

改进 Xception 模型的乳腺钼靶图像识别研究

李锦通, 安建成, 王悦, 曹锐

(太原理工大学 软件学院, 太原 030600)

摘要: 乳腺 X 线摄影技术是早期发现乳腺癌的主要方法, 但其结果很大程度上受放射科医师临床诊断经验的限制; 基于卷积神经网络对乳腺钼靶图像自动分类的研究可以为放射科医师临床诊断提供意见, 然而乳腺肿块边缘模糊且良恶性肿瘤特征差异较小, 分类任务面临重重挑战; 为了提高乳腺钼靶图像分类的准确率, 提出一种基于 Xception 模型的改进优化算法, 改进模型中的残差连接模块, 并嵌入 Squeeze-and-excitation (SE) 注意力机制对模型进行优化; 采用优化后的 Xception 模型并结合迁移学习算法进行乳腺钼靶图像特征提取, 并优化全连接层网络进行图像分类, 使用公开的乳腺癌图像数据库 CBIS-DDSM 进行实验, 将乳腺钼靶图像自动分为良性和恶性; 实验结果表明该方法可以有效提高模型的分类效果, 准确率和 AUC 分别达到了 97.46% 和 99.12%。

关键词: 深度学习; 乳腺 X 线图像; 图像分类; 卷积神经网络; Xception

Research on Mammograms Recognition with Improved Xception Model

LI Jintong, AN Jiancheng, WANG Yue, CAO Rui

(College of software, Taiyuan University of Technology, Taiyuan 030600, China)

Abstract: Mammography is the primary method for the early detection of breast cancer, but the results is largely limited by the radiologist's experience in clinical diagnosis. Based on convolutional neural network, the study on automatic classification of mammography images can provide advice for radiologists in clinical diagnosis, however the classification task of mammography images face with many challenges due to the fuzzy edge and small difference between benign and malignant tumors. In order to improve the accuracy of mammography classification, an improved optimization algorithm based on the Xception model is proposed, the residual connection modules in the model are improved, and the Squeeze and excitation (SE) attention mechanism is embedded to optimize the model. The optimized Xception model combined with transfer learning algorithm is used to extract the features of mammography images, and the full-connection layer network is optimized for image classification. Experiments are conducted on the open data set CBIS-DDSM, and the mammography images are automatically divided into benign and malignant. The experimental results show that this method can effectively improve the classification effect of the model, and the accuracy and AUC reached 97.46% and 99.12% respectively.

Keywords: deep learning; mammography; image classification; convolutional neural network; xception

0 引言

世界卫生组织国际癌症研究机构发布了 2020 年全球最新癌症数据^[1], 数据显示乳腺癌成为全球发病率最高的癌症。2022 年 1 月 12 日, 美国癌症协会公布了最新一期的《2022 年度癌症统计报告》预测 2022 年女性癌症发病率中乳腺癌发病率为 31%, 在女性所有癌症中占比最高, 预测病死率中乳腺癌占比 15%, 占比第二位, 仅次于肺癌^[2]。而且, 在我国乳腺癌的发病率位居女性癌症发病率第 1 位, 病死率位居第 2 位^[3]。

乳腺 X 线摄影 (乳腺钼靶成像) 技术作为一种无创、微辐射的检查手段^[4], 是所有乳腺检查影像技术中最有效、最被广泛接受的方法, 也是世界公认的乳腺癌检测标准工

具之一。特别是随着乳腺 X 线摄影技术的广泛应用, 可以早期发现无症状隐匿的乳腺癌, 大大降低了乳腺癌死亡率^[5]。一般情况下, 放射科医师需要结合乳腺钼靶图像的各种特点和丰富的临床经验进行诊断。然而, 基于人工筛查诊断的方法极其依赖放射科医师的临床经验, 而且受到长时间工作产生视觉疲劳、专注度下降及图像清晰度差等因素影响, 可能会发生误诊、漏诊等情况。

在过去的几十年里, 计算机辅助诊断 (CAD, computer aided diagnosis) 技术一直是研究的一个主要领域。CAD 使用机器学习方法分析成像或非成像患者数据, 并对患者的病情进行评估, 这些评估可用于协助临床医生进行诊断决策^[6]。相关研究表明, 计算机辅助诊断技术可以有效提高临床诊断效率, 降低误诊率, 减轻患者的负担^[7]。目前,

收稿日期: 2022-03-08; 修回日期: 2022-04-06。

基金项目: 山西省自然科学基金 (201901D111093); 山西省重点研发项目 (201803D421047)。

作者简介: 李锦通 (1996-), 男, 山西洪洞人, 硕士研究生, 主要从事深度学习、图像处理方向的研究。

曹锐 (1982-), 男, 山西吕梁人, 博士, 副教授, 主要从事人工智能、智能信息处理方向的研究。

通讯作者: 安建成 (1963-), 男, 山西临汾人, 硕士, 副教授, 主要从事深度学习、图像处理方向的研究。

引用格式: 李锦通, 安建成, 王悦, 等. 改进 Xception 模型的乳腺钼靶图像识别研究[J]. 计算机测量与控制, 2022, 30(8): 189-196.

在许多医疗机构中, 计算机辅助诊断系统已经作为医生的参考, 应用于临床诊断^[8]。

传统的计算机辅助诊断基本是半自动的, 首先由人工提取图像中的可疑区域, 然后利用机器学习的方法提取特征, 最后送入到例如 K 近邻算法^[9]、支持向量机^[10]、多层感知机^[11]等算法中进行分类。然而传统的机器学习方法不仅耗时费力, 而且不易提取高质量的特征图像, 很大影响它在实际工程中的应用。近年来, 随着卷积神经网络的发展, 深度学习技术成功推动了新的研究和方向, 提高了计算机辅助诊断系统的性能, 并开发 CAD 用于许多其他复杂的临床任务^[12]。

目前, 越来越多的学者使用卷积神经网络对乳腺癌图像自动分类的任务展开了广泛的研究。Sahine 等^[13]设计了一个三层的卷积神经网络实现对乳腺钼靶图像的肿块和正常组织的分类, 对 168 张肿块图像和 504 张正常图像分类时 ROC 曲线下的面积 (AUC, area under ROC curve) 达到 0.87, 表明将卷积神经网络运用到乳腺钼靶图像分类的有效性。Kooi 等^[14]提出了一个类似于 VGG 模型结构的卷积神经网络作为特征提取器, 对乳腺肿块良恶性二分类, AUC 达到 0.8, 表明卷积神经网络在乳腺肿块良恶性分类任务上具有很大潜力。许文慧等^[15]提出了一种将注意力机制与残差网络 ResNet50 模型相结合的方法, 在局部乳腺肿块切片数据集和全局乳腺钼靶数据集上的 AUC 分别达到 0.860 7 和 0.808 1。Chougrad 等^[16]迁移学习 VGG-16、ResNet50 和 InceptionV3 模型利用不同微调策略, 通过大量实验在 DDSM 数据集上获得了 97.35% 的准确率和 0.98 的 AUC, 表明利用迁移学习可以有效提高乳腺癌图像分类的准确率。Zhang 等^[17]从两个视图提取乳腺 X 线图像特征, 并在 DenseNet 模型上添加基于通道和空间的注意力机制, 在 DDSM 数据库上获得正常图像和异常肿块图像分类的准确率、敏感性和 AUC 值分别为 94.92%、96.52%、94.72%; 良恶性分类的准确率、敏感性和 AUC 值分别为 95.24%、96.11% 和 95.03%。

目前, 基于卷积神经网络的乳腺癌图像识别方法研究中, 大多数方法通过空间相关性和通道相关性的联合映射, 主要依靠改进网络的深度或利用多尺度卷积来提高网络的分类性能, 忽略了特征通道的重要性。本研究通过空间相关性和通道相关性分开映射, 改进 Xception 模型中的残差连接模块来防止模型丢失一些重要的特征信息, 并添加 SE 注意力机制使网络可以自注意每个特征通道的信息, 来达到更好的分类效果。

乳腺钼靶图像识别的难点在于乳腺肿块的轮廓、形状和纹理细节都比较单一, 且肿块边缘模糊, 良性肿块与恶性肿块的特征差异较小。为了提高分类精度, 有必要强调图像的更多细节和更多的局部信息, 首先改进了 Xception 模型的残差连接模块, 使网络在特征提取阶段可以保存更多的有用信息; 然后在深度可分离卷积层后嵌入 SE 注意力机制

模块提出最终的 Xception-C 模型来解决这个问题。Xception-C 模型不仅可以提取更多的乳腺钼靶图像深层和细节特征信息, 而且能实现卷积操作提取特征过程中的特征重标定。此外, 为了避免因乳腺癌图像难以收集导致实验数据集较少, 训练过程中易出现过拟合的问题, 提出了优化全连接层分类器的方法。

1 相关工作

1.1 Xception 模型

Xception^[18]是谷歌公司提出的对 Inception-V3 模型的改进版本。该模型主要由深度可分离卷积和残差连接网络结构组成, 深度可分离卷积可独立查看跨通道相关性和空间相关性, 使卷积过程更轻松、更高效, 与标准的卷积操作相比, 减少了参数数量和运算成本; 残差连接网络通过直接将输入信息绕道传到输出, 保护信息的完整性, 减少卷积操作在信息传递时信息丢失、损耗的问题, 同时有效避免了梯度消失或梯度爆炸的问题, 可以训练很深的卷积神经网络。

通常的卷积操作将特征图的通道相关性与空间相关性一起处理, 而 Xception 模型的作者考虑解耦通道相关性与空间相关性, 通过不断简化 Inception-V3 模块, 最终推导出深度可分离卷积。深度可分离卷积的步骤可分为两步实现: 1) Depthwise Convolution, 即逐通道卷积, 对输入特征图的每个通道分别进行 3×3 卷积操作, 并通过 concat 操作将结果合并; 2) Pointwise Convolution, 即逐点卷积, 将逐通道卷积后的结果进行 1×1 卷积操作。深度可分离卷积不仅处理空间维度, 还处理深度维度的数量, 它可以在不降低准确率的前提下大大减少了模型的复杂度和计算量。

图 1 为 Xception 模型的网络结构图, 被分为输入层、中间层和输出层三部分, 它一共包含 36 个卷积层, 被构造为 14 个模块, 除了第一个和最后一个模块外, 所有这些模块周围都具有线性残差连接^[19]。采用深度可分离卷积不仅可以加快模型的训练速度, 还可以减少卷积神经网络的参数量。但是由于 Xception 模型增加了网络的宽度, 使得其参数量与 Inception-V3 模型差不多。但与 Inception-V3 模型相比, 在 ImageNet 数据集上的实验结果, Xception 模型的准确率更高, 且收敛速度更快。

1.2 SE-Net 模型

SE-Net (squeeze-and-excitation networks) 模型是由 Momenta 研发工程师 Hu 等^[20]提出, 它由一系列 SE 模块组成, 每个模块由 5 个连续操作的组合函数组成, 分别为一个全局池化层, 一个全连接层, 一个 ReLU 函数, 一个全连接层, 一个 Sigmoid 函数。图 2 为 SE 模块的结构图, 主要包含压缩 (Squeeze)、激励 (Excitation) 和重标定 (Reweight) 3 个步骤。

Squeeze: 顺着空间维度进行特征压缩, 将 k 个二维的特征图变成一个实数, 得到包含 k 个实数的一维特征向量,

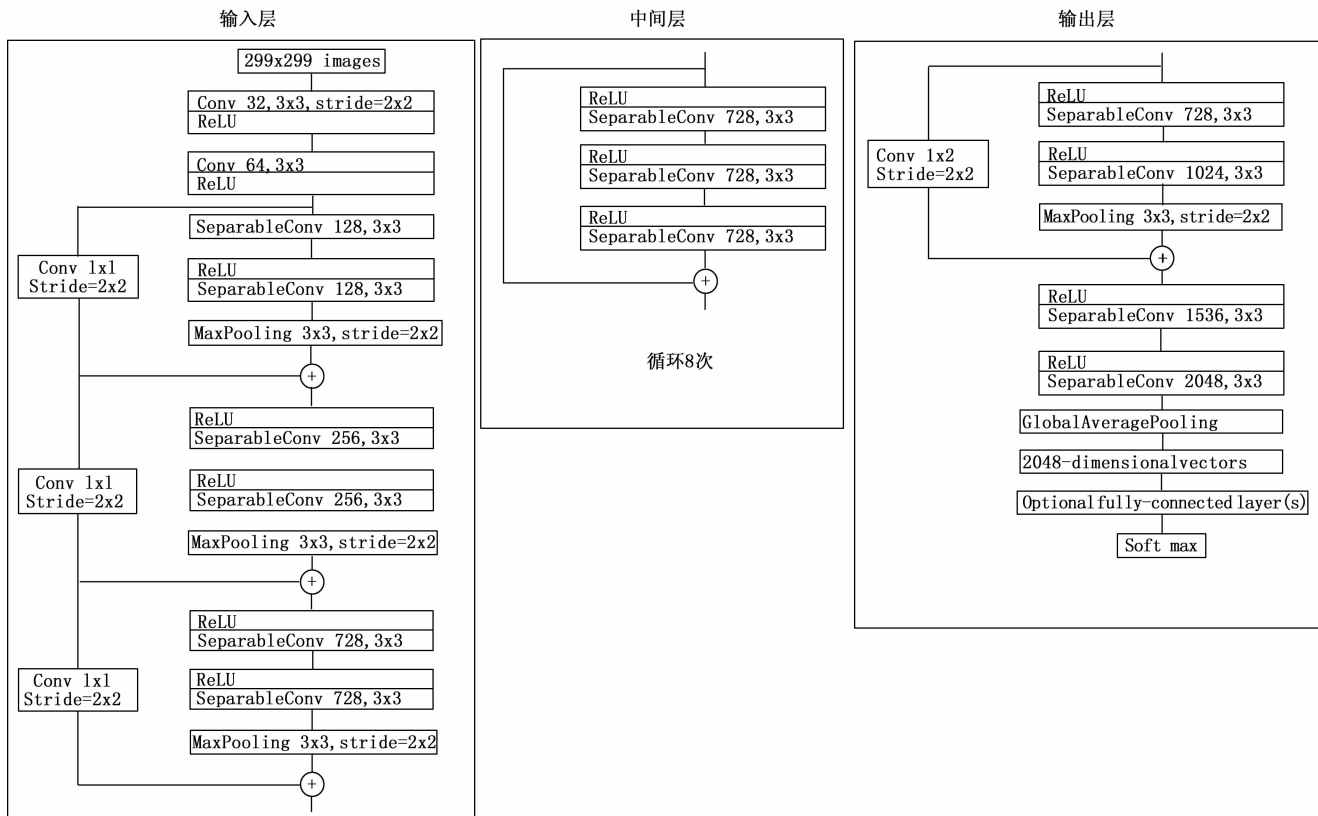


图 1 Xception 模型的网络结构图




图 2 SE 模块结构图

其计算公式如下:

$$F_{sq}u_k = \frac{1}{(H \times W)} \sum_{i=1}^H \sum_{j=1}^W u_k(i, j) \quad (1)$$

其中: $F_{sq}(\ast)$ 为 Squeeze 函数, H 与 W 分别为特征图的宽和高, $u_k(i, j)$ 为特征图在坐标位置 (i, j) 处的取值。

$$F_{ex}(z, W) = \sigma(W_2 \delta(W_1 z)) \quad (2)$$

其中: $F_{ex}(\ast)$ 为 Excitation 函数, z 为经过 Squeeze 后的特征向量, $\sigma(\ast)$ 为 Sigmoid 函数, $\delta(\ast)$ 为 ReLU 函数, W_1 、 W_2 为两个全连接层权重, 其中 $W_1 \in R^{c \times c}$ 、 $W_2 \in R^{c \times c}$ 。

Reweight: 将激励步骤输出的权重通过乘法加权到每个特征通道上, 实现在通道维度上的对原始特征进行重标定, 公式如下:

$$F_{scale}(u_k, s_k) = u_k \times s_k \quad (3)$$

其中: $F_{scale}(\ast)$ 为 Reweight 函数, s_k 为第 k 个特征

图的权重值。

由上述描述可以得知 SE 模块构造非常简单, 几乎可以嵌入到所有的网络结构中, 不需要引入新的函数或者层。在卷积层后嵌入 SE 模块, 经过压缩、激励和重标定一系列操作后会输出每个通道的权重值, 将该权重值与每个通道卷积后的特征相乘, 从而达到特征重标定的目的, 通过计算每个通道特征图像的权重, 抑制不重要的特征图像, 强调重要的特征图像。

1.3 迁移学习

迁移学习^[21]是将预训练好的模型参数应用到目标领域的模型训练过程中。众所周知, 训练一个卷积神经网络需要大量的带注释的数据集, 这在医学领域是很缺乏的。并且从头训练一个卷积神经网络需要很高的计算能力、很大的数据集资源以及很多时间, 如果提供的数据很少的话, 很容易出现过拟合等问题。克服这个问题的一个办法是从自然图像 (例如: ImageNet) 迁移学习, 但是由于医学图像与自然图像差别较大, 直接使用在 ImageNet 数据集上的预训练权重效果可能不是很好, 需要利用不同的微调策略, 即微调网络最后几层, 效果不好的话可以从网络中间层开始微调, 如果效果还不够好, 可以尝试微调网络所有层。

2 本文方法

2.1 改进 Xception 模型

Xception 模型在 Inception-V3 模型的基础上将深度可分

离卷积替换掉 Inception 模块，并添加了残差连接模块，在基本不增加网络复杂度的情况下提高了模型的分类精度及减少了模型训练的时间。为了进一步提升 Xception 模型对乳腺钼靶图像的分类效果，对该模型的残差连接模块进行了改进，并通过在深度可分离卷积后嵌入 SE 模块的自注意力机制来优化模型。

Xception 模型的输入层后 3 个模块和输出层的第一个模块都采用了支路为一个步长为 2 的 1×1 卷积层构成的残差连接结构，本文改进的残差连接模块由支路先连接一个步长为 2、大小为 2×2 的最大池化层，再连接一个步长为 1、卷积核大小为 1×1 的卷积层组成，称为 Xception-A 模型。图 3 展示具体改进结构图，采用 Xception 模型输出层的第一个模块的改进示例展示，该模型输入层的 3 个带残差连接的模块均进行改进。考虑到残差连接的支路使用步长为 2 的 1×1 卷积层，可能会丢失一部分重要信息，然而，先通过一个步长为 2 的最大池化层来保存重要信息，再进行步长为 1 的 1×1 卷积层，这样的改进方法与原方法相比，可以残差连接模块映射输入信息时再进行一次特征选择，防止一些重要的特征信息丢失。

模块的具体流程图，将激励步骤输出的权重通过乘法加权到每个特征通道上，使模型可以自注意各个特征通道的重要程度。

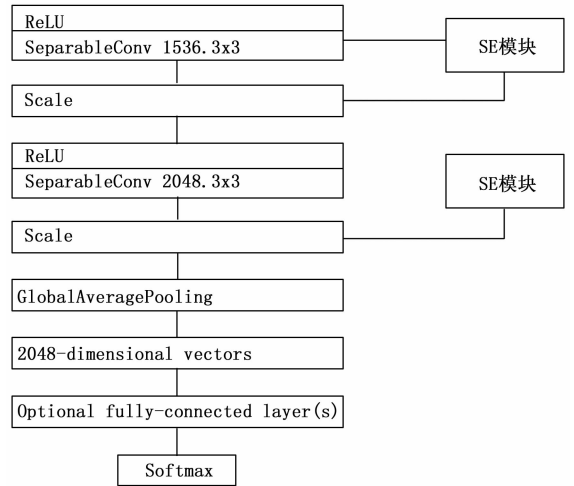


图 4 基于 Xception 嵌入 SE 模块的网络结构图

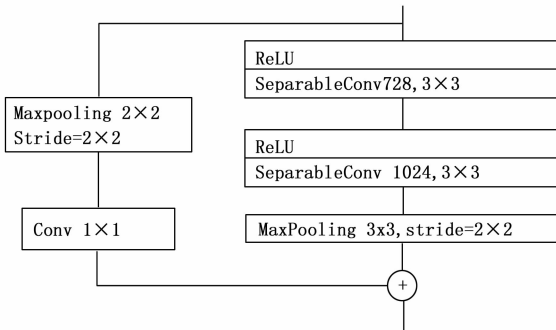


图 3 改进后的残差连接结构图

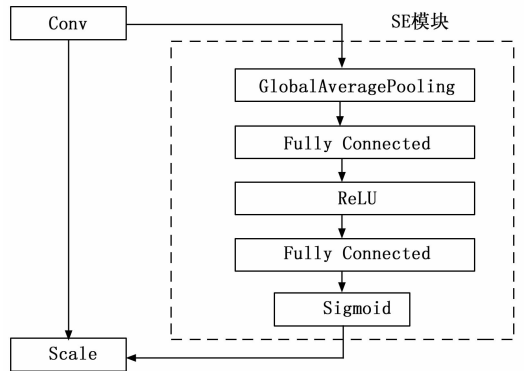


图 5 SE 模块流程图

为了使模型可以自注意通道之间的关系，让模型可以自动学习到不同特征通道的重要程度，在 Xception 模型的基础上嵌入 SE 模块的注意力机制。卷积神经网络对图像进行特征提取的核心是卷积层，卷积操作在局部感受野上将空间信息和特征通道的信息聚合进行特征提取，来获取图像的全局信息。很多研究工作通过增加网络宽度的方法增大感受野，或通过增加网络深度等方式从空间维度层面来提升卷积神经网络的性能。采用在深度可分离卷积层后嵌入 SE 模块的方法，不仅可以解耦通道相关性与空间相关性，还可以从不同特征通道之间的关系入手，通过学习的方式来自动获取每个特征通道的重要程度，从而提高模型的特征提取能力，获得更好的分类效果。

具体改进方法如图 4 所示，首先保留 Xception 模型前 12 个模块不变，即图 1 中原模型输入层与中间层不变，在输出层的最后两个深度可分离卷积层后嵌入 SE 模块，称为 Xception-B 模型。同时使用改进残差连接模块和嵌入 SE 注意力机制方法的模型称为 Xception-C。图 5 展示了嵌入 SE

2.2 优化“分类器”

由于带标注的乳腺钼靶图像数据集难以制作，导致因数据集数量较少在卷积神经网络的训练过程中可能出现过拟合的问题，为了解决这个问题，以及进一步提高模型的性能，对模型最后的全连接层“分类器”进行了优化改进，利用全局平均池化层（global average pooling）代替原来的全连接层，增加密集连接层，同时添加批标准化（BN, batch normalization）、激活函数、Dropout。具体改进步骤如图 6 所示，利用卷积神经网络提取特征图像后，经过一个全局平均池化层，两个全连接层，两个 BN 层，两个 Dropout 层，两个 ReLU 激活函数层，最后利用 Sigmoid 激活函数得到乳腺钼靶图像良恶性二分类的结果。其中全局平均池化层将特征图的所有像素值相加求平均值，用该值表示对应特征图，对空间信息进行了归纳，减少了参数数量和计算量；Dropout 层通过在模型的训练过程中按比例随机忽略一部分神经元来缓解模型训练过程中出现的过拟合问题，在一定程度上达到正则化的效果；批标准化层对

输入激活函数的特征归一化处理, 减少引起的偏移量, 不仅可以增加模型的训练速度, 以及提高网络的泛化能力, 还可以使 Sigmoid 这种容易导致梯度消失的激活函数被使用。

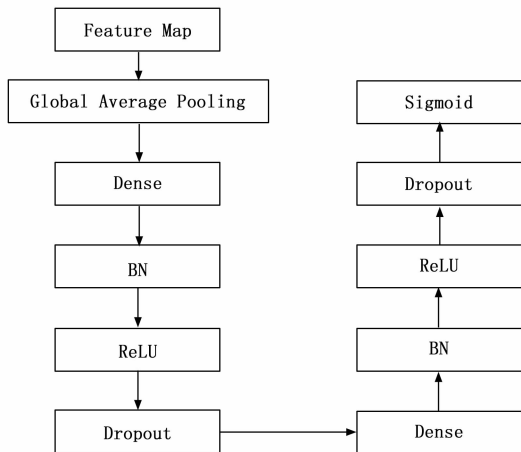


图 6 优化“分类器”流程图

3 实验及结果分析

3.1 实验数据集

实验采用公开的乳腺癌图像数据集 CBIS-DDSM^[22] (curated breast imaging subset of DDSM), 该数据集是 DDSM^[23] (the digital database for screening mammography) 的更新和标准化版本。DDSM 是一个包含 2 620 个扫描乳腺 X 线摄影技术的数据库, 它包含正常、良性肿块和恶性肿块的病例。CBIS-DDSM 是 DDSM 数据的子集, 由专业的医生挑选图像并更新修改标注错误的 ROI 注释, 以及将图像格式转化为易于访问的医学数字成像和通信 (DICOM) 格式。

为了提高计算机辅助诊断系统的性能, 在构建数据集时, 图像预处理是一个重要的步骤。图 7 中分别展示了良性和恶性乳腺图像, 可以看出乳腺肿块大小只占整幅乳腺钼靶图像很小的面积, 直接对整幅图像训练分类容易导致数据不平衡, 难以取得较好的分类效果, 因此实验使用制作的感兴趣区域 (ROI, region of interest) 图像数据集进行训练实验。

CBIS-DDSM 数据集已经将数据分为训练数据和测试数据, 并提供了乳腺钼靶图像、掩模图像和 ROI 图像, 由于原数据集提供的 ROI 图像像素尺寸相对较大, 且每个 ROI 图像的大小和长宽比都不同, 因此根据数据集提供的掩模图像中病灶的位置, 从原乳腺图像中自动裁剪出固定大小的 ROI 图像。最终训练集共裁剪出 2 325 张 ROI 图像, 其中良性肿块图像 1 187 张, 恶性肿块图像 1 138 张; 测试集共裁剪出 670 张 ROI 图像, 其中良性肿块图像 409 张, 恶性肿块图像 261 张。由于 Xception 模型在 ImageNet 数据集上预训练的图像大小为 299x299, 因此将裁剪的 ROI 图像




图 7 CBIS-DDSM 数据集乳腺图像

大小裁定为 299x299, 并对所有 ROI 图像归一化于 0~1 之间。

3.2 数据增强

众所周知, 卷积神经网络模型的训练需要大量的数据样本才能达到较好的泛化效果, 而医学图像受病例过少、病人隐私等因素限制难以大量收集数据, 此外还需要专业的临床医师标注图像, 使得构建高质量的大规模医学图像数据集面临重重挑战。虽然通过迁移学习方法可以适当减少实验需要的数据量, 但数据量过少时即使迁移学习也很难取得较好的分类效果。因此可以使用数据增强的方式来增加训练样本数据, 通过上下翻转、左右翻转、平移、旋转不同角度等方法将训练集数据集扩充 6 倍, 扩充后的图像数量为 13 950 张, 按照比例 (80%: 20%) 将数据随机分为训练集、验证集。

3.3 实验参数

实验的硬件设备如下: 操作系统为 Windows10, 24 G 显存 Nvidia GeForce GTX 3090 显卡一块, 处理器为 Inter Core i9-10 900 K @ 3.70 GHz, 内存为 32 GB, python 版本为 3.7, 并使用 TensorFlow 和 keras 等深度学习框架来构建卷积神经网络模型。

在模型的训练过程中, 选择随机梯度下降法作为模型参数优化器; 损失函数采用二进制交叉熵损失函数; epoch 设置为 50 次; 批大小设置为 16; dropout 设置为 0.5; 初始学习率设置为 0.000 1, 当连续 7 个 epoch 学习率不变时以乘以因子为 0.2 降低学习率; 并设置提前停止机制为 13, 当验证集损失函数值连续 13 个 epoch 都不下降时提前结束训练, 防止过拟合。

3.4 实验结果及分析

3.4.1 实验设计

实验的主要流程为: 首先, 在数据集的原图像上自动截取提取感兴趣区域, 制作 ROI 图像数据集并预处理; 然后将改进后的 Xception 模型作为特征提取器, 迁移学习在

ImageNet 上的预训练权重初始化参数,并微调训练网络所有层,提取乳腺肿块 ROI 图像的特征信息;最后,将提取的特征图像输入给优化后的全连接层“分类器”预测输出乳腺肿块的良恶性,得到最终的分类结果。

3.4.2 迁移学习和非迁移学习方法比较

首先,比较了 Xception-C 模型基于迁移学习和不迁移学习方法对乳腺钼靶图像良恶性分类的性能差异,模型训练过程中分别使用 ImageNet 数据集上的预训练权重初始化参数与随机初始化参数训练进行实验对比,在训练 30 个 epoch 的情况下对比训练过程中准确率和损失值曲线的变化趋势。

图 8 展示了迁移学习时和不迁移学习时训练和验证过程中准确率和损失值的变化曲线,结果显示迁移学习比不迁移学习可以使模型更快的达到收敛,且准确率更高。由图 8 可知,在训练过程中不使用迁移学习时损失函数值经过很多迭代次数才能逐渐收敛且损失函数值的波动较大,在训练很少的次数时难以达到较高的分类准确率。然而,当使用迁移学习时损失值可以很快达到收敛,并且训练相同代数有很高的分类准确率。因此,当我们研究领域的数据集缺乏时,可以利用迁移学习训练很少的次数就能取得更好的实验效果,节省了训练时间和计算机的计算成本。

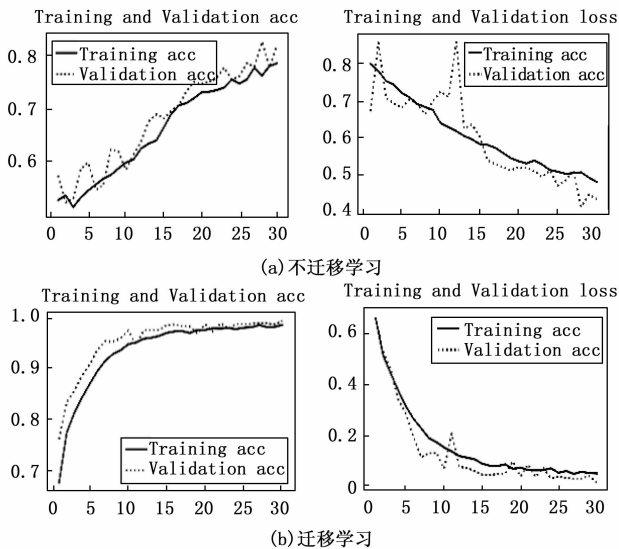


图 8 训练和验证过程中准确率和损失值变化曲线

3.4.3 优化“分类器”的实验对比

为了验证提出的优化“分类器”方法的实验效果,比较了 ResNet50、MobileNetV2、InceptionV3、Xception 和提出的 Xception-C 模型在使用优化分类器和不使用优化分类器两种情况下的分类效果。分别使用上述模型在乳腺钼靶图像数据集上训练实验,各模型实验结果的准确率如表 1 所示,可以看出各模型使用优化分类器的分类准确率都有不同程度的提高,准确率平均提高了 3.7%,表明利用全局平均池化层代替全连接层,以及添加 BN、激活函数和

Dropout 等方法可以缓解模型训练过程中出现的过拟合问题,也说明优化后的分类器可以有效提高卷积神经网络在乳腺钼靶图像识别任务上分类的准确率。

表 1 各模型使用优化“分类器”前后实验结果比较

模型	不使用优化分类器 ACC/%	使用优化分类器 ACC/%
ResNet50	86.60	90.54
MobileNetV2	71.24	74.92
InceptionV3	88.64	92.26
Xception	89.52	93.14
Xception-C	93.76	97.46

3.4.4 改进的 Xception 模型实验分析

为了验证优化改进 Xception 模型后提出的 Xception-A、Xception-B 和 Xception-C 模型的有效性,与常用于图像分类任务的卷积神经网络模型 ResNet50、MobileNetV2、InceptionV3 和 Xception 作对比。为了评估模型的性能,主要使用准确率 (Accuracy)、AUC 值和混淆矩阵这几项评价指标来评估。其中,准确率是指预测正确的样本数量占全部样本的比例,当准确率的值越大时代表模型的预测结果越接近于真实结果;AUC 被定义为接受者工作特征 (ROC, receiver operating characteristic) 曲线与坐标轴围成的面积,这个面积值最大值为 1,经常被用作衡量卷积神经网络二分类性能优劣的一种评价指标,当 AUC 值越大时表明该模型的性能越好;混淆矩阵的横轴是模型预测各类别样本的统计数量,纵轴是真实标签的统计数量,可以直观反映各分类类别的预测结果。混淆矩阵的正对角线上的数字越大,代表预测结果准确性越好。

表 2 展示了改进后的 Xception 模型在乳腺钼靶 ROI 图像分类任务上训练实验和其他对比模型训练实验的分类准确率、AUC 值和参数数量,实验中每个模型都使用优化后的分类器。可以看出 MobileNetV2 模型的准确率最低,仅有 74.92%,但该模型作为轻量级模型,参数数量远远少于其他几个模型,在其他图像识别任务上该模型的性能也不如 ResNet50、InceptionV3 和 Xception 这种大型的卷积神经网络。Xception-A 模型分类的准确率为 95.13%,比原 Xception 模型分类的准确率提高了接近 2%,证明本研究提出的改进 Xception 模型的残差连接模块方法的有效性,该方法在残差连接模型的支路使用步长为 2 的最大池化层和步长为 1 的 1×1 卷积层代替原来的步长为 2 的 1×1 卷积层,比原来方法多进行一次特征选择,来防止一些重要的特征信息丢失,从而加强模型的特征提取能力。Xception-B 模型分类的准确率比改进前的模型提高了 2.73%,表明本文方法在深度可分离卷积后嵌入 SE 注意力机制方法的可行性,使模型可以自注意各个通道的重要程度,突出重要的特征通道,抑制不重要的特征通道。最终提出的 Xception-C 模型取得了 97.46% 的准确率和 99.12% 的 AUC 值,明显

高于其他模型, 表明将两种改进方法同时应用在 Xception 模型可以有效提高分类的准确率, 也证明了改进后的 Xception-C 模型在乳腺钼靶图像良恶性分类任务上有更好图像识别能力。而且与改进前的 Xception 模型相比, 只增加了少量的参数数量, 准确率就高出 4.32%, 表明将 SE 模块嵌入 Xception 模型的深度可分离卷积层和改进残差连接模块方法的可行性。

表 2 改进 Xception 模型与其他模型实验结果比较

模型	ACC/%	AUC/%	参数数量
ResNet50	90.54	94.41	25 953 665
MobileNetV2	74.92	80.47	3 837 505
InceptionV3	92.26	95.86	24 168 737
Xception	93.14	98.44	23 227 433
Xception-A	95.13	98.54	23 369 115
Xception-B	95.87	98.87	24 278 313
Xception-C	97.46	99.12	24 875 297

图 9 展示了 Xception-C 模型测试结果的混淆矩阵, 可以看出对良性肿块和恶性肿块预测错误的样本数量差距不大, 虽然测试集中良性肿块的样本数量较多, 但整体每个类别预测错误的比例相差不大。

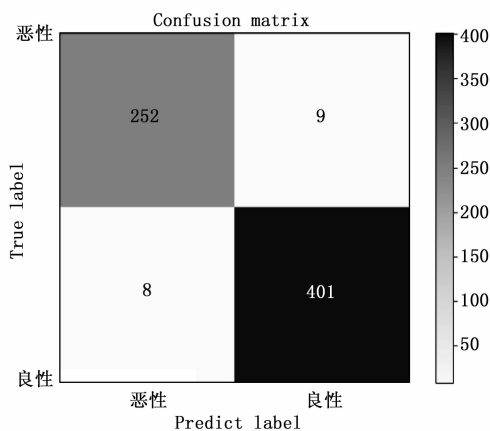


图 9 测试结果混淆矩阵

3.4.5 与最新研究方法比较

表 3 显示了 3 种最新研究方法的分类准确率, 这些方法都是在 CBIS-DDSM 数据集上利用不同的深度学习方法对乳腺钼靶图像进行良恶性分类。可以看出, 本文提出方法的分类准确率高于其他方法。与这些方法相比, 本研究的实验中处理数据集时没有使用 CBIS-DDSM 数据集提供的 ROI 图像, 而是根据数据集提供肿块位置自动裁剪出肿块边缘信息更全面的 ROI 图像; 选择解耦通道相关性和空间相关性的 Xception 模型, 并对该模型进行改进优化, 实验结果证明 Xception-C 模型有更好的特征提取能力和对乳腺钼靶图像良恶性识别的能力。

4 结束语

本研究提出了基于改进 Xception 模型的乳腺钼靶图像

表 3 与其他方法分类准确率比较

方法	ACC/%
白茹等 ^[24]	88.2
Zhang 等 ^[19]	95.24
J. Sharaf 等 ^[25]	96.0
本文方法	97.46

分类方法, 端到端实现将 CBIS-DDSM 数据库里的乳腺钼靶图像自动分为良性和恶性两类。实验结果表明, 与其他常用的分类模型相比, 本文模型更加适用于乳腺癌图像分类, 取得了更好的分类效果。与改进前的 Xception 模型相比, 实验结果证明改进残差连接模块和在后两个可分离卷积后嵌入 SE 自注意力机制方法的可行性, 可以使模型更加关注通道间的信息, 特征提取时能够提取更多的有用信息, 提升一定的准确率, 使模型更加稳定。本实验只对乳腺钼靶图像简单的进行良恶性二分类, 为了可以帮助临床医师进行更加精准的诊断, 在未来的工作中, 可以展开对乳腺癌图像正常、良性、恶性、钙化良性、钙化恶性等多分类的研究。

参考文献:

- [1] 刘军兰. 乳腺癌首次成为全球最常见的癌症 [J]. 中华乳腺病杂志 (电子版), 2020, 14 (6): 389 - 389.
- [2] SIEGEL R L, MILLER K D, FUCHS H E, et al. Cancer statistics, 2022 [J]. CA: A Cancer Journal for Clinicians, 2022, 72 (1): 7 - 33.
- [3] 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 - 376.
- [4] GAO Y M, GERAS K J, LEWIN A A, et al. New frontiers: An update on computer-aided diagnosis for breast imaging in the age of artificial intelligence [J]. American Journal of Roentgenology, 2019, 212 (2): 712 - 719.
- [5] MURTAZA G, SHUIB L, WAHAB A, et al. Deep learning-based breast cancer classification through medical imaging modalities: state of the art and re-search challenges [J]. Artificial Intelligence Review, 2020, 53 (3): 1655 - 1720.
- [6] 黄晓莹. 基于计算机辅助的医学图像测量与控制方法研究 [J]. 计算机测量与控制, 2017, 25 (6): 17 - 20.
- [7] 杨婷婷, 武林会, 米红妹, 等. 改进的 3D Canny 算子在 MRI 乳腺图像分析中的应用 [J]. 计算机测量与控制, 2017, 25 (9): 143 - 149.
- [8] FUJITA H. AI-based computer-aided diagnosis (AI-CAD): the latest review to read first [J]. Radiological physics and technology, 2020, 13 (1): 6 - 19.
- [9] LI Y F, CHEN H J, WEI X Y, et al. Mass classification in mammograms based on two-concentric masks and discriminating texton [J]. Pergamon, 2016, 60 (1): 648 - 656.
- [10] LIU X M, TANG J S. Mass classification in mammograms u-

sing selected geometry and texture features, and a new SVM-based feature selection method [J]. *IEEE Systems Journal*, 2013, 8 (3): 910 - 920.

[11] BRIJESH V, PETER M, ALAN K. A novel soft cluster neural network for the classification of suspicious areas in digital mammograms [J]. *Pattern Recognition*, 2009, 42 (9): 1845 - 1852.

[12] CHAN H, HADJIISKI L M, SAMALA R K. Computer-aided diagnosis in the era of deep learning [J]. *Medical physics*, 2020, 47 (5): 218 - 227.

[13] SAHINER B, CHAN H, PETRICK N, et al. Classification of mass and normal breast tissue: a convolution neural network classifier with spatial domain and texture images [J]. *IEEE Transactions on Medical Imaging*, 1996, 15 (5): 598 - 610.

[14] KOOI T, VAN G B, KARSSEMEIJER N, et al. Discriminating solitary cysts from soft tissue lesions in mammography using a pretrained deep convolutional neural network [J]. *Medical physics*, 2017, 44 (3): 1017 - 1027.

[15] 许文慧, 裴以建, 朱久德, 等. 基于注意力机制与迁移学习的乳腺钼靶肿块分类 [J]. *激光与光电子学进展*, 2021, 58 (4): 146 - 154.

[16] CHOUGRAD H, ZOUAKI H, ALHEYANE O. Deep Convolutional Neural Networks for breast cancer screening [J]. *Computer methods and programs in biomedicine*, 2018, 157: 19 - 30.

[17] ZHANG C, ZHAO J M, NIU J, et al. New convolutional neural network model for screening and diagnosis of mammograms [J]. *PloS one*, 2020, 15 (8): 1800 - 1807.

[18] CHOLLET, FRANCOIS. Xception: deep learning with depthwise separable convolutions [J]. *30TH IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR 2017)*, 2017: 1800 - 1807.

[19] HE KM, ZHANG XY, REN SQ, et al. Deep residual learning for image recognition [C] // *2016 the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016: 770 - 778.

[20] HU J, LI S, ALBANIE S, et al. Squeeze-and-excitation networks [J]. *IEEE transactions on pattern analysis and machine intelligence*, 2020, 42 (8): 2011 - 2023.

[21] 关胤. 基于残差网络迁移学习的花卉识别系统 [J]. *计算机工程与应用*, 2019, 55 (1): 174 - 179.

[22] REBECCA S L, FRANCISCO G, ASSAF H, et al. A curated mammography data set for use in computer-aided detection and diagnosis research [J]. *Scientific Data*, 2017, 4 (1): 177 - 189.

[23] SALLAM M, BOWYER KW, WOODS K, et al. The digital database for screening mammography: Lessons learned [J]. *RADIOLOGY*, 1997, 205: 323 - 334.

[24] 白茹, 余慧, 安建成, 等. 基于改进 DenseNet 的乳腺钼靶肿块分类方法 [J/OL]. *计算机工程与应用*: 1 - 15 [2022 - 02 - 10]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20210420.1340.064.html>.

[25] SHARAF JM, ARSHAD H. Automated breast mass classification system using deep learning and ensemble learning in digital mammogram [J]. *IEEE Access*, 2021, 9 (2): 55312 - 55328.

[15] MIRJALILI S. Genetic algorithm [M] // *Evolutionary algorithms and neural networks*. Springer, Cham, 2019: 43 - 55.

[16] 陈斌, 徐华中. 一种改进遗传算法及其在 TSP 问题中的应用 [J]. *计算机工程*, 2002, 28 (9): 90 - 92.

[17] 苑立伟, 刘付显, 赵保军. 改进遗传算法及其在背包问题中的应用 [J]. *系统工程与电子技术*, 2005, 27 (4): 718 - 719.

[18] 高媛. 非支配排序遗传算法 (NSGA) 的研究与应用 [D]. 杭州: 浙江大学, 2006.

[19] 关志华. 非支配排序遗传算法 (NSGA) 算子分析 [J]. *管理工程学报*, 2004, 18 (1): 56 - 60.

[20] 张超勇, 董星, 王晓娟, 等. 基于改进非支配排序遗传算法的多目标柔性作业车间调度 [J]. *机械工程学报*, 2010 (11): 156 - 164.

[21] 郑强. 带精英策略的非支配排序遗传算法的研究与应用 [J]. 杭州: 浙江大学, 2006, 1 - 71

[22] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II [J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6 (2): 182 - 197.

[23] ISHIBUCHI H, IMADA R, SETOYUCHI Y, et al. Performance comparison of NSGA-II and NSGA-III on various many-objective test problems [C] // *2016 IEEE Congress on Evolutionary Computation (CEC)*, IEEE, 2016: 3045 - 3052.

[24] 王健, 熊福敏. 基于北斗卫星通信的航天测控频段故障诊断系统设计 [J]. *计算机测量与控制*, 2021, 29 (12): 8 - 12.

[25] 杜素忠, 张录彬. 挖掘机北斗高精度自动定位和引导方法 [J]. *计算机测量与控制*, 2021, 29 (4): 165 - 169, 174.

[26] 郭喜明. 北斗卫星导航系统在交通运输检测领域的应用及未来发展方向 [J]. *中小企业管理与科技 (下旬刊)*, 2018 (1): 162 - 163.

[27] 杨子辉, 薛彬. 北斗卫星导航系统的发展历程及其发展趋势 [J]. *导航定位学报*, 2022, 10 (1): 1 - 14.

[28] 邱雪, 王永忠, 赵志, 等. 基于多目标算法合理配置火灾中的无人机组 [J]. *计算机测量与控制*, 2021, 29 (10): 211 - 216.

(上接第 188 页)