

基于集成学习的MRI脑肿瘤智能诊断

李鑫蕊, 张艳芳, 康晓东, 李博, 韩俊玲

引用本文

李鑫蕊, 张艳芳, 康晓东, 李博, 韩俊玲. [基于集成学习的MRI脑肿瘤智能诊断](#)[J]. 计算机科学, 2024, 51(6A): 230600043-7.

LI Xinrui, ZHANG Yanfang, KANG Xiaodong, LI Bo, HAN Junling. [Intelligent Diagnosis of Brain Tumor with MRI Based on Ensemble Learning](#) [J]. Computer Science, 2024, 51(6A): 230600043-7.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[CTGANBoost:基于CTGAN与Boosting的信贷欺诈检测研究](#)

CTGANBoost:Credit Fraud Detection Based on CTGAN and Boosting

计算机科学, 2024, 51(6A): 230600199-7. <https://doi.org/10.11896/jsjcx.230600199>

[基于改进Efficientnetv2模型的铁矿石图像分类方法](#)

Iron Ore Image Classification Method Based on Improved Efficientnetv2

计算机科学, 2024, 51(6A): 230600212-6. <https://doi.org/10.11896/jsjcx.230600212>

[多重注意力引导的超声乳腺癌肿瘤图像分割](#)

Multiple Attention-guided Mechanisms for Ultrasound Breast Cancer Tumor Image Segmentation

计算机科学, 2024, 51(6A): 230500004-6. <https://doi.org/10.11896/jsjcx.230500004>

[基于多距离测度异质集成学习的结肠病理图像细粒度分类研究](#)

Fine-grained Colon Pathology Images Classification HAN Based on Heterogeneous Ensemble Learningwith Multi-distance Measures

计算机科学, 2024, 51(6A): 230400043-7. <https://doi.org/10.11896/jsjcx.230400043>

[面向3D肝脏CT图像分割的改进vnet模型](#)

Improved vnet Model for 3D Liver CT Image Segmentation

计算机科学, 2024, 51(6A): 230400038-6. <https://doi.org/10.11896/jsjcx.230400038>

基于集成学习的 MRI 脑肿瘤智能诊断

李鑫蕊¹ 张艳芳² 康晓东¹ 李博³ 韩俊玲^{1,4}

1 天津医科大学医学影像学院 天津 300202

2 重庆大学附属黔江医院 重庆 409000

3 天津市第三中心医院 天津 300170

4 天津市第一中心医院 天津 300192

(lixinrui1121@163.com)

摘要 脑肿瘤是由于颅脑内部组织出现癌变而导致的高危害疾病,及时诊断脑肿瘤对其治疗及预后至关重要。现阶段不同的网络模型有不同的分类效果,单一的网络模型很难在多个评价指标上有突出的表现。文中基于集成学习提出了一种分类功能强大的 Treer-Net 模型,它是以 TransFG,ResNet50,EfficientNet B4,EfficientNet B7 和 ResNeXt101 为基础模型,通过集成学习的加权平均的结合策略得到的模型。文中将其在脑肿瘤 MRI 二分类、三分类和四分类的公开数据集上训练完成分类任务。实验数据和结果表明,Treer-Net 模型在脑肿瘤三分类数据集上的准确率、精确率、召回率和 AUC 分别高达 99.15%,99.16%,99.15%和 99.87%,通过对比分析,充分验证了所提的集成学习方法具有精准、快捷的优越性,更适用于临床辅助诊断脑肿瘤。

关键词: 肿瘤;集成学习;图像分类;核磁共振影像

中图分类号 TP391

Intelligent Diagnosis of Brain Tumor with MRI Based on Ensemble Learning

LI Xinrui¹, ZHANG Yanfang², KANG Xiaodong¹, LI Bo³ and HAN Junling^{1,4}

1 School of Medical Imaging, Tianjin Medical University, Tianjin 300202, China

2 Chongqing University Qianjiang Hospital, Chongqing 409000, China

3 Tianjin Third Central Hospital, Tianjin 300170, China

4 Tianjin First Central Hospital, Tianjin 300192, China

Abstract Brain tumors are high-risk diseases caused by cancerous changes in the internal tissues of the brain, and timely diagnosis of brain tumors is crucial for their treatment and prognosis. At present, different network models have different classification effects, and a single network model is difficult to achieve outstanding performance on multiple evaluation indicators. This paper proposes a Treer-Net model with powerful classification function based on ensemble learning, which is based on TransFG, ResNet50, EfficientNet B4, EfficientNet B7 and ResNeXt101, and is obtained through the weighted average combination strategy of ensemble learning. This paper trains it to complete the classification tasks on the publicly available datasets of brain tumor MRI binary, tertiary and quaternary classifications. Experimental data and results show that the accuracy, precision recall and AUC of the Treer-Net model in the three classification datasets of brain tumors are up to 99.15%, 99.16%, 99.15% and 99.87% respectively. Through comparative analysis, it fully verifies that the ensemble learning method in this paper has the advantages of accuracy and speed, and is more suitable for clinical auxiliary diagnosis of brain tumors.

Keywords Brain tumor, Ensemble learning, Image classification, Magnetic resonance imaging

1 引言

脑肿瘤具有强扩散性,当其占据一定空间时,会不断压迫周围组织,进而损害中枢神经系统,威胁患者生命^[1],因此及早诊断脑肿瘤的类型对患者极为重要。核磁共振成像(Magnetic Resonance Imaging, MRI)是放射成像领域常用的技术,其因为具有无损伤、无电离辐射、软组织成像对比度大等优点,已成为诊断脑肿瘤的首选成像方法^[2]。然而, MRI 扫描的大部分数据是肉眼无法检测到的,如与肿瘤形状、纹理或图

像强度相关的细节。除此之外,脑肿瘤的诊断需要影像医师大量阅读医学图像,这会导致诊断错误率提升。

近些年,图像分类算法在医学诊断方面取得了广泛应用^[3]。现在深度学习已经成功应用于医疗诊断领域,有效地提高了准确率,降低了医生的工作量^[4]。

He 等^[5]提出了一种新的细粒度识别框架 TransFG。在细粒度图像分类算法中,基于特征提取的传统算法中的局部特征选择过程繁琐,表述能力有限,其自身也存在一定缺陷,即忽略了不同局部特征之间的关联以及与全局特征之间的位

基金项目:京津冀协同创新项目(17YEXTZC00020)

This work was supported by the Beijing-Tianjin-Hebei Collaborative Innovation Project(17YEXTZC00020).

通信作者:张艳芳(lixinrui1121@163.com)

置空间关系,因此并没有取得令人满意的结果。然而,随着深度学习的兴起,从神经网络中自动获得的特征,比人工特征具有更强大的描述能力,在一定程度上极大地促进了细粒度图像分类算法的发展。

Ayadi 等^[6]提出了一种用于脑肿瘤分类的多层深度 CNN,用 3 个数据集,即 Figshare、Radiopaedia 和分子脑肿瘤数据存储库(REMBRANDT),评估了该模型的有效性。该模型表现出了令人印象深刻的性能,与以前的方法相比,所需的预处理更少。Ali 等^[7]通过对预先训练的 ImageNet 权重进行迁移学习并微调卷积神经网络,在 HAM10000 数据集上训练了 EfficientNets B0-B7,其中最好的模型 EfficientNet B4 的 F1 得分为 87%,准确率为 87.91%。Jiang 等^[8]提出了一种基于 SE-ResNeXt101 网络的分类框架对神经胶质瘤进行分类,并采用了 3 种优化策略来提高精度,使用的两个数据集的准确度分别达到了 97.45% 和 98.99%。Wang 等^[9]提出了一种与 ResNeXt101 和 Bi-LSTM 融合的网络 3D_RexNeXt_Bi-LSTM,用于从神经成像中分类和识别阿尔兹海默病(AD)和正常对比度(NC),分类准确率高达 98.97%。

综上,不同模型对脑肿瘤数据集有不同的判别优势,然而,个体网络模型在处理某个问题时很容易遇到模型泛化瓶颈,不能保证在解决多种问题时有出色的表现^[10]。集成学习可以将多个模型结合,获得比单一模型显著优越的泛化性能。

在深度卷积神经网络的背景下,集成学习被定义为模型的组合,以产生更好的分类性能。正如 Ju 等^[11]和 Müller 等^[12]所述,医学影像数据集通常很小,因此有效训练数据使用的集成学习技术特别受欢迎。从经验上讲,基于集成学习的管道往往更优越,这符合这样一种假设,即不同模型的组装有优势,将它们的优势结合在一起,专注于不同的特征,同时平衡模型的个体能力^[11]。尽管多位作者如 Ganaiea 等^[13]对一般集成学习进行了广泛的综述,但只有少数文献开始调查深度学习集成领域,集成学习策略在基于深度学习的脑肿瘤 MRI 分类中还没有得到充分的应用。

目前关于脑肿瘤分类的深度学习相关工作基本上是针对单个模型的改进和创新,并没有提出基于多个模型的集成算法。本文提出将集成学习应用于脑肿瘤 MR 图像分类中,为验证此方法在 MRI 分类领域的优异表现,本文实验思路如下:首先,用 TransFG 模型、ResNet50 模型、EfficientNet B4 模型、EfficientNet B7 模型和 ResNeXt101 模型训练脑肿瘤 MR 影像二分类、三分类和四分类数据集,然后采用加权平均的集成学习算法,得到 Treer-Net 模型,并将其与上述 5 种模型进行对比分析,验证 Treer-Net 的可靠性和准确性。同时,为验证此方法可适用于各种脑肿瘤 MR 图像并为临床分类工作提供参考意义,本文将 Treer-Net 模型与过去的相关工作的分类结果进行对比分析。实验结果表明,对于脑肿瘤 MR 影像三分类数据集,本文方法在准确率(accuracy, Acc)、精确率(Precision)、召回率(recall)、AUC 这 4 个指标上均高于用于集成算法的 5 个网络模型。并且,对于不同的脑肿瘤 MR 数据集,本文方法表现出了较好的优异性,可为临床脑肿瘤 MR 影像分类工作提供参考,具有使用价值。

2 基础理论

2.1 TransFG 模型

TransFG 模型的结构如图 1 所示。

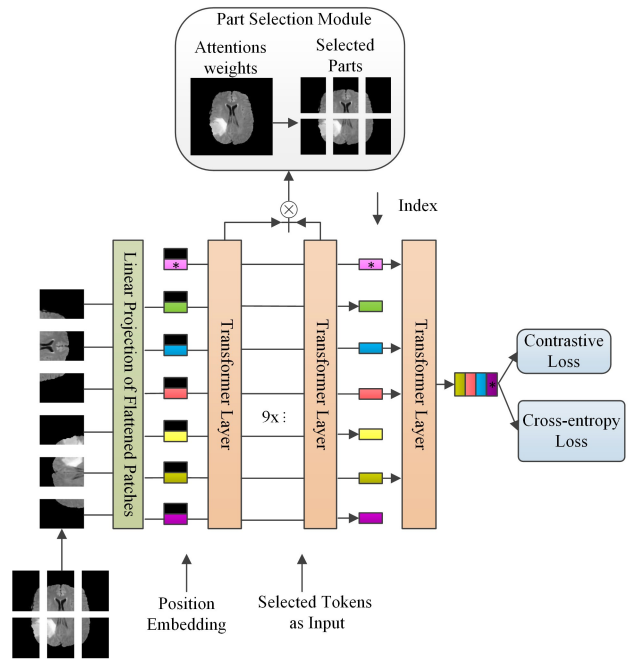


图 1 TransFG 的结构

Fig. 1 Architecture of TransFG

细粒度分类研究工作主要集中在如何定位差异性图片区域,以此提高网络捕捉微小差异的能力,而大部分工作主要通过使用不同的模型来提取特定区域的特征,但这种方式会使流程复杂化,并从特定区域提取出大量冗余特征。用于细粒度分类的 Transformer 结构 TransFG 将所有原始注意力权重整合至注意力映射中,以此来指导模型高效地选取差异性图片区域^[5]。

首先,简单介绍 Transformer 的框架,展示如何进行一些预处理步骤,并将其扩展到细粒度识别中。

1) 局部选取模块(PSM)

首先假设模型中具有 K 个自注意首部,各层注意力权重如式(1)所示:

$$a_l = [a_l^0, a_l^1, a_l^2, \dots, a_l^K], l \in 1, 2, \dots, L-1 \quad (1)$$

$$a_i^l = [a_i^{l0}, a_i^{l1}, a_i^{l2}, \dots, a_i^{lK}], i \in 0, 1, \dots, K-1$$

其中, a_l 指第 l 层 K 个首部注意力权重。

如式(2)所示,将所有层的注意力权重进行矩阵相乘, a_{final} 捕捉了图像信息从输入到更深层的整个过程,相比原有 ViT,其包含了更多信息,更加有助于选取具有识别性的区域。

$$a_{final} = \prod_{l=0}^{L-1} a_l \quad (2)$$

选取 a_{final} 中 K 个不同注意力首部的最大值 A_1, A_2, \dots, A_K 并将其与分类 token 进行拼接,其结果如式(3)所示。该步骤不仅保留了全局信息,也让模型更加关注与不同类别之间的微小差异。

$$Z_{local} = [z_{L-1}^0; z_{L-1}^1; z_{L-1}^2; \dots; z_{L-1}^{K-1}] \quad (3)$$

2) 对比损失

如式(4)所示,对比损失的目标是最小化不同类别对应的分类 tokens 的相似度,并最大化相同类别对应的分类 tokens 的相似度。

$$\mathcal{L}_{con} = \frac{1}{B^2} \sum_i \sum_{j: y_i \neq y_j} (1 - Sim(z_i, z_j)) + \sum_{j: y_i = y_j} \max((Sim(z_i, z_j) - \alpha), 0) \quad (4)$$

其中, z_i 和 z_j 用 l_2 归一化进行预处理, 并且 $Sim(z_i, z_j)$ 是 z_i 和 z_j 的点积。

图 1 中, 图像被分割成小块(显示非重叠的分割)并投影到嵌入空间中。变压器编码器的输入包括补丁嵌入以及可学习的位置嵌入。在最后一个 Transformer 层之前, PSM 被应用于选择与判别图像补丁相对应的标记, 并且仅使用这些选择的标记作为输入。最终分类标记上的交叉熵损失和对比损失有助于 TransFG 的训练^[5]。

2.2 ResNet50 模型

ResNet50 模型解决了由于网络的加深会造成梯度爆炸和梯度消失的问题。针对这一问题, 文献[14]提出引入跳跃连接线来建立深度残差网络, 以加深网络的层数, 如图 2 所示。输入 x 进入第一层权重层后得到映射函数 $F(x)$; 使用 ReLU 激活函数进入第二层权重层, 同时加入 x 的跳跃连接, 得到最终的映射函数 $F(x) + x$ 。该结构的优点是能使浅层特征直接映射到深层, 以加深两层的沟通^[15]。构建块的定义为:

$$y = \mathcal{F}(x, \{W_i\}) + x \quad (5)$$

其中, x 和 y 是所考虑的层的输入和输出向量。函数 $\mathcal{F}(x, \{W_i\})$ 表示要学习的残差映射。对于图 2 中有两层的例子, $\mathcal{F} = W_2 \sigma(W_1 x)$, 其中 σ 表示 ReLU 和被忽略的偏差。操作 $F + x$ 是通过快捷连接和元素相加来执行的。该模型采用加法后的秒非线性(即 $\sigma(y)$, 见图 2)。

式(5)中, x 和 F 的尺寸必须相等。




图 2 残差单元结构图

Fig. 2 Residual unit structure diagram

ResNet50 主要包括卷积层、池化层、全连接层和残差模块, 其中残差模块可分为恒等残差块 (Identity Block) 和卷积残差块 (Conv 4Block)^[15]。

2.3 EfficientNet 模型

传统的神经网络通常通过加深网络深度、加宽网络通道大小和提高图像数据分辨率来获得更加复杂的网络。其不仅提高了网络的识别精度, 还带来了梯度爆炸参数的计算成本。EfficientNet 模型是 Tan 等^[16]提出的一种可以通过设置合适的合成比例系数来平衡网络的宽度、深度和分辨率的深度学习网络, 以此在拓展网络的三维时可以获得更好的模型性能。

2.4 ResNeXt 模型

ResNeXt 网络^[17]引入了分组卷积的概念, 把同一卷积层中包含较多通道数的卷积模板平均分成若干组通道数相同的卷积模板^[18], ResNeXt 的结构如图 3 所示。




图 3 ResNeXt 的结构^[17]

Fig. 3 Architecture of ResNeXt^[17]

ResNeXt 结构的第一个卷积层中 1×1 的卷积模板的作用是减少输入特征图的通道数, 降低训练网络过程中产生的计算量。第二个分组卷积层首先将第一层的输出通道分成每组通道数相同的 3×3 卷积模板, 然后将卷积后的特征图级联

在一起作为输入传到下一个卷积层。当分组数设置为 32 时, 卷积模板通道数从 128 变为 4, 每个分组都采用相同的拓扑结构。第三个卷积层通过 1×1 的卷积模板把分组卷积层级联后的特征图提高到原来的维度, 也就是卷积后得到的特征通道数为 256。图 3 中“弯曲箭头”表示残差结构的恒等映射, \oplus 表示输入特征图与输出特征图逐个像素点相加, 得到一个新的输出特征图。

$$y = \sum_{i=1}^{\tau} \mathcal{F}_i(x) + x \quad (6)$$

式(6)表示 ResNeXt 结构的运算过程, 其中 τ 表示为 $1 \times 1 \rightarrow 3 \times 3 \rightarrow 1 \times 1$ 一系列的卷积操作。

2.5 迁移学习

迁移学习是把已训练好的模型参数迁移到新的模型上, 更好地帮助新模型训练, 从而加快并优化模型的学习效率。本文使用的迁移学习方法是把 5 种基础模型在 ImageNet 数据集上训练好的参数作为预训练参数, ImageNet 是一个包含 140 万个图像、1 000 个类的大型数据集。

3 本文方法

本文提出利用集成学习实现脑肿瘤 MR 图像分类。本文方法包括数据集预处理、模型训练和集成学习优化 3 个步骤。

首先, 本文对脑肿瘤 MR 数据集进行预处理操作, 对数据实现归一化, 平滑和简化图像中各项目的轮廓^[19]; 将图片的 (h, w) 均转换为 $(256, 256)$; 对图片进行水平和垂直翻转; 把数据进行标准化处理, 标准差为 0.5, 均值为 0.5。

其次, 通过两个相关实验设计验证基于集成学习脑肿瘤 MR 图像分类的有效性。首先, 将 TransFG 模型、ResNet50 模型、EfficientNet B4 模型、EfficientNet B7 模型和 ResNeXt101 模型同时应用于脑肿瘤 MR 二分类、三分类和四分类数据集, 然后把这 5 类基础模型通过集成学习的加权平均的联合算法得到 Treer-Net 模型。对比分析评价指标(准确率、精确率、召回率和 AUC), 验证集成学习在脑肿瘤 MR 图像分类中的有效性。对比实验中, 进一步将 Treer-Net 模型与过去的相关工作进行对比, 利用评估指标对实验结果进行定量与定性的分析, 展现集成学习更好的分类指标, 证明其应用于临床脑肿瘤 MR 影像分类工作中的参考意义以及临床使用价值。

模型集成是将多个训练好的模型进行融合, 基于某种方式来实现测试数据的多模型融合, 使最终的分类结果能“取长补短”, 把多个模型的学习能力融合起来, 提高 Treer-Net 模型的泛化能力。

本文依据权重将 5 个模型分类结果进行集成, 以得到更准确的分类结果, Treer-Net 模型的集成表达式为:

$$result = x_1 \cdot n_1 + x_2 \cdot n_2 + x_3 \cdot n_3 + x_4 \cdot n_4 + x_5 \cdot n_5 \quad (7)$$

其中, $result$ 为脑肿瘤最后的分类结果, n_1, n_2, n_3, n_4, n_5 分别为 5 个模型分类结果, x_1, x_2, x_3, x_4, x_5 分别为 5 个模型的

权重, 且 $\sum_{i=1}^5 x_i = 1$; 模型权重的初始值为: $x_1 = x_2 = x_3 = x_4 = x_5 = 0.2$, 为得到更精确的分类结果, 需要不断对权重更新迭代, 当模型分类结果达到最优时, 即分别得到 5 个模型的最优权重。经过实验证明, $x_1 = x_2 = x_3 = x_4 = x_5 = 0.2$ 是最优权重, 如表 1-表 3 所列。

本文算法的流程如图 4 所示。

表 1 不同权重下 Treer-Net 模型在二分类上的实验结果

Table 1 Experimental results of Treer-Net model on two classifications with different weights

weight	model					Results of Treer-Net/%			
	TransFG	ResNet50	EfficientNet B4	EfficientNet B7	ResNeXt101	Accuracy	Precision	Recall	AUC
I	0.1	0.1	0.2	0.4	0.2	96.99	96.06	97.68	99.77
II	0.2	0.1	0.3	0.3	0.1	96.90	95.97	97.55	99.77
III	0.1	0.1	0.4	0.3	0.1	96.37	95.34	97.14	99.74
IV	0.2	0.1	0.2	0.4	0.1	96.99	96.06	97.68	99.77
V	0.2	0.2	0.2	0.2	0.2	98.05	97.37	98.50	99.81

注:表中加粗数据为最优结果。

表 2 不同权重下 Treer-Net 模型在三分类上的实验结果

Table 2 Experimental results of Treer-Net model on three classifications with different weights

weight	model					Results of Treer-Net/%			
	TransFG	ResNet50	EfficientNet B4	EfficientNet B7	ResNeXt101	Accuracy	Precision	Recall	AUC
I	0.1	0.1	0.2	0.4	0.2	98.43	98.44	98.43	99.86
II	0.2	0.1	0.3	0.3	0.1	98.55	98.55	98.55	99.87
III	0.1	0.1	0.4	0.3	0.1	98.31	98.32	98.32	99.85
IV	0.2	0.1	0.2	0.4	0.1	98.43	98.43	98.43	99.86
V	0.2	0.2	0.2	0.2	0.2	99.15	99.16	99.15	99.87

注:表中加粗数据为最优结果。

表 3 不同权重下 Treer-Net 模型在四分类上的实验结果

Table 3 Experimental results of Treer-Net model on four classifications with different weights

weight	model					Results of Treer-Net/%			
	TransFG	ResNet50	EfficientNet B4	EfficientNet B7	ResNeXt101	Accuracy	Precision	Recall	AUC
I	0.1	0.1	0.2	0.4	0.2	97.94	97.97	97.83	99.95
II	0.2	0.1	0.3	0.3	0.1	98.25	98.24	98.16	99.97
III	0.1	0.1	0.4	0.3	0.1	97.94	97.92	97.83	99.94
IV	0.2	0.1	0.2	0.4	0.1	97.94	97.96	97.83	99.96
V	0.2	0.2	0.2	0.2	0.2	99.24	99.26	99.20	99.98

注:表中加粗数据为最优结果。

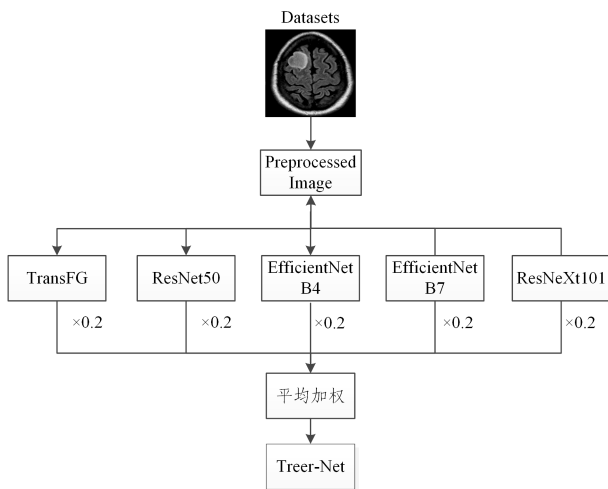


图 4 本文方法的流程图

Fig. 4 Flow chart of the proposed method

4 实验设计与实验结果

4.1 数据集

本文共使用 3 个公开数据集进行实验。3 个公开数据集分别是脑肿瘤 MR 影像二分类、三分类和四分类数据集,均来自 kaggle 网络平台。

脑肿瘤二分类数据集是具有图像一阶和二阶特征的脑肿瘤数据集,共 3762 张图像,其中有脑肿瘤的图像有 1683 张,没有脑肿瘤的图像有 2079 张,是较平衡的数据集,如图 5 所示。训练集和测试集的比例是 8:2,原始图像分辨率是 240×

240,图像格式为 JPG¹⁾。




(a) 有肿瘤

(b) 无肿瘤

图 5 二分类脑肿瘤数据集

Fig. 5 Binary classification brain tumor dataset

脑肿瘤三分类数据集中,训练集内有 3 个文件夹,分别是胶质瘤(6301 张切片)、脑膜瘤(5951 张切片)、垂体瘤(6146 张切片),共 18398 张图片。测试集内有 3 个文件夹,分别是胶质瘤(286 张切片)、脑膜瘤(270 张切片)、垂体瘤(272 张切片),共 828 张图片。该数据集总共 19200 张图像,图像格式为 PNG,如图 6 所示²⁾。



(a) 胶质瘤

(b) 脑膜瘤

(c) 垂体瘤

图 6 三分类脑肿瘤数据集

Fig. 6 Three classification brain tumor dataset

¹⁾ <https://www.kaggle.com/datasets/jakeshbohaju/brain-tumor>

²⁾ <https://www.kaggle.com/datasets/mahdinavaei/brain-tumor-mri-images-huge>

脑肿瘤四分类数据集中,测试集内有4个文件夹,分别是胶质瘤(300张切片)、脑膜瘤(306张切片)、无肿瘤(405张切片)、垂体瘤(300张切片),共1311张图片。训练集内有4个文件夹,分别是胶质瘤(1321张切片)、脑膜瘤(1339张切片)、无肿瘤(1595张切片)、垂体瘤(1457张切片),共5712张图片。该数据集总共7022张图片,图像格式为JPG,如图7所示¹⁾。




图7 四分类脑肿瘤数据集

Fig. 7 Four classification brain tumor dataset

训练集用于训练模型;验证集用于调整模型的超参数,对模型的能力进行初步评估,并判断何时停止训练;测试集用来评估最终模型的泛化能力。

4.2 数据处理平台

本实验以Pytorch框架为实验环境,操作系统为linux, GPU的版本为11.2,内存与显卡均为24GB。采用Adam优化器,epoch的训练轮数为50,初始设置的学习率为0.0001。

4.3 实验评价指标

基于对脑肿瘤MR影像的分类,本文中评估模型的质量主要通过4个指标进行,分别是准确率、精确率、召回率和AUC。这些指标的定义中涉及如表4所列的混淆矩阵术语。

表4 混淆矩阵定义

Table4 Confusion matrix definition

Class	Statement	Formula
True Positive	属于生病患者的图像,并且模型正确地知道这些图像	TP
True Negative	属于健康且模型正确认识的患者的图像	TN
False Positive	属于健康但被模型诊断为患病的患者的图像	FP
False Negative	属于生病但被模型诊断为健康的患者的图像	FN

表1中的测量值分别按下述条件确定。

1) 准确性

准确预测事件的百分比除以预测事件的总数称为准确度。

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (8)$$

2) 精确率

精确率是真阳性的数量除以真阳性的总数加假阳性的数量。

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

3) 召回率

召回率是所发现的相对相关事件总数的百分比^[19]。

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

4) AUC

AUC是衡量学习器优劣的一种性能指标,可通过对ROC曲线下各部分的面积求和得出。AUC的统计意义是从所有正样本随机抽取一个正样本,从所有负样本随机抽取一个负样本,对应的预测可能性中该正样本排在负样本前面的

概率。式(11)、式(12)中, M 为正样本个数, N 为负样本个数。

$$CorrectPair = \sum_{i \in \text{正样本集合}} rank_i - \frac{M(M+1)}{2} \quad (11)$$

$$AUC = \frac{CorrectPair}{MN} \quad (12)$$

4.4 实验过程及结果

消融实验将本文提出的Treer-Net模型与常见的医学图像分类模型TransFG, ResNet50, EfficientNet B4, EfficientNet B7和ResNeXt101分别应用于脑肿瘤二分类、三分类和四分类数据集并进行对比研究,基于医学图像分类标准,得出对比实验结果,如表5—表7所列。

表5 本文方法在二分类上的实验结果

Table 5 Experimental results of the proposed method on two classification

Algorithm	Accuracy	Precision	Recall	AUC
TransFG	98.49	98.03	98.72	99.14
ResNet50	99.11	98.77	99.32	99.98
EfficientNet B4	94.42	93.19	95.41	97.07
EfficientNet B7	94.86	93.74	95.52	98.51
ResNeXt101	98.58	98.06	98.91	99.65
Treer-Net	98.05	97.37	98.50	99.81

注:表中加粗数据为最优结果。




图8 二分类训练损失曲线

Fig. 8 Binary training loss curve




图9 二分类验证损失曲线

Fig. 9 Binary validation loss curve

表6 本文方法在三分类上的实验结果

Table 6 Experimental results of the proposed method on three classification

Algorithm	Accuracy	Precision	Recall	AUC
TransFG	97.83	97.84	97.84	99.53
ResNet50	98.91	98.90	98.90	99.53
EfficientNet B4	96.01	96.07	95.99	99.16
EfficientNet B7	97.22	97.22	97.20	98.87
ResNeXt101	97.95	97.94	97.95	99.69
Treer-Net	99.15	99.16	99.15	99.87

注:表中加粗数据为最优结果。

¹⁾ <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>




图 10 三分类训练损失曲线

Fig. 10 Three classification training loss curve




图 11 三分类验证损失曲线

Fig. 11 Three classification validation loss curve

表 7 本文方法在四分类上的实验结果

Table 7 Experimental results of the proposed method on four classification

Algorithm	Accuracy	Precision	Recall	AUC
TransFG	98.86	98.76	98.84	99.61
ResNet50	99.69	99.69	99.67	99.97
EfficientNet B4	96.34	96.25	96.12	99.15
EfficientNet B7	95.12	95.00	95.13	98.60
ResNeXt101	98.32	98.34	98.18	99.60
Treer-Net	99.24	99.26	99.20	99.98

注:表中加粗数据为最优结果。




图 12 四分类训练损失曲线

Fig. 12 Four classification training loss curve




图 13 四分类验证损失曲线

Fig. 13 Four classification validation loss curve

消融实验的结果表明,本文提出的 Treer-Net 模型在二分类和四分类数据集上的分类结果不如 ResNet50 模型。然而,该算法应用于脑肿瘤 MR 三分类数据集上的准确率、

精确率、召回率和 AUC 分别高达 99.15%,99.16%,99.15% 和 99.87%,在本文中所涉及的 4 项评估指标上均优于其他基础网络,表现优异。

在对比实验中,为进一步证明本文提出的 Treer-Net 模型确实有效和验证准确性,以及将其应用于脑肿瘤 MR 影像中的临床价值,将本文的集成算法与过去的相关工作进行对比分析,如表 8—表 10 所列。

表 8 二分类数据集在相关工作中的分类结果对比

Table 8 Comparison of classification results of binary classification datasets in related work

Related Work	Model	Accuracy
Latif 等 ^[20]	SVM	96
Khan 等 ^[21]	VGG-19	94
Yahyaoui 等 ^[22]	DenseNet	92
Bhatele 等 ^[23]	Hybrid Ensemble	95.2
Murthy 等 ^[24]	CNN Ensemble	95
—	VGG16	97.08
ours	Treer-Net	98.05

注:表中加粗数据为最优结果。

表 9 三分类数据集在相关工作中的分类结果对比

Table 9 Comparison of classification results of three classification datasets in related work

Algorithm	Accuracy	Precision	Recall	AUC
VGG16	95.41	95.42	95.43	98.30
ours	99.15	99.16	99.15	99.87

注:表中加粗数据为最优结果。

表 10 四分类数据集在相关工作中的分类结果对比

Table 10 Comparison of classification results of four classification datasets in related work

Related Work	Accuracy	Precision%	Recall
Deepak 等 ^[25]	—	94.70	96.00
Ghassemi 等 ^[26]	—	95.28	94.91
OÖzkaraca 等 ^[27]	—	96.00	96.50
R Ali 等 ^[28]	98.40	97.00	96.75
VGG16	97.64	97.55	97.60
ours	99.24	99.26	99.20

注:表中加粗数据为最优结果。

实验结果表明,本文提出的集成学习算法在 3 个数据集上的分类结果均优于过去的相关工作。

结束语 针对脑肿瘤 MR 影像分类,本文提出了一种基于集成学习的脑肿瘤 MR 影像图像分类算法。首先,把 MR 进行归一化处理,以完成对数据集图像的预处理;然后,应用 TransFG, ResNet50, EfficientNet B4, EfficientNet B7, ResNeXt101 模型分别训练 3 个数据集,接着采用集成学习的加权平均的联合算法得出分类结果。与上述 5 个基础模型的实验结果进行对比,Treer-Net 模型在三分类数据集上的评估指标最优。实验结果同时表明,该模型可以更好地对脑肿瘤进行分类。但是该方法也存在一些局限性,例如在二分类和四分类数据集上的分类效果有待加强,这主要是因为二分类和四分类数据集过小,导致集成模型种类预测性能变差,如何在较小的数据集上取得更好的集成效果,这也是我们今后进一步的研究方向。

参考文献

- [1] LIU M H,ZHANG G. Research progress in brain tumor imaging based on deep learning [J]. *Imaging Technology*, 2021, 33(5):50-55.
- [2] SUN F Q,CUI Z Q,ZOU P, et al. Brain tumor segmentation algorithm based on multi-scale features [J]. *Computer Science*, 2022,49(S1):12-16,73.
- [3] BUCHLAK Q D,ESMAILI N,LEVEQUE J C, et al. Machine learning applications to neuroimaging for glioma detection and classification: An artificial intelligence augmented systematic review[J]. *J Clin Neurosci*,2021,89:177-198.
- [4] ZHENG L Y. Research and Implementation of Brain Tumor Image Classification Based on Deep Learning [D]. Chengdu: University of Electronic Science and Technology of China, 2021.
- [5] CHEN J H J N,LIU S,KORTYLEWSKI A, et al. TransFG: A Transformer Architecture for Fine-grained Recognition [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2022:852-860.
- [6] AYADI W,ELHAMZI W,CHARFI I, et al. Deep CNN for Brain Tumor Classification[J]. *Neural Processing Letters*,2021, 53(1):671-700.
- [7] ALI K,SHAIKH Z A,KHAN A A, et al. Multiclass skin cancer classification using EfficientNets-a first step towards preventing skin cancer[J]. *Neuroscience Informatics*,2022,2(4):100034.
- [8] JIANG L Q,NING C Y,LI J Y. Glioma classification framework based on SE-ResNeXt network and its optimization[J]. *IET Image Processing*,2022,16(2):596-605.
- [9] WANG X,YI J,LI Y. Application of Fusion Model of 3D-ResNeXt and Bi-LSTM Network in Alzheimer's Disease Classification[C]//2022 6th International Conference on Communication and Information Systems(ICCIIS). 2022:136-140.
- [10] GONG A,YAO X J,DU B, et al. Dermatoscope image classification method based on Ensemble learning and Generative adversarial network [J]. *Science, Technology and Engineering*,2021, 21(3):1071-1076.
- [11] JU C,BIBAUT A,VAN DER LAAN M. The relative performance of ensemble methods with deep convolutional neural networks for image classification[J]. *Journal of Applied Statistics*, 2018,45(15):2800-2818.
- [12] MÜLLER D,SOTO-REY I,KRAMER F. Multi-disease detection in retinal imaging based on ensembling heterogeneous deep learning models[M]//German Medical Data Sciences 2021: Digital Medicine: Recognize-Understand-Heal. IOS Press, 2021: 23-31.
- [13] GANAIE M A,HU M,MALIK A, et al. Ensemble deep learning: A review[J]. *Engineering Applications of Artificial Intelligence*,2022,115:105151.
- [14] HE K,ZHANG X,REN S, et al. Deep residual learning for image recognition[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:770-778.
- [15] GU R F,LI X,REN W M. Research on Image Classification Based on ResNet50 Improved Model [J]. *Modern Electronic Technology*,2023,46(4):107-112.
- [16] TAN M,LE Q. Efficientnet: Rethinking model scaling for convolutional neural networks[C]//International Conference on Machine Learning. 2019:6105-6114.
- [17] XIE S,GIRSHICK R,DOLLÁR P, et al. Aggregated residual transformations for deep neural networks[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017:1492-1500.
- [18] JIANG L Q. Research on Brain Tumor Image Classification Technology Based on Deep Learning [D]. Changchun: Changchun University of Science and Technology, 2022.
- [19] SAHAAI M B,JOTHILAKSHMI G,RAVIKUMAR D, et al. ResNet-50 based deep neural network using transfer learning for brain tumor classification[C] // AIP Conference Proceedings. 2022.
- [20] LATIF G,BEN BRAHIM G,ISKANDAR D A, et al. Glioma Tumors' classification using deep-neural-network-based features with SVM classifier[J]. *Diagnostics*,2022,12(4):1018.
- [21] KHAN A R,KHAN S,HAROUNI M, et al. Brain tumor segmentation using K-means clustering and deep learning with synthetic data augmentation for classification[J]. *Microscopy Research and Technique*,2021,84(7):1389-1399.
- [22] YAHYAOU H,GHAZOUANI F,FARAH I R. Deep learning guided by an ontology for medical images classification using a multi modal fusion[C] // 2021 International Congress of Advanced Technology and Engineering(ICOTEN). 2021:1-6.
- [23] BHATELE K R,BHADAURIA S S. Machine learning application in Glioma classification: review and comparison analysis[J]. *Archives of Computational Methods in Engineering*, 2022, 29(1):247-274.
- [24] MURTHY M Y B,KOTESWARARAO A,BABU M S. Adaptive fuzzy deformable fusion and optimized CNN with ensemble classification for automated brain tumor diagnosis[J]. *Biomedical Engineering Letters*,2022,12(1):37-58.
- [25] DEEPAK S,AMEER P. Brain tumor classification using deep CNN features via transfer learning[J]. *Computers in Biology and Medicine*,2022,12(1):37-58.
- [26] GHASSEMI N,SHOEIBI A,ROUHANI M. Deep neural network with generative adversarial networks pre-training for brain tumor classification based on MR images[J]. *Biomedical Signal Processing and Control*,2020,57:101678.
- [27] ÖZKARACA O,BAĞRIAÇIK O,GÜRÜLER H, et al. Multiple Brain Tumor Classification with Dense CNN Architecture Using Brain MRI Images[J]. *Life*,2023,13(2):349.
- [28] ALI R,AL-JUMAILI S,DURU A D, et al. Classification of Brain Tumors using MRI images based on Convolutional Neural Network and Supervised Machine Learning Algorithms [C] // 2022 International Symposium on Multidisciplinary Studies and Innovative Technologies(ISMSIT). 2022:822-827.



LI Xinrui, born in 2002, undergraduate. Her main research interest is medical image processing.



ZHANG Yanfang, born in 1975, bachelor. Her main research interests include imaging research of cardiovascular and cerebrovascular diseases.