

基于改进 EfficientNet 的乳腺肿瘤诊断

方祯祺, 李雪, 莫红

(长沙理工大学电气与信息工程学院, 湖南 长沙 410114)

摘要: 乳腺肿瘤严重影响女性的身心健康。病理学图像分析是医生诊断乳腺肿瘤的一个重要方法, 不同类型肿瘤细胞的结构具有高度的相关性, 这使得常规方法的诊断不易进行。改进的 EfficientNet 被用来诊断乳腺肿瘤, 其使网络模型能自动学习疾病的特征并提高乳腺肿瘤诊断的准确率。基于此, 首先, 采用卷积块注意力模型提取乳腺肿瘤病理图像的有效特征; 其次, 引入分组卷积和通道混洗操作来提高模型的特征表达能力; 再次, 利用 Hard-Swish 激活函数提升模型的收敛速度; 最后, 实验验证了改进后的 EfficientNet 在 BreakHis 数据集上的 8 分类准确率达到 98.4%, 该方法成为乳腺肿瘤诊断的一个有力的决策辅助工具。

关键词: 乳腺肿瘤; EfficientNet; 图像分类; 卷积神经网络

中图分类号: TP391.4

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202343

Diagnostic of breast tumors based on improved EfficientNet

FANG Zhenqi, LI Xue, MO Hong

School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha, 410114, China

Abstract: Breast tumors adversely affect the holistic well-being of women. Histopathological images are a critical substantiation for doctors to diagnose breast tumor types. The structure of various types of tumor cells exhibits significant correlations, thereby posing challenges to the diagnosis using conventional methods. In this work, the enhanced EfficientNet was employed for the diagnosis of breast tumors, which enabled the network model to learn the features of the disease automatically and improve the accuracy of the diagnosis of breast tumor types. Firstly, the convolutional block attention module was used to extract effective features. Secondly, the group convolution and channel shuffle operations were introduced to improve the feature representation ability of the model. Thirdly, the Hard-Swish activation function was applied to improve the convergence speed of the model. Finally, Experiments showed that the improved EfficientNet network achieved 98.4% accuracy in eight classifications on the BreakHis dataset, which was expected to act a decision aid tool in breast tumor diagnostic research.

Key words: breast tumor, EfficientNet, image classification, convolutional neural network

0 引言

我国乳腺癌发病率逐年上升^[1], 癌症的早发现和早治疗对于改善乳腺癌患者的治疗效果, 提高患者的生存率具有重要意义^[2]。病理学检查是乳腺癌

及肿瘤类型诊断的金标准^[3], 常用的检查方法组织学切片技术以全视野数字切片的形式保存^[4], 因病理图像具有高分辨率和复杂结构, 需花费大量时间和精力进行人工审阅, 具有主观性。另外, 病理科人才极度短缺, 导致癌症患者无法得到高效的治

收稿日期: 2023-08-06; 修回日期: 2023-11-13

通信作者: 莫红, mohong198@163.com

基金项目: 国家自然科学基金项目 (No.61473048)

Foundation Item: The National Natural Science Foundation of China (No.61473048)

疗^[5]。因此,使用计算机辅助病理学技术对提高诊断效率和准确性十分关键。

卷积神经网络(convolutional neural network, CNN)作为图像处理领域中一种高效的识别方法^[6-12],在医学自助诊断中对乳腺肿瘤图像进行自动分类取得了显著成就。Spanhol等人^[13]使用AlexNet自动进行乳腺癌病理图像的分类,发现在二分类任务上精度比机器学习算法高出6%。Nahid等人^[14]使用长短期记忆网络(long short term memory, LSTM)和门控循环单元(gated recurrent unit, GRU)进行乳腺癌的二分类,准确率为93.01%。Das等人^[15]提出了一种基于CNN的多实例学习(multiple-instance learning, MIL)框架,分类精度为88%。Shallu等人^[16]基于VGG-16微调进行迁移学习二分类,精度为92.6%。何雪英等人^[17]基于卷积神经网络模型GoogLeNet进行迁移学习,对乳腺癌二分类的精度为91%。Zhan等人^[18]通过微调Inception-v3来实现乳腺癌图像的二分类,精度达到95.7%。Gour等人^[19]提出一个基于残差学习的卷积神经网络,准确率达到92.52%。Boumaraf等人^[20]基于ResNet18进行迁移学习,在多分类上的精度为89.56%~94.49%。

上述学者验证了CNN对乳腺肿瘤分类的有效性,然而,这些研究主要集中在乳腺肿瘤的良性、恶性分类上,并且基于大模型实现分类任务,较少关注轻量化模型。大模型存在梯度消失、计算成本高和内存需求大等问题^[21],当前的总体改进趋势是在不影响性能的情况下设计轻量级架构^[22]。轻量化模型EfficientNet利用复合缩放方法来扩大网络深度、宽度和分辨率,比其他模型需要更少的计算资源。

本文针对乳腺肿瘤组织病理学图像自身存在的问题,在EfficientNetB0模型的基础上进行改进,通过引入分组卷积和通道混洗操作、卷积块注意力模型(convolutional block attention module, CBAM)以及Hard-Swish激活函数,提出了一种基于GSCH-EfficientNet(group convolution, channel shuffle, CBAM and hard-swish efficientnetb0)的轻量级网络。主要工作是对数据集进行处理(数据增强、数据预处理以及数据的分批分类)、对乳腺肿瘤图片EfficientNetB0模型进行改进、对GSCH-EfficientNet模型进行训练和调整,以提高模型效率、减少训练参数量,最后实现乳腺肿瘤的8分类,具体流程如

图1所示。

本文其他章节如下:第1节介绍本文使用的相关方法;第2节提出基于GSCH-EfficientNet的乳腺肿瘤分类方法;第3节进行实验证明;第4节为总结。

1 相关方法

1.1 乳腺肿瘤组织切片图像数据预处理

本文在BreakHis数据集^[23]上进行实验,该数据集为三通道RGB图片,图片格式为PNG,统一大小为700×460像素,包含7 909张图片以及4个放大倍数(40×、100×、200×、400×),见表1。其中良性图像2 480张,包括腺病(adenosis, A)、纤维腺瘤(fibroadenoma, F)、叶状瘤(phylloides tumor, PT)及管状腺瘤(tubular adenoma, TA);恶性图像5 429张,其中包括导管癌(ductal carcinoma, DC)、小叶癌(lobular carcinoma, LC)、粘液癌(mucinous carcinoma, MC)及乳头状癌(papillary carcinoma, PC),各类别之间数据分布不均衡,存在很大差异。

在进行分类任务前,考虑到该数据集原始数据规模仍然较小且各类肿瘤样本量大小不一,使用空间变化来完成乳腺肿瘤病理组织图像数据增强任务,避免分布不均对最终分类准确度造成干扰。数据集通过旋转180°、水平翻转、垂直翻转等方式进行扩充,使8类乳腺肿瘤的图像数量分布均衡。在训练时采用随机裁剪、缩放、中心位置裁剪等操作进行预处理,提高模型的泛化能力和鲁棒性。

1.2 可视化方法

深度学习的决策预测机制缺乏足够的可解释性,网络的性能和输入输出只能通过其内部的权重值和结构等数据来解释^[24],与医生关心的可疑区域存在显著差异。为了解释深度学习模型对特征输入做出某种决策的原因,著性图、图像字幕和视觉注意图等技术被提出。梯度加权类激活映射(gradient-weighted class activation mapping, Grad-CAM)^[25]是一种先进的热力图可视化技术,利用目标类别相对卷积层的梯度来生成热力图,直观地展示模型在图像中寻找的特征位置,突出组织病理学图像中的区分区域,使病理学家信任深度神经网络的输出,提供具有可解释性的结果。用Grad-CAM技术来可视化解释GSCH-EfficientNet模型的




图1 工作流程

表1 BreakHis数据集图像分布

图像类型	40×/张	100×/张	200×/张	400×/张
A	114	113	111	106
F	253	260	264	237
PT	109	121	108	115
TA	149	150	140	130
DC	864	903	869	788
LC	156	170	163	137
MC	205	222	196	169
PC	145	142	135	138

决策过程，查看模型对某类乳腺肿瘤图片中感兴趣的区域。首先将网络进行正向传播得到特征层和网络对这一类肿瘤的预测值，接着对预测值进行反向传播得到反传回特征层的梯度信息，再通过式（1）计算得到针对特征层每个通道的重要程度，加权求和后通过ReLU函数得到可视化结果，具体过程如式（2）所示。

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (1)$$

$$L_{\text{Grad-CAM}}^c = \text{ReLU}(\sum_k \alpha_k^c A^k) \quad (2)$$

其中， A 代表某个特征层， k 代表特征层 A 中第 K 个通道， c 代表通道数， y^c 代表网络针对类别 c 的预测值， A^k 代表特征层 A 中通道 k 的数据，下标 ij 为坐标位置， Z 为特征层的宽度与高度的积。

1.3 评价标准

本文采用分类中常用的评价指标对实验结果进行评估，它们分别是准确率（accuracy，ACC）、精确率（precision，P）、召回率（recall，R）、特异性（specificity，SP），平衡F分数（balanced score，F1-Score），并采用宏观平均法计算出多分类的相应指标。具体如下：

$$\text{ACC} = \frac{TP + TN}{TP + FN + FP + TN} \times 100\% \quad (3)$$

$$P = \frac{TP}{TP + FP} \times 100\% \quad (4)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (5)$$

$$\text{SP} = \frac{TN}{FP + FN} \times 100\% \quad (6)$$

$$F1-Score = \frac{2 \times P \times R}{P + R} \times 100\% \quad (7)$$

$$Average(x) = \frac{1}{M} \sum_{m=1}^M x(m) \quad (8)$$

其中, TP 表示真实标签和输出均为正类。 FP 表示真实标签为正类, 输出为负类。 TN 表示真实标签和输出均为负类。 FN 表示真实标签为负类, 输出为正类。 M 表示类别总数, $x(m)$ 表示类别 m 对应的 ACC、P、R、SP 和 F1-Score 的值。

2 基于 GSCH-EfficientNet 的乳腺肿瘤分型

Google 提出了一种方法, 利用简单而高效的复合系数对深度、宽度、分辨率的所有维度进行均匀缩放, 以提高模型的性能。使用神经架构搜索 (neural architecture search, NAS) 技术得到合理的网络结构, 设计了一个新的基线模型 EfficientNetB0^[20], 并将其扩展为一系列模型 EfficientNetB0-EfficientNetB7, 在 ImageNet 数据集上, EfficientNet 达到了高精度和推理速度。移动翻转瓶颈卷积 (mobile inverted bottleneck convolution, MBConv) 模块作为 EfficientNetB0 模型的基础核心模块, 其结构如图 2 所示, 由 2 个普通卷积 (Conv)、批量归一化层 (batch normalization, BN)、1 个深度卷积 (Depthwise Conv, DWConv)、1 个 SE (squeeze-and-excitation) 模块包含 1 个平均池化层 (average pooling, AvgPooling)、2 个全连接层 (fully connected, FC) 和一个随机失活层 (Dropout) 构成。其中捷径分支 (shortcut) 和随机失活层仅当输入特征矩阵和输出特征矩阵的大小相同时才存在。

本文提出一种基于改进 EfficientNetB0 的轻量级乳腺肿瘤图像分类模型, 如图 3 所示。通过引入 CBAM 模块、分组卷积 (group convolution, GConv) 和通道混洗操作以及 Hard-Swish 激活函数得到了改进后的 MBConv, 并命名为 MCBCConv 模块。当输入特征图输入 MCBCConv 模块时, 首先经过一个 1×1 的分组卷积层进行升维, 其卷积核的个数为输入特征矩阵的 1 倍或 6 倍, 相比普通卷积, 本文利用分组卷积降低了参数值和计算量, 随后通过批量归一化层 (batch normalization, BN) 层和 Hard-Swish 激活函数加快网络的训练和收敛速度。再通过一个 $k \times k$ 的 DWConv 减少模型运算和参数量, 其中 k 为 3 或 5, 同样利用 BN 层和 Hard-Swish 激活函数提高网络效率。特征图经过 CBAM 模块, 在




图2 MBConv模块结构

CBAM 模块中分别进行平均池化和最大池化后相加, 经过 Sigmoid 函数再与输入 CBAM 模块的特征图相乘, 实现了空间和通道加权的操作, 对特征图进行了校准。随后经过 1×1 的分组卷积层进行降维, 通过 BN 层后增加了一个通道混洗操作避免出现分组卷积带来的组间信息不流通的问题, 提升信息交流的效率。最后通过 Dropout 层后与输入特征图相加得到输出特征图。

改进的 EfficientNetB0 的轻量级模型由 16 个 MCBCConv 模块、2 个普通卷积模块、1 个全局平均池化层和 1 个全连接分类层构成。

2.1 CBAM 注意力机制模块

乳腺组织病理图像结构上的复杂特点导致管状腺瘤和纤维腺瘤出现了难以区分的情况。MBConv 模块中 SE 模块通过学习获取每个通道的重要程度, 对输入特征图进行通道特征加强。而 SE 模块只学习通道特征, 忽略了图像中某些对分类起决定作用的空间像素信息, 导致特征提取过程的效果不佳。

CBAM 模块结合了通道注意力模块和空间注意力模块, 能够自适应地选择对于当前任务最重要的通道和空间位置。本文提出将 CBAM 嵌入 MBConv 中, 在通道注意力模块中将输入特征图 F 分别进行平均池化 (AvgPool) 和最大池化 (Max-Pool), 接着送入一个只有一个隐藏层的多层感知




图3 GSCH-EfficientNet结构

机 (multilayer perceptron, MLP) 中, 将得到的结果相加后经过 sigmoid 函数得到权重系数 M_c , 如图4所示。将权重系数和原来的特征 F 相乘得到缩放后的新特征 F' 。与通道注意力不同, 空间注意力模块将得到的特征图 F' 分别通过平均池化和最大池

化后按通道拼接在一起, 然后经过一个激活函数为 sigmoid 的卷积层得到权重系数 M_s , 如图5所示。将权重系数 M_s 和特征 F' 相乘得到缩放后的新特征, 最后得到的特征图结合了通道注意力和空间注意力两个子模块, 减少了原始图像信息的丢失率。




图4 通道注意力机制




图5 空间注意力机制

2.2 分组卷积和通道混洗

EfficientNetB0 对 MCBConv 模块进行反复堆叠, 随着网络的深入, 卷积层中的大部分通道用于生成

更详细的滤波器而产生了更大的参数。同时, 普通卷积受局部感受野的限制, 只能捕捉到输入图像上有限区域内的特征信息, 无法有效地处理不同尺度

和层次的特征。在识别包含多细节以及结构复杂特征的乳腺肿瘤组织病理图像时,可能会失去一些关键的上下文信息。

本文采用分组卷积代替 MBConv 中的普通卷积,减少模型参数量,提高表达和泛化能力,避免发生过拟合。另外,分组卷积存在组间信息不流通

的问题,导致某些关键信息无法被有效传递,需要在分组卷积后面添加通道混洗操作,使原本分散在不同组内的通道之间可以进行信息交换和融合,改善组间信息阻塞。通道混洗操作如图6所示,先将通道分为 n 组,再将数据按组变换维度然后进行转置,再展平进行拼接组合,得到混洗后的新特征图。




图6 通道混洗操作

2.3 激活函数

Swish 非线性激活函数在更深层次的模型上表现得很好,但在移动设备上 Swish 激活函数存在计算量大、计算成本较高的问题,其定义为:

$$\text{Swish}(x) = x \cdot \text{sigmoid}(x) \quad (9)$$

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (10)$$

本文将 Hard-Swish 作为激活函数,减少模型计算量,提升收敛速度,如式(11)所示。

$$\text{Hard-Swish}(x) = x \cdot \frac{\text{ReLU}_6(x+3)}{6} \quad (11)$$

$$\text{ReLU}_6(x) = \min(\max(0, x), 6) \quad (12)$$

观察 Swish 激活函数和 Hard-Swish 激活函数的原函数发现,在同样区间内的函数值变化几乎是一致的,但 Hard-Swish 激活函数求导过程更为简单,能很好地保留激活函数的非线性特性,更好地拟合数据且提供更为平滑的激活响应。

3 实验

先将 BreakHis 数据集按比例 8:2 分为训练集和测试集,再将训练集的 20% 作为验证集。模型采用 Python 语言、PyCharm 实验平台、Pytorch 深度学习框架。利用随机梯度下降 (stochastic gradi-

ent descent, SGD) 优化器来最小化交叉熵损失函数,用余弦退火算法动态调整训练期间的学习率,初始学习率设置为 0.01,余弦退火参数设置为 0.01,训练周期 (epoch) 为 300,批量大小 (batch size) 设置为 16。

3.1 实验结果分析

GSCH-EfficientNet 模型的训练效果如图7所示,随着训练次数的增加,GSCH-EfficientNet 模型的训练准确率和验证准确率逐渐升高,准确率最高分别达到了 98.9% 和 98.4%,并且训练过程中二者差距很小,表明 GSCH-EfficientNet 模型具有良好的泛化能力。

3.2 消融实验

为了验证每项改进的贡献,对改进的每一项分别进行了实验。如图8所示,当 EfficientNetB0 分别引入 Hard-Swish 激活函数、CBAM 模块、分组卷积和通道混洗操作时,将它们分别命名为 H-EfficientNet、C-EfficientNet 和 GS-EfficientNet,其准确率分别达到了 93.9%、94.3% 和 94.7%。综合 3 项改进得到的 GSCH-EfficientNet 模型准确率达到 98.4%,高于基线网络 EfficientNetB0 以及 C-EfficientNet、H-EfficientNet 和 GS-EfficientNet,肯定了本文提出的改进方法。




图7 GSCH-EfficientNet模型训练效果




图8 改进模型准确率验证曲线

改进模型的性能参数如表2所示，表中列出了VGG16和ResNet34两种大模型的参数量（parms）和计算量（FLOPs）作为参考。与基线网络EfficientNetB0相比，当网络使用Hard-Swish作为激活函数时，分类准确率提高了0.7%，且收敛速度更快；当网络嵌入CBAM模块时，在增加了少量参数量的情况下将分类准确率提高了1.1%；当网络引入分组卷积和通道混洗操作时，模型参数量减少了1.38 MB，计算量减少了159.23 MB，同时分类准确率还提高了1.5%；当网络同时引入Hard-Swish、CBAM模块、分组卷积和通道混洗操作时，分类准确率提高了5.2%的同时参数量和计算量分别减少了1.07 MB和151.24 MB。

3.3 分类测试

通过测试集绘制GSCH-EfficientNet模型的混淆矩阵，显示了不同类别的预测结果。矩阵的行和列表示乳腺肿瘤类别的真实值和预测值，对角线上

表2 改进模型性能对比

模型	ACC/%	parms/MB	FLOPs
VGG16	88.8	138.36	15.5 GB
ResNet34	92.0	21.8	3.68 GB
EfficientNetB0	93.2	5.3	399.36 MB
H-EfficientNet	93.9	5.29	399.36 MB
C-EfficientNet	94.3	5.59	407.36 MB
GS-EfficientNet	94.7	3.92	240.13 MB
GSCH-EfficientNet	98.4	4.23	248.12 MB

的值则表示分类正确的乳腺肿瘤项目数量，而对角线外的值则表示错误分类的乳腺肿瘤项目的数量。混淆矩阵主对角线的颜色越深，代表分类的准确度越高。EfficientnetB0在测试集上得到的混淆矩阵如图9所示，GSCH-EfficientNet在测试集上得到的混淆矩阵如图10所示。




图9 EfficientNetB0在测试集上的混淆矩阵




图10 GSCH-EfficientNet在测试集上的混淆矩阵

模型改进前在TA和F这两类的识别上出现了图像混淆的情况,分析混淆矩阵可知,经过改进后对TA和F的判断得到了提升,从原来的精确率分别为85.8%、86.2%提高到98.4%、99.8%,能够较好地地区分F和TA两类图像。改进后模型在其他的肿瘤类型的识别上也得到了提高,改进前TA中有68张误判为F,24张误判为PC,21张误判为DC,7张误判为MC,2张误判为A;改进后,TA预测错误数为0。改进前PT中有16张误判为A,8张误判为DC,18张误判为F,3张误判为TA;改进后PT预测错误数为0。改进前PC中有2张误判为DC,3张误判为MC,3张误判为PT,34张误判为PT;改进后PC预测错误数为0。改进前A中有9张误判为PT,1张误判为F;改进后A预测错误数为0。

3.4 主流模型的比较和分析

为了验证改进模型的先进水平,本文选择了轻量级模型EfficientNetB0、MobileNetv2和ShuffleNetv2,以及大型模型VGG16、RestNet34和DenseNet121与GSCH-EfficientNet进行对比。图11表示了各个模型在验证集上的准确率变化曲线,EfficientNetB0、MobileNetv2、ShuffleNetv2、VGG16、RestNet34和DenseNet121的准确率分别达到了93.2%、89.1%、90.9%、88.8%、92.0%和92.1%,可以看出GSCH-EfficientNet实现了更高的准确率,改进模型后能在训练中快速达到稳定,收敛较快。




图11 主流模型准确率对比

各个模型在测试集上的准确率、精确率、召回率、特异性和F1-Score的具体数据如表3所示,GSCH-EfficientNet在ACC、P、R、SP和F1-Score上比EfficientNetB0分别要高出5.2%、5.8%、

6.1%、0.9%、6%;比MobileNetv2分别高出9.3%、9.7%、10.2%、1.8%、10%;比ShuffleNetv2分别高出7.5%、7.7%、7.9%、1.4%、7.9%;比VGG16分别高出9.6%、10.1%、11.5%、5%、10.9%;比RestNet34分别高出6.4%、6%、6.3%、1%、6.2%;比DenseNet121分别高出6.3%、5.9%、6%、1.1%、6%;在主流模型中对BreakHis数据集进行8分类任务,GSCH-EfficientNet取得了最高准确率98.4%、最高精确率97.9%、最高召回率97.8%、最高特异性99.7%、最高F1-Score 97.9%。

表3 各模型性能对比

模型	准确率/%	精确率/%	召回率/%	特异度/%	F1-Score/%
VGG16	88.8	87.8	86.3	94.7	87.0
RestNet34	92.0	91.9	91.5	98.7	91.7
DenseNet121	92.1	92.0	91.8	98.6	91.9
MobileNetV2	89.1	88.2	87.6	97.9	87.9
ShuffleNetV2	90.9	90.2	89.9	98.3	90.0
EfficientNetB0	93.2	92.1	91.7	98.8	91.9
GSCH-EfficientNet	98.4	97.9	97.8	99.7	97.9

3.5 可视化结果分析

本节使用Grad-CAM技术探讨基于GSCH-EfficientNet的乳腺肿瘤诊断方法的决策过程,通过该技术可以直观地表达输入图像中每个像素区域对最终分类输出的关键特征重要程度。本文利用流入网络最后一个卷积层的梯度生成热力图,突出输入图像中模型关注的关键区域。图12展示了基于GSCH-EfficientNet模型的Grad-CAM对不同放大倍数下的乳腺组织病理学图像所获得的输出以及对应输入。对每个图像行提供了其属于的类和子类,以及分别在4个放大倍数下的可视化结果,红色区域表示高激活,蓝色区域表示低激活。

分析可视化结果可知,细胞核的形态特征是影响模型输出的关键因素,生成的热力图主要集中在具有复杂形态和边缘特征的细胞核上。对于恶性肿瘤的定位主要集中在形状不规则的细胞、有较明显的核仁以及染色质浓聚的细胞核上。而良性肿瘤的定位则集中在形态比较规则、细胞核均匀一致以及核边缘清晰或有边界的细胞上。

从图中观察到组织病理图像存在复杂的结构特点与互相重叠的细胞核,尤其在放大倍数为400的(400×)数据中表现得更为明显,正是这种复杂的




图12 可视化结果

结构影响着模型的判断，导致一定数量的假阳性和假阴性结果。因此，在后续的研究中需要针对这种结构带来的负面影响进一步改进模型，提高模型性能。

4 结束语

本文结合深度学习对乳腺肿瘤病理图像进行了处理和分类，实现了对8种乳腺肿瘤的自动分类。提出了一种新的轻量级网络模型GSCH-EfficientNet，对核心MBConv模块进行了优化，使用CBAM模块优化模型的特征提取能力，采用分组卷积和通道混洗操作提取关键的上下文信息，最后在MBConv模块用Hard-Swish激活函数提升模型收敛速度。通过实验，GSCH-EfficientNet模型在准确率、精确率、召回率、特异度和F1-Score等评价指标上均优于主流网络模型。本文提出的GSCH-EfficientNet模型有望帮助医疗机构实现辅助诊断。随着大语言模型的问世，模糊理论^[26-27]将为实现精准医疗提供帮助。

参考文献：

- [1] 郑莹, 吴春晓, 张敏璐. 乳腺癌在中国的流行状况和疾病特征[J]. 中国癌症杂志, 2013, 23(8): 561-569.
ZHENG Y, WU C X, ZHANG M L. The epidemic and characteristics of female breast cancer in China[J]. China Oncology, 2013, 23(8): 561-569.
- [2] 肖怀远, 郝希山. 乳腺癌早诊早治关键技术的研究与应用[J]. 科技导报, 2021, 39(7): 75-78.
XIAO H Y, HAO X S. Research and application of key technologies for early diagnosis and treatment of breast cancer[J]. Science and Technology Review, 2021, 39(7): 75-78.
- [3] LIANG Z Y, WANG Q Y, LIAO H W, et al. Artificially engineered anti-ferromagnetic nanopores for ultra-sensitive histopathological level magnetic resonance imaging[J]. Nature Communications, 2021, 12(1): 3840.
- [4] ARAÚJO T, ARESTA G, CASTRO E, et al. Classification of breast cancer histology images using convolutional neural networks[J]. PLoS One, 2017, 12(6): e0177544.
- [5] 卞修武, 平轶芳. 我国病理学科发展面临的挑战和机遇[J]. 第三军医大学学报, 2019, 41(19): 1815-1817.
BIAN X W, PING Y F. Pathology in China: challenges and opportunities[J]. Journal of Third Military Medical University, 2019, 41(19): 1815-1817.
- [6] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, (2): 25.
- [7] GUO Y, WANG Y, YANG H, et al. Dual-attention EfficientNet based on multi-view feature fusion for cervical squamous intraepithelial lesions diagnosis[J]. Biocybernetics and Biomedical Engineering, 2022, 42(2): 529-542.
- [8] 邵虹, 张鸣坤, 崔文成. 基于分层卷积神经网络的皮肤镜图像分类方法[J]. 智能科学与技术学报, 2021, 3(4): 474-481.
SHAO H, ZHANG M K, CUI W C. Classification method of dermoscopic image based on hierarchical convolution neural network[J]. Chinese Journal of Intelligent Science and Technology, 2021, 3(4): 474-481.
- [9] 王禾扬, 杨启鸣, 朱旗. 基于深度卷积集成网络的视网膜多种疾病筛查和识别方法[J]. 智能科学与技术学报, 2021, 3(3): 259-267.
WANG H Y, YANG Q M, ZHU Q. Retinal multi-disease screening and recognition method based on deep convolution ensemble network[J]. Chinese Journal of Intelligent Science and Technology, 2021, 3(3): 259-267.
- [10] 邵虹, 左常升, 张萍. 结合 Attention U-Net 与瓶颈检测的肺部细胞图像分割方法[J]. 智能科学与技术学报, 2022, 4(4): 610-616.
SHAO H, ZUO C S, ZHANG P. Lung cell image segmentation method combining attention U-Net and bottleneck detection[J]. Chinese Journal of Intelligent Science and Technology, 2022, 4(4): 610-616.
- [11] 丛晓峰, 桂杰, 章军. 基于视觉 Transformer 的多损失融合水下图像

- 增强网络[J]. 智能科学与技术学报, 2022, 4(4): 522-532.
- CONG X F, GUI J, ZHANG J. Underwater image enhancement network based on visual transformer with multiple loss functions fusion [J]. Chinese Journal of Intelligent Science and Technology, 2022, 4(4): 522-532.
- [12] 李颖, 陈龙, 黄钊宏, 等. 基于多尺度卷积神经网络特征融合的植株叶片检测技术[J]. 智能科学与技术学报, 2021, 3(3): 304-311.
- LI Y, CHEN L, HUANG Z H, et al. Plant leaf detection technology based on multi-scale CNN feature fusion[J]. Chinese Journal of Intelligent Science and Technology, 2021, 3(3): 304-311.
- [13] SPANHOL F A, OLIVEIRA L S, PETITJEAN C, et al. Breast cancer histopathological image classification using convolutional neural networks[C]//Proceedings of 2016 International Joint Conference on Neural Networks (IJCNN). Piscataway: IEEE Press, 2016: 2560-2567.
- [14] NAHID A A, MEHRABI M A, KONG Y N. Frequency-domain information along with LSTM and GRU methods for histopathological breast-image classification[C]//Proceedings of 2017 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT). Piscataway: IEEE Press, 2018: 410-415.
- [15] DAS K, CONJETI S, ROY A G, et al. Multiple instance learning of deep convolutional neural networks for breast histopathology whole slide classification[C]//Proceedings of 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018). Piscataway: IEEE Press, 2018: 578-581.
- [16] SHALLU, MEHRA R. Breast cancer histology images classification: Training from scratch or transfer learning?[J]. ICT Express, 2018, 4 (4): 247-254.
- [17] 何雪英, 韩忠义, 魏本征. 基于深度学习的乳腺癌病理图像自动分类[J]. 计算机工程与应用, 2018, 54 (12): 121-125.
- HE X Y, HAN Z Y, WEI B Z. Breast cancer histopathological image auto-classification using deep learning[J]. Computer Engineering and Applications, 2018, 54 (12): 121-125.
- [18] ZHAN X, ZHANG T, FENG W Y, et al. Breast cancer diagnosis from histopathological image based on deep learning[C]//Proceedings of 2019 Chinese Control and Decision Conference (CCDC). Piscataway: IEEE Press, 2019: 4616-4619.
- [19] GOUR M, JAIN S, SUNIL KUMAR T. Residual learning based CNN for breast cancer histopathological image classification[J]. International Journal of Imaging Systems and Technology, 2020, 30(3): 621-635.
- [20] BOUMARAF S, LIU X B, ZHENG Z S. A new transfer learning based approach to magnification dependent and independent classification of breast cancer in histopathological images[J]. Biomedical Signal Processing and Control, 2021, 63: 102192.
- [21] LI Z, LIU F, YANG W, et al. A survey of convolutional neural networks: analysis, applications, and prospects[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(12):6999-7019.
- [22] KHAN A, SOHAIL A, ZAHOORA U, et al. A survey of the recent architectures of deep convolutional neural networks[J]. Artificial Intelligence Review, 2020, (53):5455-5516.
- [23] SPANHOL F A, OLIVEIRA L S, PETITJEAN C, et al. A dataset for breast cancer histopathological image classification[J]. IEEE Transactions on Biomedical Engineering, 2016, 63(7): 1455-1462.
- [24] SUPRIYO C, RICHARD T, RAMYA R, et al. Interpretability of deep learning models: a survey of results[C]//Proceedings of IEEE SmartWorld. Piscataway: IEEE Press, 2017: 1-6.
- [25] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[C]//Proceedings of 2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2017: 618-626.
- [26] 王飞跃, 莫红. 关于二型模糊集合的一些基本问题[J]. 自动化学报, 2017, 43(7): 1114-1141.
- WANG F Y, MO H. Some fundamental issues on type-2 fuzzy sets[J]. Acta Automatica Sinica, 2017, 43(7): 1114-1141.
- [27] MO H, WANG F Y, ZHOU, M, et al. Footprint of uncertainty for type-2 fuzzy sets[J]. Information Sciences: An International Journal, 2014, 272: 96-110.

[作者简介]



方祯祺 (1999-), 女, 长沙理工大学电气与信息工程学院硕士生, 主要研究方向为智慧医疗。



李雪 (1998-), 女, 长沙理工大学电气与信息工程学院硕士生, 主要研究方向为智慧医疗。



莫红 (1972-), 女, 长沙理工大学电气与信息工程学院教授, 主要研究方向为主要研究方向为智慧医疗、模糊AI和复杂系统管理与控制。