

基于改进 ResNet34 网络的脑肿瘤分类方法研究

嵇小辅^{1,2}, 金兆雄¹

(1. 江南大学 物联网工程学院, 江苏 无锡 214122;

2. 江南大学 物联网工程学院轻工过程先进控制教育部重点实验室, 江苏 无锡 214122)

摘要: 传统的人工分辨脑肿瘤医学影像费时费力、浅层的卷积神经网络模型分类准确率较低, 为了提高脑肿瘤图像分类的高效性和准确率, 提出了一种基于改进 ResNet34 网络的脑肿瘤分类模型; 该模型以 ResNet34 残差网络作为骨干网络, 结合多尺度特征提取思想, 采用多尺度输入模块作为 ResNet34 网络的第一层, 将 inceptionv2 模块作为残差下采样层; 再通过通道注意力机制模块, 从通道域的角度赋予图像不同通道不同的权重, 得到更重要的特征信息; 经过五折交叉实验后的结果表明, 改进后的新网络模型的平均分类准确率约为 98.82%, 比 ResNet34 提升约 1.1%, 且模型参数数量仅为原模型的 80%; 这说明改进后的网络不仅提高了准确率, 还减少了模型复杂度, 达到了参数更少, 准确率更高的分类效果。

关键词: 图像处理; 改进 ResNet34; 脑肿瘤分类; 多尺度输入; 注意力机制; inception v2

Research on Classification Method for Brain Tumors Based on Improved ResNet34 Network

JI Xiaofu^{1,2}, JIN Zhaoxiong¹

(1. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China;

2. Key Laboratory of Advanced Control of Light Industry Process of Ministry of Education, College of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China)

Abstract: Traditional manual sorting methods for brain tumor medical images are time-consuming and laborious, and shallow convolutional neural network models have lower classification accuracy. In order to improve the efficiency and accuracy of brain tumor image classification, a brain tumor classification model based on improved ResNet34 network is proposed. The model uses ResNet34 residual network as the backbone network, combines the idea of multi-scale feature extraction, adopts the multi-scale input module as the first layer of ResNet34 network, and takes the inception v2 module as the residual downsampling layer. Then through the channel attention mechanism module, different weights are assigned to different channel images from the channel domain to obtain more important feature information. The experimental results of 5-fold cross-validation show that the classification average accuracy of the improved network model is about 98.82%, which is 1.1% higher than that of the ResNet34, and the number of model parameters is only 80% of the original model. This indicates that the improved network not only improves accuracy, but also reduces model complexity, and achieves classification effects with fewer parameters and higher accuracy.

Keywords: image processing; improved ResNet34; brain tumor classification; multi scale input; attention mechanism; inception v2

0 引言

随着现代社会的高速发展和生活方式的变迁, 人们的健康问题也日益凸显。其中, 脑肿瘤作为一种严重的疾病, 正逐渐成为困扰着社会的健康隐患。脑肿瘤是指在人体的脑组织中形成的一类肿瘤, 它可以影响人的认

知、行为、感知和运动能力, 其患者的死亡率占人体肿瘤发病率的 2.4%^[1]。脑肿瘤有多种类型, 其中最常见的是胶质瘤、脑膜瘤和垂体瘤^[2]。临床上诊断脑肿瘤最常用的方法为核磁共振成像^[3-4] (MRI, magnetic resonance imaging)。MRI 具有多序列和多类型成像能力,

收稿日期:2023-12-11; 修回日期:2024-01-19。

作者简介:嵇小辅(1979-),男,博士,教授,硕士生导师。

引用格式:嵇小辅,金兆雄. 基于改进 ResNet34 网络的脑肿瘤分类方法研究[J]. 计算机测量与控制, 2025, 33(2):184-191.

能够清晰地显示人体的软组织结构,为明确病变性质提供更加丰富的影像信息。因此,如何高效准确地判断 MRI 影像中是否含有肿瘤、含有哪种类型的肿瘤是临床上急需解决的问题。

早期的 MRI 影像检测是由人工肉眼去看脑部 MRI 图片,由于数据量大,而且脑肿瘤的具体类型不同,这种方法耗时长,容易出现人为错误,所以引入计算机辅助诊断^[5]是必要的。近年来,卷积神经网络在许多领域的应用中取得了巨大成功,如图像处理、语音识别、自然语言处理、目标跟踪、医疗诊断^[6]等。伴随着这股研究浪潮,最近几年,越来越多的学者们将卷积神经网络引入到医学影像领域。Hossain 等人^[7]分别用传统分类器和深度学习中卷积神经网络两种方法对脑肿瘤检测进行研究,研究结果显示通过利用卷积神经网络的方法得到的检测效果明显优于传统分类器的检测效果。Abiwinanda^[8]也将卷积神经网络(CNN, convolutional neural network)应用在脑肿瘤分类中,通过简单卷积网络实现了胶质瘤、脑膜瘤和垂体瘤的三分类任务,虽然准确率略低,但仍然可以与基于区域预处理的传统算法的准确率相媲美。Vankdothu 等人^[9]结合 CNN 与长短期记忆,构建出一个新卷积网络,在 kaggle 脑肿瘤数据集上实现了胶质瘤、脑膜瘤、垂体瘤和无肿瘤的四分类,得到了 92% 的准确率。Ayadi 等人^[10]构建了一个 11 层的卷 CNN 对 figure 数据集中的脑肿瘤图像进行 3 分类,获得了 94.74% 的准确率。这些模型都是浅层意义上的 CNN,还没有达到深层次的 CNN 范畴。Khan 等人^[11]用一个简单的 CNN 模型实现了脑肿瘤的良恶性分类,达到了 100% 的准确率,但因其样本太小,总共只有 253 张图片,难以摆脱单一数据集中小样本问题对模型泛化性能的影响。

随着 CNN 网络被应用于诸多领域,学者们发现随着卷积层的不断加深,会出现梯度消失或梯度爆炸现象,使得准确率大幅下降。而残差网络可以缓解这个现象。Kumar 等人^[12]通过残差网络和全局平均池化对脑肿瘤数据集进行三分类,将全局平均池化代替全连接层来缓解过拟合问题,获得了 97.48% 的准确率。ResNet^[13]残差网络可以训练非常深的神经网络,有效缓解了训练时梯度消失和梯度爆炸现象,能加速网络收敛,提高模型的表达能力和性能;其中的残差连接可以保留原始特征,使得网络的学习更加顺畅和稳定,进一步提高了模型的精度和泛化能力。但 Resnet 网络是从单一尺度上去提取特征的,没有融合多个尺度的卷积核提取的特征。在 CNN 中大的卷积核具有更大的有效接受野和更高的形状偏差,小的卷积核则更注重纹理偏差^[14]。因此结合不同尺寸的卷积核从多个尺度对输入数据进行处理可以适当提高模型的性能。Diaz 等人^[15]将多尺度

方法应用于深度 CNN 中,对公开脑肿瘤数据集的 3 064 张 MRI 图片进行三分类,得到了 97.3% 的分类准确度。黄敏等人^[16]将多尺度思想融入残差网络中,使残差块具有多个分支,从而控制通道数量,使得在每次卷积过程中感受到的信息及提取的特征都不相同。除此之外,在对输入数据进行处理时,采用注意力机制能够从大量信息中筛选高价值信息^[17],对关键信息赋予更多的关注度,使模型能够更好地表达关键特征,同时也能降低噪声和冗余特征的敏感性,提高模型的泛化能力。

针对传统的人工分辨脑肿瘤医学影像费时费力、浅层的 CNN 模型分类准确率较低以及堆叠深度网络又易出现梯度消失等问题,本文结合多尺度思想以及注意力机制的优点,对能够缓解梯度消失问题的深度残差网络进行研究,主要研究方面为:1) 采用 Resnet34 残差网络作为模型的骨干网络,其中的残差模块可以有效缓解深层网络的梯度消失问题;2) 在主干网络中引入多尺度特征提取思想,对主干网络的第一层卷积层和下采样层进行多尺度特征提取和拼接,以丰富提取的特征信息并确保在下采样时对输入特征的充分利用;3) 最后在网络中添加 SE 通道注意力机制模块,以提高重要特征的表示能力。通过这些研究提出新网络,以提高脑肿瘤分类的准确率。

1 网络结构

1.1 ResNet34 残差结构

ResNet34 是 ResNet 系列网络的一个具体实现,其主要架构包括卷积层、池化层、残差块(residual block)以及全连接层。在 ResNet 中,残差块是其核心思想之一,而其中的快捷连接(shortcut connection)分支允许浅层特征直接映射到深层网络中。这种快捷连接的设计有助于缓解深度神经网络随着层数增加而带来的准确率下降问题。残差块的结构如图 1 所示,它的核心思想在于通过跨层连接来实现残差学习,这使得网络在训练过程中可以更轻松地学习到残差信息,从而提高了模型的性能和收敛速度。这一架构的创新性大大推动了深度卷积神经网络的发展,使得我们能够构建更深层次的神经网络而不会受到性能下降的制约。

图 1 中右边的分支 x 表示残差结构的恒等映射,表示像素点逐个相加。公式如下:

$$H(x) = F(x) + x \quad (1)$$

式中, $H(x)$ 为底层映射, F 表示经过两个卷积层的计算过程(包括 ReLu 激活操作), x 为输入。

残差映射 $F(x) = H(x) - x$, 当网络达到相对饱和,即 $F(x)$ 足够小时,输出 $H(x)$ 就会近似地变为 x , 这就变成了恒等映射函数 $H(x) = x$, 恒等映射保证了网络性能不会下降,使得网络在输入特征的基础上学习




图 1 残差块结构图

到新的特征，且恒等映射不会给网络增加额外的参数和计算量，却可以加快模型的训练速度，优化训练效果^[18]。因此，随着网络的深度加深，反向传播中梯度不会消失，这使得残差网络被广泛应用于多个领域。

1.2 改进的 ResNet34 网络模型

为了改进 ResNet34 网络并克服其一些局限性，本研究对 ResNet34 进行了优化。改进后的网络模型仍以 ResNet34 作为骨干网络结构，但在架构上进行了调整。首先，将 ResNet34 的首层 7×7 卷积替换为多尺度输入模块，这一模块能够运用多种尺寸的卷积核对图像进行特征提取，从而提高了特征信息的丰富性和多样性。其次，将 ResNet34 中的残差下采样模块替换为本文提出的下采样模块。这一新型下采样模块不仅引入了多尺度思想，还能够充分利用所有输入信息，进一步增强了模型的性能。最后，为了进一步提高网络的表现，在每个残差块中引入了 SE 注意力机制，这有助于网络更聚焦地学习和利用关键特征。网络结构如图 2 所示。

1.3 下采样模块

下采样是用于减小图像或信号的尺寸或分辨率的一种操作，可以降低模型的计算量。在 ResNet34 网络中，除了采用卷积核大小为 3×3 ，步距为 2 的最大池化下采样层，还包括一种基于残差结构的下采样模块，如图 3 所示。需要注意的是，图 3 中下采样模块的快捷连接是一个卷积核大小为 1×1 ，步距为 2 的卷积层，这意味着经过此卷积层的输入特征会经历信息损失，其中可能包括一些重要信息。为了解决这一问题，再结合多尺度和 inception 模块的思想，本文提出了将 inceptionv2 模块作为下采样模块，把原 1×1 卷积核分支改为 3×3 的卷积核，网络结构如图 4 所示。图 4 中 channels 表示通道数， H 、 W 分别表示输入特征图的高和宽，stride 表示卷积操作的步长，stride=2 表示进行下采样操作，将输入特征图的尺寸减小为原来的一半。该下采样模块有 4 个分支，各个分支运算完后进行通道拼接，每个分支的最终输出通道数都相同，拼接后的通道数为输入通




图 2 改进的 Resnet34 网络结构图

道数的两倍。




图 3 残差块下采样模块

1.4 多尺度输入特征提取模块

不同大小的卷积核在特征提取方面表现出差异，大卷积核主要关注形状信息，而小卷积核则更注重捕捉纹理细节^[14]。多尺度特征提取的核心思想在于利用




图4 inception v2 下采样模块

不同大小的卷积核分别提取特征, 然后将它们的输出相加或拼接, 从而获得更加丰富的特征信息。本文采用的多尺度输入特征提取模块首先将输入数据经过卷积核大小分别为 3×3 、 5×5 、 7×7 和 11×11 的 4 个卷积层进行特征提取。随后, 这 4 个输出分别两两相加, 生成两个中间输出。接下来, 这两个中间输出分别经过卷积核大小为 3×3 和 5×5 的两个卷积层, 最终通过通道拼接的方式将它们合并。这种多尺度特征提取策略有助于更全面地捕捉图像中的各种特征信息。具体的结构如图 5 所示, 其中的 32 和 64 分别表示输出通道数。




图5 多尺度输入模块

1.5 通道注意力机制

在卷积、池化过程中, 默认特征图的每个通道的重要性是相同的, 而在实际的问题中, 不同通道的特征重要性可能存在差异。为了更准确地捕捉特征图中通道之间的差异, 本文引入了 SE 通道注意力机制^[19], 它可以通过一个权重矩阵, 从通道域的角度赋予图像不同通道不同的权重, 以突出更为重要的特征信息。SE 主要包含压缩 (squeeze)、激发 (excitation) 和重置 (scale)

这 3 个部分。

压缩部分是通过全局平均池化 (GAP, global average pooling) 将输入特征图的大小从 $H \times W \times C$ 压缩为 $1 \times 1 \times C$, 即将特征图的每个通道的所有像素点求平均值得到唯一的一个值, 公式如下:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (2)$$

式中, z_c 表示输入特征图第 c 个通道的全局压缩特征, F_{sq} 表示压缩过程, u_c 表示输入特征图第 c 个通道的特征图, H 、 W 分别表示输入特征图的高和宽。

激发部分是通过两个全连接层和一个激活层对压缩部分得到的集合 z 进行处理, 得到想要的权重值 s , s 中不同的数值表示不同通道的权重信息。公式如下:

$$s = F_{ex}(z, W) = \sigma[W_2 \delta(W_1 z)] \quad (3)$$

式中, F_{ex} 为激发过程; z 为压缩部分得到的输出; W 为全连接层, W_1 、 W_2 分别表示第一和第二个全连接层, δ 表示 ReLU 激活层, σ 表示 sigmoid 激活函数。

重置部分是将激活部分所得到的每个通道的权重值 s 与压缩步骤之前的输入进行对应通道相乘, 以达到对不同通道赋予不同权重的目的。公式如下:

$$\tilde{X}_c = F_{scale}(u_c, s_c) = s_c u_c \quad (4)$$

式中, $\tilde{X}_c = [\tilde{x}_1, \tilde{x}_2, \tilde{x}_3, \dots, \tilde{x}_c]$, $\tilde{x}_1 = s_1 u_1$, F_{scale} 表示重置过程, u_c 为输入特征, s_c 为输入特征 u_c 经过压缩和激活两个过程后得到的输出权重。

2 实验与分析

2.1 实验环境及参数设置

本实验采用的是 Pytorch 深度学习模型框架, 编程语言为 Python 3, 并在 Pycharm 编译软件中进行开发, 操作系统为 Windows11, CPU 为 Intel i7-12500H, GPU 则为 NVIDIA RTX3090, 以利用强大的图形处理单元进行计算。在网络训练过程中, 训练时的 epoch 设置为 300, 每个 epoch 使用的 batch size 设置为 64。采用 Adam 优化算法, 并设置初始学习率为 0.001, 采用学习率线性衰减策略, 即学习率每经过 100 个 epoch 就衰减为原来的 0.1 倍, 以加快模型收敛, 缓解震荡和过拟合。

2.2 数据集与预处理

本实验使用的脑肿瘤 MRI 数据集来自 figshare 官网中的 3 064 张脑肿瘤 MRI 图片^[20]和 paperwithcode 网站中的 1 436 张无肿瘤 MRI 图片^[21]。其中 figshare 中的 3 064 张脑肿瘤图片收集了 233 例脑膜瘤 (708 片)、胶质瘤 (1 426 片) 和垂体瘤 (930 片) 3 种脑肿瘤的患者, 每张切片的肿瘤类型都由放射科医生标记。该数据集是当前各脑肿瘤分类任务中用得最多的一个公共数据集, 以 Matlab 数据格式提供的, 每个文件储存一个包含图像信息的结构体, 如肿瘤类型与真值标签之间的关

系（1 表示脑膜瘤，2 表示胶质瘤，3 表示垂体瘤）。将 Matlab 格式文件转为图片文件后的不同类型的脑肿瘤以及无肿瘤 MRI 图片如图 6 所示。




图 6 脑肿瘤及无肿瘤图片

数据集全部转换为图片文件后，随机筛选其中的五分之一作为测试集，然后将剩余的数据集按 4：1 的比例随机划分为训练集和验证集，详细分布情况如表 1 所示。在将数据集送入训练网络之前，需要对数据集进行预处理操作。首先，对每张图片进行随机裁剪，将其调整为固定的 224×224 大小，以便于输入网络。接着，对裁剪后的图片进行标准化处理，这样可以消除尺度差异，提高梯度下降的稳定性。由于数据集相对较小，为了增加数据集的多样性，采用数据增强操作^[22]，对输入图片进行随机水平翻转、随机垂直翻转和随机提亮操作，确保每个训练周期输入网络的数据不完全相同，以缓解模型训练时可能出现的过拟合问题，提高模型的泛化性能。

表 1 数据集分布情况

Tumor types	Training set	Validation set	Test set	total
Meningioma	454	113	141	708
Glioma	913	228	285	1 426
Pituitary	596	148	186	930
no tumor	920	229	287	1 436

2.3 评价指标

评价指标是用来衡量模型训练的好坏程度，本文采用以下评价指标作为实验结果的标准：

1) 准确率：表示测试结果中预测值与真实值相同的样本数占总样本的比例，公式如下：

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$
 (6)

2) 精确率：表示测试结果中预测值为正的样本中真实值，也为正的样本数的占比，公式如下：

$$Precision = \frac{TP}{TP + FP}$$
 (7)

3) 召回率：表示测试结果中真实值为正的样本中预测值，也为正的样本数的占比，公式如下：

$$Recall = \frac{TP}{TP + FN}$$
 (8)

4) 特异度：表示测试结果中真实值为负的样本中预测值，也为负的样本数的占比，公式如下：

$$Specificity = \frac{TN}{TN + FP}$$
 (9)

5) $F_1\text{ score}$ ：表示精确率与召回率的一个加权平均， $F_1\text{ score}$ 越高，说明模型越稳健，公式如下：

$$F_1\text{ score} = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$
 (10)

上述公式中的 TP 表示模型正确地将正类别的样本分类为正类别，即为模型成功识别的正类别样本数量； TN 表示模型正确地将负类别的样本分类为负类别，即为模型成功识别的负类别样本数量； FP 表示模型错误地将负类别的样本分类为正类别，即为模型错误地将负类别样本标记为正类别的数量； FN 表示模型错误地将正类别的样本分类为负类别，即为模型错误地将正类别样本标记为负类别的数量。

2.4 实验结果

为了深入研究所提方法的有效性以及改进后的各个模块对原始 ResNet34 网络准确性的影响，本文将 ResNet34 网络分别与 inception v2 模块、多尺度输入模块和注意力机制模块相结合，采用消融实验验证方法，通过将这些模块集成到 ResNet34 网络中，并在训练数据集上进行训练。将这 5 个模型的性能在测试数据集上进行了评估，其平均测试结果见表 2，同时在表 3 中列示了各模型的其他评价指标。这一实验设计旨在全面评估不同模块对模型性能的影响，为模型的优化提供了深刻的见解。

表 2 各模型的测试平均准确率

Model	ResNet34	A	B	C	Accuracy/%
1	✓	×	×	×	97.71
2	✓	✓	×	×	98.33
3	✓	×	✓	×	98.22
4	✓	×	×	✓	98.28
5	✓	✓	✓	✓	98.82

表 2 中，A 表示 inception v2 模块，B 表示多尺度输入模块，C 表示 SE 注意力机制模块。Model 1 表示只有 ResNet34 网络，Model 2 表示将 inception v2 模块替换 ResNet34 中的下采样层后构成的新网络，Model 3 表示 ResNet34 结合多尺度输入模块构成的新网络，Model 4 表示在 ResNet34 中加入 SE 注意力机制模块构成的新网络，Model5 表示在 ResNet34 中融入 A、B、C 共 3 个模块构成的新网络。这 5 种不同架构的网络在测试集上的平均准确率结果显示，添加了新模块的改进网络在脑肿瘤图像分类中的准确率都高于原网络，说明这些模块都提升了原模型对脑肿瘤图像分类的性能，其中聚合 3 个模块的网络模型的准确率最佳，达到了 98.82%，相较于 ResNet34 网络提升了约 1.1 个百分点。

表 3 各模型的平均评价指标 %

Model	Type	Precision	Recall	Specificity	F ₁
1	glioma	98.18	98.25	99.15	98.21
	meningioma	94.06	93.90	98.89	93.97
	no tumor	100	99.30	100	99.65
	pituitary	96.28	97.31	99.02	96.79
	average	97.13	97.19	99.27	97.16
2	glioma	97.92	99.12	99.02	98.52
	meningioma	96.08	95.74	99.27	95.91
	no tumor	100	99.48	100	99.74
	pituitary	98.10	97.31	99.51	97.71
	average	98.03	97.91	99.45	97.97
3	glioma	98.94	98.42	99.51	98.68
	meningioma	94.41	95.75	98.95	95.07
	no tumor	100	99.83	100	99.91
	pituitary	97.31	97.31	99.30	97.31
	average	97.67	97.83	99.44	97.74
4	glioma	98.44	99.12	99.10	98.60
	meningioma	96.09	95.75	99.27	95.92
	no tumor	100	98.95	100	99.47
	pituitary	97.59	97.85	99.37	97.72
	average	98.03	97.92	99.44	97.93
5	glioma	99.24	98.88	99.74	99.16
	meningioma	96.12	97.87	99.26	96.98
	no tumor	100	99.79	100	99.90
	pituitary	97.95	97.74	99.47	97.85
	average	98.33	98.57	99.62	98.47

表 3 中 type 下的 glioma、meningioma、no tumor 和 pituitary 分别表示胶质瘤、脑膜瘤、无肿瘤和垂体瘤，average 表示三者平均值。根据表 2 和表 3 的详细数据分析，可以明确观察到，在模型性能的多个评价指标上，包括精确率、召回率、特异度和 F_1 ，模型 2、3、4 和 5 均优于模型 1。这一结果证明了经过改进的各网络模型在性能上的提升，相较于原始网络，改进后的模型在各项评价指标上均表现出更高的水平。

为了确保模型的可靠性和鲁棒性，采用了五折交叉验证的方法进行广泛的实验验证。图 7 为其中一次改进后的模型与原 ResNet34 模型的训练损失和验证准确率的对比，其中改进后的网络模型的训练损失比原模型低，验证准确率也高于原模型，说明改进后模型的训练结果更接近真实值。测试结果的混淆矩阵有助于更详细地了解模型的分类结果和性能表现，所以统计了每次验证后的混淆矩阵，如图 8 所示。其中横轴为真实值，纵轴为预测值，可以看到，每一类仅有极少的脑肿瘤 MRI 图片被错误的预测为其他类，绝大多数脑肿瘤 MRI 图片都能被正确分类，且无肿瘤预测效果几乎为 100%。通过混淆矩阵还可以计算出模型在多项评价指标上的表现，详见表 4。




图 7 改进后的网络与 resnet34 网络的训练损失和验证准确率曲线

表 4 改进后网络模型的五折交叉验证的平均评价指标 %

K-Fold	Accuracy	Precision	Recall	Specificity	F ₁
1	99.00	98.64	98.84	99.67	98.74
2	98.67	98.15	98.58	99.59	98.35
3	98.89	98.58	98.62	99.65	98.60
4	98.67	98.17	98.44	99.59	98.30
5	98.89	98.54	98.62	99.65	98.58
average	98.82	98.42	98.62	99.63	98.51

通过对表 4 中数据的深入分析，观察到改进后的模型在 5 次交叉验证中展现出了相近的测试准确率，表明其性能的稳定性。除了准确率，还对模型的精确率、召回率、特异度以及 F_1 分数等关键性能指标进行了全面的评估。这些指标在 5 次验证中也显示出了相似的结果，进一步证实了改进模型的可靠性和鲁棒性。为了更全面地评价模型的性能，将其与当前学术和实践领域中广泛采用的几种分类算法进行了详尽的比较。所有模型在同一测试集上进行性能评估，其详细结果已在表 5 中呈现。

此外，本文还对新模型与 ResNet34 模型的参数数量进行了详细统计，ResNet34 网络模型的参数数量约为 21.3 M，而提出的新模型网络的参数约为 17.3 M，




图 8 改进后网络模型的 5 折交叉验证的预测混淆矩阵

表 5 改进后网络其他分类网络的平均评价指标 %

Model	Accuracy	Precision	Recall	Specificity	F ₁
Vgg16	95.77	95.59	94.41	98.55	94.93
ResNet50	97.88	97.96	96.99	99.27	97.40
ResNext101	98.22	97.79	97.83	99.43	97.80
GoogleNet	97.66	97.24	96.99	99.23	97.10
EfficientNet V2	98.22	97.90	97.56	99.41	97.72
DenseNet	98.22	98.06	97.69	99.40	97.87
ours	98.82	98.42	98.62	99.63	98.51

约为 ResNet34 参数量的 80%，这表明新模型在保持高性能的同时还降低了空间复杂度，为资源有效性和模型轻量化提供了可行性。将本文提出的新模型与最近几年的脑肿瘤分类领域的相关研究进行比较，如表 6 所示，我们的模型准确率相对更高。

表 6 与近几年相关研究的准确率比较

Author	Year	Approach	Accuracy/%
Swati et al ^[23]	2019	VGG19 + Fine Tuning	94.82
Kaplan et al ^[24]	2020	LBP	95.56
Kumar et al ^[12]	2021	ResNet-50 + Global Average Pooling	97.48
Huang et al ^[16]	2022	Multiscale Residual Network	98.58
ours	—	ResNet34 + Multiscale Inputs + Inception v2+ SE	98.82

3 结束语

针对传统的人工分辨脑肿瘤医学影像费时费力、浅层的 CNN 模型分类准确率较低以及堆叠深度网络又易出现梯度消失等问题。本文是将 ResNet34 残差网络模型与多尺度思想、注意力机制模块相结合，应用于脑肿瘤 MRI 图像的四分类任务。通过利用残差网络强大的缓解深度神经网络中随深度带来的梯度消失的能力，使卷积神经网络能够堆叠到一定深度。为了解决 ResNet34 从单一尺度进行特征提取和下采样残差块可能导致信息损失的问题，本文引入了多尺度输入和 inceptionv2 模块，以确保多样性的特征提取，同时避免信息丢失。此外，还加入了 SE 注意力机制模块，以从通道的角度赋予图像不同通道不同的权重，从而更有效地捕捉关键特征信息。最后通过五折交叉验证进行实验，结果显示改进后的新模型的平均准确率为 98.82%，相对于 ResNet34 模型提高了约 1.1%，而且网络模型的参数数量也更少。与其他分类算法和近几年的相关研究相比，该模型准确率也相对更高。

改进后模型应用于脑肿瘤图像分类的具体过程和实现步骤为：1) 首先将脑肿瘤图像数据集分为训练集、验证集和测试集；2) 对数据集进行裁剪、标准化和转换等预处理操作；3) 用改进后的网络模型通过训

练模块对处理后的训练集进行训练,从而生成训练权重;4)将每次得到的训练权重在验证集上进行测试,通过验证准确率来保留最优的训练权重;5)得到最优的训练权重后,用其对测试集进行测试,若其在测试集上表现的性能也很好且较为稳定,就可以将训练权重与测试代码模块结合部署到诊断软件或医疗健康系统中,从而实现对脑肿瘤类型的检测,这将有助于医生更精准地诊断脑肿瘤类型,可以提高诊断的效率和准确性。

参考文献:

- [1] 褚晶辉,李晓川,张佳祺,等.一种基于级联卷积网络的三维脑肿瘤精细分割[J].激光与光电子学进展,2019,56(10):67-76.
- [2] ASIF S, ZHAO M, CHEN X H, et al. BMRI-NET: a deep stacked ensemble model for multi-class brain tumor classification from MRI images [J]. Interdisciplinary Sciences: Computational Life Sciences, 2023; 1-16.
- [3] ABDEI KADER I, XU G Z, ZHANG S, et al. Differential deep convolutional neural network model for brain tumor classification [J]. Brain Sciences, 2021, 11(3): 352.
- [4] 江宗康,吕晓钢,张建新,等. MRI 脑肿瘤图像分割的深度学习综述[J].中国图象图形学报,2020,25(2): 215-228.
- [5] 郑光远,刘峡壁,韩光辉.医学影像计算机辅助检测与诊断系统综述[J].软件学报,2018,29(5):1471-1514.
- [6] 林景栋,吴欣怡,柴毅,等.卷积神经网络结构优化综述[J].自动化学报,2020,46(1):24-37.
- [7] HOSSAIN T, SHISHIR F S, ASHRAF M, et al. Brain tumor detection using convolutional neural network [C] // 2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT). IEEE, 2019; 1-6.
- [8] ABIWINANDA N, HANIF M, HESAPUTRA S T, et al. Brain tumor classification using convolutional neural network [C] // World Congress on Medical Physics and Biomedical Engineering 2018, Prague, Czech Republic (Vol. 1). Springer Singapore, 2018: 183-189.
- [9] VANKDOTHU R, HAMEED M A, FATIMA H. A brain tumor identification and classification using deep learning based on CNN-LSTM method [J]. Computers and Electrical Engineering, 2022, 101: 107960.
- [10] AYADI W, ELHAMZI W, CHARFI I, et al. Deep CNN for brain tumor classification [J]. Neural Processing Letters, 2021, 53: 671-700.
- [11] KHAN H A, JUE W, MUSHTAQ M, et al. Brain tumor classification in MRI image using convolutional neural network [J]. Mathematical Biosciences and Engineering, 2020, 17(5): 6203-6216.
- [12] KUMAR R L, KAKARLA J, ISUNURI B V, et al. Multi-class brain tumor classification using residual network and global average pooling [J]. Multimedia Tools and Applications, 2021, 80: 13429-13438.
- [13] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.
- [14] DING X H, ZHANG X Y, HAN J G, et al. Scaling up your kernels to 31x31: Revisiting large kernel design in cnns [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022: 11963-11975.
- [15] DIAZ-PERNAS F J, MARTINEZ-ZARZUELA M, ANTON-RODRIGUEZ M, et al. A deep learning approach for brain tumor classification and segmentation using a multiscale convolutional neural network [C] // Healthcare, MDPI, 2021, 9(2): 153.
- [16] 黄敏,熊正云,朱俊琳.基于多尺度残差网络的 MRI 脑肿瘤分类[J].磁共振成像,2023,14(1):124-129.
- [17] 艾玲梅,李天东,廖福元,等.基于注意力 U-Net 的脑肿瘤磁共振图像分割[J].激光与光电子学进展,2020,57(14):279-286.
- [18] 周涛,霍兵强,陆惠玲,等.残差神经网络及其在医学图像处理中的应用研究[J].电子学报,2020,48(7):1436-1447.
- [19] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 7132-7141.
- [20] DEEPAK S, AMEER P M. Brain tumor classification using deep CNN features via transfer learning [J]. Computers in Biology and Medicine, 2019, 111: 103345.
- [21] SINGH P, SIZIKOVA E, CIRRONE J. CASS: cross architectural self-supervision for medical image analysis [J]. Arxiv Preprint Arxiv: 2206.04170, 2022.
- [22] 马崇昇,唐娉,赵理君,等.深度学习图像数据扩增方法研究综述[J].中国图象图形学报,2021,26(3): 487-502.
- [23] SWATI Z N K, ZHAO Q, KABIR M, et al. Brain tumor classification for MR images using transfer learning and fine-tuning [J]. Computerized Medical Imaging and Graphics, 2019, 75: 34-46.
- [24] KAPLAN K, KAYA Y, KUNCAN M, et al. Brain tumor classification using modified local binary patterns (LBP) feature extraction methods [J]. Medical hypotheses, 2020, 139: 109696.