOv3 提高了 1.8 个百分点,且每张钼靶图像的检测时间仅为 28 ms。

关键词 图像处理; 乳腺钼靶图像; YOLOv3; 特征融合; 距离交并比; 软非极大值抑制; 目标检测

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202259.0410003

Improved Breast Mass Recognition YOLOv3 Algorithm Based on Cross-Layer Feature Aggregation

Wang Shan¹, Hu Yiyi^{1*}, Feng Liang², Guo Linying²

¹School of Information Engineering, East China JiaoTong University, Nanchang,
Jiangxi 330013, China;

²Department of Breast Oncology, The Third Hospital of Nanchang, Nanchang,
Jiangxi 330009, China

Abstract Aiming at the problem that small masses and occluded masses are easy to be missed in breast cancer diagnosis based on deep learning, an improved YOLOv3 algorithm for breast mass detection is proposed. First, a bottom-up path is added into the feature fusion module, and the cascading and cross-layer connections are adopted to make full use of the underlying feature information to improve the recognition accuracy of small masses. Second, to filter out more accurate prediction bounding boxes and avoid missed detection of masses that occlude each other, the distance intersection over union (DIoU) is introduced in soft non-maximum suppression (Soft-NMS) algorithm to suppress the redundant prediction bounding boxes. The experimental results demonstrate that the proposed breast mass detection algorithm has high accuracy and speed in detecting small masses and occluded masses, mean average precision (mAP@0.5) reaches 96.1%, which is 1.8 percentage point higher than that of YOLOv3, and the detection time of each mammogram target image is only 28 ms.

Key words image processing; mammogram; YOLOv3; feature fusion; distance intersection over union; soft non-maximum suppression; object detection

收稿日期: 2021-02-08; 修回日期: 2021-03-14; 录用日期: 2021-03-22

通信作者: *yiyinghu1125@163.com

1 引言

乳腺癌在全球女性恶性肿瘤发病率中位居榜首^[1],对乳腺癌的早期筛查可以有效地控制病情的发展并显著提高生存率^[2-3]。由于乳房X线摄影是一种投影成像,肿块很容易被致密的腺体组织挡住,放射科医生只有积累了大量的经验,才能对乳房X线照片做出更准确的判断^[4-5];此外,持续阅片会造成视觉和心理上的疲劳^[6-7],误诊和漏诊的情况经常发生。因此,乳腺肿块的检测仍然是一项具有挑战性的任务,一种乳腺癌辅助诊断技术亟待开发^[8-9]。

传统的肿块检测方法包括两个步骤:1)提取手工制作的特征并选择最优的特征组合;2)将特征传递给分类器。即使同一类型的病灶,在形状、纹理等方面也有很大差异,而且手工制作的特征并不能很好地描述不同病灶^[10-11]。近年来,深度学习被用于乳腺癌辅助诊断系统领域,以应对传统方法的局限性。2018年,Ribli等^[12]提出了一种基于Faster R-CNN的诊断系统,该系统采用区域建议网络(RPN)生成区域建议框。然而,将Faster R-CNN直接应用于乳房肿块检测仍然面临一些限制。Eggert等^[13]研究了RPN在小目标实例上的弱点。小目标很容易被忽视,因为RPN很难对它们进行精确定位。此外,RPN只提取感兴趣区域(ROI)的局部信息,忽略全局上下文信息,对混淆目标的辨识能力差,假阳性率高。最

近,一种基于回归的目标检测方法被用于乳房肿块检测任务中。例如,Al-Masni等^[14]提出了一种基于you only look once(YOLO)的乳腺癌诊断系统,该系统不需要生成和选择候选区域,在预测目标包围框位置时充分结合图像上下文信息,降低了假阳性检测率,但对互相遮挡的肿块的识别能力还有待提高。

针对上述方法的局限性,本文提出了一种改进的YOLOv3检测算法来实现乳腺钼靶X线肿块的检测和分类。所提算法使用一个新的多尺度级联特征聚合结构(MCFN)代替YOLOv3中的特征金字塔结构(FPN)^[15]。该特征聚合结构是受路径聚合网络(PANet)^[16]的启发而来的,在此基础上采用级联的方式充分融合各层信息,还添加了跨连接路径,连接骨干网络的特征和自底向上的特征。该结构能够提高对小肿块的分类和定位能力。为了筛选出更准确的边界框,避免删除被遮挡肿块的边界框,所提算法将软非极大值抑制(Soft-NMS)算法^[17-18]应用到YOLOv3中,并在Soft-NMS中使用距离交并比(DIoU)^[19]来抑制周围的边界框。

2 YOLOv3目标检测算法

所提算法采用YOLOv3为基础网络来对乳腺钼靶X线肿块进行检测^[20],整个网络由3部分组成,分别为特征提取模块、特征融合模块和结果预测模块,如图1所示,其中CBL模块表示卷积、批量归一

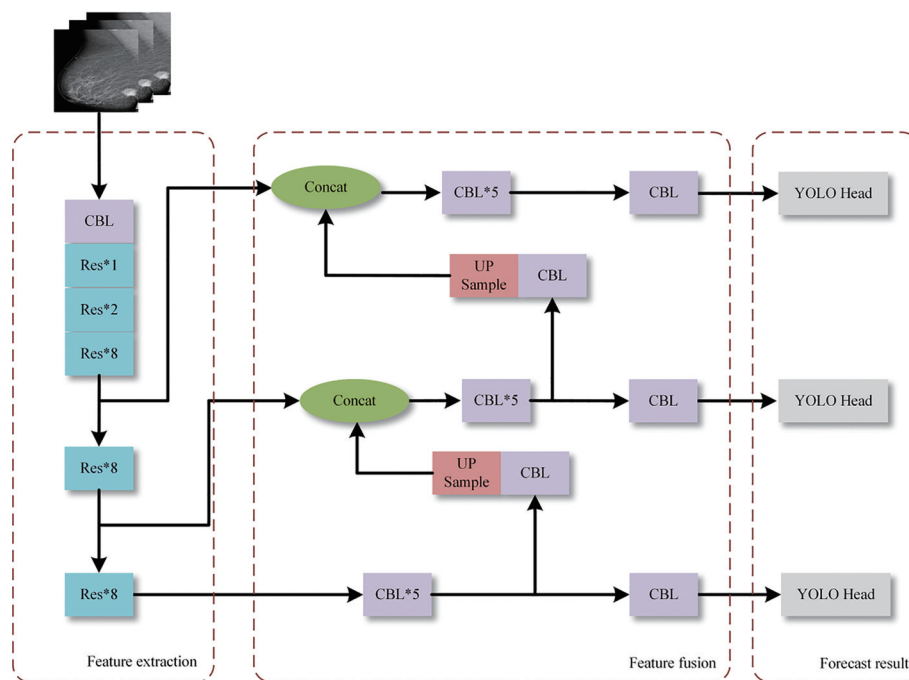


图1 YOLOv3网络结构^[20]

Fig. 1 Network structure of YOLOv3^[20]

化和 leaky ReLU 函数, Res 模块表示残差单元^[21], 具体结构如图 2 所示。首先, 将乳腺钼靶 X 线图像输入到特征提取模块, 并通过一系列残差块来提取特征。其次, 在特征融合阶段, 从残差块中取出 3 种不同大小的特征映射和上采样之后得到的特征映射进行串联, 目的是将底层的位置信息和高层的语义

信息结合起来, 得到不同尺寸的感受野, 有利于检测不同尺寸的肿块。3 个特征映射的尺寸分别为 $52 \times 52, 26 \times 26, 13 \times 13$ 。最后, 在特征映射模块进行结果预测, 以获得不同大小的预测边界框的信息、肿块类别和置信度。




图 2 YOLOv3 结构单元^[21]。(a) CBL 单元; (b) 残差单元

Fig. 2 Structural unit of YOLOv3^[21]. (a) CBL unit; (b) residual unit

3 改进的 YOLOv3 模型

3.1 改进的特征融合方式

YOLOv3 采用 FPN 结构进行特征融合^[15], 该结构只有自顶向下的特征融合路径, 如图 3 所示。FPN 对顶层特征图的过度下采样会导致顶层的抽象信息和底层的细节信息之间不平衡, 不利于小肿块的检测。而顶层的抽象信息主要用于分类, 底层

的细节信息主要用于定位, 将这两者信息充分结合对提升小肿块的检测性能至关重要。针对这一问题, 所设计的 MCFN 具体结构如图 4 所示。该结构的设计思路如下: 首先, 在传统 FPN 结构之后加上一条自底向上的特征融合路径, 有效地提高了网络平衡顶层抽象信息与底层细节信息的能力; 其次, 采用了级联的方式, 将两个相同的特征融合结构串联在一起, 充分地将骨干网络中的 3 个特征图进行




图 3 特征金字塔网络^[15]

Fig. 3 Feature pyramid network^[15]

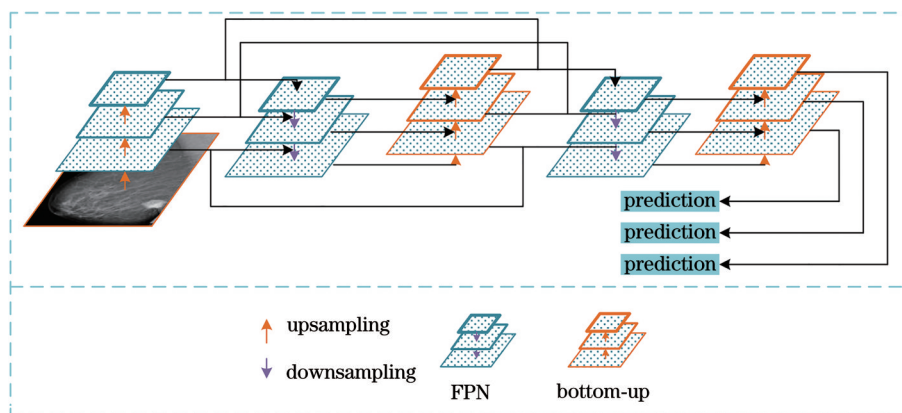


图 4 MCFN 结构

Fig. 4 Structure of MCFN

融合;最后,由于骨干网络中包含输入图像最重要的特征信息,为了充分利用该特征信息,将骨干网络的特征和自底向上的特征跨路径连接起来。MCFN将顶层特征和底层特征进行了很好的融合,可以提高对小肿块的分分类能力和定位能力。

3.2 改进的非极大值抑制算法

在肿块检测阶段,真实目标肿块周围会输出多个重复预测边界框。NMS算法^[17]被广泛应用于去除冗余的预测边界框,只留下最准确的结果。YOLOv3将交并比(IoU)值作为NMS来抑制多余边界框的主要指标。首先,NMS算法根据人为设置的置信度阈值,将置信度大于阈值的边界框保留下来,删除置信度小于阈值的边界框。然后,设定一个IoU阈值,计算得分最大的预测框和其余框的IoU值,将IoU大于阈值的框舍去,小于阈值的框保留。但是,如果一个肿块在另一个肿块区域内出现,即当两个肿块接近且互相重叠时,分数更低的框就会因为IoU过大而被删掉,从而出现肿块漏检的情况。Soft-NMS算法解决了这个问题,该算法基于IoU的大小为相邻预测框设置一个衰减函数而非彻底将其分数置为零,采用的衰减函数为高斯惩罚函数^[18]。但是,以IoU作为评价策略也存在不足,即两个肿块预测框的IoU值相同时,重叠方式不一定一样。因此,在Soft-NMS阈值判断条件中增加了两个预测框中心点之间的距离^[19],进一步改进了Soft-NMS算法,提出了新的soft-distance-NMS(SD-NMS)算法来抑制多余预测框。

SD-NMS算法的大致思路如图5所示, M 代表得分最大的预测框, $B = \{b_1, \dots, b_N\}$,其中 b_i 代表每个类别的预测框, $S = \{s_1, \dots, s_N\}$,其中 s_i 代表当前

```



---


Input:  $B, S, N_t$ 


---


begin
     $D \leftarrow \{ \}$ 
    While  $B \neq \emptyset$  do
         $m \leftarrow \operatorname{argmax} S$ 
         $M \leftarrow b_m$ 
         $D \leftarrow D \cup M; B \leftarrow B - M$ 
        for  $b_i$  in  $B$  do
             $s_i \leftarrow s_i \cdot f[\operatorname{IoU}(M, b_i)]$ 
        end
    end
    return  $D, S$ 


---


end
    
```

图5 SD-NMS算法的伪代码

Fig. 5 Pseudo code of SD-NMS algorithm

预测框的得分。

s_i 的计算过程为

$$s_i = \begin{cases} s_i, & R_{\text{IoU}} - R_{\text{DloU}}(M, b_i) < N_t \\ s_i \cdot \exp[-R_{\text{IoU}}^2(M, b_i)], & R_{\text{IoU}} - R_{\text{DloU}}(M, b_i) \geq N_t \end{cases}, \quad (1)$$

$$\begin{cases} R_{\text{IoU}} = \frac{\operatorname{area}(M) \cap \operatorname{area}(b_i)}{\operatorname{area}(M) \cup \operatorname{area}(b_i)}, \\ R_{\text{DloU}} = \frac{\rho^2(M, b_i)}{c^2} \end{cases}, \quad (2)$$

式中: N_t 代表两个预测框的IoU阈值,一般设置为0.3; $\operatorname{area}(\cdot)$ 为某个预测框的面积; $\operatorname{area}(M) \cap \operatorname{area}(b_i)$ 表示 M 和 b_i 两个预测框重叠部分的面积; $\operatorname{area}(M) \cup \operatorname{area}(b_i)$ 表示两个预测框的总面积; c 为覆盖两个预测框的最小闭合区域的对角线距离; $d = \rho(M, b_i)$ 为两个预测框中心点的距离,如图6所示^[19]。预测框 b_i 与分数最大的预测框 M 重叠程度越大,衰减效果就越明显,更新后的 s_i 就越小; b_i 与 M 的重叠程度越小,衰减效果就越弱,更新后的 s_i 不会受太大影响。总而言之,该方法不仅有效地提高了检测模型的精度,还解决了互相遮挡的肿块易漏检的问题。




图6 R_{DloU} 的计算示意图^[19]

Fig. 6 Schematic diagram of R_{DloU} ^[19]

3.3 改进的网络结构

所提乳腺钼靶X线肿块检测框架(MCF-YOLO)如图7所示。MCF-YOLO在特征融合阶段采用了MCFN,充分利用骨干网络提取的特征信息,提高了小肿块的检测精度;在结果预测阶段采用了SD-NMS算法,解决了传统NMS对于检测重叠肿块的不足。因此,MCF-YOLO不仅提升了模型的检测精度,还解决了互相遮挡的肿块容易被漏检的问题。

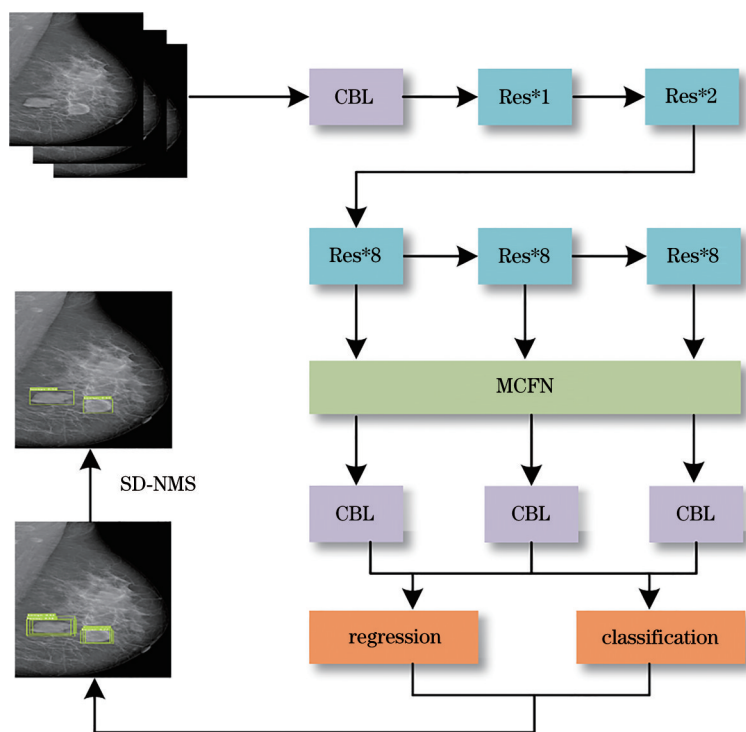


图 7 所提网络结构

Fig. 7 Structure of proposed network

4 实验结果分析

4.1 数据来源

使用的乳腺钼靶 X 线摄影图片数据集来源于南昌市第三医院,该数据集囊括了 1460 个女性患者的乳腺筛查情况,每个患者均有 4 个 X 线的标准视角,分别为右头足位(R-CC)、左头足位(L-CC)、右内外斜侧位(R-MLO)和左内外斜侧位(L-MLO),每张图片的像素尺寸为 1914 pixel×2294 pixel,以 JPG 格式存储。所有图像包括了正常

图像和非正常图像,其中非正常图像的病灶种类主要包括肿块、钙化、不对称和结构扭曲等。南昌市第三医院放射科医师为数据集中的所有带病灶的乳房 X 线摄影图像提供了病灶类型、病灶位置等信息。其中一部分图像不止包含一个肿块,因此收集到的数据集中共有良性肿块 855 个,恶性肿瘤 521 个。图 8 列举了一些病例的图像,第 1 行为恶性病例,第 2 行为良性病例。从左到右的视角依次为 R-CC、L-CC、R-MLO 和 L-MLO,肿块采用圆圈标记,未标记的为正常图像。




图 8 乳腺癌筛查病例说明

Fig. 8 Illustration of breast cancer screening cases

4.2 数据预处理

从图 8 中可以看出,乳腺钼靶 X 线图像存在大面积的黑色背景,乳房区域只占了一小部分。事实上,在临床中只有乳腺区域是感兴趣的区域,因此有必要对原始图像进行预处理,去除无关的黑色背景和标签来获得乳腺区域,这样不仅可以节约内存空间,还加快了网络处理图像的速度。裁剪后的图像如图 9 所示。




图 9 裁剪后的图像

Fig. 9 Cropped images

在乳腺钼靶 X 线图像中,由于肿块组织区域和周围组织区域之间的差异性较小,肉眼难以快速准确地定位出肿块,因此需要采用图像处理的方法凸显出肿块区域。所提算法采用了双帽变换的方法,其中结构元素使用的是“球状”,如图 10 所示^[22]。这样可以在增强结构元素内的肿块信息的同时保持结构元素外的组织信息不变,达到局部增强的效果^[23]。

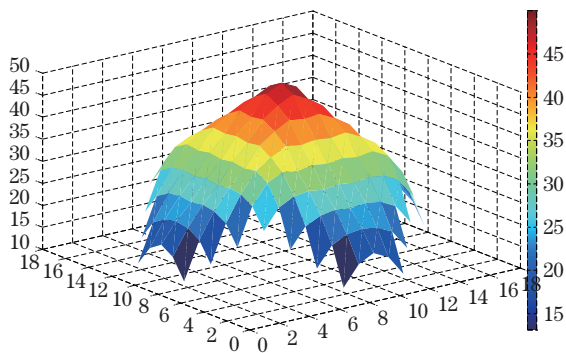


图 10 “球状”结构元素^[22]

Fig. 10 “Sphere” structural element^[22]

图像 f 的顶帽变换表达式为

$$T_{\text{hat}}(f) = f - (f \circ b), \quad (3)$$

式中 \circ 是形态学中的开操作; b 是图 10 所示“球状”结构元素。类似地, f 的底帽变换表达式为

$$B_{\text{hat}}(f) = (f \cdot b) - f, \quad (4)$$

式中 \cdot 表示形态学中的闭操作。那么,局部增强之后的图像为

$$I_{\text{enhance}} = f + T_{\text{hat}}(f) - B_{\text{hat}}(f). \quad (5)$$

双帽变换处理后的乳腺肿块图像如图 11(b) 所示,通过与原图[图 11(a)]对比可知,肿块部分的纹理特征更加清晰了。




图 11 局部增强的结果。(a)原图;(b)增强的图像

Fig. 11 Result of local enhancement. (a) Original image; (b) enhanced image

4.3 实验环境和评价指标

实验所用计算机平台的 GPU 为 NVIDIA GeForce GTX 2060, CPU 为 Inter i7-8700,内存为 32 GB;操作系统是 Ubuntu 16.04,主要的编程语言为 Python 3.6 和 C++。

网络训练过程中的参数设置如下:输入图像的尺寸大小为 416×416 ,初始学习率为 0.005,每 10 个 epoch 学习率衰减 0.01, batch size 为 64, mini-batch 大小为 16,学习速率更新策略是“step”,权重衰减为 0.0005,动量为 0.93,总共迭代了 200 个 epoch。为了便于观察训练过程中各性能评价指标的变化,对相关指标进行了可视化操作,如图 12 所示。图 12 前 3 列分别为训练集(第 1 行)和验证集(第 2 行)的边界框损失、置信度损失和类别损失。3 个损失曲线表明,随着训练次数的增加,损失值逐渐降低并趋于稳定,这意味着所提方法在优化网络时产生了更好的模型参数。图 12 后 2 列分别是精确率(P)、召回率(R)、平均均值精度(mAP),其中 $mAP@0.5$ 和 $mAP@0.5:0.95$ 中 @ 后面的数字表示 IoU 的阈值,这 3 个指标是目标检测中常用的评估指标,可以衡量模型在分类问题中的性能。一般来说,性能越好的分类器这 3 个指标的值越高。

4.4 实验结果

将所提 MCF-YOLO 和其他先进的目标检测算法在相同数据集上的肿块检测结果进行了定量对比分析,结果如表 1 所示,粗体表示 5 种算法中性能最

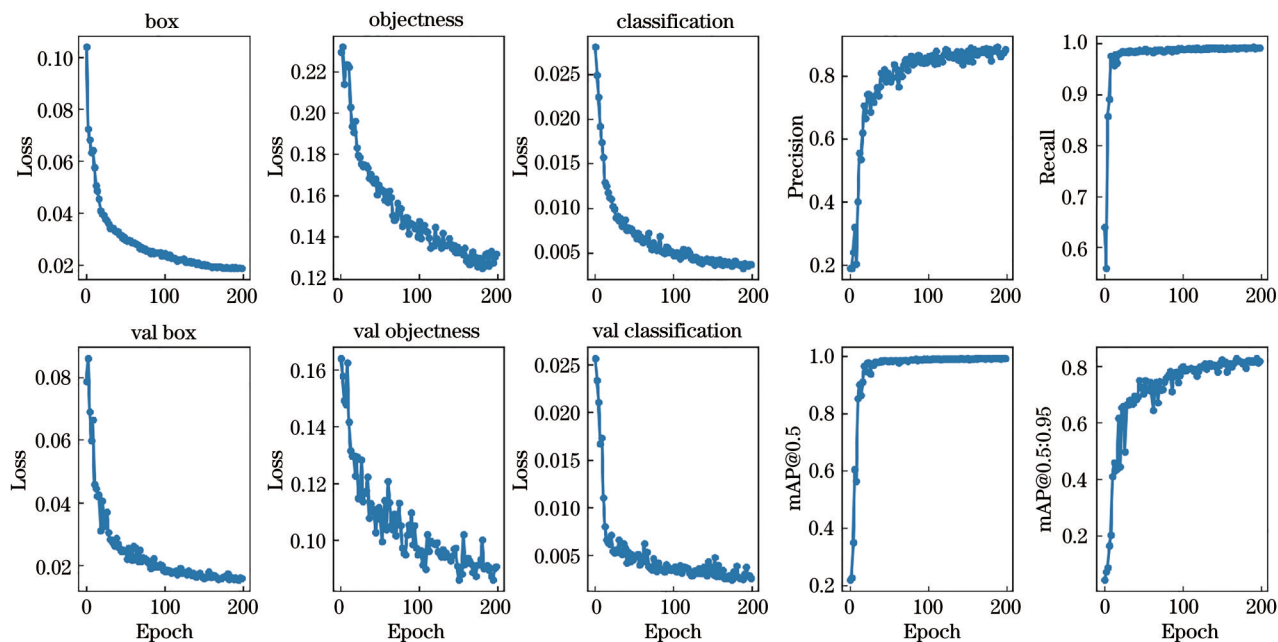


图 12 MCF-YOLO 的训练结果

Fig. 12 Training results of MCF-YOLO

表 1 MCF-YOLO 和其他目标检测算法的定量比较

Table 1 Quantitative comparison between MCF-YOLO and other object detection algorithms

Algorithm	Backbone	AP (benign) /%	AP (malignant) /%	mAP@0.5 /%	mAP@0.5:0.95 /%	Time /ms
Faster RCNN	ResNet-101	92.6	96.8	94.7	79.2	101
SSD	ResNet-101	86.5	90.1	88.3	73.1	46
RetinaNet	ResNet-101	94.1	96.7	95.4	80.5	57
YOLOv3	Darknet53	91.2	97.4	94.3	79.0	22
MCF-YOLO	Darknet53	94.8	97.4	96.1	81.6	28

好的。一阶段检测器比两阶段检测器的检测速度更快,但检测精度却较低。MCF-YOLO 的 mAP 值和 Faster RCNN 相近,但是读取一张图像的时间仅仅只是 Faster RCNN 的 27.7%。与经典的一阶段目标检测器 SSD 相比, MCF-YOLO 的 mAP@0.5 提高了 7.8 个百分点,时间也缩短了接近一半。与 RetinaNet 相比, MCF-YOLO 的 mAP@0.5 虽然只提高了 0.7 个百分点,但速度上却提高了一倍。与 YOLOv3 相比,由于改进了特征融合模块和 Soft-NMS 算法, mAP@0.5 提高了 1.8 个百分点, mAP@0.5:0.95 提高了 2.6 个百分点。综上所述,所提算法在检测精度和推理速度上取得了一个相对好的平衡。

MCF-YOLO 和其他先进的目标检测算法在肿块识别上的 Precision-Recall 曲线如图 13 所示。从图中可以看出, MCF-YOLO 算法在精确率和召回率方面与其他 4 种算法相比有一定的优势,精确率较高。

为了直观地体现 MCF-YOLO 的性能,从测试

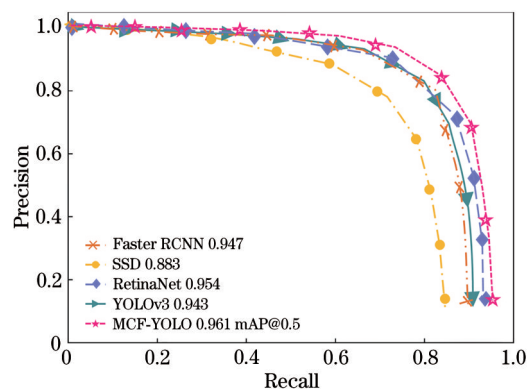


图 13 MCF-YOLO 和其他目标检测算法的 Precision-Recall 曲线对比

Fig. 13 Comparison of Precision-Recall curves between MCF-YOLO and other object detection algorithms

集中选择了 4 张典型的肿块图像,使用表 1 提到的 5 种目标检测算法来进行肿块检测,结果对比如图 14 所示。图 14(a)是乳腺肿块的真实标签;图 14(b)~(f)分别是 Faster RCNN、SSD、RetinaNet、YOLOv3、




图 14 五种算法肿块检测结果对比。(a)乳腺肿块的真实标签;(b)Faster RCNN;(c)SSD;(d)RetinaNet;(e)YOLOv3;
(f)MCF-YOLO

Fig. 14 Comparison of masses detection results of five algorithms. (a) Ground truth of breast masses; (b) Faster RCNN; (c) SSD; (d) RetinaNet; (e) YOLOv3; (f) MCF-YOLO

MCF-YOLO 的检测结果;图 14 第 1 列展示了 5 种算法在小肿块方面的检测性能,其他 4 种算法只检测出了一个稍大的肿块,漏检了右上角较小的肿块,但是 MCF-YOLO 将两个肿块都检测出来了;在第 2 列中出现了两个肿块互相遮挡的情况时,其他算法都将两个肿块检测为一个,只有 MCF-YOLO 算法可以将互相遮挡的两个肿块都检测出来;第 3 列和第 4 列展示的是 5 种算法在多个肿块和大肿块方面的检测性能,MCF-YOLO 的检测结果与 YOLOv3 基本上没有区别。上述结果表明,MCF-YOLO 对小肿块和互相遮挡的肿块有更好的检测效果。

5 结 论

为了解决乳腺钼靶 X 线图像中小肿块和互相遮挡的肿块识别困难的问题,在 YOLOv3 网络的基础上进行了改进,提出了一个新的肿块检测网络 MFC-YOLO。为了提高小肿块的检测精度,对原始 FPN 进行了改进,通过添加自底向上的特征提取路径有效地结合底层位置信息和高层语义信息,采用跨路径连接的方式充分利用骨干网络的信息;将 NMS 替换为 Soft-NMS,并在阈值判断条件中引入 DIoU 来进行优化,提高了互相遮挡肿块的识别效果。在私有数据集上与主流的目标检测网络进行了对比,实验结果表明,所提算法对识别小肿块和被遮挡的肿块的性能优于传统目标检测算法。该算法在临床实践中可以辅助放射科医生进行乳腺肿块的检测和分类。

参 考 文 献

- [1] Siegel R L, Miller K D, Jemal A. Cancer statistics, 2019[J]. CA: a Cancer Journal for Clinicians, 2019, 69(1): 7-34.
- [2] Wang Y, Li J Y, Yang Y L, et al. Breast tumor segmentation based on SLIC and GVF snake algorithm[J]. Laser & Optoelectronics Progress, 2020, 57(14): 141023. 王燕, 李积英, 杨宜林, 等. 基于 SLIC 和 GVF Snake 算法的乳腺肿瘤分割[J]. 激光与光电子学进展, 2020, 57(14): 141023.
- [3] Niu X M, Lü X Q, Gu Y, et al. Breast cancer histopathological image classification based on improved ResNeXt[J]. Laser & Optoelectronics Progress, 2020, 57(22): 221021. 牛学猛, 吕晓琪, 谷宇, 等. 基于改进 ResNeXt 的乳腺癌组织病理学图像分类[J]. 激光与光电子学进展, 2020, 57(22): 221021.
- [4] Katzen J, Dodelzon K. A review of computer aided detection in mammography[J]. Clinical Imaging, 2018, 52: 305-309.
- [5] Skaane P. Studies comparing screen-film mammography and full-field digital mammography in breast cancer screening: updated review[J]. Acta Radiologica, 2009, 50(1): 3-14.
- [6] Li H, Zhuang S S, Li D A, et al. Benign and malignant classification of mammogram images based on deep learning[J]. Biomedical Signal Processing and Control, 2019, 51: 347-354.
- [7] Bae M S, Moon W K, Chang J M, et al. Breast cancer detected with screening US: reasons for nondetection at mammography[J]. Radiology, 2014, 270(2): 369-377.
- [8] Huang Y J, Shi Z F, Wang Z Q, et al. Improved U-net based on mixed loss function for liver medical image segmentation[J]. Laser & Optoelectronics Progress, 2020, 57(22): 221003. 黄泳嘉, 史再峰, 王仲琦, 等. 基于混合损失函数的改进型 U-Net 肝部医学影像分割方法[J]. 激光与光电子学进展, 2020, 57(22): 221003.
- [9] Sun Y J, Qu Z Y, Li Y H. Study on target detection of breast tumor based on improved mask R-CNN[J]. Acta Optica Sinica, 2021, 41(2): 0212004. 孙跃军, 屈赵燕, 李毅红. 基于改进的 Mask R-CNN 的乳腺肿瘤目标检测研究[J]. 光学学报, 2021, 41(2): 0212004.
- [10] Muduli D, Dash R, Majhi B. Automated breast cancer detection in digital mammograms: a moth flame optimization based ELM approach[J]. Biomedical Signal Processing and Control, 2020, 59: 101912.
- [11] Hayward J H, Ray K M, Wisner D J, et al. Improving screening mammography outcomes through comparison with multiple prior mammograms[J]. AJR. American Journal of Roentgenology, 2016, 207(4): 918-924.
- [12] Ribli D, Horváth A, Unger Z, et al. Detecting and classifying lesions in mammograms with Deep Learning [J]. Scientific Reports, 2018, 8(1): 4165.
- [13] Eggert C, Brehm S, Winschel A, et al. A closer look: small object detection in faster R-CNN[C]// 2017 IEEE International Conference on Multimedia and Expo (ICME), July 10-14, 2017, Hong Kong, China. New York: IEEE Press, 2017: 421-426.
- [14] Al-Masni M A, Al-Antari M A, Park J M, et al. Simultaneous detection and classification of breast

- masses in digital mammograms via a deep learning YOLO-based CAD system[J]. *Computer Methods and Programs in Biomedicine*, 2018, 157: 85-94.
- [15] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 936-944.
- [16] Liu S, Qi L, Qin H F, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8759-8768.
- [17] Neubeck A, van Gool L. Efficient non-maximum suppression[C]//18th International Conference on Pattern Recognition (ICPR'06), August 20-24, 2006, Hong Kong, China. New York: IEEE Press, 2006: 850-855.
- [18] Bodla N, Singh B, Chellappa R, et al. Soft-NMS: improving object detection with one line of code[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 5562-5570.
- [19] Zheng Z H, Wang P, Liu W, et al. Distance-IoU loss: faster and better learning for bounding box regression[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(7): 12993-13000.
- [20] Redmon J, Farhadi A. YOLOv3: an incremental improvement[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 18-22, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 1-6.
- [21] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [22] Guo Y N. Research on lesion detection for mammograms [D]. Lanzhou: Lanzhou University, 2019.
郭亚南. 乳腺钼靶 X 线病灶检测研究[D]. 兰州: 兰州大学, 2019.
- [23] Wirth M, Fraschini M, Lyon J. Contrast enhancement of microcalcifications in mammograms using morphological enhancement and non-flat structuring elements[C]//Proceedings of the 17th IEEE Symposium on Computer-Based Medical Systems, June 24-25, 2004, Bethesda, MD, USA. New York: IEEE Press, 2004: 134-139