

基于深度学习的超声多模态乳腺肿块良恶性分类

王怡伟¹, 李晓兵¹, 聂生东¹, 姜立新², 万财凤², 蒋卓韵¹, 贾守强³

1. 上海理工大学健康科学与工程学院, 上海 200093; 2. 上海交通大学医学院附属仁济医院超声科, 上海 200025; 3. 山东第一医科大学附属济南人民医院影像科, 山东 济南 271100

【摘要】针对超声单模态信息量少的问题,提出基于双路神经网络的多模态乳腺肿块分类模型。收集来自上海交通大学医学院附属仁济医院2021年的96例乳腺癌患者(51例恶性,45例良性)的807张灰阶图像和807张弹性图像进行实验。首先,对传统的ResNeXt101模型进行改进,去掉最后的平均池化层和全连接层并添加注意力机制模块,以提高模型对图像重要信息的关注;然后,将病人同一病灶的灰阶图像和弹性图像分别输入至两个改进的ResNeXt101网络中;最后,将两路网络输出的特征进行拼接融合,构建全连接分类层进行良恶性鉴别。实验结果表明,使用双路网络准确率为84.27%, ROC曲线下面积(AUC)为0.932,高于单模态的准确率和AUC值。

【关键词】乳腺癌;深度学习;超声多模态;注意力机制;图像分类

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2023)08-0988-08

Deep learning-based classification for benign and malignant breast masses using multimodal ultrasound images

WANG Yiwei¹, LI Xiaobing¹, NIE Shengdong¹, JIANG Lixin², WAN Caifeng², JIANG Zhuoyun¹, JIA Shouqiang³

1. School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Department of Ultrasound, Renji Hospital, School of Medicine, Shanghai Jiaotong University, Shanghai 200025, China; 3. Department of Imaging, Ji'nan People's Hospital Affiliated to Shandong First Medical University, Ji'nan 271100, China

Abstract: A breast mass classification model based on dual neural networks and multimodal ultrasound images is proposed to address the issue of deficiency of information in monomodal ultrasound image. The 807 gray-scale images and 807 elastograms of 96 breast cancer patients (51 malignant and 45 benign) from Renji Hospital, School of Medicine, Shanghai Jiaotong University in 2021 were collected for experiment. The traditional ResNeXt101 model is improved by removing the final average pooling layer and fully connected layer, and adding an attention mechanism module to enhance the attention to important image information. Then, gray-scale images and elastograms of the same lesion of the patient are input into two improved ResNeXt101 networks separately; and the features output from the two networks are concatenated and fused to construct a fully connected classification layer for the discrimination of benign and malignant breast masses. The experimental results show that the accuracy rate and AUC of dual neural network for multimodal ultrasound images are 84.27% and 0.932, higher than those of single neural network for monomodal ultrasound image.

Keywords: breast cancer; deep learning; ultrasound multimodality; attention mechanism; image classification

前言

目前,乳腺癌已超越肺癌,成为全球第一大癌

症,其发病率和死亡率在女性中均为首位,对妇女健康构成严重威胁^[1]。因此,早期发现和适当治疗可以改善乳腺癌患者的预后。乳房X光检查是降低乳腺癌相关死亡率的推荐筛查方法。然而,钼靶X光摄影术对致密乳腺实质的敏感性较低,可能会导致诊断延迟和误诊情况^[2]。相比之下,虽然超声图像的空间分辨率较低,但超声具有安全、经济有效、对致密区肿瘤更敏感以及能够实时成像的优势^[3]。当通过其他成像方式或触诊发现异常时,超声常被用于检测和诊断乳腺病变^[4]。此外,乳腺超声有望成为乳腺密

【收稿日期】2022-11-12

【基金项目】上海市自然科学基金(19ZR1436200, 19440760800)

【作者简介】王怡伟,硕士,研究方向:医学图像处理, E-mail: 1316266695@qq.com

【通信作者】蒋卓韵,讲师,博士,研究方向:医学图像处理, E-mail: yunajiang@163.com; 贾守强,主任医师,博士,研究方向:神经影像学, E-mail: jshqlw@163.com

度较高女性的一种辅助筛查方法,这种筛查实践有望在早期发现肿瘤,并降低女性乳腺癌死亡率^[5]。B超成像(B-Mode Ultrasound, BUS)和超声弹性成像(Ultrasound Elastography, USE)因其价格低廉、无创、无电离辐射等优点,已成为临床上诊断乳腺癌的两种常用工具。BUS和USE提供多种信息,如形态、方向、内部结构、边缘等,可有效区分乳腺良恶性病变。

近年来,人工智能尤其是深度学习方法在语音自动识别、图像识别和自然语言处理等方面取得了突出的成绩。目前,常见的深度学习模型主要有深度置信网络^[6]、卷积神经网络(Convolutional Neural Networks, CNN)^[7]和循环神经网络^[8]等。深度学习在生物医学领域的应用涵盖了医学的各个层面,如生物信息学、医学图像识别、病症预测、临床辅助决策、药物开发^[9]。在医学图像识别方向,随着医学图像数据的显著增加,深度学习被广泛应用于图像分割、定位、分类和识别等任务。由于CNN具有自动提取图片特征,不同于以往需要手工制作特征,CNN在乳腺超声成像中有广泛应用^[10]。在乳腺超声图像分类中,许多文献讨论了BUS图像上良恶性病变的判别。Han等^[11]收集了大量BUS图像,利用GoogLeNet对3 154个恶性样本和4 254个良性样本进行训练,区分乳腺肿块的恶性程度,模型的准确率为91%,曲线下面积(AUC)>0.9。Fujioka等^[12]使用CNN架构的GoogLeNet Inception v2构建分类模型,将48张良性肿物图像和72张恶性肿物图像作为测试数据进行分析,模型的准确率为95.8%,AUC为0.913。Fujioka等^[13]还收集了158张良性和146张恶性肿块剪切波弹性成像(SWE)图像作为训练数据,使用38张良性和35张恶性肿块的SWE图像作为测试数据,深度学习模型使用6种最先进的架构来构建,最佳模型

(DenseNet 169)的AUC为0.898。Zhang等^[14]在一组SWE图像上使用135个良性肿瘤和92个恶性肿瘤构建一种深度学习架构,并评估其在乳腺良恶性肿瘤分化中的性能,获得的准确率为93.4%,AUC为0.947。

目前大多数文献只采用单一模态的超声图像进行实验,但单模态图像包含信息量少,可提取的图像特征少,因此本文提出基于多模态超声图像的诊断模型,使用超声灰阶图像和弹性图像作为模型的输入,为模型提供更丰富的乳腺肿块图像特征,提高模型预测的准确率。

1 数据

本文使用的数据来自上海交通大学医学院附属仁济医院,采集了2021年的96组乳腺癌患者资料,每例患者数据都采集了多模态图像。病理检查结果作为良恶性判别的金标准,其中51例病人的乳腺肿块是恶性肿块,45例病人的乳腺肿块是良性肿块,每例病人的图片张数为6~12张,共有807张图像。图像预处理流程如图1所示,由于每张图像会带有病人名字、检查日期等与病灶无关的信息,因此先使用MATLAB截取病灶区域。截取完的病灶区域一半是灰阶图像,另一半是弹性图像,两者之间一一对应,将图片一分为二后,总共获得807张灰阶图像和807张弹性图像。将所有图像尺寸统一为296×479。按病例数4:1划分为训练集和测试集,其中训练集有648张灰阶图像和648张弹性图像,良恶性乳腺肿块图像数为299:349;测试集有159张灰阶图像和159张弹性图像,良恶性肿块图像数为71:88。训练集和测试集的良恶性肿块图像数量大致为1:1。




图1 图像预处理流程示意图
Figure 1 Schematic diagram of image preprocessing

2 方法

2.1 ResNeXt101 特征提取模块

图2显示了ResNeXt101特征提取模块的结构,该模块去除了最后的平均池化层和全连接层,采用线性整流函数(ReLU)作为激活函数,并使用批量归一化(BN)层。该模块的输入尺寸为 $[3, 224, 224]$,输出尺寸为 $[2048, 7, 7]$ 。ResNeXt^[15]是ResNet^[16]网络和Inception^[17]网络的结合体,不同于Inception网络

的是ResNeXt网络的每一个分支都采用相同的拓扑结构。ResNeXt在不明显增加参数量级的情况下提升模型的准确率,同时由于拓扑结构相同,超参数也减少了,便于模型移植。ResNeXt本质上是分组卷积,通过变量基数(Cardinality)来控制组的数量。本次实验选用的是ResNeXt101_32x8d,32指进入网络的第一个ResNeXt基本结构的分组数量为32,8d表示每一个分组的通道数为8。




图2 ResNeXt101特征提取模块

Figure 2 ResNeXt101 feature extraction blocks

2.2 注意力机制模块(CBAM)

深度神经网络中的注意力机制是对人类视觉注意力机制的模仿。人眼通过扫描全局图像,获取需要重点关注的目标区域,而后对这一区域投入更多的注意力资源,获取更多与目标有关的细节信息,并忽视其他无关信息,利用有限的注意力资源从大量信息中快速筛选出高价值的信息^[18]。深度神经网络中的注意力机制是通过特征图和特征图内的值进行激活值加权,权值越大,该特征对当前识别的贡献就越大,从而提升输出特征图中重要特征与一般特征的区分程度,提高网络对目标物的定位识别能力。

图3显示了卷积模块的CBAM^[19],结合了通道注意力模块和空间注意力模块。对于通道注意力模块,输入特征图 X 分别经过最大池化和平均池化,形成两个 $[C, 1, 1]$ 的权重向量。两个权重向量分别经过同一个多层感知机网络,映射成每个通道的权重^[20]。将映射后的权重相加,并在后面接上Sigmoid输出,然后将得到的通道权重与输入特征图 X 按通道进行相乘。通道注意力模块作用在输入特征图 X 上的公式为:

$$X^c = X \otimes \text{Sigmoid}(\text{FC}(\text{Max_pool}(X)) + \text{FC}(\text{Avg_pool}(X))) \quad (1)$$

式中, X^c 为输入特征图 X 经过通道注意力模块后的输出特征图。对于空间注意力模块,特征图 X^c 按通道进行最大池化和平均池化,形成两个 $[1, H, W]$ 的权重向量。特征图维度从 $[C, H, W]$ 变为 $[1, H, W]$,即对同一特征点的所有通道进行池化操作。将得到的两张特征图进行堆叠,形成 $[2, H, W]$ 的特征图空间权重,再经过一层卷积层,将特征图维度从 $[2, H, W]$ 变为 $[1, H, W]$ 。 $[1, H, W]$ 的特征图表征了特征图上的每个点的重要程度,数值越大越重要。之后将得到的空间权重 $[1, H, W]$ 与特征图 X^c 进行相乘。空间注意力模块作用在特征图 X^c 上的公式为:

$$Y = X^c \otimes \text{Sigmoid}(F^{3 \times 3}([\text{Max_pool}(X^c); \text{Avg_pool}(X^c)])) \quad (2)$$

其中, $F^{3 \times 3}$ 卷积核尺寸为 3×3 的二维卷积, Y 为最终的输出特征图。

2.3 模型搭建

图4显示了基于双路神经网络的多模态乳腺癌肿

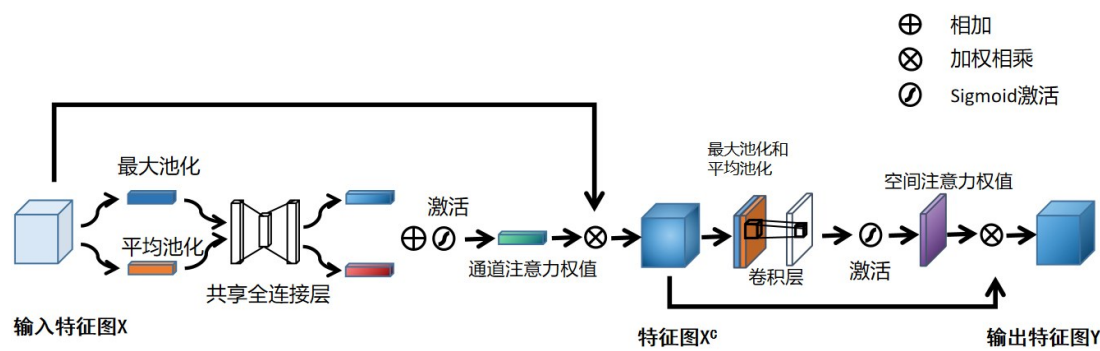


Figure 3 Convolutional block attention module

块分类模型结构,该模型的输入是同一病灶的两种模态的超声图像,分别是灰阶图像和弹性图像。将两种模态的超声图像调整为224×224大小输入网络后,分别经过ResNeXt101特征提取模块和CBAM提取图像特征,获得的特征图尺寸为[2 048, 7, 7],然后再对输出的特征层进行平均池化,获得的特征图尺寸为[2 048, 1, 1],最后将两路网络提取的特征进行拼接,获得尺寸为[4 096, 1, 1]的特征图并进行展平操作,再构建全连接分类层进行良恶性鉴别。损失函数选择二分类交叉熵损失函数,其公式为:

$$L = -[y \cdot \log y' + (1 - y) \cdot \log (1 - y')] \tag{3}$$

其中, y 为真实值, y' 为预测值。CBAM的加入有利于模型更加关注病灶区域的信息,提高模型预测的准确率。同时输入两种模态的超声图像可以为模型提供更丰富的乳腺肿块图像特征,有助于提高模型预测的准确率。

3 实验与结果

3.1 实验环境与训练参数设定

实验选择的操作系统是 Windows11,显卡为 RTX-3070,显卡内存为 8 GB,使用 Pytorch 作为深度学习框架和 Python3.9 作为开发语言。在双路神经网络

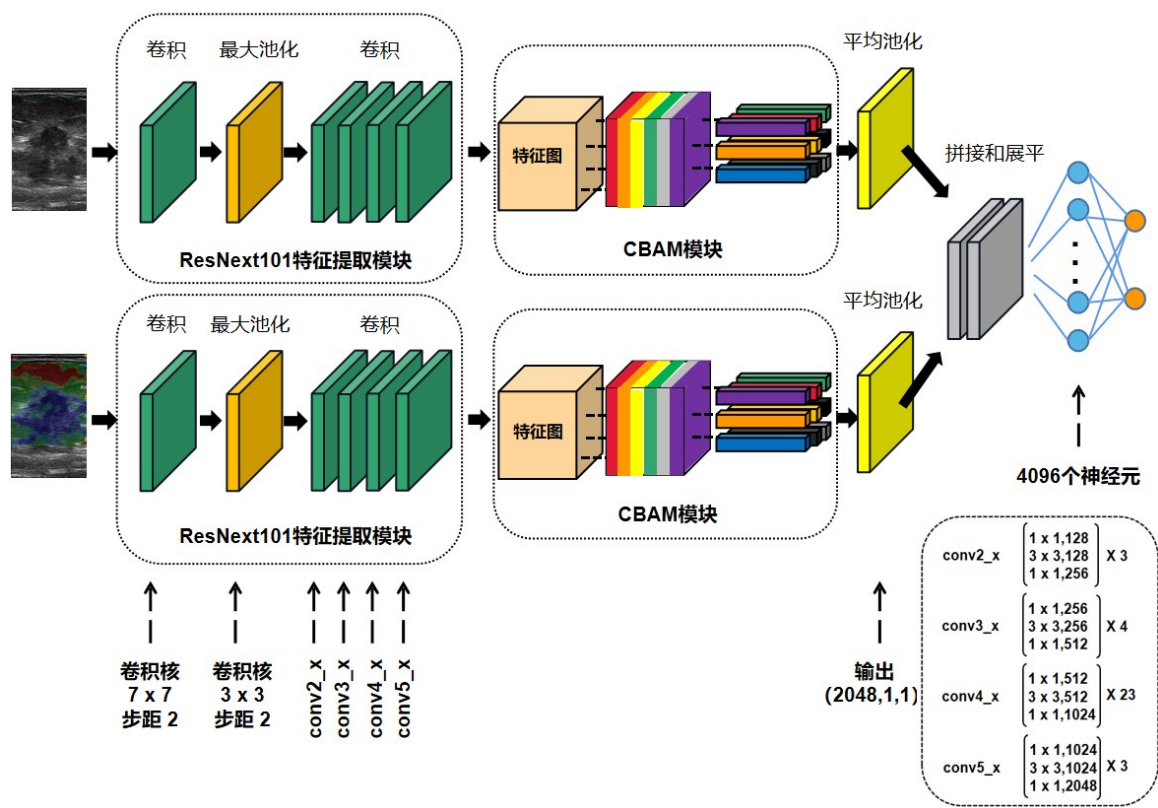


Figure 4 Breast mass classification model based on dual neural network and multimodal ultrasound images

络模型的训练过程中,对训练参数进行相应的配置:初始学习率设置为0.001,每10个epoch下降为原来的0.7倍,batch的大小设置为8,动量设置为0.9,权值衰退设置为0.0005,参数优化器选用随机梯度下降法,两路神经网络都加载ResNeXt101_32x8在ImageNet的预训练权重。

3.2 评价指标

使用准确率(Accuracy)、灵敏度(Sensitivity)、特异性(Specificity)、阳性预测值(PPV)、阴性预测值(NPV)和接受者操作特性(ROC)^[21]的AUC来评估模型的性能,如式(4)~式(8)所示:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (4)$$

$$\text{Sensitivity} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (5)$$

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (6)$$

$$\text{PPV} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (7)$$

$$\text{NPV} = \frac{\text{TN}}{\text{TN} + \text{FN}} \quad (8)$$

其中,真阳性(TP)表示正样本被正确分类的个数,真阴性(TN)表示负样本被正确分类的个数,假阳性(FP)表示负样本被错误分类为正样本的个数,假阴性(FN)表示正样本被错误分类为负样本的个数。以上指标中,准确率表示正确预测的样本数占总预测样本数的比值;灵敏度表示所有正例样本中被正确预测的概率;特异性表示所有负例样本中被正确预测的概率;PPV表示所有被预测为正类的样本中,真正是正类的样本比例;NPV表示所有被预测为负类的样本中,真正是负类的样本比例;ROC曲线是反映灵敏度和特异性连续变量的综合指标,AUC用来评估该二元分类器的可信度,其值为0~1,AUC值越大说明其可信度越高。

3.3 单路网络实验对比

表1列举了11个在医学图像分类中常用的CNN模型,为了提高模型准确率,表中列举的模型都会添加CBAM。在对807张超声灰阶图像和807张超声弹性图像的单路神经网络对比实验结果中发现,ResNeXt101模型相比于其它模型,对超声灰阶图像和超声弹性图像的分类性能更好。虽然在弹性图像的分类实验中,ResNeXt101相比DenseNet169准确率稍低,但是在对灰阶图像的分类实验中,ResNeXt101的准确率明显高于DenseNet169。

3.4 双路网络实验对比

本文使用了在表1中对灰阶图像和弹性图像具有较高准确率的网络构建双路神经网络模型,每个模型都添加了CBAM,表2列举了实验结果,图5a显

示了各模型的ROC曲线对比结果。从表2和图5a中可以看出用ResNeXt101搭建的双路神经网络模型的性能明显优于其它模型的性能。并且对比用ResNeXt101搭建的单路和双路网络实验中发现,用ResNeXt101搭建的双路网络具有更高的准确率和更大的AUC值。因此,实验结果表明用ResNeXt101搭建的双路神经网络,能提取到更多的乳腺肿块图像特征,两种模态图像进行了信息互补,这是单路网络和单模态图像所不具备的优势。

3.5 数据扩增和注意力机制

表3列举了可提高ResNeXt101搭建的双路神经网络模型性能的策略,其中的原始策略未添加任何注意力机制,采用的数据扩增方法是图片以0.5的概率进行水平和垂直翻转。实验结果表明,数据扩增能提高模型预测的准确率以及添加CBAM的有效性。双路神经网络中添加CBAM后,模型的各项性能指标都有了明显提升。但是当把CBAM替换成SE(Squeeze-and-Excitation)^[22]或ECA(Efficient Channel Attention)^[23]模块或仅使用空间注意力机制时,会降低对双路神经网络模型性能的提升效果,这是因为CBAM同时具有通道注意力机制和空间注意力机制,从而使得模型能够同时在通道维度和空间维度上关注重要信息。图5b显示了用ResNeXt101搭建的双路神经网络模型添加不同注意力机制的ROC曲线对比结果,从图中的ROC曲线对比也可以证明添加CBAM比添加其他注意力机制模块,对网络性能的提升更大。

3.6 与公开文献的对比

表4列举了本文方法与公开文献中方法的对比结果,文献[2]是用ResNet18搭建三路神经网络模型并在每一路神经网络中添加SE注意力机制模块,融合方式为中间融合。由于文献[2]中的输入是3种模态的超声图像,分别是超声灰阶图像、超声血流图像和超声弹性图像,为满足实验可比性,对文献[2]中的模型进行修改,将输入改为两种模态的超声图像,只输入超声灰阶图像和超声弹性图像。文献[24]是使用ResNet50搭建三路神经网络模型,融合方式为决策级融合,为满足实验可比性,将文献[24]中的模型的通道数改为2。文献[25]是用ResNet152和VGG19搭建双路神经网络模型,融合方式为决策级融合。通过实验对比发现本文提出的模型在性能上优于文献[2, 24-25]提出的模型。本文提出的模型具有更高的预测准确率和更大的AUC值。相比文献[2]的方法,因本文使用的ResNeXt101比ResNet18层数更深,因此可以更好地提取特征,并且本文使用的CBAM同时具有通道注意力机制和空间注意力机制,

表 1 单路神经网络模型性能对比

Table 1 Performance comparison among single neural network models

模型	数据	准确率	灵敏度	特异性	PPV	NPV	AUC
ResNeXt101	灰阶	78.61	0.761	0.807	0.761	0.807	0.861
	弹性	81.76	0.803	0.830	0.792	0.839	0.872
InceptionV4	灰阶	71.06	0.746	0.682	0.654	0.769	0.719
	弹性	72.95	0.634	0.773	0.692	0.723	0.789
InceptionResNetV2	灰阶	73.58	0.789	0.693	0.675	0.803	0.793
	弹性	77.98	0.662	0.875	0.810	0.762	0.845
VGG19	灰阶	72.95	0.704	0.750	0.694	0.759	0.801
	弹性	78.61	0.732	0.830	0.776	0.793	0.815
VGG16	灰阶	72.32	0.549	0.864	0.765	0.704	0.821
	弹性	77.35	0.690	0.841	0.778	0.771	0.845
DenseNet161	灰阶	74.84	0.606	0.864	0.782	0.731	0.848
	弹性	81.13	0.634	0.955	0.918	0.764	0.842
DenseNet169	灰阶	72.95	0.535	0.886	0.792	0.703	0.832
	弹性	83.01	0.775	0.875	0.833	0.828	0.847
DenseNet201	灰阶	75.47	0.634	0.852	0.776	0.743	0.833
	弹性	81.13	0.831	0.795	0.766	0.854	0.834
ResNet18	灰阶	78.61	0.592	0.943	0.894	0.741	0.809
	弹性	76.10	0.662	0.841	0.770	0.755	0.833
ResNet50	灰阶	72.32	0.592	0.830	0.737	0.716	0.839
	弹性	76.72	0.817	0.727	0.707	0.831	0.844
ResNet101	灰阶	77.35	0.620	0.898	0.830	0.745	0.809
	弹性	79.24	0.789	0.795	0.757	0.824	0.832

表 2 双路神经网络模型性能对比

Table 2 Performance comparison among dual neural network models

模型	数据	准确率	灵敏度	特异性	PPV	NPV	AUC
DenseNet161	灰阶+弹性	78.61	0.662	0.886	0.825	0.765	0.878
DenseNet169	灰阶+弹性	78.61	0.662	0.886	0.825	0.765	0.859
DenseNet201	灰阶+弹性	81.76	0.648	0.955	0.920	0.771	0.911
VGG19	灰阶+弹性	79.24	0.746	0.830	0.779	0.802	0.839
ResNet18	灰阶+弹性	78.61	0.746	0.818	0.768	0.800	0.823
ResNet50	灰阶+弹性	78.61	0.704	0.852	0.794	0.781	0.849
ResNet101	灰阶+弹性	77.98	0.732	0.818	0.765	0.791	0.843
ResNeXt101	灰阶+弹性	84.27	0.789	0.886	0.848	0.839	0.932

优于仅含有通道注意力机制的SE模块和ECA模块。相比文献[24-25]的方法,本文提出的模型添加了CBAM,使得模型更专注于学习病灶区域的特征,因此获得了更高的准确率。图 5c 显示了本文模型和公开文献中的模型的 ROC 曲线对比结果,从图中也可以证明本文模型的性能优于公开文献中模型的性能。

4 结 语

针对单一模态的超声图像所能提供的乳腺肿块信息少的问题,提出基于双路神经网络的多模态乳腺肿块良恶性分类模型,将超声灰阶图像和超声弹性图像作为模型输入,使用 ResNeXt101 搭建双路神

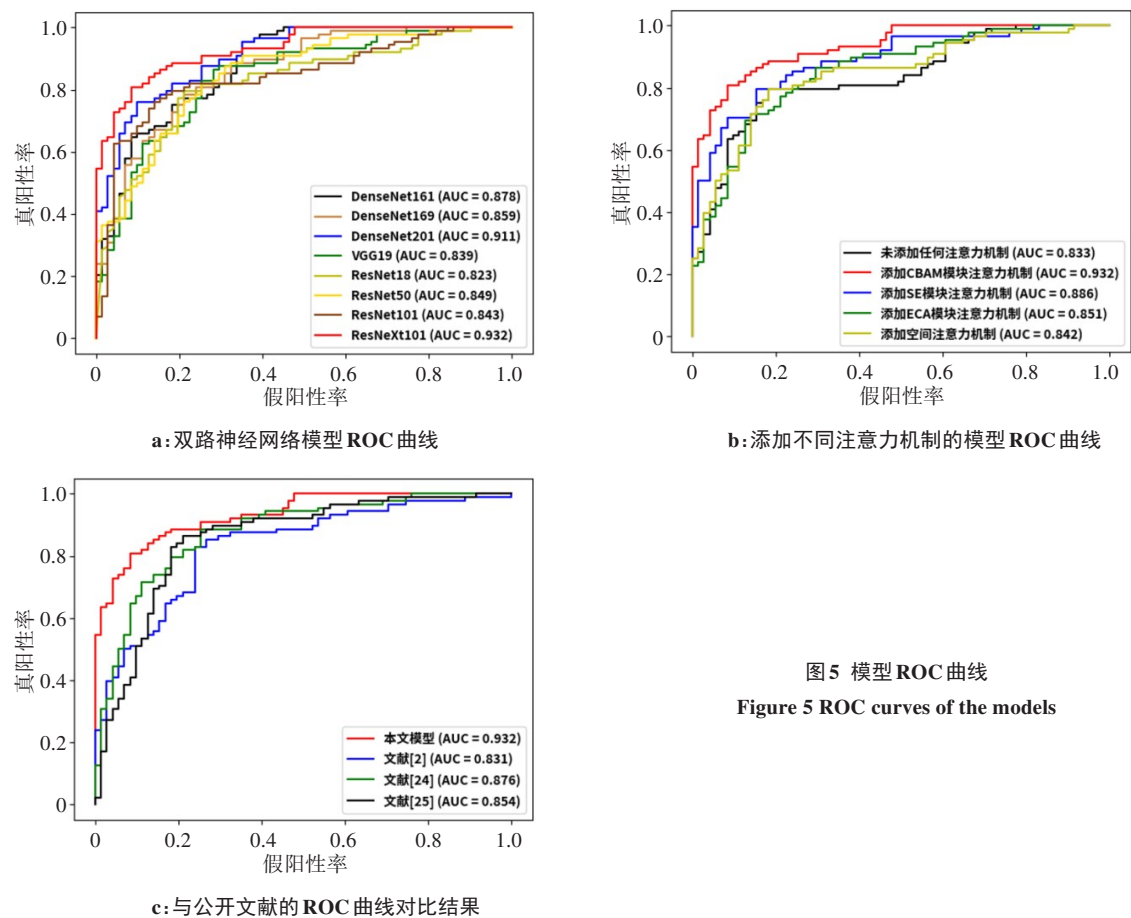


图5 模型 ROC 曲线
Figure 5 ROC curves of the models

表3 双路网络性能提升策略						
Table 3 Performance improvement strategies for dual neural network						
策略	准确率	灵敏度	特异性	PPV	NPV	AUC
原始数据	79.24	0.817	0.773	0.744	0.840	0.833
数据扩增	83.64	0.817	0.852	0.817	0.852	0.846
添加CBAM模块注意力机制	84.27	0.789	0.886	0.848	0.839	0.932
添加SE模块注意力机制	80.50	0.746	0.852	0.803	0.806	0.886
添加ECA模块注意力机制	79.24	0.704	0.864	0.806	0.784	0.851
添加空间注意力机制	80.50	0.817	0.795	0.763	0.843	0.842

表4 本文模型与公开文献的对比						
Table 4 Comparison the proposed model with other literatures						
方法	准确率	灵敏度	特异性	PPV	NPV	AUC
本文模型	84.27	0.789	0.886	0.848	0.839	0.932
文献[2]	79.87	0.732	0.852	0.800	0.798	0.831
文献[24]	78.61	0.662	0.886	0.825	0.765	0.876
文献[25]	81.76	0.732	0.886	0.839	0.804	0.854

神经网络,并添加CBAM注意力机制模块。通过对96例病人,共807张超声灰阶图像和807张超声弹性图像进行实验,发现该双路神经网络模型对乳腺肿块预测的准确率为84.27%,AUC值为0.932。本文方法和文献[2, 24-25]中提到的模型进行对比,发现本文方法优于上述文献的方法。但本文方法也存在一些

不足之处,由于图片数量较少,且每个病人的图片张数不一致,导致数据集的划分对实验结果影响较大。在未来的研究中,应收集更多病人的超声乳腺肿块图像,构建一个鲁棒性和泛化性更强的超声乳腺肿块良恶性分类模型。

【参考文献】

- [1] Bray F, Ferlay J, Soerjomataram I, et al. Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA-Cancer J Clin, 2018, 68(6): 394-424.
- [2] Qian X, Pei J, Zheng H, et al. Prospective assessment of breast cancer risk from multimodal multiview ultrasound images via clinically applicable deep learning[J]. Nat Biomed Eng, 2021, 5(6): 522-532.
- [3] Vaughan CL. Novel imaging approaches to screen for breast cancer: recent advances and future prospects[J]. Med Eng Phys, 2019, 72: 27-37.
- [4] Kornecki A. Current status of breast ultrasound[J]. Can Assoc Radiol J, 2011, 62(1): 31-40.
- [5] Ohuchi N, Suzuki A, Sobue T, et al. Sensitivity and specificity of mammography and adjunctive ultrasonography to screen for breast cancer in the Japan Strategic Anti-cancer Randomized Trial (J-START): a randomised controlled trial[J]. Lancet, 2016, 387(10016): 341-348.
- [6] Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [7] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks[J]. Commun ACM (USA), 2017, 60(6): 84-90.
- [8] Zaremba W, Sutskever I, Vinyals O. Recurrent neural network regularization[J]. arXiv preprint, 2014, arXiv: 1409.2329.
- [9] 朱冬亮, 文奕, 陶欣. 深度学习在生物医学领域的应用进展述评[J]. 世界科技研究与发展, 2020, 42(5): 510-519.
Zhu DL, Wen Y, Tao X. Review of application progress of deep learning in biomedicine[J]. World Science and Technology Research and Development, 2020, 42(5): 510-519.
- [10] Fujioka T, Mori M, Kubota K, et al. The utility of deep learning in breast ultrasonic imaging: a review[J]. Diagnostics (Basel), 2020, 10(12): 1055-1067.
- [11] Han S, Kang HK, Jeong JY, et al. A deep learning framework for supporting the classification of breast lesions in ultrasound images[J]. Phys Med Biol, 2017, 62(19): 7714-7728.
- [12] Fujioka T, Kubota K, Mori M, et al. Distinction between benign and malignant breast masses at breast ultrasound using deep learning method with convolutional neural network[J]. Jpn J Radiol, 2019, 37(6): 466-472.
- [13] Fujioka T, Katsuta L, Kubota K, et al. Classification of breast masses on ultrasound shear wave elastography using convolutional neural networks[J]. Ultrason Imaging, 2020, 42(4-5): 213-220.
- [14] Zhang Q, Xiao Y, Dai W, et al. Deep learning based classification of breast tumors with shear-wave elastography[J]. Ultrasonics, 2016, 72: 150-157.
- [15] Xie S, Girshick R, Dollar P, et al. Aggregated residual transformations for deep neural networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 1492-1500.
- [16] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 770-778.
- [17] Szegedy C, Liu W, Jia YQ, et al. Going deeper with convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston: IEEE, 2015: 1-9.
- [18] 赵宇督, 彭振伟, 马骏, 等. 基于多尺度注意力机制的三维卷积神经网络肺结节检测算法[J]. 生物医学工程学杂志, 2022, 39(2): 320-328.
Zhao YD, Peng ZW, Ma J, et al. 3D convolutional neural network lung nodule detection algorithm based on multi-scale attention mechanism[J]. Journal of Biomedical Engineering, 2022, 39(2): 320-328.
- [19] Woo S, Park J, Lee J, et al. CBAM: convolutional block attention module[C]//Proceedings of the European conference on computer vision (ECCV). Munich: Springer, 2018: 3-19.
- [20] Yan HM, Jiang YT, Zheng J, et al. A multilayer perceptron-based medical decision support system for heart disease diagnosis[J]. Expert Syst Appl, 2006, 30(2): 272-281.
- [21] Kamarudin AN, Cox T, Kolumunnage-dona R. Time-dependent ROC curve analysis in medical research: current methods and applications[J]. BMC Med Res Methodol, 2017, 17(1): 1-19.
- [22] Hu J, Shen L, Sun G, et al. Squeeze-and-excitation networks[C]//Proceedings of the 31st IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake: IEEE, 2018: 7132-7141.
- [23] Wang Q, Wu B, Zhu P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 11531-11539.
- [24] Chen H, Yang BW, Qian L, et al. Deep learning prediction of ovarian malignancy at US compared with O-RADS and expert assessment[J]. Radiology, 2022, 304(1): 106-113.
- [25] Tanaka H, Chiu SW, Watanabe T, et al. Computer-aided diagnosis system for breast ultrasound images using deep learning[J]. Phys Med Biol, 2019, 64(23): 235013.

(编辑:陈丽霞)