

鲸鱼优化算法在乳腺癌图像分类的应用研究^{*}

陈 诺 朱 璘 赵启程 刘圣凯

(江苏科技大学海洋学院 镇江 212001)

摘 要: 针对乳腺癌超声图像中恶性与良性肿瘤的区分难题,提出了一种基于 EfficientNet 模型改进的方法。本文引入了改进的鲸鱼优化算法(WOA)和全局上下文(GC)模块,旨在提高乳腺癌早期检测的准确性和效率。该模型通过深度可分离卷积和大核心卷积结合,优化了特征提取和分类性能。此外,还对模型进行了动态超参数调整和数据增强处理,进一步增强了模型的泛化能力和稳定性。实验结果显示,该模型在训练集上的准确率达到 99.81%,验证集上达到 98.06%,明显优于传统方法。平均精度(mAP)从 96.42% 提升至 98.60%,表明该模型能有效提高早期诊断的准确性和可靠性,为乳腺癌的早期筛查和诊断提供了一种高效的技术路径。

关键词: 超声乳腺癌分类;EfficientNet;鲸鱼优化;分组卷积;全局上下文

中图分类号: TN87 **文献标识码:** A **国家标准学科分类代码:** 520.2

Study on the application of whale optimization algorithm for
breast cancer image classification

Chen Nuo Zhu Jin Zhao Qicheng Liu Shengkai

(Ocean College, Jiangsu University of Science and Technology, Zhenjiang 212001, China)

Abstract: To addresses the challenge of distinguishing between malignant and benign tumors in breast cancer ultrasound images, an improved method based on the EfficientNet model is proposed. This thesis introduced an enhanced whale optimization algorithm (WOA) and a global context (GC) module to improve the accuracy and efficiency of early breast cancer detection. The model optimizes feature extraction and classification performance by combining depthwise separable convolution and large kernel convolution. Additionally, dynamic hyperparameter tuning and data augmentation were applied to further enhance the model's generalization ability and stability. Experimental results show that the model achieved an accuracy of 99.81% on the training set and 98.06% on the validation set, significantly surpassing traditional methods. The mean average precision (mAP) was increased from 96.42% to 98.60%, demonstrating the model's effectiveness in improving the accuracy and reliability of early diagnosis, providing an efficient technical pathway for early screening and diagnosis of breast cancer.

Keywords: ultrasound breast cancer classification;EfficientNet;whale optimization;grouped convolution;global context

0 引 言

乳腺癌作为全球高发率和死亡率的癌症之一,对女性健康构成了巨大威胁。世界卫生组织的数据显示^[1],乳腺癌在女性新发癌症中的比例达到了 25%,并且是导致女性癌症死亡的主要原因之一。根据《临床医师癌症杂志》2023 年的数据^[2],全球新发乳腺癌病例数为 297,790,占女性新发癌症病例的 31%。

当前,影像学检查,特别是超声检查^[3],已成为乳腺癌筛查的重要手段。尽管病理活检仍为金标准^[4],但非侵入

性的影像学方法对于早期发现和评估乳腺癌具有重要价值。近年来,计算机辅助诊断系统和影像组学的发展显著提高了医学图像处理的精确度。通过边缘检测、感兴趣区域分割和人工智能算法等技术,研究者能够更准确地识别和分类乳腺组织的病变。应用卷积神经网络(convolutional neural network,CNN),通过精细化的图像特征提取和优化的网络结构,能实现对乳腺癌图像的高效识别和分类。

尽管在医学图像领域,研究者们面临着数据集规模较小、标注过程复杂以及图像质量参差不齐等诸多挑战,但通

过对预处理技术的持续改进和智能算法的精细优化,研究者们已经取得了显著成果,但同时也面对新的挑战。在面对大规模标注数据集难以获得的问题上,Yang 等^[5]提出了一种基于综述搜索、精英征收突变和分散觅食策略的增强差异进化框架来探索最优阈值,该方法在 5 级阈值下的平均峰值信噪比和特征相似度指数分别为 21.231 和 0.951,但是该方法的复杂性及对初始参数敏感度较高可能限制了其广泛应用。Yu 等^[6]在分割方向提出了一种新的基于混合伴随的重力聚类优化(hybrid attendseg based gravitational clustering optimization, HA-GC)方法,利用 s 型过滤器预处理,结合混合注意机制网络,最终实现了分割精度值为 98.957% 和交并比(intersection over union, IoU)为 85.634%,但其在不同质地背景下的适应性和稳定性仍待提高。Bong 等^[7]针对超声诊断小于 1 cm 的乳腺癌,采用了回归的组合模型和决策树方法,通过基于掩模区域的卷积神经网络(region-based convolutional neural network, R-CNN)结合 CNN 和预先训练好的 ResNet101 结构生成输入图像的特征图,取得了受试者工作特征曲线(receiver operating characteristic, ROC)下的面积为 0.85。然而,对于更小或是更模糊的癌变,该方法的识别能力可能面临挑战。这些进展不仅展示了乳腺癌研究领域内的活跃探索和技术创新,也为未来乳腺癌早期检测和治疗的发展方向提供了重要指引。

在乳腺癌超声图像的 EfficientNet-B0^[8]分类应用中,该模型虽广泛使用但也面临局限性。本研究针对 EfficientNet-B0 在小型数据集上易于过拟合的问题,采取了包括随机裁剪和旋转在内的多种数据增强技术,以增强模型的鲁棒性和准确性。此外,为了解决 EfficientNet-B0 在处理低分辨率图像时对细节捕捉不足的问题,引入了全局上下文(global context, GC)模块,以提升模型对关键特征的捕捉能力。同时,对主干网络的深度可分离卷积中的

kernel size 进行了优化,并采用改进后的鲸鱼优化算法动态调整敏感超参数,如动量和学习率,旨在实现更高的识别率。

本文将会对比其他研究人员提出对乳腺癌图像分类模型进行对比,来凸显模型改进的有效性。通过这些技术的应用,本研究可以提供一种有效对未来乳腺癌的早期诊断方法。

1 方 法

如图 1(a)所示,在非局部网络的基础上,GC 模块通过计算不同位置间的关系(即权重值)来表示某个位置对 query 位置的重要性。通过可视化 attention map,发现不同 query 位置对应的 attention map 几乎一致。因此,简化了非局部网络,去除了分支和一次矩阵乘法操作,得到简化的非局部网络,如图 1(b)所示。计算公式如下:

$$z_i = x_i + W_z \sum_{j=1}^{N_p} \frac{f(x_i, x_j)}{C(x)} (W_v \cdot x_j) \quad (1)$$

z_i 第 i 个位置更新后的特征表示, x_i 第 i 个位置原始的特征表示, $W_z W_v$ 一个可学习的权重矩阵, $f(x_i, x_j)$ 是计算位置 j 和 i 的特征之间的关系或交互, $C(x)$ 是一个归一化因子。为了进一步简化运算,将 attention pooling 的分配率计算外置,优化了运算并降低复杂度。结合 Squeeze-and-Excitation block (SE)^[9] 概念,得到了 GC^[10] 模块,如图 1(c)所示。公式如下:

$$z_i = x_i + W_v \sum_{j=1}^{N_p} \frac{\exp(W_K x_j)}{\sum_{m=1}^{N_p} \exp(W_K x_m)} x_j \quad (2)$$

此外,还利用了分组卷积^[11]技术,隔离不同组的信息交换特性,在每个输出与输入部分特征图相关联时,分组卷积展现出比常规卷积更优的性能。改进后的 GC 模块内部细节如图 2 所示。

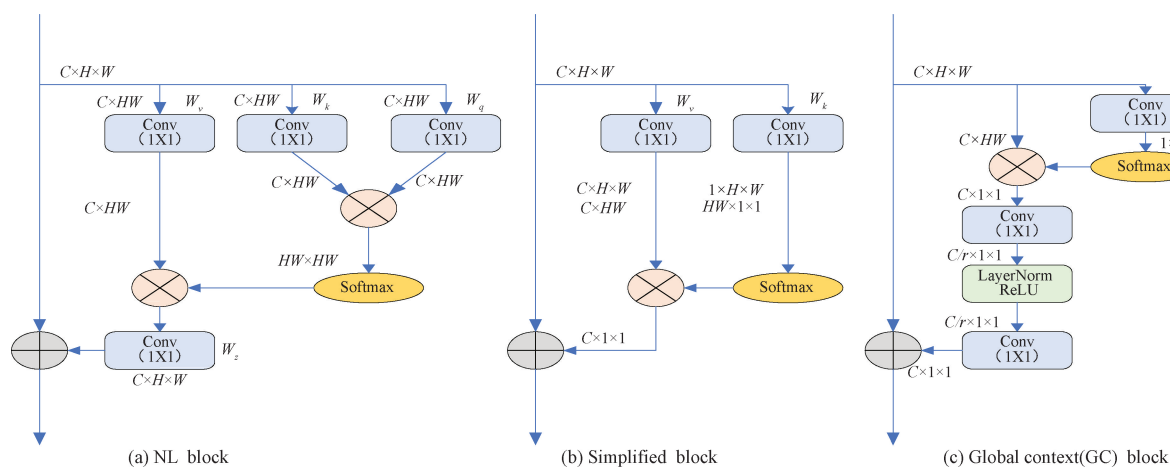


图 1 非局部网络,简化的非局部网络,GC 模块

Fig. 1 Non-local network, simplified non-local network, GC module




图 2 最终优化的 GC 模块框图

Fig. 2 Block diagram of the final optimized GC module

同时,为了继续加强网络的分类能力,结合 RepLKNet^[12]中大卷积核的思想,通过增加 kernelsize 尺寸,用更大感受野以捕捉到更多的空间信息。把在 EfficientNet 的原本的深度可分离卷积中的逐点卷积

kernelsize 增大,在经过深度卷积的切片后,通过 2×2 的卷积视野获得比 1×1 的卷积更大的信息量,对于处理乳腺癌超声波这种复杂图像是有益的。所以最后引入改进的 GC 模块和主体完整结构图如图 3 所示。

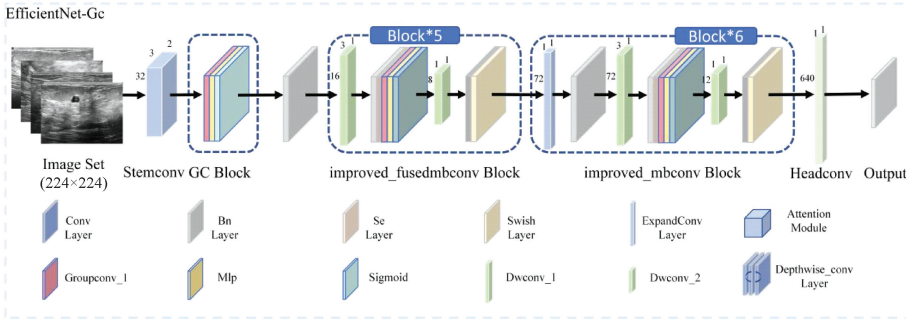


图 3 My-EfficientNet 框图

Fig. 3 My-EfficientNet block diagram

超参数的动态调整

鲸鱼优化算法 (whale optimization algorithm, WOA)^[13]在算法优化领域^[14-15]得到了广泛的应用。通过模拟鲸鱼捕食的行为,让这些解决方案在迭代过程中不断进化。算法的核心是在探索和利用两种策略之间寻找平衡,帮助避免陷入局部最优解,同时又能快速收敛到全局最优解。其主要步骤包括包围猎物、收缩包围、螺旋更新和搜索猎物,这些步骤凭借数学式(3)~(7)来分别对应于算法的不同部分。

$$\mathbf{A} = 2\mathbf{a} \times \mathbf{r}_1 - \mathbf{a} \quad (3)$$

$$\mathbf{C} = 2 \times \mathbf{r}_2 \quad (4)$$

$$\mathbf{D} = |\mathbf{C} \times \mathbf{X}^* - \mathbf{X}| \quad (5)$$

$$\mathbf{D}_p = |\mathbf{X}^*(t) - \mathbf{X}(t)| \quad (6)$$

$$\mathbf{X}(t+1) = \begin{cases} \mathbf{X}^*(t) - \mathbf{A} \times \mathbf{D} \\ \mathbf{X}^*(t) - \mathbf{D}_p \times e^{bl} \times \cos(2\pi l) \end{cases} \quad (7)$$

鲸鱼优化算法通过核心参数 \mathbf{a} 、 \mathbf{A} 、 \mathbf{C} 和 l 协同工作解决优化问题。 \mathbf{a} 调节搜索范围,随迭代缩小以平衡初期探索与后期集中搜索。 \mathbf{A} 结合随机数和 \mathbf{a} 调控移动方向与步长,促进向最优或潜在解进发。 \mathbf{C} 决定接近目标的程度,影响位置关系。 l 模拟螺旋猎食,与其他参数合作细化解的探索。这些参数整合使 WOA 效率地识别并优化解。鲸鱼优化算法的执行步骤(如图 4 所示)包括:

- 1) 初始化鲸鱼种群数量、最大迭代次数等参数;
- 2) 对超出搜索空间的鲸鱼位置进行调整;

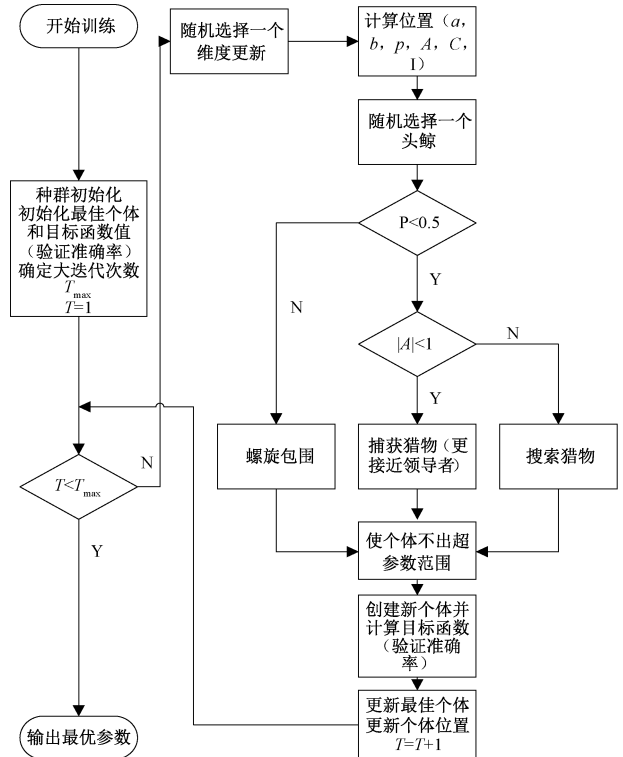


图 4 鲸鱼优化流程

Fig. 4 Whale optimization process

- 3) 通过目标函数评估初始种群的适应度,确定当前最

佳解 X^* ;

4) 随迭代过程更新参数 a 、 A 、 C 、 l , 并生成随机数 P ;

5) 基于 P 和 A 的值, 选择执行收缩包围、搜索猎物或螺旋更新策略;

6) 完成当前迭代, 更新参数;

7) 最终, 返回找到的最优解 X^* 。

在传统鲸鱼优化算法中, 关键参数主要靠随机数生成, 缺乏理论基础, 如包围和螺旋行为的随机选择, 导致其行动模式选择缺乏适应性。此外, 参数 a 的递减和参数 b 的固定值影响搜索效率和精度。为提高性能, 本文引入自适应阈值、参数调整和拉丁超立方采样初始化。

通过引入自适应概率阈值 ($P_{adaptive}$), 算法能够根据当前环境动态选择最适合的捕食策略。随着迭代次数增加, $P_{adaptive}$ 减小, 使得早期迭代倾向于包围策略, 而后期更倾向于螺旋策略。这种方法改进了传统 WOA 算法的策略选择, 优化了全局与局部搜索之间的平衡, 提升了算法的预测准确性、收敛速度以及自适应性。

$$P_{adaptive} = 1 - \frac{1}{6} \times \left(\frac{4t^e}{T_{Max}} + \frac{2t^2}{T_{Max}^2} \right) \quad (8)$$

通过采用自适应参数策略, 算法使用非线性变化的参数 a 以更快进入局部搜索阶段, 加强局部搜索能力, 从而提高求解精度与速度。同时, 将参数 b 映射到迭代次数上进行自适应调整, 使其随迭代次数减小, 早期利于加速全局搜索, 后期有助于提高收敛速度和精度, 优化了 WOA 算法的整体性能和效率。

$$a = 2 \times \left(1 - \tan^{-1} \left(\sqrt{\frac{t}{T_{Max}}} \right) \right) \quad (9)$$

$$b = 5 \times \left(1 - \frac{t}{T_{Max}} \right) \quad (10)$$

采用拉丁超立方采样初始化种群, 通过将每个维度均等分割成 n 个区间覆盖所有敏感参数范围, 实现均匀采样。这方法全面探索敏感参数影响, 提高最优解寻找几率。同时, 维度间随机采样增加搜索多样性, 提升算法收敛速度与探索效率。

2 实 验

2.1 数据集预处理以及增强

首先, 获取网上 kaggle 公开数据集 Breast Ultrasound Images Dataset^[16], 将他们按照 7:3 分成训练数据集, 验证数据集。通过观察掩面发现那些病灶都处于图片的中央位置, 所以旋转导致的边角信息损失不会影响分类任务的识别, 进而采用了数据增强手段, 将训练集图片按照以下方法随机变化, 首先挑选几何变换, 在选择像素变换, 进行 3 次不重复的扩充如图 5 所示, 左侧为原始图像; 右侧为处理后图像。

2.2 评价指标

为了用评价指标来检验本文提出的改进模型的分




图 5 数据增强后的图片变化

Fig. 5 Picture changes after data enhancement

性能, 使用混淆矩阵、精度、召回率、AP、mAP、PR 曲线, 以及 ROC 曲线和 AUC (area under curve, AUC) 值作为评估指标。

混淆矩阵展示了分类模型预测结果与实际情况的对比, 通过表格形式, 其中每行代表实际类别, 每列对应预测类别。主要包括 4 个指标: 真正例 (true positives, TP) 为正确预测的正例, 假正例 (false positives, FP) 为错误预测的正例, 真负例 (true negatives, TN) 为正确预测的负例, 假负例 (false negatives, FN) 为错误预测的负例。这些指标用于计算模型性能指标。

精度 (Accuracy) 为模型预测的阳性样本数与所有检测样本的数量之比, 计算式如式 (11) 所示。

$$Accuracy = \frac{TN + TP}{TN + TP + FN + FP} \quad (11)$$

召回率 (recall) 是指模型正确预测的阳性样本数量与实际出现的阳性样本数量的比值。召回率计算公式:

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

平均精度 (average precision, AP) 等于精度-查全率曲线下的面积, 其计算方法如式 (13) 所示。

$$AP = \int_0^1 Precision(Recall) d(Recall) \quad (13)$$

均值平均精度 (mean average precision, mAP) 是由所有样本类别的 AP 值的加权平均值得到的结果, 用于衡量模型在所有类别中的检测性能, 公式如式 (14) 所示。

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (14)$$

2.3 实验结果

通过最后训练结果可以知道,训练精度达到最大值 99.81%,验证精度达到最大值 98.06%,在大约 90 轮达到饱和阶段。然而,验证曲线在 90 轮达到最大值后开始发散。因此,将该模型保存为 90 轮选取这 90 次训练最好轮数来进行测试。

混淆矩阵显示了分类器在盲测试数据集上的预测统计量,如图 6 所示。结果表明,在盲测数据集的 38 例正常,63 例良性和 141 例恶性病例中,该分类器预测了对于正常的图片 36 例为 TP,201 例为 TN,3 例为 FP 例,3 例为 FN。对于良性的图片 139 例为 TP,100 例为 TN,2 例为 FP 例,2 例为 FN。对于恶性的图片 61 例为 TP,178 例为 TN,2 例为 FP 例,2 例为 FN。

根据混淆矩阵的数值列出表 1,可以看出表 1 中 EfficientNet 在集成了不同模块后,在准确率和召回率两个指标上均呈现出了提高。原始的 EfficientNet 模型在准确率和召回率上分别达到了 91.72%和 91.66%。本文对 EfficientNet 进行了迭代改进,逐步集成 WOA、GC 模块、

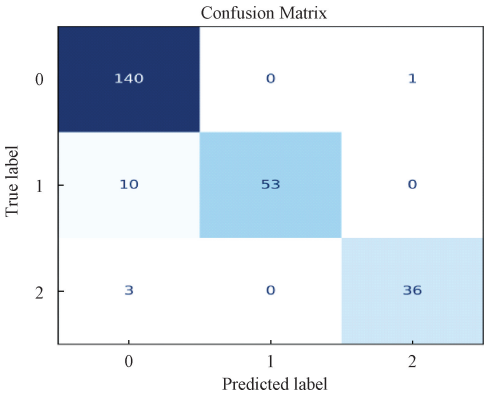


图 6 混淆矩阵

Fig. 6 Confusion matrix

分组卷积和 kernelsize 改进后,性能得到了逐步提升。当同时集成所有模块后,最后的模型的准确率达到了 97.97%,召回率也达到了 97.11%。体现了 GC 模块全局视野的全面观察和优化后鲸鱼算法对网络超参数优秀选择。

表 1 各阶段的算法比较
Table 1 Comparison of algorithms at each stage

方法	模块				Accuracy/%	Recall/%
	WOA	GC	GroupConv	kernelsize		
EfficientNet	—	—	—	—	91.72	91.66
EfficientNet_WOA	✓	—	—	—	92.68	92.59
EfficientNet_GC	✓	✓	—	—	94.83	94.65
My_EfficientNet_GCCov	✓	✓	✓	—	96.55	96.29
My_EfficientNet	✓	✓	✓	✓	97.97	97.11

如表 2 所示,与其他研究方法相比,文献[17]使用的基于 VGG16 的迁移学习方法,该方法通过使用中值滤波器来过滤噪声,以及文献[18]的决策树方法通过结合多种分类器来找到每个数据集最有效的处理策略,本文的 My_EfficientNet 在精确度和召回率上均显示出显著的提升。具体来说,文献[17]的研究显示精确度为 91%,召回率为

94%,而本文的方法分别高出 6.97%和 3.11%。此外,文献[19]结合 AlexNet、VGG16、Inception 架构以及 GAN 扩充技术的方法,在精确度和召回率上也低于本文的模型。同样,CEIMVEN 的 Efficient-B1 和 B2 虽然表现出平衡的性能,但无论是精确度还是召回率都未能超越本文的模型。通过以上对比验证了改进模型的先进性。

表 2 最终结果与相关研究比较
Table 2 Comparison of final results with related studies

相关研究	方法	Accuracy/%	Recall/%
文献[17]	Transfer learning with VGG16	91	94
文献[18]	Decision tree j48+ MLP+ NB+SMO+ IBK	96.99	—
文献[19]	AlexNet+ VGG16+ Inception+ ResNet+ Nasnet	94	—
文献[20]	Efficient-B1	91.36	93.25
文献[20]	Efficient-B2	92.6	93.77
本文	My_EfficientNet	97.97	97.11

根据程序计算出的 AP 和 mAP,如表 3 所示,可以看

到随着鲸鱼优化策略、全局上下文以及卷积的改进策略的

表 3 各阶段的算法 AP 与 mAP 指标
Table 3 Algorithmic AP and mAP metrics by phase

方法	AP(良性)/%	AP(恶性)/%	AP(正常)/%	mAP/%
EfficientNet	95.68	95.74	97.84	96.42
EfficientNet_WOA	98.49	96.29	92.29	95.69
EfficientNet_GC	99.36	97.39	96.07	97.34
My_EfficientNet_GCCov	99.16	98.03	94.82	97.61
My_EfficientNet	99.21	97.37	99.23	98.60

应用,模型的分类精度有了明显提升。基本的模型的整体平均精度(mAP)为 96.42%。加入 WOA 后,mAP 提高至 95.69%。

结合 WOA 和 GC,mAP 增至 97.34%,而在进一步加入 kernelsize 改进后,mAP 提升至 97.61%。在所有模型中,EfficientNet 结合 WOA、GC 模块、GC 卷积和 kernelsize 改进策略后表现最佳,mAP 达到了 98.60%。这些数据表明,这些策略能有效提高模型的分类性能。

本研究通过 PR 和 ROC 曲线(如图 7)分析了模型在不同医学诊断类别上的性能。PR 曲线结果表明,在高召

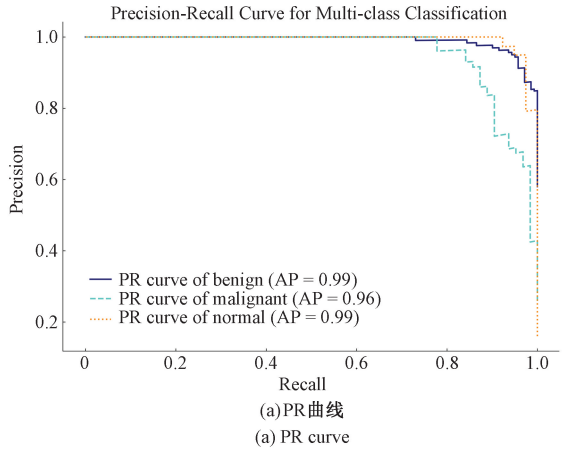


图 7 PR 曲线和 ROC 曲线
Fig. 7 PR curve and ROC curve

回率区域,良性类别的精确率较高,显示模型对良性样本有较强鉴别力;而恶性和正常类别的精确率随召回率增加快速下降,暗示区分这两类样本的难度。在召回率低时,所有类别的精确率极高,反映出模型在高置信度下的准确性。ROC 曲线显示,模型在所有类别上均有高度准确性,AUC 值为良性 0.99、恶性 0.98、正常 0.998。这表明模型是处理医学图像诊断任务、支持临床决策的提供了一种有效方法。

2.4 模型可视化分析

最后,对梯度加权类激活映射(gradient-based class activation map,Grad-CAM)的探讨表明,该技术能够在模型的最终卷积层上有效定位目标区域,为视觉解释提供支持。通过在绿色色彩尺度上计算 Grad-CAM,图 8 展现了正常、良性及恶性病例的 Grad-CAM 叠加图像以及其原始输入,左侧为原始图像,右侧为 Grad-CAM 图像。结果表

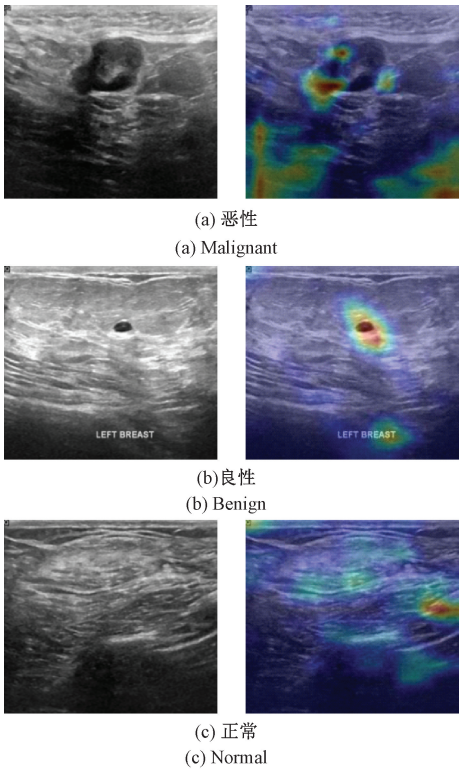


图 8 Grad-CAM 对于不同类别表现
Fig. 8 Grad-CAM for different categories of presentation

明 Grad-CAM 准确标示出恶性肿瘤的边缘、高回声和血管特征,并且能够在整个图像范围里去寻找疑似病灶,同时能够区分正常与良性样本。这表明模型中的卷积层有效提取了适合分类器的特征。

3 结 论

本研究通过使用改良 EfficientNet 对乳腺癌超声波图像进行分类,针对大面积、形状奇异病灶引入全局上下文模块和分组卷积,结合大卷积核和大视野策略增强模型。结果显示训练和验证精度分别达到 99.81% 和 98.06%,平均精度从 96.42% 提升至 98.60%,在准确率和召回率方面超越现有方法。这展示了深度学习在医学图像分析领域的潜力,为乳腺癌早诊断和治疗提供高效精准工具。考虑到增大卷积核导致计算量增加,未来研究将通过模型压缩、网络剪枝、量化技术和知识蒸馏降低计算需求,探索轻量化网络和硬件加速提高推理效率,实现边缘设备上的实时处理,同时强化模型泛化能力和数据预处理。

参考文献

- [1] SUNG H, FERLAY J, SIEGEL R L, et al. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. *Ca-A Cancer Journal for Clinicians*, 2021, 71(3): 209-249.
- [2] SIEGEL R L, MILLER K D, WAGLE N S, et al. Cancer statistics [J]. *Ca-A Cancer Journal for Clinicians*, 2023, 73(1): 17-48.
- [3] 谢亚咩,王欢. 影像新技术在乳腺疾病筛查中的应用[J]. *临床医学进展*, 2022, 12(1): 56-61.
XIE Y M, WANG H. Application of new imaging technology in breast disease screening[J]. *Advances in Clinical Medicine*, 2022, 12(1): 56-61.
- [4] 陈科威,杨婷,罗雨晴,等. 基于 MRI 的影像组学和深度学习在乳腺癌新辅助化疗中的研究进展[J]. *临床放射学杂志*, 2023, 42(8): 1364-1367.
CHEN K W, YANG T, LUO Y Q, et al. Research progress on radiomics and deep learning based on MRI in neoadjuvant chemotherapy for breast cancer [J]. *Journal of Clinical Radiology*, 2023, 42 (8): 1364-1367.
- [5] YANG X, WANG R, ZHAO D, et al. Multi-level threshold segmentation framework for breast cancer images using enhanced differential evolution [J]. *Biomedical Signal Processing and Control*, 2023, 80: 104373.
- [6] YU L, SHAAHEEMA S B, SUNIL J, et al. Breast cancer segmentation using a hybrid AttendSeg architecture combined with a gravitational clustering optimization algorithm using mathematical modelling [J]. *Open Physics*, 2023, 21(1), DOI: 10.1515/phys-2023-0105.
- [7] BONG J H, KIM T H, JEONG S. Deep learning model for the diagnosis of breast cancers smaller than 1 cm with ultrasonography: Integration of ultrasonography and clinical factors [J]. *Quantitative Imaging in Medicine and Surgery*, 2023, 13(4): 2486-2495.
- [8] TAN M X, LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks[J]. *ArXiv preprint arXiv:1905.11946*, 2019.
- [9] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018: 7132-7141.
- [10] CAO Y, XU J R, LIN S, et al. GCNet: Non-local networks meet squeeze-excitation networks and beyond[C]. *IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*, 2019: 1971-1980.
- [11] XIE S N, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks[C]. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017: 5987-5995.
- [12] DING X H, ZHANG X Y, HAN J G, et al. Scaling up your kernels to 31×31 : Revisiting large kernel design in CNNs [C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022: 11953-11965.
- [13] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. *Advances in Engineering Software*, 2016, 95: 51-67.
- [14] 刘智睿,杨志刚,赵志伟,等. 决策空间自组织多模态多目标鲸鱼优化算法研究[J]. *电子测量技术*, 2023, 46(4): 48-55.
LIU ZH R, YANG ZH G, ZHAO ZH W, et al. Research on decision space self-organized multimodal multi-objective whale optimization algorithm [J]. *Electronic Measurement Technology*, 2023, 46 (4): 48-55.
- [15] 孟宪猛,蔡翠翠. 基于精英反向学习和 Lévy 飞行的鲸鱼优化算法[J]. *电子测量技术*, 2021, 44(20): 82-87.
MENG X M, CAI C C. Whale optimization algorithm based on elite inverse learning and Lévy flight [J]. *Electronic Measurement Technology*, 2021, 44 (20): 82-87.
- [16] AL-DHABYANI W, GOMAA M, KHALED H, et al. Dataset of breast ultrasound images[J]. *Data in Brief*, 2020, 28: 104863.
- [17] JABEEN K, KHAN M A, ALHAISONI M, et al.

Breast cancer classification from ultrasound images using probability-based optimal deep learning feature fusion [J]. Sensors (Basel, Switzerland), 2022, 22(3): 807-821.

[18] SALAMA I, ABDELHALIM M, ZEID M A. Breast cancer diagnosis on three different datasets using multi-classifiers[J]. International Journal of Computer and Information Technology, 2012, 1(1): 36-43.

[19] AL-DHABYANI W, GOMAA M, KHALED H, et al. Deep learning approaches for data augmentation and classification of breast masses using ultrasound images [J]. International Journal of Advanced Computer Science and Applications, 2019, 10, DOI: 10.14569/IJACSA. 2019. 0100579.

[20] BANERJEE S, MONIR M K H. CEIMVEN: An approach of cutting edge implementation of modified versions of EfficientNet (V1-V2) architecture for breast cancer detection and classification from ultrasound images [C]. International Conference on Computing, Intelligence and Data Analytics, 2023.

作者简介

陈诺,本科,主要研究方向为图像处理。

E-mail:212241803611@stu.just.edu.cn

朱璘(通信作者),副教授,硕士生导师,主要研究方向为图像处理。

E-mail:oscar@just.edu.cn