

基于多尺度特征与通道特征融合的脑肿瘤良恶性分类模型

姜林奇 宁春玉 余海涛

Classification model based on fusion of multi-scale feature and channel feature for benign and malignant brain tumors

JIANG Lin-qi, NING Chun-yu, YU Hai-tao

引用本文:

姜林奇, 宁春玉, 余海涛. 基于多尺度特征与通道特征融合的脑肿瘤良恶性分类模型[J]. *中国光学*, 2022, 15(6): 1339-1349.

doi: 10.37188/CO.2022-0067

JIANG Lin-qi, NING Chun-yu, YU Hai-tao. Classification model based on fusion of multi-scale feature and channel feature for benign and malignant brain tumors[J]. *Chinese Optics*, 2022, 15(6): 1339-1349. doi: 10.37188/CO.2022-0067

在线阅读 View online: <https://doi.org/10.37188/CO.2022-0067>

您可能感兴趣的其他文章

Articles you may be interested in

多尺度窗口的自适应透射率修复交通图像去雾方法

A traffic image dehaze method based on adaptive transmittance estimation with multi-scale window

中国光学 (中英文). 2019, 12(6): 1311 <https://doi.org/10.3788/CO.20191206.1311>

基于改进HOG特征提取的车型识别算法

Vehicle type recognition algorithm based on improved HOG feature

中国光学 (中英文). 2018, 11(2): 174 <https://doi.org/10.3788/CO.20181102.0174>

基于改进的加速鲁棒特征的目标识别

Object detection based on improved speeded-up robust features

中国光学 (中英文). 2017, 10(6): 719 <https://doi.org/10.3788/CO.20171006.0719>

自适应特征引流管故障智能识别方法

Intelligent identification algorithm of adaptive feature drainage tube fault

中国光学 (中英文). 2017, 10(3): 340 <https://doi.org/10.3788/CO.20171003.0340>

激光诱导击穿光谱技术对烟草快速分类研究

Fast classification of tobacco based on laser-induced breakdown spectroscopy

中国光学 (中英文). 2019, 12(5): 1139 <https://doi.org/10.3788/CO.20191205.1139>

基于激光诱导击穿光谱和拉曼光谱对四唑类化合物的快速识别和分类实验研究

Fast recognition and classification of tetrazole compounds based on laser-induced breakdown spectroscopy and raman spectroscopy

中国光学 (中英文). 2019, 12(4): 888 <https://doi.org/10.3788/CO.20191204.0888>

文章编号 2097-1842(2022)06-1339-11

基于多尺度特征与通道特征融合的脑肿瘤 良恶性分类模型

姜林奇, 宁春玉*, 余海涛

(长春理工大学 生命科学技术学院, 吉林 长春 130022)

摘要: 针对脑肿瘤良恶性分类过程复杂、分类准确率不高等问题, 提出了一种基于多尺度特征与通道特征融合的分类模型。该模型以 ResNeXt 网络为主干网络, 首先, 将基于空洞卷积的多尺度特征提取模块代替第一层卷积层, 利用膨胀率获取不同感受野的图像信息, 将全局特征与局部显著特征相结合; 其次, 添加通道注意力机制模块, 融合特征通道信息, 提高对肿瘤区域的关注度, 降低对冗余信息的关注度; 最后, 采用学习率的线性衰减策略、图像的标签平滑策略以及基于医学图像的迁移学习策略的组合优化提高模型的学习能力和泛化能力。在 BraTS2017 和 BraTS2019 数据集中进行实验, 准确率分别达到 98.11% 和 98.72%。与经典模型和其他先进方法相比, 该分类模型能够有效地减少分类过程的复杂度, 提高脑肿瘤良恶性分类的准确率。

关键词: 脑肿瘤; 多尺度特征; 通道注意力机制; 深度学习

中图分类号: TP391.4 文献标志码: A doi: 10.37188/CO.2022-0067

Classification model based on fusion of multi-scale feature and channel feature for benign and malignant brain tumors

JIANG Lin-qi, NING Chun-yu*, YU Hai-tao

(School of Life Science and Technology, Changchun University of Science and Technology,
Changchun 130022, China)

* Corresponding author, E-mail: yeningcy@163.com

Abstract: Aiming at the problems of complex and inaccurate classification of benign and malignant brain tumors, a classification model was proposed based on the fusion of multi-scale and channel features. The model used ResNeXt as the backbone network. First, the multi-scale feature extraction module based on dilated convolution was used to replace the first convolution layer, which can make full use of dilation rates to obtain the image information from different receptive fields, and combine the global features with significant subtle ones. Second, the channel attention mechanism module was added in the network to fuse the feature channel information in order to increase the attention to the tumor, and reduce the attention to redundant information. Finally, the combination optimization strategy, the MultiStepLR strategy of the learning rate, the label smoothing strategy and the transfer learning strategy on medical images were adopted to improve the learning and generalization abilities of the model. The experiments were carried out on BraTS2017 Dataset

收稿日期: 2022-04-12; 修订日期: 2022-05-03

基金项目: 吉林省科技发展计划项目 (No. 20200404219YY)

Supported by the Science and Technology Development Project of Jilin Province (No. 20200404219YY)

and BraTS2019 Dataset, and the classification accuracy were 98.11% and 98.72%, respectively. Compared with other advanced methods and classical models, the proposed classification model can effectively reduce the complexity of the classification process and improve the detection accuracy of benign and malignant brain tumors.

Key words: brain tumor; multi-scale feature; channel attention mechanism; deep learning

1 引言

根据 2018 年全球癌症统计报告可知, 大脑及神经系统癌变发生率约为 2.9 人/(年·10 万人), 约占全身肿瘤的 1.6%, 死亡率高达 2.5%^[1]。根据病因可以将大脑及神经系统癌变分为原发性和继发性。其中, 胶质瘤(glioma)作为最常见的原发性脑肿瘤被广泛关注。根据磁共振肿瘤成像所呈现的特点, 可将其恶化的程度分为低级别胶质瘤(Low Grade Gliomas, LGG)和高级别胶质瘤(High Grade Gliomas, HGG)^[2]。如果医生不能准确地对肿瘤的恶化程度进行分类, 随着时间的推移良性肿瘤很有可能会恶化成恶性肿瘤。因此, 肿瘤的良好分类尤其重要^[3]。

基于传统机器学习的图像分类方法通过提取图像的纹理信息, 比如形状特征、颜色等, 再利用支持向量机(Support Vector Machines, SVM)或其他分类器实现分类^[4-6]。Raju 等人^[7]采用贝叶斯模糊聚类方法进行脑肿瘤分割, 并利用 HCS(Harmony-Crow Search)优化算法来训练 multi-SVNN 分类器的权重, 计算图像特征, 得到的分类精度为 93%。Narmatha 等人^[8]提出了将模糊算法与 Brain-storm 优化算法相结合的 Fuzzy Brain-storm optimization 算法用于脑肿瘤图像的分割与分类。该方法有效地缩短了图像的分割时间, 但最终的分类准确率仅为 93.85%。

传统的图像分类方法在图像特征的选择上更依赖于操作者的先验知识, 工作量大并且过程较复杂。近几年, 深度学习(Deep Learning, DL)作为一种新兴技术被广泛应用于图像分割、图像分类、图像识别等任务中^[9-12]。面对图像特征复杂的医学图像, 学者们提出将 DL 引进到医学影像领域当中^[13-14]。

目前, 脑肿瘤分类系统可分为非端到端式和端到端式。非端到端的分类系统是指由多个独立

部分组成的系统, 卷积神经网络(Convolutional Neural Network, CNN)担任其中一个或多个部分。Sharif 等人^[15]提出一种基于深度学习的方法来实现肿瘤的分割与分类。该方法使用预训练后的 Inception V3 网络对分割结果图进行特征提取, 并将分别由传统方法和深度学习提取的特征进行拼接, 通过粒子群优化算法(Particle Swarm Optimization, PSO)进行特征向量的优化, 最后, 通过 Softmax 分类器进行分类, 得到了 96.90% 的准确率。Khan 等人^[16]提出一种基于极限学习机(Extreme Learning Machine, ELM)的自动分类方法。该方法利用预训练过的 VGG16 提取图像特征, 然后通过 ELM 对融合的鲁棒特征进行分类, 有效减少了特征选取与融合的时间。Rehman 等人^[17]提出将 3D CNN 模型用于脑肿瘤的检测, 利用预训练的 VGG19 网络用于特征提取, 利用前馈神经网络(Feed-forward Neural Network, FNN)选取最佳特征用于分类。该方法取得了较高的准确率, 但肿瘤检测过程耗费时间较长。以上非端到端的分类系统对脑部肿瘤的分类准确率都有所提升, 但此类系统大多基于图像分割, 分类过程复杂, 故会引入较多干扰因素, 不可避免地会对分类结果造成影响。

端到端的分类系统是指仅通过卷积神经网络实现对肿瘤图像的分类。Seetha 等人^[18]针对脑肿瘤区域结构异化的问题, 提出利用小卷积核提取肿瘤区域的细微特征, 实现对肿瘤良恶性分类, 最终得到了 97.50% 的准确率。赵尚义等人^[19]提出了 3D U-Net 模型的分类算法。该方法在原始 U-Net 网络中引入了特征融合层, 将浅层特征与深层特征相融合, 实现了基于分割网络 U-Net 的分类系统。但该方法没有对浅层特征与深层特征的特征通道权重进行重新分配, 过分表达冗余特征, 导致最终的分类准确率仅达到 91.67%。端到端式的分类系统基于设计好的网络结构, 利用深度学习自动提取图像特征, 降低了分类过程复杂

性。但是上述用于脑肿瘤的分类方法没有充分利用图像的全局、局部显著特征以及特征图的通道特性, 识别准确率还有待进一步提高。

针对上述问题, 本文提出一种基于多尺度特征与通道特征融合的脑肿瘤良恶性自动分类方法 (Improved MDCA-ResNeXt), 利用 ResNeXt 网络结构的分组卷积策略, 在增加网络宽度的同时提升了网络提取特征信息的能力, 并通过多尺度特征提取模块融合全局特征与局部显著特征, 通过通道注意力机制模块提升网络对病灶区域的关注度, 减少冗余信息对分类结果造成的影响, 最终达到提高肿瘤良恶性分类精度的目的。

2 基于 Improved MDCA-ResNeXt 的脑肿瘤良恶性分类模型

2.1 MDCA-ResNeXt 网络

在对图像特征信息复杂、数据特征维度高的

医学图像进行分类时, 不仅要考虑网络提取特征信息的能力, 还需要考虑训练过程的计算复杂度等问题, 经过多番考虑, 本文选用 ResNeXt^[20] 网络作为脑肿瘤图像分类任务的主干网络, 对其进行改进, 以提高网络分类能力、降低参数冗余度、减少计算时间。首先, 将基于空洞卷积的多尺度特征提取模块 (Multi-scale Feature Extraction Module based on Dilated Convolution, MD) 代替一般的卷积层, 扩大第一层卷积层的感受野, 同时保留 HGG 图像中增强区域的局部显著特征, 将全局特征与局部显著特征融合; 其次, 添加通道注意力机制模块 (Channel Attention Module, CA), 引入特征通道信息, 对特征通道重新分配, 减少特征冗余引起的影响, 提高肿瘤区域在整幅图像中的关注度; 最后, 简化 ResNeXt 网络, 减少 ResNeXt 结构个数, 避免因网络过深导致的过拟合现象。图 1 为本文提出的 MDCA-ResNeXt 网络结构。

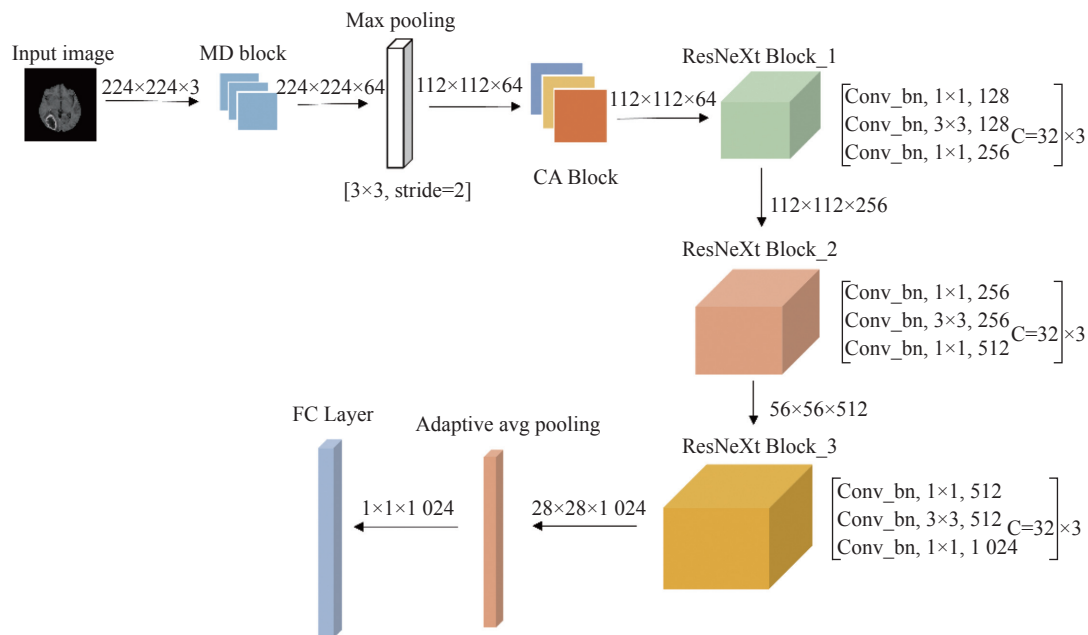


图 1 MDCA-ResNeXt 网络结构

Fig. 1 MDCA-ResNeXt network structure

2.1.1 ResNeXt 结构

ResNeXt 结构采用 Inception 结构^[21] 中的拆分-转换-合并的思想, 沿用 ResNet^[22] 的残差结构, 构造重复的多分组卷积层。ResNeXt 结构的本质是分组卷积, 它通过变量基数 C 来控制组的数量, 从而达到两种策略的平衡。图 2 为 $C = 32$ 的 ResNeXt 结构。图中“弯曲的箭头”表示残差结构的

恒等映射, \oplus 表示逐个像素点相加。

ResNeXt 结构的运算过程可用数学公式表达为:

$$y = \sum_{i=1}^c \tau_i(x) + x \quad (1)$$

其中 τ 表示 $1 \times 1 \rightarrow 3 \times 3 \rightarrow 1 \times 1$ 一系列的卷积操作。




图 2 C = 32 的 ResNeXt 结构^[20]

Fig. 2 ResNeXt structure with C = 32^[20]

2.1.2 多尺度特征提取模块

空洞卷积(dilated convolution)^[23]相对于正常卷积模板多一个膨胀率 d ,它表示在卷积核中插入权重为 0 的行和列的数量。图 3 为不同膨胀率 的空洞卷积。当 $d = 1$ 时,卷积模板的感受野与 3×3 的卷积模板相同;当 $d = 2$ 时,卷积模板的感受野与 5×5 的卷积模板相同;当 $d = 3$ 时,卷积模板的感受野与 7×7 的卷积模板相同。




图 3 不同膨胀率的空洞卷积

Fig. 3 Dilated convolution results with different dilation rates

图 4 为本文提出的 MD 模块,该模块的第一层卷积层包括了 1×1 的普通卷积模板以及卷积尺寸为 3×3 、膨胀率 d 分别为 1,2,3 的空洞卷积模板。第二层的卷积层是由 1×1 卷积模板组成,其作用是将上一层的输出特征图拼接在一起,得到同时包含全局与局部显著特征信息的特征图。

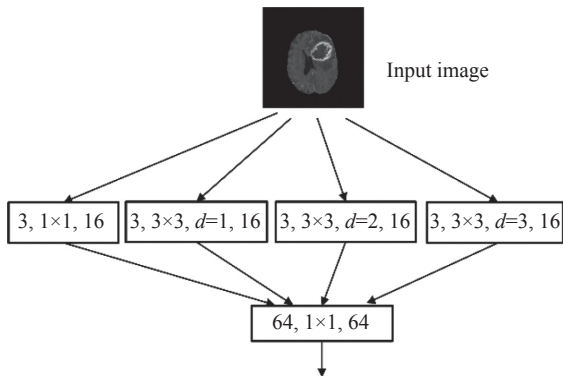


图 4 MD 模块

Fig. 4 MD module

2.1.3 通道注意力机制模块

图 5 为注意力机制^[24]中的通道注意力机制模块(Channel Attention Module, CA),该模块通过建立特征图之间的通道关系,生成通道注意力图,对特征通道重新分配权重,提高网络对输入图像中重要信息的关注度,降低网络对冗余信息的关注度。其计算过程如下:

$$M_{CA}(F) = \sigma(\text{MLP}(\text{Avgpool}(F)) + \text{MLP}(\text{Maxpool}(F))) = \sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))) \quad (2)$$

$$F' = M_{CA}(F) \otimes F \quad (3)$$

其中, Avgpool 和 Maxpool 分别表示对输入特征 F 进行全局平均池化操作和全局最大池化操作, MLP 表示多层感知器(Multi-layer Perceptron, MLP), W_0 和 W_1 为 MLP 层之间的共享权重,其维数分别为: $W_0 \in R^{C/r \times C}$, $W_1 \in R^{C \times C/r}$, r 表示降维系数, σ 表示 sigmoid 函数, \otimes 表示像素点相乘。




图 5 CA 模块

Fig. 5 CA module

2.2 基于 MDCA-ResNeXt 网络的优化策略

在设计分类模型过程中,网络结构对图像特征的提取起着关键作用,但是在训练过程中需要设置的超参数也会影响网络的学习能力。此外,提高网络的学习能力是一个比较漫长、复杂的过程。在脑肿瘤的前期分类任务中,本文作者提出了学习率的线性衰减策略、图像的标签平滑策略以及基于医学图像的迁移学习策略 3 种优化策略的组合^[25]。为了提高网络的学习能力,减少训练的迭代次数,本文采用相同的优化策略对 MDCA-ResNeXt 网络进行优化,经过优化的网络简记为 Improved MDCA-ResNeXt 网络。预训练过程中网络的训练迭代次数为 50,批次大小为 8,优化算法为带有动量随机梯度下降优化算法(Stochastic Gradient Descent with Momentum, SGDM),初始学习率为 0.01,学习率衰减迭代次数分别为 30 和 40,标签平滑系数为 0.01,采用 Cheng 等人^[26]提供的 CE-MRI 数据库作为预训练数据集。该数据库包含了 TIC 模式下 233 名病人的 3064 张脑

肿瘤 MRI 切片图像,其中包含了 1426 张胶质瘤图像、930 张脑膜瘤图像和 708 张垂体瘤图像。

3 实验设计

3.1 实验数据

3.1.1 BraTS 数据库

本文使用的 BraTS2017 和 BraTS2019 数据库分别为 2017 年和 2019 年举办的多模态脑肿瘤分割挑战赛提供的开源数据库。BraTS2017 数据库中包含 210 例 HGG 和 75 例 LGG, BraTS2019 数据库包含 259 例 HGG 和 76 例 LGG。数据库中每个病例都包括 FLAIR、T2、T1 和 T1C 4 种模态的 MRI 序列,每个序列包含 155 张切片图像,图像分辨率为 240 pixel×240 pixel。图 6、图 7 为 4 种模态下的 HGG 和 LGG 肿瘤图像。通过对比




图 6 4 种模态下的 HGG 图像

Fig. 6 HGG images in four modalities




图 7 4 种模态下的 LGG 图像

Fig. 7 LGG images in four modalities

不同模态 MRI 图像可知,添加了造影剂的 T1C 模态能够更加凸显病灶区域的特征,因此本文选用该模态下的图像作为原始输入。

3.1.2 数据预处理

图 8 为去噪前后对比图。图 8(a)中矩形虚线框内图像中含有一些不均匀的信号,这是由于设备老化等问题造成的灰度变化不均。这种现象称为偏置场效应。如果在图像预处理阶段不对其进行处理,很容易造成网络对图像的错误判断,所以本文使用优化后的 N3(Nonparametric nonuniform intensity normalization)^[27]算法——N4ITK 算法^[28]对原始图像数据进行偏置场校正。图 8(b)是 N4ITK 算法校正后的 MRI 图像,可见虚线框内的亮度变得比较均匀。

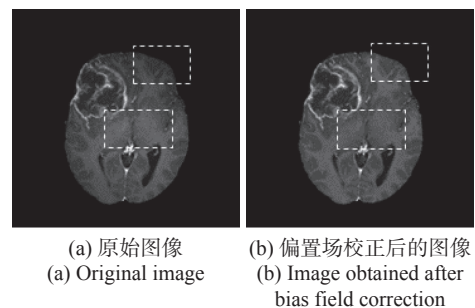


图 8 去除噪声前后对比图

Fig. 8 Comparison before and after preprocessing

在分类任务中,不同类别下的图像数量分布不均可能会造成过拟合,因此需要对 LGG 样本进行数据扩充。本文利用随机翻转、旋转等操作对 LGG 样本进行扩充。并通过训练集中的图像进行随机旋转、随机擦除^[29]等数据增强操作来增加数据集中来自同一病例的切片图像的差异性,从而提高网络分辨能力的鲁棒性。

3.1.3 实验数据集

为了验证所提出的分类模型对胶质瘤图像的分类能力,本文将数据增强后的 BraTS2017 和 BraTS2019 数据集分别划分成 5 个图像数量相等的子集,进行五折交叉验证实验。表 1 所示为实验数据集的分布情况。

表 1 实验数据集分布

Tab. 1 Distribution of experimental datasets

数据集	肿瘤类别	数据分布		总数
		训练集	测试集	
BraTS2017数据集	HGG	840	210	1050
	LGG	900	225	1125
BraTS2019数据集	HGG	1035	260	1295
	LGG	915	225	1140

3.2 实验环境及参数设置

本文基于 Pytorch 深度学习模型框架, 采用 Python 作为编程语言, 在操作系统为 Windows 10、GPU 为 NVIDIA Tesla K40m 的实验平台搭建了基于 Improved MDCA-ResNeXt 网络模型的脑肿瘤图像良恶性分类框架。网络训练过程中的训练迭代次数为 30, 批次大小为 8, 优化算法为 SGDM, 初始学习率为 0.01, 学习率衰减迭代次数为 20, 标签平滑系数为 0.01, 网络初始化参数为迁移学习得到的。

3.3 评价指标

本文采用准确率 (Accuracy)、灵敏度 (Sensitivity)、特异度 (Specificity)、阳性预测值 (Positive Predictive Value) 以及阴性预测值 (Negative Predictive Value) 对分类结果进行性能评价。上述指标分别记为 ACC、SEN、SPE、PPV 及 NPV, 计算公式如式(4)~式(8)所示。

$$ACC = \frac{\alpha + \beta}{\alpha + \beta + \gamma + \delta}, \quad (4)$$

$$SEN = \frac{\alpha}{\alpha + \delta}, \quad (5)$$

$$SPE = \frac{\beta}{\beta + \gamma}, \quad (6)$$

$$PPV = \frac{\alpha}{\alpha + \gamma}, \quad (7)$$

$$NPV = \frac{\beta}{\beta + \delta}, \quad (8)$$

式中 α 和 β 分别表示真实标签与预测标签相同的 HGG 和 LGG 样本个数, δ 和 γ 分别表示真实标签与预测标签不相同的 HGG 和 LGG 样本个数。

3.4 实验结果与分析

3.4.1 网络结构消融实验

本小节将仅含有 MD 模块的 MD-ResNeXt 网络和仅含有 CA 模块的 CA-ResNeXt 网络与 MDCA-ResNeXt 网络进行对比, 以验证 MDCA-ResNeXt 的有效性。为了保证实验结果的科学性, 所有网络的初始化参数均由相同的随机数种子生成, 实验数据集为 BraTS2017。

图 9 (彩图见期刊电子版) 为 MD-ResNeXt、CA-ResNeXt 和 MDCA-ResNeXt 3 个网络在 5 个

交叉验证集中获得的分类结果评价图, 图中数字为评价标准的平均值, 线段为标准差。从图 9 可以看出, MDCA-ResNeXt 对 HGG 样本和 LGG 样本的分辨能力, 相较于 MD-ResNeXt 和 CA-ResNeXt 都有提升, 并且标准差相对较小, 说明 MDCA-ResNeXt 在不同验证集的表现都相对稳定, 鲁棒性强。

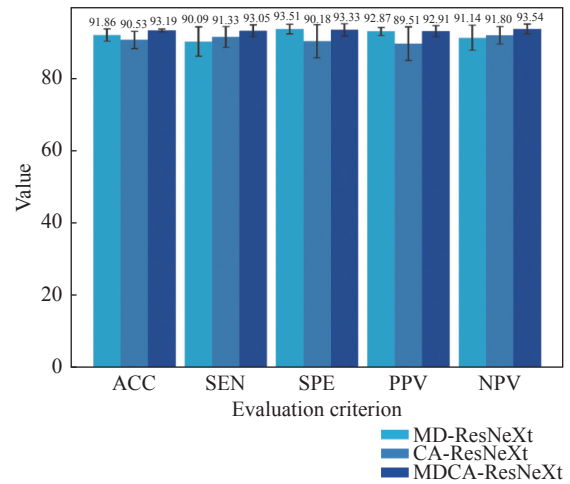


图 9 3 种网络的分类结果评价图

Fig. 9 Evaluation diagram of classification results for three kinds of Nets

为探究 MDCA-ResNeXt 工作机制的有效性, 对特征图进行了可视化处理, 图 10 和图 11 分别为 HGG 样本、LGG 样本的原始图像和特征可视化图。在图 10(a) 中, 肿瘤区域位于右侧大脑颞部, 并且核心肿瘤的外围有增强区域包裹, 在图像中表现为高频信号。图 10(b)~10(e) 分别表示 4 种网络结构在同一层输出的特征图。对比图 10(b) 和图 10(c) 可以看出, MD-ResNeXt 相较于 ResNeXt 更好地保留了脑部组织结构, 对肿瘤的增强区域有积极的“响应”; 对比图 10(b) 和图 10(d) 可以看出, CA-ResNeXt 相较于 ResNeXt 更好地突出了肿瘤的增强区域, 减少了冗余的特征信息; 对比图 10(c) 和图 10(e) 可以看出, MDCA-ResNeXt 只对肿瘤的增强区域有积极的“响应”, 相较于 MD-ResNeXt 减少了对冗余信息的“响应”, 充分说明了在网络结构中添加 CA 模块可以有效地避免冗余特征信息对分类结果造成的影响; 对比图 10(d) 和图 10(e) 可以看出, 相较 CA-ResNeXt, 添加了 MD 模块的 MDCA-ResNeXt 能够较好地体现肿瘤区域的图像特征。

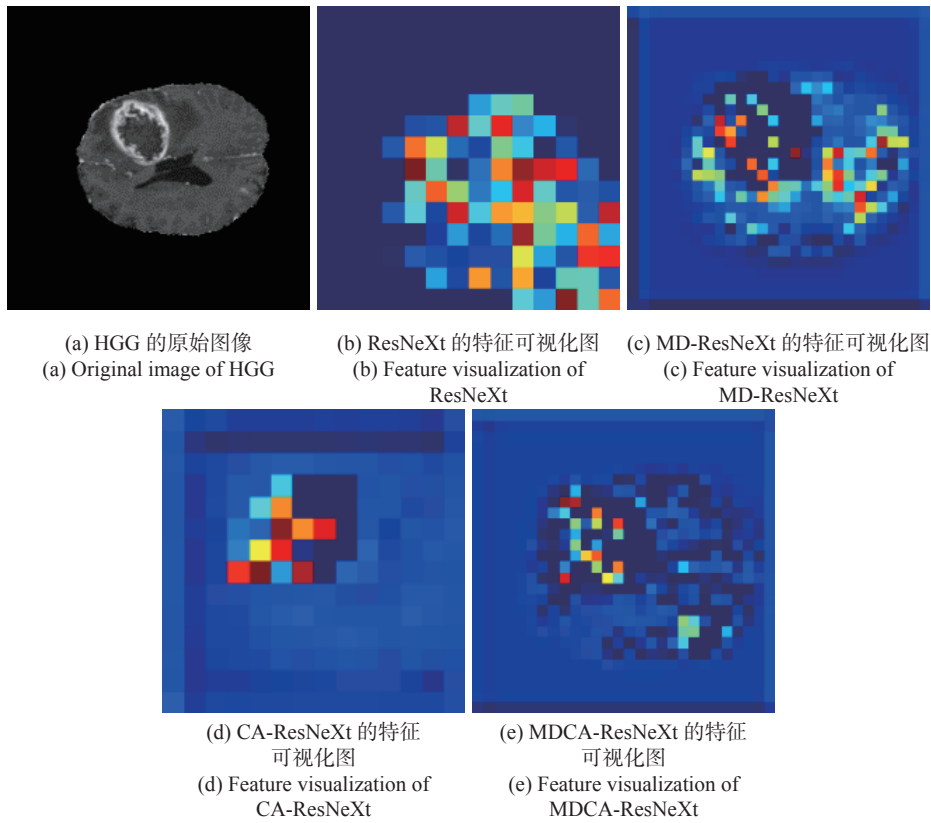


图 10 HGG 的原始图像和特征可视化图

Fig. 10 Original image and feature visualizations of HGG

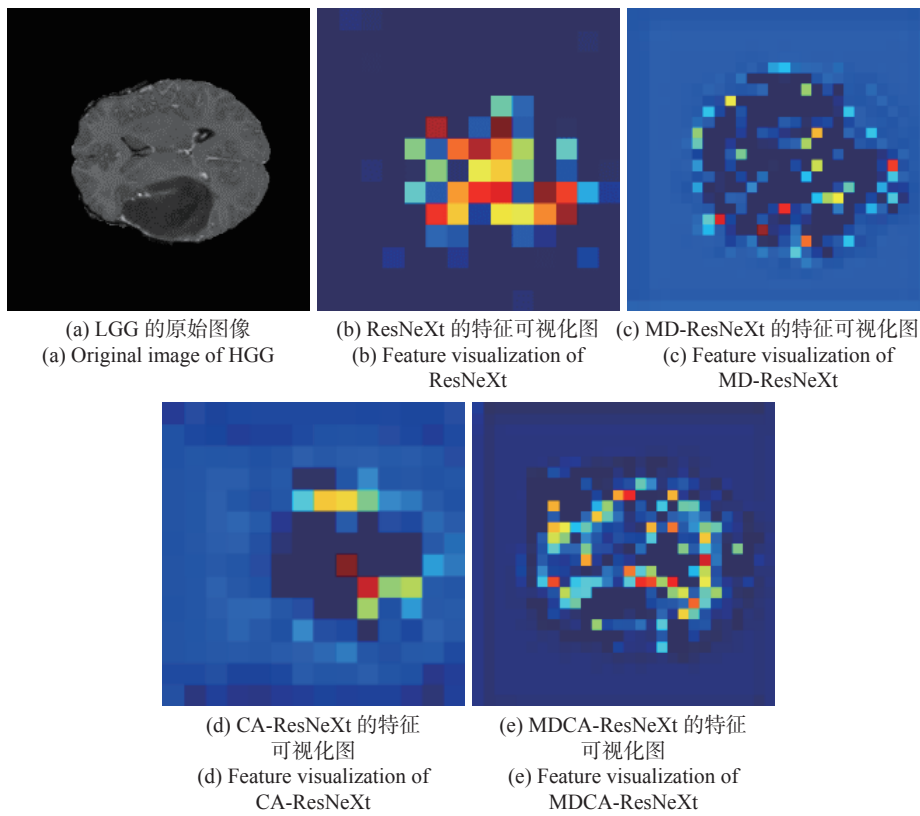


图 11 LGG 的原始图像和特征可视化图

Fig. 11 Original image and feature visualization of LGG

在图 11(a)中,肿瘤区域位于左侧大脑额前部,而良性的胶质瘤在图像中呈现低频信号,并且肿瘤外围没有出现增强区域。对比图 11(b)、图 11(c)、图 11(d)和图 11(e)可以看出,MDCA-ResNeXt 网络能够更有效地保存脑肿瘤图像的特征信息,能够更好地区分 HGG 样本和 LGG 样本。

3.4.2 经典网络对比实验

为验证本文提出的 MDCA-ResNeXt 网络以及优化后的 Improved MDCA-ResNeXt 网络在脑肿瘤良恶性分类任务中的优势,本文设置了两组对比实验,一组实验是将 ResNet 网络、ResNeXt 网络和 SENet 网络^[30]应用在 BraTS2017 和 BraTS2019 数据集中,把 3 种经典网络的分类结果与 MDCA-ResNeXt 网络进行比较;另一组是将优化后的 3 种经典网络与 Improved MDCA-Res-

NeXt 网络的分类结果进行对比。

根据表 2 和表 3 可知,MDCA-ResNeXt 的分类结果与其他 3 个经典网络相比都是最高的。对比不同网络的 SPE 值和 NPV 值可以看出,MDCA-ResNeXt 提高了对 LGG 样本的分类能力。从表 4 和表 5 可以看出,本文提出的 Improved MDCA-ResNeXt 的各项分类评价标准同样都是最高的。

根据以上 4 个分类结果评价表可以得出以下结论:首先,本文提出的 MDCA-ResNeXt 网络是以 ResNeXt 为主干网络进行的改进,改进后的网络能够有效区分良恶性脑肿瘤,并且提高了网络在不同分类任务的鲁棒性;其次,本文采取 3 种优化策略的组合可以提高网络的分类准确率和泛化能力。

表 2 优化前 BraTS2017 数据集的分类结果评价表

Tab. 2 Evaluation of classification results on BraTS2017 before optimization

网络	ACC(%)	SEN(%)	SPE(%)	PPV(%)	NPV(%)
ResNet	89.15±1.83	88.76±3.38	89.51±3.38	88.92±3.67	89.60±2.58
SENet	90.44±3.25	93.05±2.09	89.25±7.41	88.21±5.69	93.19±1.77
ResNeXt	90.34±1.14	89.23±3.36	92.53±2.18	91.85±1.96	90.22±2.57
MDCA-ResNeXt	93.19±0.35	93.05±1.67	93.33±1.69	92.91±1.54	93.54±1.36

表 3 优化前 BraTS2019 数据集的分类结果评价表

Tab. 3 Evaluation of classification results on BraTS2019 before optimization

网络	ACC(%)	SEN(%)	SPE(%)	PPV(%)	NPV(%)
ResNet	91.83±2.73	93.31±2.12	90.13±4.59	91.71±3.65	92.10±2.51
SENet	91.91±2.42	90.54±5.63	91.74±4.83	93.00±3.76	93.25±2.54
ResNeXt	93.57±1.50	94.23±2.02	92.80±2.99	93.85±2.31	93.35±2.15
MDCA-ResNeXt	94.10±1.40	94.38±1.67	93.78±2.33	94.76±2.12	93.60±1.59

表 4 优化后 BraTS2017 数据集的分类结果评价表

Tab. 4 Evaluation of classification results on BraTS2017 after optimization

网络	ACC(%)	SEN(%)	SPE(%)	PPV(%)	NPV(%)
Improved ResNet	96.87±1.49	96.76±0.71	96.98±2.90	96.84±2.97	96.98±0.64
Improved SENet	97.56±1.04	96.67±0.89	98.40±1.43	98.27±1.52	96.94±0.83
Improved ResNeXt	97.98±1.33	97.43±2.06	98.49±1.28	98.38±1.39	97.63±1.88
Improved MDCA-ResNeXt	98.11±0.41	97.43±0.26	98.76±0.91	98.66±0.97	97.63±0.22

表5 优化后 BraTS2019 数据集的分类结果评价表

Tab. 5 Evaluation of classification results on BraTS2019 after optimization

网络	ACC(%)	SEN(%)	SPE(%)	PPV(%)	NPV(%)
Improved ResNet	97.03±1.95	97.31±2.02	96.62±3.04	97.20±2.55	96.91±2.23
Improved SENet	96.69±0.88	94.38±1.89	98.74±0.93	98.62±1.01	94.99±1.57
Improved ResNeXt	97.98±0.57	97.69±0.47	98.31±0.73	98.53±0.64	97.36±0.54
Improved MDCA-ResNeXt	98.72±0.31	98.62±0.64	98.85±0.51	99.00±0.44	98.41±0.73

3.4.3 其他先进方法的对比结果

为充分说明本文提出的基于 Improved MDCA-ResNeXt 网络的脑肿瘤良恶性分类模型的性能,将本文方法与其他先进方法进行对比,对比结果如表6所示。

表6中,文献[7]和文献[8]为传统机器学习的分类方式,文献[19]、[15]、[16]和[17]为深度学习的分类方式。上述对比方法中大多是基于

分割结果图进行肿瘤分类的,而图像分割是基于图像像素点进行的0-1分类过程,对分割算法和分割模型的性能要求更高,并且分割结果会直接影响分类结果。除此之外,先分割后分类的方法,增加了分类过程中的不可控因素。基于此,本文提出的 Improved MDCA-ResNeXt 分类算法在肿瘤良恶性分类任务中更具有优势,分类准确率更高。

表6 先进方法分类结果对比表

Tab. 6 Comparison of classification results of advanced methods

文献	方法	肿瘤分割	数据集	准确率(%)
文献[7]	HCS+ Multi-SVNN	是	BraTs2014	93.00
文献[15]	Inception V3+POS	是	BraTs2017	96.90
文献[16]	VGG16+ELM	否	BraTs2017	96.90
文献[17]	3D CNN+VGG19+FNN	是	BraTs2017	96.97
文献[8]	FBSO	是	BraTs2018	93.85
文献[19]	3D U-Net	否	BraTs2018	91.67
本文方法	Improved MDCA-ResNeXt	否	BraTs2017	98.11
		否	BraTs2019	98.72

4 结 论

本文提出一种基于 Improved MDCA-ResNeXt 网络的脑肿瘤良恶性分类方法,不仅能将原始图像中细微的局部特征和全局特征相融合,保留 HGG 的肿瘤增强区的特征信息,还能将特征图的特征通道重新排列,提高网络对肿瘤区域的关注度,降低网络对冗余特征的关注度;采用学习率的线性衰减策略、图像标签平滑策略

以及基于医学图像的迁移学习策略的组合优化策略可提高网络的学习能力和泛化性能。在 BraTS2017 和 BraTS2019 数据集上的实验结果表明,本文方法相较经典网络和其他先进方法的分类准确率、鲁棒性有所增强,其中准确率分别达到 98.11% 和 98.72%。在未来的研究工作中需要进一步优化网络结构,可以考虑引入新的技术,减少具有相似性的冗余特征对分类结果的影响和计算消耗,进一步提升分类准确率、降低运算时间。

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: A Cancer Journal for Clinicians*, 2018, 68(6): 394-424.
- [2] BRAY F, FERLAY J, SOERJOMATARAM I, *et al.*. Erratum: global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. *CA: A Cancer Journal for Clinicians*, 2020, 70(4): 313.
- [3] BAKAS S, AKBARI H, SOTIRAS A, *et al.*. Advancing the cancer genome atlas glioma MRI collections with expert segmentation labels and radiomic features[J]. *Scientific Data*, 2017, 4: 170117.
- [4] MOHAN G, SUBASHINI M M. MRI based medical image analysis: survey on brain tumor grade classification[J]. *Biomedical Signal Processing and Control*, 2018, 39: 139-161.
- [5] KHARRAT A, HALIMA M B, AYED M B. MRI brain tumor classification using Support Vector Machines and meta-heuristic method[C]. *IEEE 2015 15th International Conference on Intelligent Systems Design and Applications (ISDA)*, IEEE, 2015: 446-451.
- [6] 徐立, 白金牛, 李磊民. 基于脑部MR图像GMM特征决策分类的肿瘤诊断[J]. *控制工程*, 2017, 24(8): 1718-1722.
XU L, BAI J N, LI L M. Diagnosis of tumor in brain MR images based on GMM features and decision tree classifier[J]. *Control Engineering of China*, 2017, 24(8): 1718-1722. (in Chinese)
- [7] RAJU A R, SURESH P, RAO R R. Bayesian HCS-based multi-SVNN: a classification approach for brain tumor segmentation and classification using Bayesian fuzzy clustering[J]. *Biocybernetics and Biomedical Engineering*, 2018, 38(3): 646-660.
- [8] NARMATHA C, ELJACK S M, TUKA A A R M, *et al.*. A hybrid fuzzy brain-storm optimization algorithm for the classification of brain tumor MRI images[J]. *Journal of Ambient Intelligence and Humanized Computing*, doi: 10.1007/s12652-020-02470-5.
- [9] 黄乐弘, 曹立华, 李宁, 等. 深度学习的空间红外弱小目标状态感知方法[J]. *中国光学*, 2020, 13(3): 527-536.
HUANG L H, CAO L H, LI N, *et al.*. A state perception method for infrared dim and small targets with deep learning[J]. *Chinese Optics*, 2020, 13(3): 527-536. (in Chinese)
- [10] 郑江鹏, 余平, 赵萌, 等. 利用低信噪比小样本太赫兹光谱实现心肌淀粉样变检测[J]. *中国光学*, 2022, 15(3): 443-453.
ZHENG J P, YU P, ZHAO M, *et al.*. Detection of myocardial amyloidosis by a small number of terahertz spectra with low signal-to-noise ratio[J]. *Chinese Optics*, 2022, 15(3): 443-453. (in Chinese)
- [11] 吴海滨, 魏喜盈, 王爱丽, 等. 八度卷积和双向门控循环单元结合的X光安检图像分类[J]. *中国光学*, 2020, 13(5): 1138-1146.
WU H B, WEI X Y, WANG A L, *et al.*. X-ray security inspection images classification combined octave convolution and bidirectional GRU[J]. *Chinese Optics*, 2020, 13(5): 1138-1146. (in Chinese)
- [12] 李宇, 刘雪莹, 张洪群, 等. 基于卷积神经网络的光学遥感图像检测[J]. *光学精密工程*, 2018, 26(1): 200-207.
LI Y, LIU X Y, ZHANG H Q, *et al.*. Optical remote sensing image retrieval based on convolutional neural networks[J]. *Optics and Precision Engineering*, 2018, 26(1): 200-207. (in Chinese)
- [13] 陈筱, 朱向冰, 吴昌凡, 等. 基于迁移学习与特征融合的眼底图像分类[J]. *光学精密工程*, 2021, 29(2): 388-399.
CHEN X, ZHU X B, WU CH F, *et al.*. Research on fundus image classification based on transfer learning and feature fusion[J]. *Optics and Precision Engineering*, 2021, 29(2): 388-399. (in Chinese)
- [14] GNANASEKARAN V S, JOYPAUL S, SUNDARAM P M, *et al.*. Deep learning algorithm for breast masses classification in mammograms[J]. *IET Image Processing*, 2020, 14(12): 2860-2868.
- [15] SHARIF M I, LI J P, KHAN M A, *et al.*. Active deep neural network features selection for segmentation and recognition of brain tumors using MRI images[J]. *Pattern Recognition Letters*, 2020, 129: 181-189.
- [16] KHAN M A, ASHRAF I, ALHAISONI M, *et al.*. Multimodal brain tumor classification using deep learning and robust feature selection: a machine learning application for radiologists[J]. *Diagnostics*, 2020, 10(8): 565.
- [17] REHMAN A, KHAN M A, SABA T, *et al.*. Microscopic brain tumor detection and classification using 3D CNN and feature selection architecture[J]. *Microscopy Research and Technique*, 2021, 84(1): 133-149.
- [18] SEETHA J, RAJA S S. Brain tumor classification using Convolutional Neural Networks[J]. *Biomedical and Pharmacology Journal*, 2018, 11(3): 1457-1461.
- [19] 赵尚义, 王远军. 基于3D CNN的脑胶质瘤分类算法[J]. *光学技术*, 2019, 45(6): 749-755.

- ZHAO SH Y, WANG Y J. Brain glioma classification algorithm based on 3D CNN[J]. *Optical Technique*, 2019, 45(6): 749-755. (in Chinese)
- [20] XIE S N, GIRSHICK R, DOLLÁR P, *et al.*. Aggregated residual transformations for deep neural networks[C]. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2017: 5987-5995.
- [21] SZEGEDY C, VANHOUCKE V, IOFFE S, *et al.*. Rethinking the inception architecture for computer vision[C]. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2016: 2818-2826.
- [22] HE K M, ZHANG X Y, REN SH Q, *et al.*. Deep residual learning for image recognition[C]. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2016: 770-778.
- [23] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[C]. 4th International Conference on Learning Representations, 2016: <https://doi.org/10.48550/arXiv.1511.07122>.
- [24] WOO S, PARK J, LEE J Y, *et al.*. CBAM: convolutional block attention module[C]. *Proceedings of the 15th European Conference on Computer Vision*, Springer, 2018: 3-19.
- [25] JIANG L Q, NING CH Y, LI J Y. Glioma classification framework based on SE-ResNeXt network and its optimization[J]. *IET Image Processing*, 2022, 16(2): 596-605.
- [26] CHENG J, HUANG W, CAO SH L, *et al.*. Enhanced performance of brain tumor classification via tumor region augmentation and partition[J]. *PLoS One*, 2015, 10(12): e0140381.
- [27] VOVK U, PERNUS F, LIKAR B. A review of methods for correction of intensity inhomogeneity in MRI[J]. *IEEE Transactions on Medical Imaging*, 2007, 26(3): 405-421.
- [28] TUSTISON N J, AVANTS B B, COOK P A, *et al.*. N4ITK: improved N3 bias correction[J]. *IEEE Transactions on Medical Imaging*, 2010, 29(6): 1310-1320.
- [29] ZHONG ZH, ZHENG L, KANG G L, *et al.*. Random erasing data augmentation[C]. *Proceedings of the 34th AAAI Conference on Artificial Intelligence, AAAI*, 2020: 13001-13008.
- [30] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2018: 7132-7141.

作者简介:



姜林奇(1999—),女,内蒙古呼伦贝尔人,硕士研究生,2019年于南华大学获得学士学位,主要从事深度学习、图像分类等方面的研究。E-mail: 631540532@qq.com



宁春玉(1976—),女,吉林农安人,硕士,副教授,硕士生导师,2005年于吉林大学获得计算机应用技术硕士学位,主要从事图像处理、模式识别的研究。E-mail: yeningcy@163.com