

DOI:10.19651/j.cnki.emt.2519530

# 优化 EfficientNet 架构的可解释性脑肿瘤 分类模型研究\*

郭心茹 吕卫东 王蕊 赵迪妮

(兰州交通大学数理学院 兰州 730070)

**摘要:** 脑肿瘤是一类具有高度侵袭性的神经系统疾病,其早期准确诊断对于制定个性化治疗方案至关重要。基于深度学习的计算机辅助诊断(CAD)技术在医学成像分析中取得了显著进展,但在分类准确性、计算效率及可解释性方面仍存在不足。为此,研究提出了一种基于迁移学习和微调策略优化的 EfficientNet 模型,通过改进部分卷积层和全连接层,并在网络顶部添加全局平均池化层与 Dropout 层,以增强模型的特征提取能力与分类性能。同时,引入 Grad-CAM 技术实现模型决策过程可视化,有效突出脑肿瘤的关键判别特征区域,从而增强模型的可解释性与临床应用可信度。在 Figshare 数据集上的实验结果表明,所提模型在显著降低参数量与计算复杂度的同时,测试集上的准确率达到 99.35%,主要性能指标均优于 VGG16、ResNet152V2 及 Vision Transformer 等模型。此外,跨数据集验证实验中模型的准确率达到 92.51%,进一步验证了其良好的稳定性与泛化能力。

**关键词:** 脑肿瘤;EfficientNet;图像分类;可解释性

**中图分类号:** TP391;TN911 **文献标识码:** A **国家标准学科分类代码:** 520.6040

## Research on optimizing interpretability of EfficientNet architecture brain tumor classification model

Guo Xinru Lyu Weidong Wang Rui Zhao Dini

(School of Mathematics and Physics, Lanzhou Jiaotong University, Lanzhou 730070, China)

**Abstract:** Brain tumors are highly invasive neurological diseases, and accurate early diagnosis is crucial for developing personalized treatment plans. Computer-aided diagnosis (CAD) based on deep learning techniques has achieved significant progress in medical image analysis, but limitations remain in terms of classification accuracy, computational efficiency, and interpretability. To address these issues, this study proposes an optimized EfficientNet model based on transfer learning and fine-tuning strategies. The model improves certain convolutional and fully connected layers and adds a global average pooling layer and a Dropout layer at the top of the network to enhance feature extraction capability and classification performance. Additionally, gradient-weighted class activation mapping (Grad-CAM) is introduced to visualize the model's decision-making process, effectively highlighting key discriminative regions of brain tumors, thereby improving interpretability and clinical reliability. Experimental results on the Figshare dataset demonstrate that the proposed model achieves an accuracy of 99.35% on the test set while significantly reducing parameter count and computational complexity, outperforming baseline models including VGG16, ResNet152V2, and Vision Transformer across all major metrics. Furthermore, cross-dataset validation shows that the model attains an accuracy of 92.51%, further demonstrating its robust stability and generalization capability.

**Keywords:** brain tumor; EfficientNet; image classification; explainability

## 0 引言

人脑作为调控生理功能的主要器官,易受到多种疾病

的侵袭,脑肿瘤是常见且侵袭性较强的一种,可生长在脑内任何位置,通过压迫周围正常组织影响神经功能,严重时可危及生命<sup>[1]</sup>。脑肿瘤生长速度、分期及位置是评估预后的

收稿日期:2025-08-04

\* 基金项目:国家自然科学基金(12462002)项目资助

关键因素,因此,在确定治疗方案前需明确脑肿瘤类型及病变程度。医学影像技术是诊断脑肿瘤的主要手段,常用方法包括核磁共振成像(magnetic resonance imaging, MRI)、计算机断层扫描(CT)等。其中,MRI 具备高分辨率和多参数成像优势,可直观呈现肿瘤形态、大小与边界,其弥散加权成像能分析脑组织的微观结构变化,有助于评估脑肿瘤区域的血流特征<sup>[2-3]</sup>。而当前人工诊断方法存在主观性强、耗时久与误判风险高等缺点,且脑肿瘤在大小、形状和分期等方面存在差异,进一步增加了检测和分类难度。

近年来,深度学习凭借自动特征提取和分类能力被广泛用于医学影像分析。研究表明,深度学习技术能够从大规模影像数据中自动提取深层特征,有效提高检测准确性与临床诊断效率<sup>[4-5]</sup>,加快治疗决策。Sadad 等<sup>[6]</sup>基于卷积神经网络(convolutional neural network, CNN)提出 NASNet 模型,在多类别脑肿瘤分类中的准确率高达 99.6%,优于 ResNet50 和 MobileNetV2 模型。Maqsood 等<sup>[7]</sup>将支持向量机与深度神经网络融合,在多模态脑肿瘤分类任务上取得了 96% 的准确率。Noreen 等<sup>[8]</sup>提出了一种基于迁移学习的融合特征方法,提取 Inception-V3 与 DenseNet201 的深度特征进行串联,准确率达到了 99.34% 和 99.51%。Rajinikanth 等<sup>[9]</sup>探索了基于 CNN 分类的 CAD 技术,发现 SVM 在 10 倍交叉验证中准确率为 97.0%,DenseNet201 等 CNN 模型准确率仅为 89%。Ye 等<sup>[10]</sup>采用遗传算法进行脑肿瘤 MRI 图像分割,在不同数据集上达到了 98.6% 和 99.1% 的分类准确率。Elhadidy 等<sup>[11]</sup>将 Swin Transformer 与 EfficientNet-B7 模型用于脑肿瘤多分类任务,精确率分别为 98.08% 与 98.72%。随着深度学习在图像诊断中的广泛应用,模型的可解释性问题在临床实践中引发关注。Hossain 等<sup>[12]</sup>比较了 VGG16 与 InceptionV3 多种 CNN 的分类性能,并引入 LIME 实现可视化分析,增强模型可解释性。

尽管现有研究在脑肿瘤分类领域中取得了显著进展,但在计算成本与运行效率、模型可解释性等方面仍存在局

限。部分模型(如 Swin Transformer)虽能在一定程度上提高网络性能,但其参数规模及计算资源消耗较大,难以满足实际临床应用的效率要求;此外,已有研究引入 LIME 等方法提升模型可解释性,但缺乏深入的可解释性分析。针对上述问题,本文基于 EfficientNet 架构进行改进,提出了一种分类性能强且计算复杂度低的脑肿瘤 MRI 图像分类方法,并引入 Grad-CAM 技术。该方法充分利用自动缩放网络的深度、宽度和图像分辨率的优势,在提升分类准确率的同时提高模型效率、降低计算复杂度,增强其在临床场景中的应用性与可信度。研究的主要创新点和贡献为:

1)在预训练的 EfficientNet 系列模型基础上优化部分卷积层和全连接层结构,并在骨干网络顶部添加全局平均池化层与 Dropout 层,以增强特征泛化能力,从而构建高性能的 EfficientNet-B2 脑肿瘤分类模型。

2)系统评估多种主流深度学习模型,在公共脑肿瘤 MRI 数据集上对 VGG16、ResNet152V2、Vision Transformer (ViT) 及改进的 EfficientNet 模型进行对比实验。结果表明, EfficientNet-B2 模型在有效控制参数规模与计算资源消耗的同时,表现出优异性能。

3)引入梯度加权类激活映射(weighted class activation mapping, Grad-CAM)技术<sup>[13]</sup>增强模型可解释性,有效突出了脑肿瘤的关键判别特征区域,验证了其在临床应用中的潜在价值。

## 1 方 法

脑肿瘤 MRI 图像分类的整体框架如图 1 所示。考虑到数据有限性及类别不平衡问题,首先对图像进行预处理及数据增强。随后,基于优化的 EfficientNet 模型进行图像特征提取与分类,该模型由多层堆叠的 MBConv 模块的卷积块构成,能够高效提取多尺度图像特征;通过全局平均池化有效保留图像的关键信息。此外,结合迁移学习策略对模型进行训练,并引入 Grad-CAM 技术进行可视化分析。

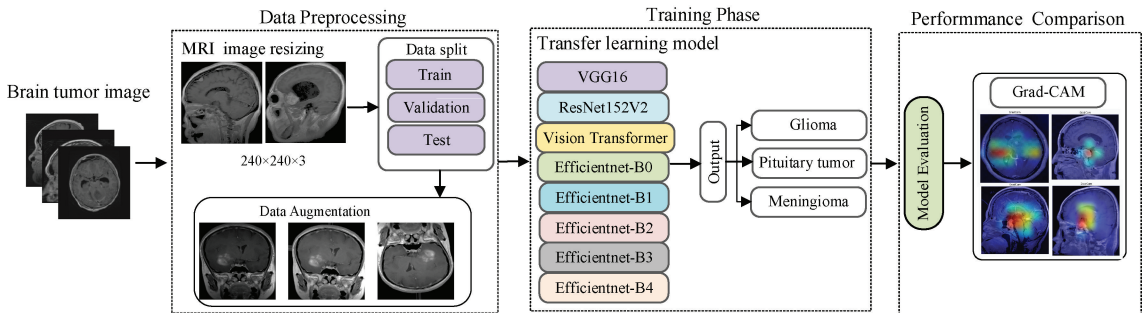


图 1 整体框架

Fig. 1 Overall framework

### 1.1 EfficientNet 模型

EfficientNet 是一种高效卷积神经网络架构<sup>[14]</sup>,基于神经架构搜索(neural architecture search, NAS)技术以结构化的方式扩展网络架构,在显著减少参数数量和计算开销

的同时展现出卓越性能<sup>[15-16]</sup>。考虑脑肿瘤图像数据规模、模型参数量及计算资源等因素,本研究选择 EfficientNet-B0 至 EfficientNet-B4 模型作为脑肿瘤分类的骨干网络,模型结构如图 2 所示。整体网络架构包括 Stem 层、7 个主模

块及输出层。其中,Block1 采用扩展因子为 1 的 MBCConv1 模块,结合  $3 \times 3$  卷积核提取初级特征,而其余 Block 采用 MBCConv6 模块,卷积核尺寸在  $3 \times 3$  和  $5 \times 5$  之间变化,以捕获更广泛的上下文信息,增强复杂背景下对脑肿瘤的认识能力。上述模块通过逐步提取和整合图像特征,增加感受野和特征丰富度,实现高效特征提取和分类。




图 2 EfficientNet 模型架构  
Fig. 2 EfficientNet architecture

示。该模块首先对输入的特征图通过  $1 \times 1$  卷积扩展维度以增强网络的表示能力,随后利用深度卷积提取高维特征,并通过  $1 \times 1$  卷积进行降维,以减少计算量。




图 4 MBCConv 结构  
Fig. 4 MBCConv structure

在深度卷积后引入 SE 注意力机制,以有效增强通道间的特征表达能力;加入批量归一化(batch normalization, BN)操作能够在训练过程中动态调整归一化参数。此外, MBCConv 采用残差连接结构,将输入特征图与深度可分离卷积的输出相加,有助于缓解梯度消失问题。

### 1.2 改进的 EfficientNet-B2 结构

研究基于迁移学习技术对 EfficientNet 模型进行微调,以 EfficientNet-B2 模型为例,改进的网络架构如图 5 所示。在结构设计上,保留了模型原有的 7 个模块、Swish 激活函数、SE 注意力机制及批量归一化操作等,这些结构能够更好地捕捉 MRI 图像的复杂细节,提升模型的特征提取能力。

在特征提取阶段,将输入图像经过结合 SE 的卷积层进行初步特征提取,随后通过多层堆叠的 MBCConv 模块进一步提取图像特征。通过在网络顶部引入全局平均池化层,将特征图的空间维度压缩到固定大小以有效提取图像的关键信息,降低过拟合风险;同时添加 Dropout 层,在训练过程中随机丢弃部分神经元,确保模型不会过度依赖于特定的数据点或模式;最后,添加了一个包含 3 个神经元的全连接层,并使用 Softmax 激活函数输出概率分布。此外,为避免特征提取阶段参数过度更新、降低模型的过拟合风险,在引入 Dropout 层前,选择性地冻结 EfficientNet 网络中部分初始卷积块。

## 2 数据处理与实验设置

### 2.1 数据集介绍

研究采用 Figshare 数据集<sup>[19]</sup>,该数据集于 2005 年~2010 年期间从广州南方医院和天津医科大学总医院获得,包含 233 名患者的 3 064 张加权增强 MRI 图像,涵盖 3 类脑肿瘤:脑胶质瘤(glioma, 1 426 张)、脑膜瘤(meningioma, 708 张)和垂体瘤(pituitary tumor, 930 张),如图 6 所示。每张图像均为 2D 切片,由 3 名经验丰富的神经放射科医生手工标注肿瘤与正常组织的边界,能够清晰呈现脑部结构与病变区域的细节信息。

### 2.2 数据预处理

为了提升模型在脑肿瘤 MRI 分类任务中的鲁棒性与

### 1) SE 注意力机制

SE(squeeze and excitation)<sup>[17]</sup>注意力是一种通道注意力机制,其核心思想是对原始特征进行重构得到更重要的特征信息并抑制无关的特征信息。SE 注意力机制主要包含特征压缩、激活映射和通道加权 3 个关键步骤,其结构如图 3 所示。图 3 中  $U$  为特征图像; $W$  为图像的宽; $H$  为图像的高; $C$  为图像的通道数; $X$  为经过 SE 注意力处理后输出的特征图像。




图 3 SE 注意力模块  
Fig. 3 SE attention module

第 1 层将平均值向量压缩为  $1 \times 1 \times C$  的特征,以减少计算开销,计算公式为:

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

其中,  $W$  和  $H$  分别为输入特征的宽和高;  $u_c(i, j)$  为通道  $i$  和  $j$  上的单一元素点。

第 2 层为激活层,使用 Sigmoid 或 ReLu 激活函数学习各通道的权重,表达式为:

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

其中,  $\sigma$  为 ReLu 激活函数;  $\delta$  为 Sigmoid 激活函数;  $W_1$  为降维层的参数;  $W_2$  为升维层的参数。

第 3 层,通过特征加权  $F_{scale}(\cdot, \cdot)$  逐通道加权到原特征图上完成通道维度上的注意力机制计算,计算公式为:

$$F_{scale}(u_c, s_c) = s_c u_c \quad (3)$$

其中,  $s_c$  为第  $C$  个通道的裁剪系数,  $u_c$  为第  $C$  个通道的特征图。

### 2) MBCConv 模块

EfficientNet 模型主要由 MBCConv 核心模块组成,其具有与 MobileNetV2<sup>[18]</sup>网络类似的倒残差结构,如图 4 所

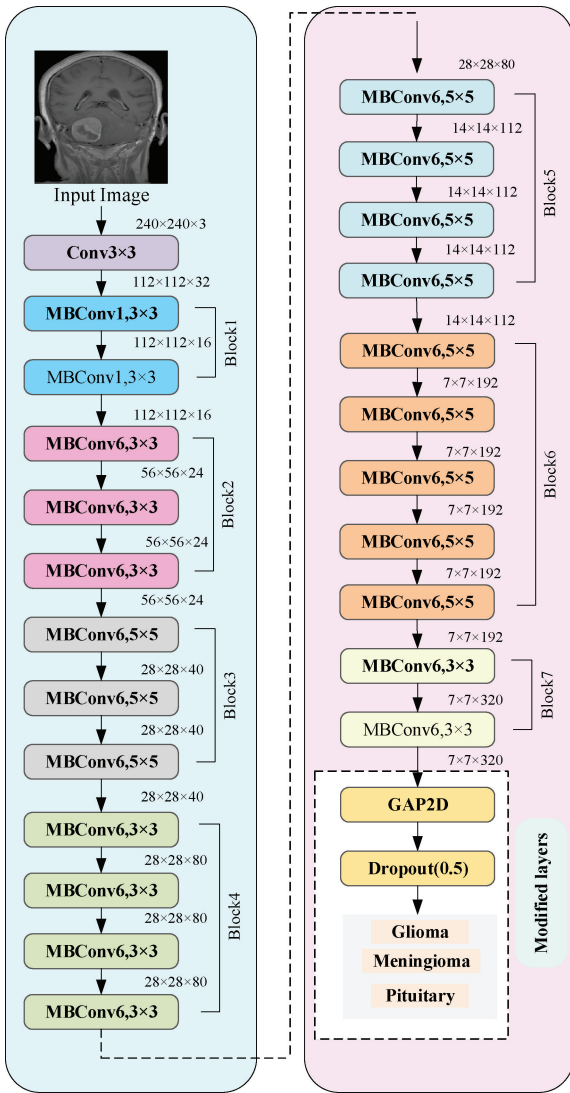


图 5 微调的 EfficientNet-B2 模型结构

Fig. 5 Structure of the EfficientNet-B2 model

性能,对原始图像进行数据预处理。由于伪影和脑组织在灰度分布上具有显著差异,采用基于全局阈值的二值化策略,这里采用 `cv2.threshold()` 函数并设定阈值  $T$  为 50,将灰度值低于  $T$  的伪影、背景等干扰信息像素点设为 0,而灰度值大于或等于  $T$  的部分保持不变,作为感兴趣区域 (region of interest, ROI)。随后使用  $5 \times 5$  高斯核进行模糊处理并分别执行两次腐蚀和两次膨胀操作,进一步去除孤立小噪声区域与伪影干扰。为准确获取肿瘤区域,从处理后的图像中提取面积最大的外部轮廓以确定上、下、左、右 4 个边界坐标,并在此基础上外扩 10~15 个像素,在保留关键病灶区域信息同时剔除背景噪声和冗余部分。最终将图像裁剪为  $240 \times 240 \times 3$ ,以满足后续模型的输入要求<sup>[20]</sup>。

为避免在模型训练中引入图像数据序列偏差,在实验前将所有样本随机打乱,采用 `splitfolders_ratio` 工具,设定




图 6 不同类型的脑肿瘤图像

Fig. 6 Image of different brain tumor types

随机种子  $seed=3$ ,按照 8:2 的比例划分训练集和测试集,数据集分布如表 1 所示。

表 1 数据集分布情况

Table 1 Dataset distribution

类别	原数量	训练集数量	测试集数量
Glioma	1 426	1 140	286
Meningioma	708	566	142
Pituitary tumor	930	744	186
合计	3 064	2 450	614

为防止模型过拟合并提升泛化能力,研究采用旋转、平移、翻转等 5 种数据增强策略<sup>[21]</sup>扩充样本,增强模型鲁棒性,数据增强的具体参数设置如表 2 所示。

表 2 数据增强的参数设置

Table 2 Data augmentation parameters

参数设置	作用
<code>rotation_range=10</code>	图像随机旋转 $\pm 10^\circ$
<code>width_shift_range=0.1</code>	图像水平平移,范围为图像宽度的 10%
<code>height_shift_range=0.1</code>	图像垂直平移,范围为图像高度的 10%
<code>horizontal_flip=True</code>	随机水平翻转
<code>vertical_flip=True</code>	随机垂直翻转
<code>fill_mode='nearest'</code>	由于变换导致的图像边缘出现空白区域,使用最近邻策略填充

为避免影响模型评估准确性,研究仅在训练集上执行数据增强,测试集不作处理。同时,将脑胶质瘤、脑膜瘤和垂体瘤图像分别增强至原始数量的 2 倍、5 倍和 4 倍以平衡数据集的类别分布,数据增强后的图像数量如图 7 所示。最后,将胶质瘤、脑膜瘤和垂体瘤的标签分别编码为

0、1 和 2, 并进行独热编码处理, 为后续模型训练做准备。

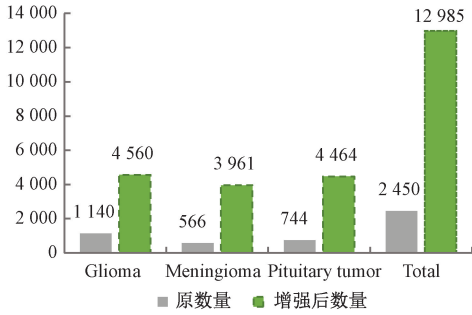


图 7 数据增强后的样本分布

Fig. 7 Sample distribution after data augmentation

### 3 实验结果与分析

#### 3.1 实验配置

本实验环境为 64 位 Windows10 操作系统, 编程语言为 Python 3.10, 采用 TensorFlow2.10.0 为主要框架, 结合 CUDA11.2 实现 GPU 加速, 硬件配置为 NVIDIA GeForce RTX 4060, 第 12 代 Intel® Core™ i7-12650H 处理器(2.30 GHz)。

训练过程中的训练集由原始图像及增强图像组成, 验证集仅包含原始图像, 以避免数据泄露。采用 Adam 优化器, 使模型更好地学习脑肿瘤图像中的判别特征; 选择交叉熵损失函数确定预测损失, 该损失函数适用于处理多类别任务中 one-hot 编码标签, 计算公式为:

$$\text{Loss} = - \sum_{i=1}^N p_i \log(q_i) \quad (4)$$

$$p_i = \begin{cases} 1, & y = i \\ 0, & y \neq i \end{cases} \quad (5)$$

其中,  $N$  为类别数;  $q_i$  表示模型的预测概率。

模型训练参数如下: EfficientNet 模型训练轮数设为 30, VGG16、ResNet152v2 及 ViT 模型设为 50 轮, 批处理大小均为 32。为防止过拟合并提高训练效率, 引入 ReduceLROnPlateau 回调机制: 当验证准确率在连续 5 个周期内无明显提升时, 将初始学习率 0.001 以衰减因子 0.3 进行降低, 设定最小变化阈值为 0.001, 训练过程通过回调函数保存验证集表现最佳的模型权重, 便于后续性能比较与分析。此外, 在训练时加入早停机制, 当验证准确率连续 5 个周期内未提升时提前终止训练, 并恢复验证性能最佳时的模型权重。针对特征提取阶段可能出现的过拟合问题, 在引入 Dropout 层前冻结部分初始卷积模块, 减少特征提取阶段的过度更新。

#### 3.2 性能评估指标

为全面评估模型在脑肿瘤分类任务中的性能, 研究引入了多种常用的性能评价指标进行分析, 包括准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall)、F1 分数 (F1)、敏感性 (Sensitivity) 和特异性 (Specificity)。相关计

算公式如式(6)~(11)所示。

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

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

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

$$F1 = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (9)$$

$$\text{Sensitivity} = \text{Recall} = \frac{TP}{TP + FN} \quad (10)$$

$$\text{Specificity} = \text{TNR} = \frac{TN}{TN + FP} \quad (11)$$

其中, 真阳性(true positive, TP)表示预测和实际值均为正类; 真阴性(true negative, TN)表示预测和实际值均为负类; 假阳性(false positive, FP)表示预测为正类, 实际为负类; 假阴性(false negative, FN)表示预测为负类, 实际为正类。

#### 3.3 对比实验

##### 1) 模型性能对比

在脑肿瘤的多分类任务中, 分别对 VGG16、ViT、ResNet152V2 及微调后的 EfficientNet-B0 至 EfficientNet-B4 模型的性能进行评估, 实验结果如表 3 所示。由表 3 可知, 微调后的 EfficientNet-B2 模型在所有评估指标上均表现最优; 同时, 模型在脑膜瘤类别上的识别敏感性相对较差, 可能与其在测试集中样本数量相对较少有关。由表 4 可知, EfficientNet-B2 模型在测试集上表现出优越性能, 准确率为 99.35%, 精确率为 99.36%、召回率为 99.35%, F1 分数为 99.35%。

为评估 EfficientNet-B2 模型在训练过程中的性能变化, 绘制在训练集和验证集上的准确率与损失变化曲线。由图 8(a)可知, 模型在训练初期收敛速度较快, 随后趋于稳定, 在第 22 个 epoch 时模型已基本收敛。图 8(b)显示训练损失持续降低并最终接近零, 表明模型有效优化参数以最小化预测误差。

图 9 展示了模型在测试集上的多类别混淆矩阵, 可以看出, 胶质瘤的 286 例均被正确分类; 脑膜瘤中的 139 例被正确识别, 其中 3 例被误分类为胶质瘤; 垂体瘤有 185 例被正确识别, 仅 1 例被误判为胶质瘤, 模型对各类肿瘤的分类总体准确。对于少数脑膜瘤和垂体瘤样本误判为胶质瘤, 可能与不同肿瘤类型间影像特征的重叠或图像细节的细微相似性有关<sup>[22]</sup>。模型在判断胶质瘤时通常更关注脑部边缘区域, 而部分脑膜瘤在该区域具有与胶质瘤相似的图像特征, 可能导致模型误判<sup>[23]</sup>。此外, 胶质瘤和垂体瘤在训练集中样本量较少, 这种差异造成的类别不平衡可能会影响模型的判别能力。

##### 2) 数据增强对所模型泛化能力的影响

为验证数据增强的效果, 分别在原始数据集和增强数

表 3 不同模型对比实验


Table 3 Comparative experiments of models different models

模型	类别	Pre	Sen	Spe	F1	模型	类别	Pre	Sen	Spe	F1
VGG16	Glioma	0.959 8	0.916 4	0.957 0	0.937 7	EfficientNet-B1	Glioma	0.979 4	0.996 5	0.981 7	0.987 9
	Meningioma	0.901 5	0.896 2	0.875 0	0.898 8		Meningioma	0.992 7	0.957 7	0.997 9	0.974 9
	Pituitary	0.982 0	0.991 0	0.970 0	0.986 4		Pituitary	1.000 0	1.000 0	1.000 0	1.000 0
ResNet152V2	Glioma	0.945 4	0.938 6	0.951 0	0.941 9	EfficientNet-B2	Glioma	<b>0.993 0</b>	<b>1.000 0</b>	<b>0.993 9</b>	<b>0.994 8</b>
	Meningioma	0.915 8	0.972 0	0.915 2	0.943 1		Meningioma	<b>1.000 0</b>	<b>0.978 9</b>	<b>1.000 0</b>	<b>0.989 3</b>
	Pituitary	0.945 3	0.965 0	0.949 0	0.955 1		Pituitary	<b>1.000 0</b>	<b>0.994 6</b>	<b>1.000 0</b>	<b>0.99 73</b>
ViT	Glioma	0.912 0	0.906 1	0.918 0	0.909 0	EfficientNet-B3	Glioma	0.986 0	0.986 0	0.987 8	0.986 0
	Meningioma	0.919 0	0.917 0	0.918 3	0.918 0		Meningioma	0.971 2	0.950 7	0.991 5	0.960 9
	Pituitary	0.922 7	0.933 8	0.923 0	0.928 2		Pituitary	0.984 1	1.000 0	0.993 0	0.992 0
EfficientNet-B0	Glioma	0.986 2	0.996 5	0.987 8	0.993 1	EfficientNet-B4	Glioma	0.993 0	0.986 0	0.993 9	0.989 5
	Meningioma	0.992 9	0.978 9	0.997 9	0.985 8		Meningioma	0.936 6	0.993 9	0.956 8	0.977 9
	Pituitary	0.994 7	1.000 0	0.997 7	0.997 3		Pituitary	1.000 0	0.981 3	0.978 9	0.958 8


表 4 EfficientNet 模型的性能表现

Table 4 Performance of EfficientNet model

模型	Accuracy	Precision	Recall	F1
EfficientNet-B0	0.986 2	0.993 5	0.991 8	0.992 6
EfficientNet-B1	0.988 6	0.988 7	0.988 6	0.988 5
EfficientNet-B2	0.993 5	0.993 6	0.993 5	0.993 5
EfficientNet-B3	0.982 1	0.982 0	0.982 1	0.982 0
EfficientNet-B4	0.978 8	0.979 1	0.978 8	0.978 7



(a) 准确率  
(a) Accuracy



(b) 损失  
(b) Loss

图 8 准确率和损失变化曲线

Fig. 8 Accuracy and loss curves

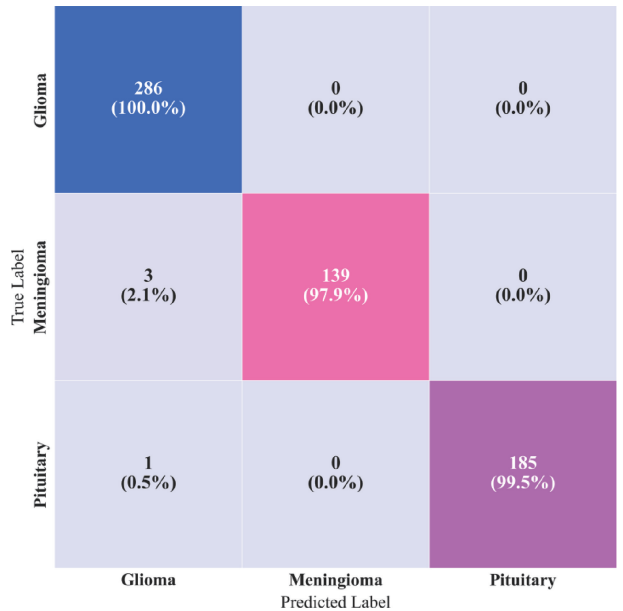


图 9 分类结果混淆矩阵

Fig. 9 Confusion matrix of classification results

数据集上训练模型并进行性能比较,对比结果如图 10 所示。结果显示,当采用数据增强策略时,模型在各项指标上均取得更优表现,数据增强使模型分类准确率提升了 1.63%,有效增强了模型的泛化能力。

3)与前沿方法比较

表 5 总结并对比了本文模型与多种深度学习方法在脑肿瘤分类任务中的性能表现。结果显示, EfficientNet-B2 模型在测试集上取得了 99.35% 的准确率,优于其他模型,进一步验证了所提方法在复杂临床图像分类中的有效性和应用潜力。

4)计算复杂度和参数量对比

除分类性能外,本文模型在参数量和计算资源消耗方面也具有明显优势, EfficientNet-B2 模型在保证高精度的

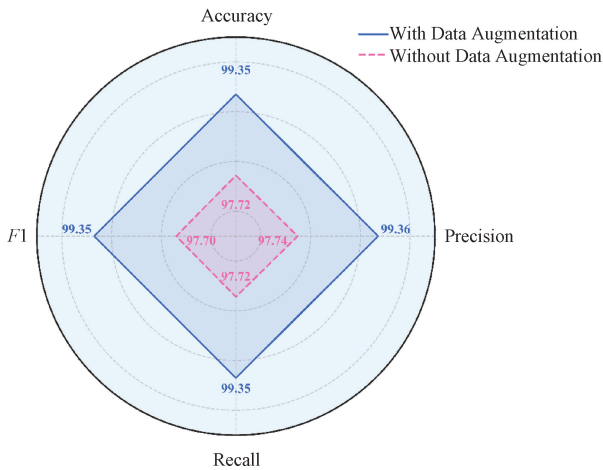


图 10 使用数据增强技术前后的性能对比

Fig. 10 Performance before and after data augmentation

表 5 性能比较分析结果

Table 5 Results of performance comparison analysis

来源	模型	Acc
文献[24]	UL-DLA+GLCM	99.23
文献[25]	Adaptive fusion network	98.98
文献[26]	Densenet121	91.30
	YOLO3	96.70
文献[27]	MobileNetV3	98.50
文献[28]	NeuroNet19	99.31
文献[29]	Customized EfficientNet-B7 model	98.40
文献[30]	Ensemble (Inceptionv3+Xception)	96.89
本文方法	Proposed EfficientNet-B2	<b>99.35</b>

同时,显著降低了模型体积与计算开销。在推理效率上, EfficientNet-B2 模型相较于 VGG16 提速超过两倍,较 ResNet152V2 提升约 1.5 倍,显著增强了对 MRI 图像的处理能力。进一步比较 EfficientNet-B0 至 B4 模型,随着参数量从  $4.05 \times 10^6$  增大至  $17.70 \times 10^6$ ,模型 EfficientNet-B3

与 EfficientNet-B4 的分类准确率并未提升,具体如表 6 所示。结果表明, EfficientNet-B2 模型在中等参数规模下准确率达到 99.35%,高于其他模型,参数量为  $7.7 \times 10^6$ ,计算复杂度仅为  $1.64 \times 10^9$  FLOPs,在减少模型体积与计算成本的同时具有优越性能,为医学图像分类提供了一种快速、高效的轻量化解决方案。

表 6 模型的参数量, FLOPs 及分类性能

Table 6 Model parameters, FLOPs, and performance

模型	输入尺寸	参数量 ( $\times 10^6$ )	FLOPs ( $\times 10^9$ )	Acc/ %
VGG16	224 $\times$ 224	58.34	30.71	94.21
ResNet152V2	224 $\times$ 224	17.68	25.36	92.60
ViT	224 $\times$ 224	86.84	16.85	91.35
EfficientNet-B0	224 $\times$ 224	4.05	0.96	98.62
EfficientNet-B1	224 $\times$ 224	6.58	1.42	98.86
EfficientNet-B2	224 $\times$ 224	7.77	<b>1.64</b>	<b>99.35</b>
EfficientNet-B3	224 $\times$ 224	10.79	2.38	98.21
EfficientNet-B4	224 $\times$ 224	17.70	3.72	97.97

### 3.4 使用 Grad-CAM 进行可视化分析

在脑肿瘤分类领域,模型的可解释性对辅助临床决策有重要意义。Grad-CAM 能够突出显示输入图像中对某类别预测最具贡献的区域,该方法利用目标梯度的概念,将传递到最后一个卷积层和激活层,生成一张表示不同空间位置对预测贡献程度的定位图。从 EfficientNet-B2 模型的最后一个卷积层提取特征,得到的可视化结果如图 11 所示。在图 11 中,最下方为原始脑肿瘤 MRI 图像;中间为生成的特征空间注意力图与原始图像叠加所形成的红色区域,表示对预测贡献最大的区域,最上方则为模型提取的特征注意力图。从图中可以看出,模型聚焦的重点区域与肿瘤及瘤周区域高度一致,为分类结果提供了可靠依据。Grad-CAM 的应用可以帮助医生更好地理解模型决策,为脑肿瘤的认识与诊断提供有效支持。

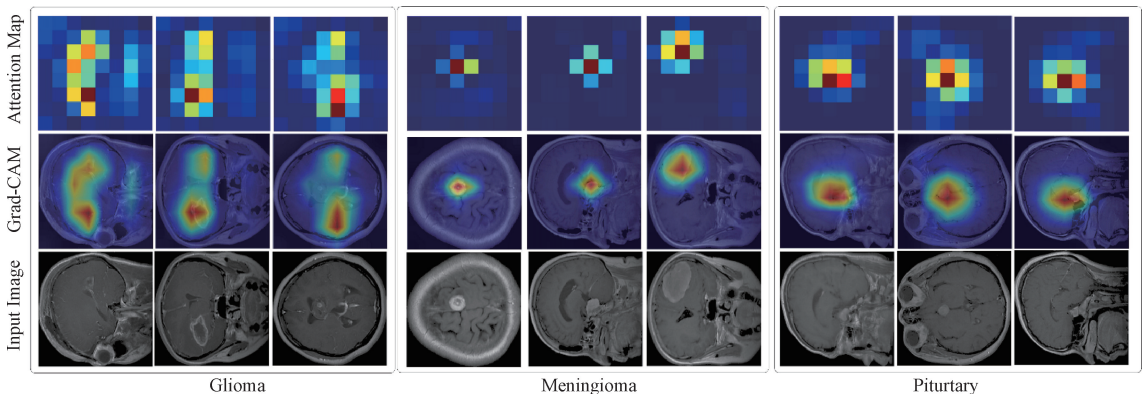


图 11 Grad-CAM 热力图

Fig. 11 Grad-CAM heatmaps

### 3.5 泛化实验

为验证本文 EfficientNet-B2 模型在其他数据集上的泛化能力与稳定性,本文在公开的 Kaggle 脑肿瘤 MRI 数据集上<sup>[31]</sup>进行泛化实验,该数据集有 3 264 张图像,包含脑胶质瘤、脑膜瘤、垂体瘤和无肿瘤 4 种类别。由于所提模型未针对正常情况进行训练,因此在验证中排除了正常类别。在保持原本数据处理流程和超参数设置不变的情况下将泛化数据集送入模型中进行实验,表 7 展示了本文的改进的 Efficient 系列模型的实验结果。

表 7 Kaggle 数据集实验结果

Table 7 Kaggle dataset experiment results %

模型	Accuracy	Precision	Recall	F1
EfficientNet-B0	0.891 8	0.896 2	0.891 8	0.892 5
EfficientNet-B1	0.888 9	0.903 2	0.888 9	0.890 2
EfficientNet-B2	0.925 1	0.925 6	0.925 1	0.925 2
EfficientNet-B3	0.841 2	0.854 7	0.841 2	0.842 7
EfficientNet-B4	0.888 2	0.895 4	0.888 2	0.888 4

由实验结果可知,其他 4 种模型在原始数据集上表现良好,但在该泛化数据集上表现一般,而本文提出的 EfficientNet-B2 模型在 Figshare 数据集和公开的 Kaggle 脑肿瘤 MRI 数据集上均表现出最佳性能,其准确率、精确率、召回率和 F1 分数分别为 92.51%、92.56%、92.51% 和 92.52%,进一步证实了其在泛化适应性方面的显著优势。

## 4 结 论

本文对脑肿瘤 MRI 图像进行分类研究,所提模型在公开脑肿瘤数据集上展现出卓越的分类能力,并有效控制了参数规模与计算资源。同时,引入 Grad-CAM 可视化技术增强模型决策过程的可解释性。改进后的 EfficientNet-B2 模型在测试集上的各项评价指标上均优于对比模型,表现出较高的分类能力。考虑到本研究仅使用 MRI 图像数据进行训练,未能充分捕捉真实临床场景中数据的多样性,未来研究可将患者病史等多源临床数据相整合,进一步增强模型的预测能力和对代表性不足的患者群体的诊断能力,实现个性化和精确诊断。其次,未来可在本研究基础上进一步探究如单一脑转移瘤、胶质瘤亚型分级等具体分类任务,以推动模型的临床适用性。

## 参考文献

[1] SAEEDI S, REZAYI S, KESHAVARZ H, et al. MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques[J]. BMC Medical Informatics and Decision Making, 2023, 23(1): 16.

[2] 薛彩强, 刘显旺, 邓娟, 等. 深度学习在脑肿瘤医学图像研究进展[J]. 中国医学影像技术, 2019, 35(12): 1813-1816.

XUE C Q, LIU X W, DENG J, et al. Research progress of deep learning in brain neoplasm imaging[J]. Chinese Journal of Medical Imaging Technology, 2019, 35(12): 1813-1816.

[3] 钟海杰, 吴晓红, 卿粼波, 等. 基于多模态脑影像的阿尔茨海默病分类方法[J]. 电子测量技术, 2024, 47(23): 134-143.

ZHONG H J, WU X H, QING L B, et al. Classification of Alzheimer's disease based on multimodal brain images[J]. Electronic Measurement Technology, 2024, 47(23): 134-143.

[4] 冷冰, 冷敏, 常智敏, 等. 基于 Transformer 结构的深度学习模型用于外周血白细胞检测[J]. 仪器仪表学报, 2023, 44(5): 113-120.

LENG B, LENG M, CHANG ZH M, et al. Deep learning model based on Transformer architecture for peripheral blood leukocyte detection [J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 113-120.

[5] 夏平, 何志豪, 雷帮军, 等. 密集级联卷积与自注意力特征聚合的视网膜血管分割算法[J]. 电子测量与仪器学报, 2024, 38(9): 36-44.

XIA P, HE ZH H, LEI B J, et al. Retinal vascular segmentation algorithm based on full scale dense convolutional u-shaped networks [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(9): 36-44.

[6] SADAD T, REHMAN A, MUNIR A, et al. Brain tumor detection and multi-classification using advanced deep learning techniques[J]. Microscopy Research and Technique, 2021, 84(6): 1296-1308.

[7] MAQSOOD S, DAMAŠEVIČIUS R, MASKELIŪNAS R. Multi-modal brain tumor detection using deep neural network and multiclass SVM[J]. Medicina, 2022, 58(8): 1090.

[8] NOREEN N, PALANIAPPAN S, QAYYUM A, et al. A deep learning model based on concatenation approach for the diagnosis of brain tumor[J]. IEEE Access, 2020, 8: 55135-55144.

[9] RAJINIKANTH V, KADRY S, NAM Y. Convolutional-neural-network assisted segmentation and SVM classification of brain tumor in clinical MRI slices[J]. Information Technology and Control, 2021, 50(2): 342-356.

[10] YE J H, ZHAO ZH Y, GHAFOURIAN E, et al. Optimizing the topology of convolutional neural network(CNN) and artificial neural network(ANN) for brain tumor diagnosis(BTD) through MRIs[J]. Heliyon, 2024, 10(16): e35083.

[11] ELHADIDY M S, ELGOHR A T, EL-GENEEDY M, et al. Comparative analysis for accurate multi-classification of brain tumor based on significant deep learning models [J]. Computers in Biology and

- Medicine, 2025, 188: 109872.
- [12] HOSSAIN S, CHAKRABARTY A, GADEKALLU T R, et al. Vision transformers, ensemble model, and transfer learning leveraging explainable ai for brain tumor detection and classification[J]. IEEE Journal of Biomedical and Health Informatics, 2023, 28(3): 1261-1272.
- [13] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization [C]. 2017 IEEE international Conference on Computer Vision, 2017: 618-626.
- [14] TAN M X, LE Q V. Efficientnet: Rethinking model scaling for convolutional neural networks [C]. International Conference on Machine Learning. PMLR, 2019: 6105-6114.
- [15] ZAITOON R, MOHANTY S N, GODAVARTHI D, et al. SPBTGNS: Design of an efficient model for survival prediction in brain tumour patients using generative adversarial network with neural architectural search operations [J]. IEEE Access, 2024, 12: 140847-140869.
- [16] 吕游, 郑茜, 齐欣宇, 等. 基于改进 EfficientNet 的红外图像光伏组件故障识别研究[J]. 仪器仪表学报, 2024, 45(4): 175-184.
- LYU Y, ZHENG X, QI X Y, et al. A study on fault recognition of photovoltaic module with infrared images based on improved efficientnet[J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 175-184.
- [17] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. 2018 IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [18] SANDLER M, HOWARD A, ZHU M L, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]. 2018 IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [19] CHENG J, YANG W, HUANG M Y, et al. Retrieval of brain tumors by adaptive spatial pooling and fisher vector representation[J]. PloS One, 2016, 11(6): 0157112.
- [20] MOUSA M A A, ELGOHR A T, KHATER H. Whale-based trajectory optimization algorithm for 6 DOF robotic arm [J]. Annals of Emerging Technologies in Computing, 2024, 8(4): 99-114.
- [21] 杨锁荣, 杨洪朝, 申富饶, 等. 面向深度学习的图像数据增强综述 [J]. 软件学报, 2025, 36(3): 1390-1412.
- YANG S R, YANG H CH, SHEN F R, et al. Image data augmentation for deep learning: A survey[J]. Journal of Software, 2025, 36(3): 1390-1412.
- [22] RAHMAN M A, MIAH M B A, HOSSAIN M A, et al. Enhanced brain tumor classification using MobileNetV2: A comprehensive preprocessing and fine-tuning approach[J]. BioMedInformatics, 2025, 5(2): 30.
- [23] LI ZH K, DIB O. Empowering brain tumor diagnosis through explainable deep learning [J]. Machine Learning and Knowledge Extraction, 2024, 6(4): 2248-2281.
- [24] QURESHI S A, RAZA S E A, HUSSAIN L, et al. Intelligent ultra-light deep learning model for multi-class brain tumor detection [J]. Applied Sciences, 2022, 12(8): 3715.
- [25] AAMIR M, RAHMAN Z, ABRO W A, et al. Brain tumor classification utilizing deep features derived from high-quality regions in MRI images[J]. Biomedical Signal Processing and Control, 2023, 85: 104988.
- [26] SAHOO A K, PARIDA P, MURALIBABU K, et al. Efficient simultaneous segmentation and classification of brain tumors from MRI scans using deep learning[J]. Biocybernetics and Biomedical Engineering, 2023, 43(3): 616-633.
- [27] MATHIVANAN S K, SONAIMUTHU S, MURUGESAN S, et al. Employing deep learning and transfer learning for accurate brain tumor detection[J]. Scientific Reports, 2024, 14: 7232.
- [28] HAQUE R, HASSAN M M, BAIRAGI A K, et al. NeuroNet19: An explainable deep neural network model for the classification of brain tumors using magnetic resonance imaging data [J]. Scientific Reports, 2024, 14: 1524.
- [29] ISHAQ A, ULLAH F U M, HAMANDAWANA P, et al. Improved EfficientNet architecture for multi-grade brain tumor detection[J]. Electronics, 2025, 14(4): 710.
- [30] ASIF R N, NASEEM M T, AHMAD M, et al. Brain tumor detection empowered with ensemble deep learning approaches from MRI scan images [J]. Scientific Reports, 2025, 15: 15002.
- [31] MUEZZINOGLU T, BAYGIN N, TUNCER I, et al. PatchResNet: Multiple patch division-based deep feature fusion framework for brain tumor classification using MRI images [J]. Journal of Digital Imaging, 2023, 36(3): 973-987.

## 作者简介

郭心茹, 硕士研究生, 主要研究方向为深度学习与医学图像处理。

E-mail: 470946389@qq.com

吕卫东(通信作者), 硕士, 副教授, 主要研究方向为机器学习、可靠性理论。

E-mail: 2212963672@qq.com

王蕊, 硕士研究生, 主要研究方向为机器学习、缺陷检测。

E-mail: 1392198633@qq.com

赵迪妮, 硕士研究生, 主要研究方向为深度学习与生存分析。

E-mail: 1104256518@qq.com