

基于改进的 Mask R-CNN 的乳腺肿瘤目标检测研究

孙跃军¹, 屈赵燕^{1*}, 李毅红²¹中北大学信息探测与处理山西省重点实验室, 山西 太原 030051;²中北大学理学院, 山西 太原 030051

摘要 乳腺癌是全球女性死亡率最高的恶性肿瘤之一, 早期发现有助于提升患者的存活率。本文利用深度学习中的目标检测网络对乳腺 X 线图像中的肿瘤病变区域进行定位和分类; 然后选取 Mask R-CNN 网络作为目标检测模型, 对 Mask R-CNN 的基准网络 D-ShuffleNet 进行改进, 提出了一种新的网络——Mask R-CNN-II 网络, 并在 Mask R-CNN-II 网络中应用迁移学习算法。通过实验验证了 Mask R-CNN-II 网络比 Mask R-CNN 网络的检测精度更高, 而且验证了所提基准网络、所使用的融合图像的思想以及迁移学习算法是有效的。Mask R-CNN-II 有利于提高乳腺肿瘤的定位与分类, 可为放射科医生提供辅助诊断意见, 具有一定的临床应用价值。

关键词 测量; 乳腺肿瘤; 目标检测; 基准网络; 迁移学习

中图分类号 O434.1

文献标志码 A

doi: 10.3788/AOS202141.0212004

Study on Target Detection of Breast Tumor Based on Improved Mask R-CNN

Sun Yuejun¹, Qu Zhaoyan^{1*}, Li Yihong²¹Shanxi Key Laboratory of Signal Capturing & Processing, North University of China, Taiyuan, Shanxi 030051, China;²School of Science, North University of China, Taiyuan, Shanxi 030051, China

Abstract Breast cancer is one of the malignant tumors with the highest mortality among women globally and its early detection helps to increase the survival rate of patients. In this paper, we mainly used the target detection network in deep learning to locate and classify tumor lesion areas in the X-ray mammography images. Then, the Mask R-CNN network was taken as the target detection model for the improvement of its benchmark network D-ShuffleNet. Furthermore, a new network Mask R-CNN-II was proposed, to which the transfer learning algorithm was applied. Finally, it was experimentally demonstrated that the Mask R-CNN-II network had higher detection accuracy than the Mask R-CNN network. Besides, we also found that the proposed benchmark network, the idea of image fusion applied, and the transfer learning algorithm were effective. In conclusion, the network proposed in this paper is beneficial to improve the localization and classification of breast tumors and can provide auxiliary diagnostic advice for radiologists, which has certain clinical application value.

Key words measurement; breast tumor; target detection; benchmark network; transfer learning

OCIS codes 040.1880; 170.0110; 100.3008

1 引言

乳腺癌是全球女性死亡率最高的恶性肿瘤之一。目前, 乳腺癌已成为一个关乎我国乃至全球女

性健康的重大问题。2018 年公布的统计结果显示, 乳腺癌是发病率最高的癌症, 约占新增病例总数的 11.6%, 占死亡病例总数的 6.6%^[1]。《中国肿瘤登记年报》显示乳腺癌是中国女性癌症患者中最常见

收稿日期: 2020-07-13; 修回日期: 2020-08-15; 录用日期: 2020-08-26

基金项目: 国家自然科学基金(61801437, 61871351, 61971381)、山西省自然科学基金(201801D221206, 201801D221207)

* E-mail: 512818501@qq.com

的癌症^[2]。近 10 年来,中国女性的乳腺癌发病率和死亡率迅速上升,是全世界平均发病率和死亡率的两倍^[3]。目前,乳腺 X 线摄影技术^[4]是诊断乳腺癌最可靠的方法,主要原因是乳腺 X 线图像分辨率高。然而,乳腺 X 线图像自身也存在一些缺陷,例如,病灶区域对比度不明显,而且小的肿块或钙化点受乳腺周围组织的影响可能会使医生出现视觉上的混乱,导致医生在读取乳腺 X 线图像过程中耗时耗力,诊断效率不高^[5],甚至可能出现漏诊误诊。

近年来,随着人工智能医疗技术的快速发展,利用计算机辅助诊断(CAD)技术检测疾病已成为时代的大趋势^[6]。很多研究人员利用 CAD 技术对乳腺图像进行了研究,并取得了相应的研究成果^[7-9]。然而,这些对乳腺病灶区域的研究均是基于传统的机器学习方法进行的,虽然取得了一定效果,但其检测精度与提取的特征密切相关,而特征的提取过程需要根据人群的特异性进行调整,因此很难推广。此外,以上针对乳腺病理图像进行分类的算法大都是在小型数据集上进行研究的,模型的泛化能力无法得到保证,不适用于对大型数据集进行图像识别。

基于深度学习的方法已被成功应用于医学成像中^[10-14],极大地提升了图像识别的准确率。文献^[11]提出了 Mask R-CNN 网络,该网络使用预先训练好的卷积神经网络来抽取特征,有效地提升了识别精度。文献^[12]提出了基于 DenseNet 和反卷积的 DD-Net (DenseNet and deconvolution-based network)神经网络。DD-Net 结合了 DenseNet 和反褶积的优点,采用快捷连接的方式将 DenseNet 和反褶积串联起来,加快了网络的训练速度。然而,Mask R-CNN 网络的基准网络是残差网络,在提取特征时,精度不够高。针对这一问题,本文提出了一种新的网络——MaskR-CNN-II 网络,并在 Mask

R-CNN-II 网络中应用迁移学习算法,从病变图像中检测和分割乳腺肿瘤,以提高对肿瘤的检测精度,这对于辅助医生诊断具有积极意义。本文主要以乳腺癌的研究现状为背景,围绕乳腺 X 线图像预处理和深度学习算法,对乳腺癌的病灶区域进行了良恶性分类与检测研究。

2 乳腺图像的处理

2.1 乳腺图像预处理

本文采用的图像均取自山西医科大学第一医院,乳腺图像共计 2048 张,其中患病乳腺图像为 1072 张,正常乳腺图像为 976 张。数据库中所有的乳腺图像都已由专家进行了相应的标记,并将肿瘤划分为 6 个等级。图 1 所示为正常乳腺图像以及患病乳腺图像。




图 1 正常乳腺图像以及患病乳腺图像。

(a)正常乳腺图像;(b)患病乳腺图像

Fig. 1 Normal and diseased breast images. (a) Normal breast image; (b) diseased breast image

全数字化乳腺 X 线摄影机拍摄的图像具有较高的分辨率,且该摄影机的诊断工作台采用的是全分辨率模式,可以把图像的细节非常清晰地呈现出来。在检查过程中,可以获得左乳头头(LCC)、左乳腺侧(LMLO)、右乳头头(RCC)和右乳腺侧(RMLO)^[15]4 种类型的乳腺 X 线图像,如图 2 所示。




图 2 4 种类型的乳腺图像。(a) LCC;(b) LMLO;(c) RCC;(d) RMLO

Fig. 2 Images of four types of breast. (a) LCC; (b) LMLO; (c) RCC; (d) RMLO

2.2 乳腺图像去背景

图 3(a)是原始的乳腺 X 线图像。可以看出,在

一张原始图像中,背景占了绝大部分,而乳腺只占一小部分。为了提高模型的准确率和特征利用率,本




图 3 原始图像与去背景图像。(a)原始图像;(b)去背景图像
Fig. 3 Original image and image with background elimination.
(a) Original image; (b) image with background elimination
文对原始图像进行了批处理正则化的预处理操作,即去掉背景中的一些无用信息。将去背景后的图像数据输入到模型中进行训练,可以提高模型的收敛性。图 3(b)是去背景^[16]后的乳腺 X 线图像。

2.3 病变区域数据集及图像融合

乳腺肿瘤的种类一共有 6 种,病变等级分别为 2、3、4a、4b、4c、5,等级越高患有恶性肿瘤的可能性越大。6 种病变等级如图 4 所示。

每一张乳腺图片都可能出现多处不同等级的病变区域,医生在诊断过程中根据病变等级最高的进行判断。在本文所使用的原始数据集的标定中,出现等级 4c 或 5 就被认定为恶性肿瘤。

为了更好地实现网络的迁移学习,本文先使用 6 种等级的肿瘤图片对网络进行预训练,之后再训练原始数据集。医生已在病变图像中标记出病变区域以及分类,所有图像中一共有 1932 处病灶区域,各等级病变区域的数量及其占病变总区域数量的比例如表 1 所示。




图 4 病变等级。(a)等级 2;(b)等级 3;(c)等级 4a;(d)等级 4b;(e)等级 4c;(f)等级 5
Fig. 4 Lesion grade. (a) Lesion grade 2; (b) lesion grade 3; (c) lesion grade 4a; (d) lesion grade 4b;
(e) lesion grade 4c; (f) lesion grade 5

表 1 各等级病变区域的数量及其占病变总区域数量的比例
Table 1 Number of lesion areas of each grade and their corresponding proportions to the total number of lesion areas

Grade	Number	Proportion / %
2	463	24
3	406	21
4a	348	18
4b	289	15
4c	251	13
5	175	9

在训练模型时,数据集不足会导致模型产生过拟合现象,降低模型的准确率。为了避免此现象的

发生,本文使用图像融合^[17]的方法来扩大数据集。对于每一张病变图像,将病变区域数据与相应的健康区域进行融合,以获得大样本数据集。图 5(a)是一个病变区域的图像,图 5(b)是与之对应的健康区域的图像,图 5(c)是融合后得到的图像。每一病变等级的图片都先后与 9 张同类型的健康乳腺图片的健康区域进行融合,因此,数据集增大至原来的 10 倍。随后通过随机裁剪的方式,使各病变等级图像的数量达到 10000 张。经过图像融合以及随机裁剪之后就得到了病变区域增强数据集。




图 5 病变区域、健康区域的图像以及二者的融合图像。(a)病变区域的图像;(b)健康区域的图像;(c)融合图像

Fig. 5 Images of diseased and healthy areas and their fusion image. (a) Image of diseased area;
(b) image of healthy area; (c) fusion image

3 网络改进

本文选取 Mask R-CNN^[11] 网络作为乳腺肿瘤检测的基本网络。Mask R-CNN 是一种当前较为先进的目标检测网络,它包含两个分支,能够同时实现分类、回归及分割三项任务。该网络通过引入分割任务,有效提高了模型的检测性能;此外,该模型通过使用 ROI Align 层替代传统的 ROI pooling

层,有效克服了定位偏移的问题。下面分别介绍 Mask R-CNN 网络及其具体的改进方式。

3.1 Mask R-CNN 网络

在医学图像识别中,选取正确的网络模型非常重要,对模型的要求是不仅要快还要准。因此,本文选取了不仅精度高而且速度快的 Mask R-CNN 网络,其具体结构如图 6 所示(ROI 是 region of interest 的缩写,表示感兴趣区域)。

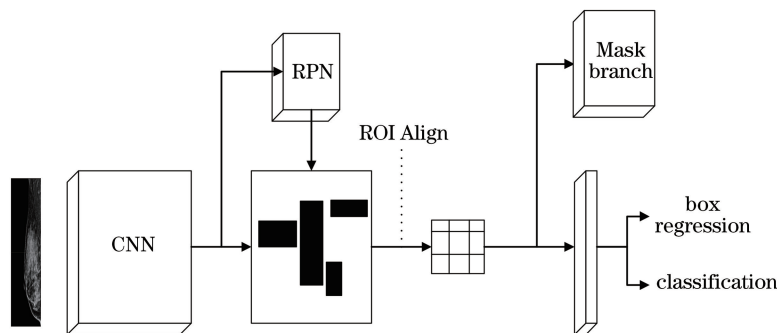


图 6 Mask R-CNN 网络结构

Fig. 6 Mask R-CNN network structure

图中 CNN 表示基准网络,RPN 代表生成建议窗口网络,ROI Align 代表使用双线性插值得到与原图中 ROI 对应的特征图中的区域(保留坐标的对应关系),Mask branch 代表分支网络。从网络结构中可以看出,Mask R-CNN 网络最终通过两个分支输出结果,第一个分支输出背景和物体的分割结果,第二个分支输出分类和坐标结果。但是由于 Mask R-CNN 网络的基准网络是残差网络,在提取特征时,精度达不到要求,因此对 Mask R-CNN 的基准网络进行改进是非常有必要的。

3.2 改进 Mask R-CNN 网络

DenseNet 神经网络模型不同于其他的卷积神经网络,其主要的特点是:1)采用了一种新的密集连接机制,即该模型当前的输入,不仅与前一层的输出有关联,还与之前所有的输出有关联。该模型将之

前所有层的输出通过一定的方式组合在一起,然后输入到该层,这样做的目的主要是提高特征图的利用率,强化特征传播。2)由于每一层的特征图都得到了重复利用,所以每一层都利用了少量的卷积核进行特征提取,大幅减少了模型产生的参数量。

图 7 是 DenseNet 中的 Dense Block 示意图。DenseNet 网络是由一个个 Dense Block 堆积而成的,具体结构如图 8 所示。




图 7 DenseNet 中的 Dense Block 示意图

Fig. 7 Schematic of Dense Block in DenseNet




图 8 DenseNet 结构示意图

Fig. 8 Schematic of DenseNet structure

DenseNet 网络是 Mask R-CNN 网络的基准网络,但是 DenseNet 网络的卷积方式会造成很大浪费。而本文实验是在三块 GPU(graphics processing unit)上运行的,使用的是分组卷积方式,在分组卷积中很难实现组与组之间的信息交流。所以本文使用 Channel Shuffle 卷积方式,目的是在减少 DenseNet 网络参数数量的同时解决分组卷积方式中难以实现组与组之间信息交流的问题。Channel Shuffle 卷积中的卷积方式与 DenseNet 网络的卷积方式并不相同。在 DenseNet 网络的卷积中,一组卷积核负责一组特征图,而在 Channel Shuffle 卷积中,则是一个卷积核负责一个特征图,这样就可以大大减少参数数量。但这样会造成同一组数据之间信息的丢失,因此可以通过

Shuffle 操作来解决分组卷积中组内信息不交流以及组与组之间信息不交流的问题。

图 9 是 Channel Shuffle 示意图,其中 input 代表输入,GConv 代表分组卷积层,feature 代表特征图,output 代表输出。图 9(a)代表分组卷积,可以看出分组卷积各分组之间并没有信息交流。图 9(b)是应用 Shuffle 的过程,可以看出各分组之间有了信息交流。图 9(c)是应用 Shuffle 之后的效果,可以看到各分组之间都有其他分组的信息。将 DenseNet 网络中的卷积方式改变为 Channel Shuffle 卷积方式,得到改进网络——D-ShuffleNet 网络,并将此网络作为 Mask R-CNN 网络的基准网络,进而得到本文的改进网络 Mask R-CNN-II 网络。

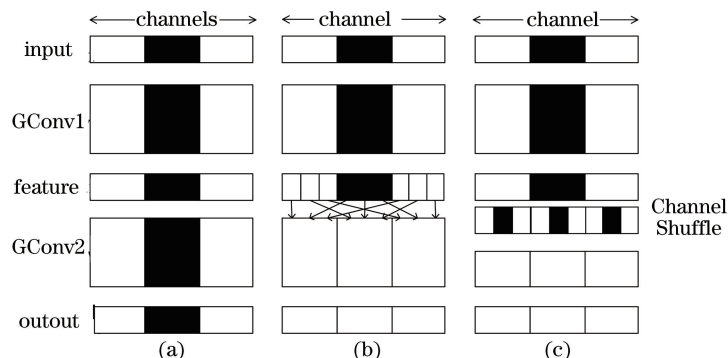


图 9 Channel Shuffle 示意图。(a)分组卷积;(b)应用 Shuffle 的过程;(c)应用 Shuffle 后的效果

Fig. 9 Schematic of Channel Shuffle. (a) Grouped convolution; (b) Shuffle process; (c) effect after applying Shuffle

4 实验仿真及结果分析

4.1 实验设置及评价指标

本文采用 Pytorch 框架进行实验,训练过程中使用 Adam 优化器,学习率设置为 0.01。将图像数据集按照 6:2:2 的比例划分为训练集、测试集以及验证集,输入到网络中的乳腺 X 线图像的尺寸为 224 pixel×224 pixel,batch size 设为 192,激活函数选择 RELU 函数。训练 600 个 epoch,每组分卷卷积核的大小为 64,初始学习率设置为 0.01,训练 600 个 epoch,每隔 100 个 epoch 改变一次学习率。

本文选用 mAP(mean average precision)^[18] 作为评价标准对网络结果进行分析评价。mAP 是平均精

度均值,即 k 个类别的精确率的均值,计算公式为

$$\alpha_{\text{mAP}} = \frac{\sum_{i=0}^{k-1} p_k}{k}, \quad (1)$$

式中: p 代表每个类别的平均精确率,用来评价每个类别的检测结果。mAP 是目标检测算法中应用得最广泛的评价指标,其值越高,模型的性能就越好,其取值在 0~1 之间。以上的概念都可以从混淆矩阵的概念中引出。分类结果的混淆矩阵表如表 2 所示,其中:TP(true positive)表示模型将健康乳腺图像正确地识别为无肿瘤图像的数量,用符号表示为 α_{TP} ;FP(false positive)表示模型将患病乳腺图像错误地识别为健康乳腺图像的数量,用符号表示为 α_{FP} ;

TN(true negative)表示模型将患病乳腺图像正确地识别为患病乳腺图像的数量,用符号表示为 α_{TN} ;FN (false positive)表示模型将健康乳腺图像错误地识别为患病乳腺图像的数量,用符号表示为 α_{FN} 。

表 2 分类结果的混淆矩阵

Table 2 Classification results confusion matrix

Real	Forecast	
	P	N
P	TP	FN
N	FP	TN

Precision(P)和 recall(R)分别指的是模型的准确率(也叫查准率)和召回率(也叫查全率),它们的表达式分别为

$$P = \frac{\alpha_{TP}}{\alpha_{TP} + \alpha_{FN}}, \quad (2)$$

$$R = \frac{\alpha_{TP}}{\alpha_{TP} + \alpha_{FP}}. \quad (3)$$

4.2 实验仿真及对比分析

4.2.1 图像去背景对模型性能的影响

为了验证去背景的意义,本文将原始图像以及去背景后的图像分为正常区域图像和病变区域图像两类。在这里,本文利用 D-ShuffleNet 网络进行迁移学习,并按照 4.1 节中的设置对模型进行训练。通过实验得到的准确率和损失函数分别如图 10 和图 11 所示。

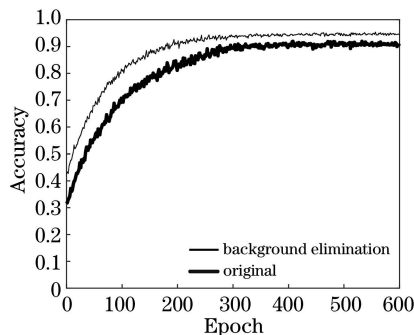


图 10 原始数据集与去背景数据集的准确率曲线

Fig. 10 Accuracy curves of original data set and data set with background elimination




图 11 原始数据集与去背景数据集的损失函数曲线

Fig. 11 Loss curves of original data set and data set with background elimination

在图 10 中可以很明显地看出细线一直处于粗线的上方,即去背景图像的模型准确率高于原始图像的模型准确率。在图 11 中,去背景图像的模型损失小于原始图像的模型损失。以上说明对原始图像进行去背景处理后,提高了模型的准确率,减小了模型的损失率。

4.2.2 网络模型对比分析

为了证明所提模型能够有效实现乳腺肿瘤的检测,本文将其与另外 4 种较为流行的网络模型进行了对比。本文按照 4.1 节中的设置进行了 5 组实验,并使用 Xavier initialization 对模型的参数进行初始化。第 1 组实验使用本文提出的 Mask R-CNN-II 网络进行训练,第 2 组实验使用原始的 Mask R-CNN 网络进行训练,第 3 组实验使用 You Only Look Once(YOLO)-V3^[19] 网络进行训练,第 4 组实验使用 Single Shot MultiBox Detector(SSD) 网络^[20] 进行训练,第 5 组实验使用 Faster R-CNN 网络进行训练。

表 3 是 5 组模型训练后的实验结果,包括每一类的平均精确率以及 mAP 值。Mask R-CNN-II 的 mAP 值最大,然后依次为 Mask R-CNN 模型、YOLO-V3 模型、Faster R-CNN 模型和 SSD 模型。通过表 3 可以看出,Mask R-CNN-II 模型的训练效果最佳,检测精度最高。与 Mask R-CNN 相比,Mask R-CNN 的效果要差,说明本文提出的

表 3 不同模型的训练结果

Table 3 Training results of each model

Model	Average precision					mAP	
	2	3	4a	4b	4c		
Mask R-CNN-II	0.94	0.93	0.85	0.93	0.85	0.94	0.907
Mask R-CNN	0.92	0.93	0.85	0.87	0.84	0.95	0.893
YOLO-V3	0.93	0.91	0.82	0.87	0.81	0.95	0.881
SSD	0.89	0.87	0.81	0.87	0.82	0.93	0.865
Faster R-CNN	0.91	0.90	0.83	0.85	0.82	0.92	0.871

D-ShuffleNet 网络是成功的。YOLO-V3 以及 Faster R-CNN 模型的性能都比 Mask R-CNN 差。可见,本文所提 Mask R-CNN-II 模型能够有效实现乳腺肿瘤的检测。

4.2.3 迁移学习对模型性能的影响

在模型训练中,迁移学习^[21]算法指的是利用神经网络模型训练一个其他的数据集,然后保留训练之后的网络参数,继续训练目标数据集。该算法具有加快训练速度和提高精度的作用。本文首先使用迁移学习的方式训练 D-ShuffleNet 网络。在模型训练收敛之后,保留模型参数,将训练之后的 D-ShuffleNet 网络作为 Mask R-CNN-II 网络的基准网络。本文按照 4.1 节中的设置对模型进行训练。实验过程使用了三块 GPU,也就是分组卷积分为了三组。网络在预训练过程中的准确率和损失函数曲线如图 12~13 所示。

此外,为了验证预训练对网络性能的影响,本文设置了另外两组对比实验。其中一组是使用原始的未经任何预处理的 1160 张病变区域数据集对模型进行预训练的模型,另一组是使用 Xavier initialization 进行参数初始化后的模型。之后本文按照 4.1 节的设置,使用经过预处理的病变区域图像对上述两组经过预训练的模型和一组没有经过预

表 4 经过预训练和未经预训练模型的实验结果

Table 4 Experimental results of models with and without pretraining

Model	Average precision					mAP	
	2	3	4a	4b	4c		5
Pre-T+Mask R-CNN-II	0.97	0.94	0.87	0.94	0.86	0.98	0.927
Pre+Mask R-CNN-II	0.96	0.95	0.86	0.93	0.85	0.98	0.921
Mask R-CNN-II	0.94	0.93	0.85	0.93	0.85	0.94	0.907

表 4 中的 Pre-T+Mask R-CNN-II 表示经融合患病区域数据集预训练的模型,Pre+Mask R-CNN-II 表示使用原始的未经过任何预处理的 1160 张病变区域图像预训练的模型,Mask R-CNN-II 表示未经预训练的模型。通过表 4 可以看出,Pre-T+Mask R-CNN-II 模型的训练效果最佳,Pre+Mask R-CNN-II 模型的训练效果与 Pre-T+Mask R-CNN-II 模型的训练效果很接近,但仍有轻微的差距,说明本文提出的通过融合图像增加病变区域数据集数量的思路是正确的。与 Pre-T+Mask R-CNN-II 和 Pre+Mask R-CNN-II 模型的训练效果相比,Mask R-CNN-II 模型的训练效果要差一些,说明迁移学习有助于模型性能的提升。




图 12 D-ShuffleNet 网络在预训练过程中的准确率

Fig. 12 Accuracy of D-ShuffleNet network in pretraining




图 13 D-ShuffleNet 网络在预训练过程中的损失函数

Fig. 13 Loss of D-ShuffleNet network in pretraining

训练的模型进行实验。表 4 是三组模型训练后的实验结果,包括平均精确率以及 mAP 值。

4.3 模型性能的评估

关于模型评估的标准,除了最常用的几种之外,受试者工作特征曲线(ROC 曲线)也是用来评价模型分类器性能的重要标准,它主要表示的是模型分类器的真阳率(灵敏性)和假阳率之间的关系。ROC 曲线经过(0,0)点,曲线下方的面积用 AUC 表示。AUC 的数值越大,表示模型对乳腺 X 线图像良恶性分类的性能越好。理想模型的 AUC 值为 1,表示模型的准确率达到 100%。ROC 曲线能很好地反映模型的泛化性能,其下方的面积为 AUC,AUC 值越大说明模型的泛化能力越好。图 14 给出了此次实验中各模型的 ROC 曲线。

从图 14 可以看出,Pre-T+Mask R-CNN-II 模

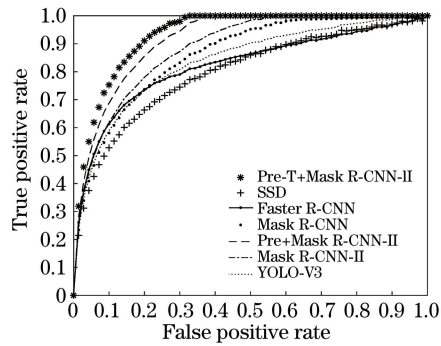


图 14 各模型的 ROC 曲线

Fig. 14 ROC curves of each model

型的 ROC 曲线一直处于最上方,且它下方的面积是最大的。可以看出,Pre-T+Mask R-CNN-II 模型 ROC 曲线下方的面积最大,然后依次是 Pre+Mask R-CNN-II 模型、Mask R-CNN-II 模型、Mask R-CNN 模型、YOLO-V3 模型、Faster R-CNN 模型、SSD 模型,上述模型 ROC 曲线下方的面积依次为 0.942、0.935、0.916、0.902、0.893、0.882、0.877,与 mAP 评价体系得出的结果一致。这一结果说明本文改进的模型是非常成功的,本文提出的 Pre-T+Mask R-CNN-II 模型具有良好的泛化性能。

5 结 论

本文通过结合 DenseNet 网络以及 Channel Shuffle 卷积方式,提出了一种新网络——D-ShuffleNet 网络,进而提出了新的目标检测网络 Mask R-CNN-II,并在 Mask R-CNN-II 网络中应用迁移学习算法对乳腺肿瘤目标进行检测研究。通过 7 组对比实验证明了本文所提 Mask R-CNN-II 网络相比其他网络的检测精度更高,同时通过实验验证了本文所使用的融合图像的思想以及迁移学习算法是有效的,最终提高了模型的准确率和识别率。然而,从实验结果中发现,虽然本文网络对 6 种等级乳腺肿瘤的识别准确率都有所提高,但是对于 4a 和 4c 这两种病变等级区域的识别率要明显低于对其他 4 种病变等级区域的识别准确率。所以,本文下一步将从各方面对网络进行研究,以提高网络的表达性能,同时提高模型对 4a 和 4c 病变等级区域的识别准确率。

参 考 文 献

- [1] Ma D D, Liu K, Qi X W. Global cancer statistics in 2018: statistics on morbidity and mortality of breast cancer [J]. Chinese Journal of Breast Disease (Electronic Edition), 2018, 12(6): 375.
- [2] 马丹丹, 刘坤, 齐晓伟. 2018 年全球癌症统计: 乳腺癌发病和死亡人数统计 [J]. 中华乳腺病杂志(电子版), 2018, 12(6): 375.
- [3] He M Y. Analysis of epidemic trend with breast cancer and research on the effect of postoperative radiotherapy [D]. Hengyang: University of South China, 2019: 20-38.
- [4] 何明艳. 乳腺癌流行趋势分析与术后放疗效应研究 [D]. 衡阳: 南华大学, 2019: 20-38.
- [5] Zhou X T, Shen S J, Sun Q. Current situation and progress of breast cancer screening in China [J]. Chinese Journal of the Frontiers of Medical Science (Electronic Version), 2020, 12(3): 6-11.
- [6] 周星彤, 沈松杰, 孙强. 中国乳腺癌筛查现状及进展 [J]. 中国医学前沿杂志(电子版), 2020, 12(3): 6-11.
- [7] Machida Y, Saita A, Namba H, et al. Automated volumetric breast density estimation out of digital breast tomosynthesis data: feasibility study of a new software version [J]. Springerplus, 2016, 5(1): 780-787.
- [8] Rouhi R, Jafari M. Classification of benign and malignant breast tumors based on hybrid level set segmentation [J]. Expert Systems With Applications, 2016, 46: 45-59.
- [9] Li C X, Shen C B, Xue K, et al. Artificial intelligence in dermatology: past, present, and future [J]. Chinese Medical Journal, 2019, 132(17): 2017-2020.
- [10] Medjahed S A, Saadi T A, Benyettou A. Breast cancer diagnosis by using k-nearest neighbor with different distances and classification rules [J]. International Journal of Computer Applications, 2013, 62(1): 1-5.
- [11] Lu Y F, Jin Q H, Jing J, et al. Detection and segmentation algorithm for bioresorbable vascular scaffolds struts based on machine learning [J]. Acta Optica Sinica, 2018, 38(2): 0215005.
- [12] 鲁逸峰, 金琴花, 荆晶, 等. 基于机器学习的可降解支架检测与分割算法 [J]. 光学学报, 2018, 38(2): 0215005.
- [13] Liu N, Shen J, Xu M, et al. Improved cost-sensitive support vector machine classifier for breast cancer diagnosis [J]. Mathematical Problems in Engineering, 2018, 2018: 1-13.
- [14] Ren R, He K, 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. [S.l.:s.n.], 2015: 91-99.
- [11] He K M, Gkioxari G, Dollár P, et al. Mask R-CNN [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 386-397.
- [12] Zhang Z, Liang X, Dong X, et al. A sparse-view CT reconstruction method based on combination of DenseNet and deconvolution [J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1407-1417.
- [13] Huang H, Peng C, Wu R Y, et al. Self-supervised transfer learning of pulmonary nodule classification based on partially annotated CT images [J]. Acta Optica Sinica, 2020, 40(18): 1810003.
黄鸿, 彭超, 吴若愚, 等. 基于部分注释 CT 图像的自监督迁移学习肺结节分类 [J]. 光学学报, 2020, 40(18): 1810003.
- [14] Yang Q L, Zhou B H, Zheng W, et al. Dim and small target detection based on fully convolutional recursive network [J]. Acta Optica Sinica, 2020, 40(13): 1310002.
杨其利, 周炳红, 郑伟, 等. 基于全卷积递归网络的弱小目标检测方法 [J]. 光学学报, 2020, 40(13): 1310002.
- [15] Jain A L, Mullins J, Smith J R, et al. Unusual recurrent metastasizing benign breast papilloma: a case report [J]. Journal of Medical Case Reports, 2020, 14(1): 1752-1947.
- [16] Wen C J. The diagnostic performance of digital breast tomosynthesis for breast lesions: a preliminary study [D]. Guangzhou: Southern Medical University, 2014: 20-30.
文婵娟. 数字乳腺断层摄影 (DBT) 对乳腺病变诊断价值的初步研究 [D]. 广州: 南方医科大学, 2014: 20-30.
- [17] Ma J Y, Ma Y, Li C. Infrared and visible image fusion methods and applications: a survey [J]. Information Fusion, 2019, 45: 153-178.
- [18] 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.
- [19] Shafiee M J, Chywl B, Li F, et al. Fast YOLO: a fast You Only Look Once system for real-time embedded object detection in video [EB/OL]. [2020-07-13]. <https://arxiv.org/abs/1709.05943>.
- [20] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector [C] // European Conference on Computer Vision. [S. l.]: Springer International Publishing, 2016: 21-37.
- [21] Zhang J X, Wang S T, Deng Z H, et al. A subspace transfer learning algorithm integrating heterogeneous features [J]. Acta Automatica Sinica, 2014, 40(2): 236-246.
张景祥, 王士同, 邓赵红, 等. 融合异构特征的子空间迁移学习算法 [J]. 自动化学报, 2014, 40(2): 236-246.