



基于 MDM-ResNet 的脑肿瘤分类方法

摘要

脑肿瘤是世界上最致命的癌症之一。由于脑肿瘤的多样性,其图像分类成为了当代研究的热点。近年来,深度神经网络(DNN)常用于医学图像分类,但随着深度的增加网络会出现梯度消失和过拟合的问题,而残差网络(ResNet)通过引入恒等映射可以缓解这些问题。因此,本文基于 ResNet 提出了一种 MDM-ResNet 网络,该网络由多尺寸卷积核模块(Multi-size convolution kernel module)、双通道池化层(Dual-channel pooling layer)和多深度融合残差块(Multi-depth fusion residual block)组成。本文实验在 Figshare 数据集上展开,采用数据增强操作对图像进行预处理,并利用 5 倍交叉验证方法对网络性能进行评估。最终实验结果表明 MDM-ResNet 能够对脑膜瘤(Meningioma)、胶质瘤(Glioma)和垂体瘤(Pituitary tumor)进行有效分类。

关键词

脑肿瘤;深度神经网络(DNN);残差网络(ResNet);多尺寸卷积核模块;双通道池化层;多深度融合残差块

中图分类号 R739.41;TP183

文献标志码 A

收稿日期 2021-01-06

资助项目 国家自然科学基金(41505017)

作者简介

夏景明,男,博士,副教授,研究方向包括机器学习和深度学习在气象学中的应用。001481@nuist.edu.cn

邢露萍(通信作者),女,硕士生,研究方向为图像识别和深度学习。20181219093@nuist.edu.cn

1 南京信息工程大学,人工智能学院,南京,210044

2 南京信息工程大学,计算机与软件学院,南京,210044

0 引言

脑肿瘤类型有 120 多种,最常见的类型是脑膜瘤(占脑肿瘤患病率的 35%)、胶质瘤(占脑肿瘤患病率的 16%)和垂体瘤(占脑肿瘤患病率的 14%)^[1]。早期发现肿瘤有助于专家在脑肿瘤生长的初期阶段制定出准确的治疗计划。在临床诊断中,磁共振成像(Magnetic Resonance Imaging, MRI)因具有高分辨率、多参数成像等特点成为了最常用的脑肿瘤诊断技术^[2]。医生对海量 MRI 图像进行手工诊断并发现早期脑肿瘤是一项非常耗时的工作,而计算机辅助诊断技术可以帮助解决这一难题。

近年来,深度学习因其高精度的性能在计算机视觉^[3-5]、图像处理^[6-7]、认证系统^[8]和语音识别^[9-10]等研究领域迅速发展。深度学习中的卷积神经网络(CNN)被认为是目前最成功的图像处理方法^[11]。AlexNet^[12]、VGG^[13]等 CNN 的发展表明增加网络深度能够在一定程度上提高网络性能。但若只通过简单的网络层堆叠来增加深度就会导致网络出现梯度消失的情况^[14]。本文通过研究多种残差网络(ResNet)^[15],提出了一种基于 MDM-ResNet 网络的脑肿瘤多分类方法,具体贡献如下:

1) 传统 CNN 结构中单通路的卷积层对局部上下文信息的接受度是有限的,然而利用不同大小的卷积核可以提取到更全面的特征信息。因此,本文提出了多尺寸卷积核模块。

2) 考虑到将最大值池化和平均池化相结合可以使两者提取到的高维信息进行互补,本文提出了双通道池化层。

3) 通过对多种 ResNet 中残差块的研究,本文提出了一种多深度融合残差块,该残差块将不同 ResNet 中“跳跃连接”跳过的卷积单元相结合,同时保留“跳跃连接”,在结合多种卷积方式的同时也增加了残差块的宽度。

将以上三种结构融合组成了本文的分类网络,即 MDM-ResNet。

1 相关工作

脑肿瘤的分类已经得到了广泛的关注,在过去的几年中研究者们提出了多种分类方法。Cheng 等^[16]提出了一种基于 DNN 的方法对大脑正常和异常的 CT 图像进行分类,并采用灰度共生矩阵(GLCM)进行特征提取,该方法的平均分类准确性为 83%;Abd-Allah 等^[17]研

究了一种两相多模型脑肿瘤自动诊断系统,其中分类阶段的模型由三部分组成,分别是预处理、CNN 特征提取和纠错输出码-支持向量机(ECOC-SVM),该模型对脑肿瘤良恶性分类获得的最高平均准确性为 99.55%.

但以上研究都只是对脑肿瘤进行二分类.2018年,Abiwinanda 等^[18]提出了一种 CNN 结构,该结构中每一个卷积层、最大值池化层和 flatten 层后面都跟有一个隐藏的全连接层,此方法对脑膜瘤、胶质瘤和垂体瘤的平均分类准确性为 84.19%.2019年,Ghassemi 等^[19]提出了一种新的深度学习方法用于脑肿瘤的 MRI 图像分类,该方法首先在不同数据集上预训练一个 DNN 作为生成对抗网络(GAN)的鉴别器,以提取 MRI 图像的鲁棒性特征并学习 MRI 图像在其卷积层中的结构,然后用 softmax 层替代网络的全连接层,将整个深度网络训练成分类器,该方法对脑膜瘤、胶质瘤和垂体瘤的平均分类准确性为 93.01%.

上述方法^[16-19]都基于深度网络,然而,随着层数的增加网络通常会出现梯度消失的情况.2021年,Kumar 等^[1]提出了一种将 ResNet50 和平均池化结合的模型来克服深度网络中梯度消失和过拟合的问题,最终实验证明该方法对脑膜瘤、胶质瘤和垂体瘤的分类具有高准确性.

2 本文方法

ResNet 由残差块搭建而成,这类模块使得网络不仅没有出现退化问题,还大大降低了错误率.在许多具有挑战性的图像识别任务中,ResNet 已经表现出了优异的性能^[20].本文通过研究 ResNet18、ResNet34 和 ResNet50 等网络,提出了一种 MDM-ResNet 网络用于脑肿瘤分类,该网络由多尺寸卷积核模块、双通道池化层和多深度融合残差块组成,其结构如图 1 所示.

2.1 多尺寸卷积核模块

文献^[21]中提出了一种 Inception v1 结构,该结构将 CNN 中常用的卷积(1×1,3×3,5×5)和池化操作(3×3)堆叠在一起,最后通过 concat 函数对四条路径的运算结果进行通道上的合并.其中 5×5 大小的卷积核能够覆盖大部分接受层的输入,且该结构在卷积的同时再进行一个池化操作,有利于减少网络空间大小,降低过度拟合.此结构不仅增加了网络的宽度,还增加了网络对尺度的适应性.受到 Inception v1 的启发,本文提出了一种类似于它的多

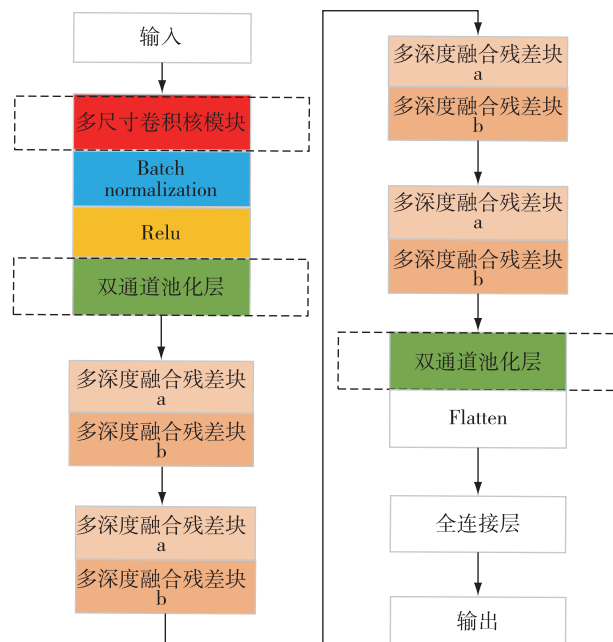


图 1 MDM-ResNet 结构

Fig. 1 Structure of the proposed MDM-ResNet

尺寸卷积核模块,该模块的结构如图 2 所示.多尺寸卷积核模块与 Inception v1 的区别在于:不使用 concat 函数连接各个分支,而采用的是 add 函数.concat 函数用于通道数的合并,即只是增加了描述图像本身的维度(通道数),每一维度下的特征信息并没有增加;而 add 函数的作用是没有增加描述图像本身特征的维度,但每一维度下的特征信息量在增加,这对最终图像的分类是有益的.

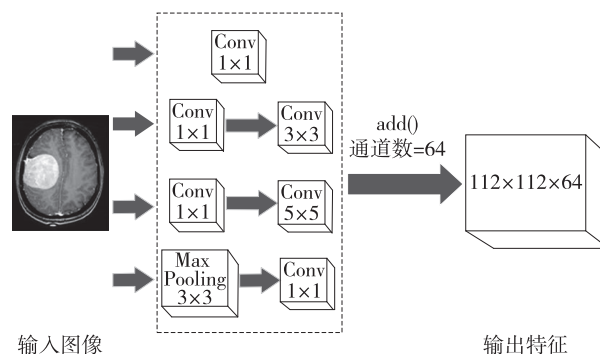


图 2 多尺寸卷积核模块结构

Fig. 2 Structure of multi-size convolution kernel module

2.2 双通道池化层

ResNet 只在残差块前后有池化层,分别是最大值池化和平均池化.最大值池化的目的是将感受野区域中激活的最大值作为最终的池化输出,它侧重于纹理信息,能够平衡卷积参数误差引起的估计均

值的偏移^[22].平均池化的目的是将感受野区域中激活的平均值作为最终的池化输出,它更侧重于背景信息,可以减小由于邻域大小限制而导致估计方差增大带来的误差.因此本文把两种池化方式结合提出了一种双通道池化层结构:上一步输出的特征分两条路径同时经过最大值池化和平均池化,然后通过 add 函数将两条路径的输出结果合并起来共同进入下一步的运算.双通道池化层的结构如图3所示.




图3 双通道池化层结构

Fig. 3 Structure of dual-channel pooling layer

2.3 多深度融合残差块

ResNet50 中的基础残差块可以使得网络在增加深度的同时,还能降低计算复杂度并解决梯度消失的问题.但它的缺点是网络在进行反向传播时并不能保证可以流经每一个残差块的 weights,因此在整个训练过程中,只有极少数的残差块能够学习到有用的特征表达,而绝大多数的残差块起到的作用并不大^[23].卷积的目的是将输入图像与卷积核进行互相关运算,由此抽取图像的特征,而多层卷积在每次卷积过程中,感受到的信息及抽取的特征都不相同^[24].因此,本文提出了多深度融合残差块,它的结构如图4所示.

图4a和图4b中,中间路径“ $1 \times 1 - 3 \times 3 - 1 \times 1$ ”和右边路径中的“ $3 \times 3 - 3 \times 3$ ”卷积模式是 ResNet50、ResNet34 等在“跳跃连接”中跳过的卷积单元.一般来说,深度更深的 ResNet 效果稍好,其残差块形态类似卷积模式“ $1 \times 3 - 3 \times 3 - 1 \times 1$ ”;但 ResNet18 和 ResNet34 训练时间短,也能够取得良好的效果,其残差块形态类似卷积模式“ $3 \times 3 - 3 \times 3$ ”.本文的多深度融合残差块将两类 ResNet 中“跳跃连接”跳过的卷积单元相结合,同时保留“跳跃连接”,并在“ $3 \times 3 - 3 \times 3$ ”卷积模式后添加 1×1 卷积用于控制通道数量,

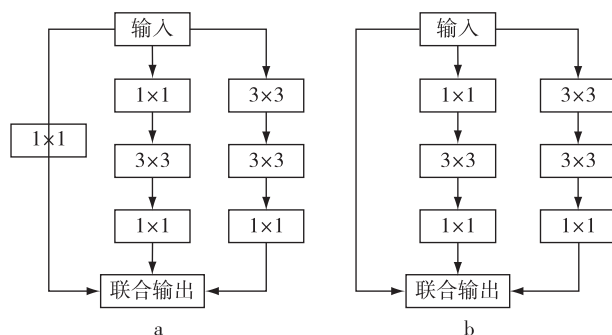


图4 多深度融合残差块

Fig. 4 Multi-depth fusion residual block

最终联合输出后可获得不同维度的特征.另外,多深度融合残差块相对基础残差块而言增加了宽度,从而网络在进行反向传播时能够保证更多的 weights 参与到学习训练中.其中, 3×3 卷积层由多个网络层组成,包括 3×3 卷积层、激活函数、批量归一化和 dropout 层.

ResNet18 在通道数量为 64、128、256、512 时各有 2 个残差块,而 ResNet34 和 ResNet50 在每种通道上分别有 3、4、6、3 个残差块.为降低网络复杂度,本文的分类网络设定每一种通道数对应 2 个多深度融合残差块,分别是图4中的多深度融合残差块(a)和多深度融合残差块(b),整个网络共计 8 个残差块.

3 实验结果与分析

3.1 数据集与预处理

本文使用的脑肿瘤数据集来自 <https://figshare.com>.该数据集由 233 名患者的脑肿瘤 MRI 图像组成,其中包含 708 张脑膜瘤切片、1 426 张胶质瘤切片和 930 张垂体瘤切片,共计 3 064 张图像.

丰富的数据是有效搭建深度学习模型的关键^[25].本文使用数据增强方法来扩大数据集,其中最常用的方式是对图像添加噪声或应用几何变换,这有助于防止网络模型出现过度拟合.因此,本文对数据集中的图像进行了一系列扩展:首先将所有图片大小统一为 224×224 ;然后将数据集按照 8:2 的比例分成训练集和验证集;最后对训练集图像使用旋转、水平翻转、垂直翻转和添加椒盐噪声的数据增强方法,验证集不做数据增强.

3.2 评价指标

为了全面的评价 MDM-ResNet 的性能,本文将利用以下指标作为实验结果的评判标准,它们的具体描述如下:

1) 准确性 (Accuracy, A): 表示样本中预测正确的数目与样本总数的比值, 计算公式如下:

$$A = \frac{TP + TN}{TP + TN + FN + FP} \quad (1)$$

2) 精度 (Precision, P): 表示正确预测为正的样本与全部预测为正的样本比值, 计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (2)$$

3) 召回率 (Recall, R): 又称查全率, 表示正确预测为正的样本与所有正样本的比值, 计算公式如下:

$$R = \frac{TP}{TP + FN} \quad (3)$$

4) F1 Score (F_1): 该指标同时兼顾了分类模型的精度和召回率, 可看作是模型精度和召回率的一种加权平均, 它的计算公式如下:

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (4)$$

上述公式中的 TP、FP、TN、FN 分别表示: 预测为正、实际为正; 预测为正、实际为负; 预测为负、实际为负; 预测为负、实际为正。

3.3 实验参数与训练策略

本文提出的 MDM-ResNet 网络模型由 python3.6 版本中的 Keras 库搭建而成, 采用随机梯度下降法 (SGD) 训练网络, 训练批次大小设置为 20, 训练轮次设置为 100, 初始学习率设置为 0.002, 动量 (momentum) 设置为 0.9, 权值衰减 (weight decay) 设置为 0.0002。在实验中本文采用 5 倍交叉验证方法来分析网络性能^[26]。5 倍交叉验证的训练集与验证集实施方案如图 5 所示。本文所有实验在 NVIDIA GeForce RTX 2080 Ti GPU 上进行。

3.4 实验结果与分析

为了确定多尺寸卷积核模块对 MDM-ResNet 网络分类准确性的影响, 本文分别在该网络的残差单元前面使用 7×7 卷积层和多尺寸卷积核模块进行了 2 次实验, 实验在交叉验证方案 a 上展开, 具体实验结果如表 1 所示。

表 1 在残差单元前面使用不同卷积方式的准确性对比

Table 1 Accuracy of using different convolution methods before residual unit

实验	方法	平均分类准确性/%
A	7×7 卷积层	91.37
B	多尺寸卷积核模块	93.68

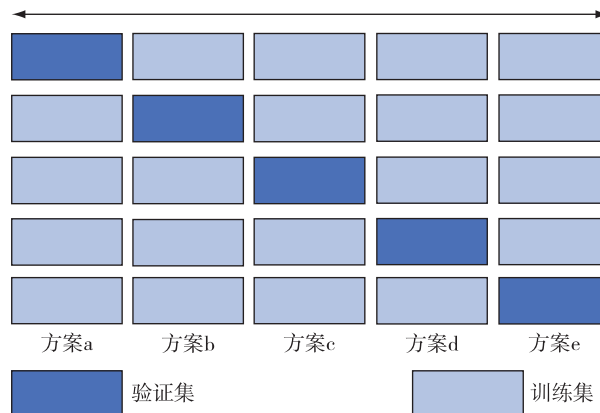


图 5 5 倍交叉验证的训练集与验证集实施方案

Fig. 5 Implementation scheme of training set and validation set for five-fold cross validation

表 1 显示, 实验 B 的准确性高于实验 A, 这表明不同大小的卷积核能够提取到输入图像中不同大小的特征, 而在进入残差块前拥有更丰富的信息有利于提高最终的分类准确性。

为了确定 MDM-ResNet 中改进池化层的最优方法, 本文在把 MDM-ResNet 残差块前面的卷积方式确定为多尺寸卷积核模块的情况下进行了以下实验, 该实验在交叉验证方案 a 上展开。具体实验结果如表 2 所示。

表 2 不同位置改进池化层的准确性对比

Table 2 Accuracy of improving pooling layer at different positions

实验	方法	平均分类准确性/%
1	残差块前面的最大值池化→双通道池化层	92.36
2	残差块后面的平均池化→双通道池化层	91.39
3	同时进行 1 和 2 的方法	93.68

表 2 显示, 将残差块前面的最大值池化层变为双通道池化层比将残差块之后的平均池化层变为双通道池化层分类效果好, 这表明平均池化相比最大值池化而言在脑肿瘤分类中扮演着更重要的角色, 揭示了复杂医学图像中全局信息的不可替代性。而实验 3 将 ResNet 中的两个单一池化层都变为双通道池化层, 平均分类准确性达到 93.68%, 这表明双通道池化层最大限度地利用了最大值池化和平均池化的优点, 使两者提取到的高维特征信息相互补充, 弥补了各自的缺点。

ResNet50^[19] 利用残差块解决了增加网络深度带来的梯度消失问题, 在不增加额外参数的情况下, 可

以单纯通过增加网络深度来加快收敛速度和提高准确性.为了体现多深度融合残差块的效果,本文在把ResNet50中7×7卷积层和单一池化层分别改进为多尺寸卷积核模块和双通道池化层的情况下与MDM-ResNet进行了实验对比,该实验在交叉验证方案a上展开,结果如表3所示.

表3 改进的ResNet50和MDM-ResNet的准确性对比

Table 3 Accuracy comparison between improved ResNet50 and MDM-ResNet

方法	平均分类准确性/%
改进的 ResNet50	93.49
MDM-ResNet	93.68

根据表3可知,MDM-ResNet对于脑膜瘤、胶质瘤和垂体瘤的平均分类准确性为93.68%,相比于改进的ResNet50,准确性小幅度地提高了0.19个百分点.这表明本文提出的多深度融合残差块对网络最终的分​​类效果是有益的.多深度融合残差块将不同残差网络中残差块内的卷积单元结合,能够在卷积过程中抽取不同的信息和特征,且MDM-ResNet在

不同的通道数量上只设有2个多深度融合残差块,这使得所有的残差模块都能够学习到有用的特征表达,从而有利于提高最终的准确性.

MDM-ResNet网络5次交叉验证中平均分类准确性训练和验证的可视化过程如图6所示.其中纵坐标为准确性,横坐标为训练轮次,蓝线和红线分别表示训练和验证过程.

由图6可以看到MDM-ResNet最初的准确性较低,通过100次的迭代训练,验证集上的准确性在40个批次后逐渐稳定.每次验证之间的准确性误差为0.092%左右,5次交叉验证的平均分类准确性为93.51%.

MDM-ResNet网络的预测分类效果可以由混淆矩阵展现,图7提供了5次验证下的混淆矩阵,其中行表示实际类别,列表示预测类别.

从图7可知,由于数据集中胶质瘤的图片数量最多,5次验证下的所有分类情况中胶质瘤被正确分类的概率最高.同时可以发现,每次验证中胶质瘤被分类成垂体瘤的概率最小,这是因为胶质瘤属于恶性肿瘤,而垂体瘤生长在垂体附近,属于良性

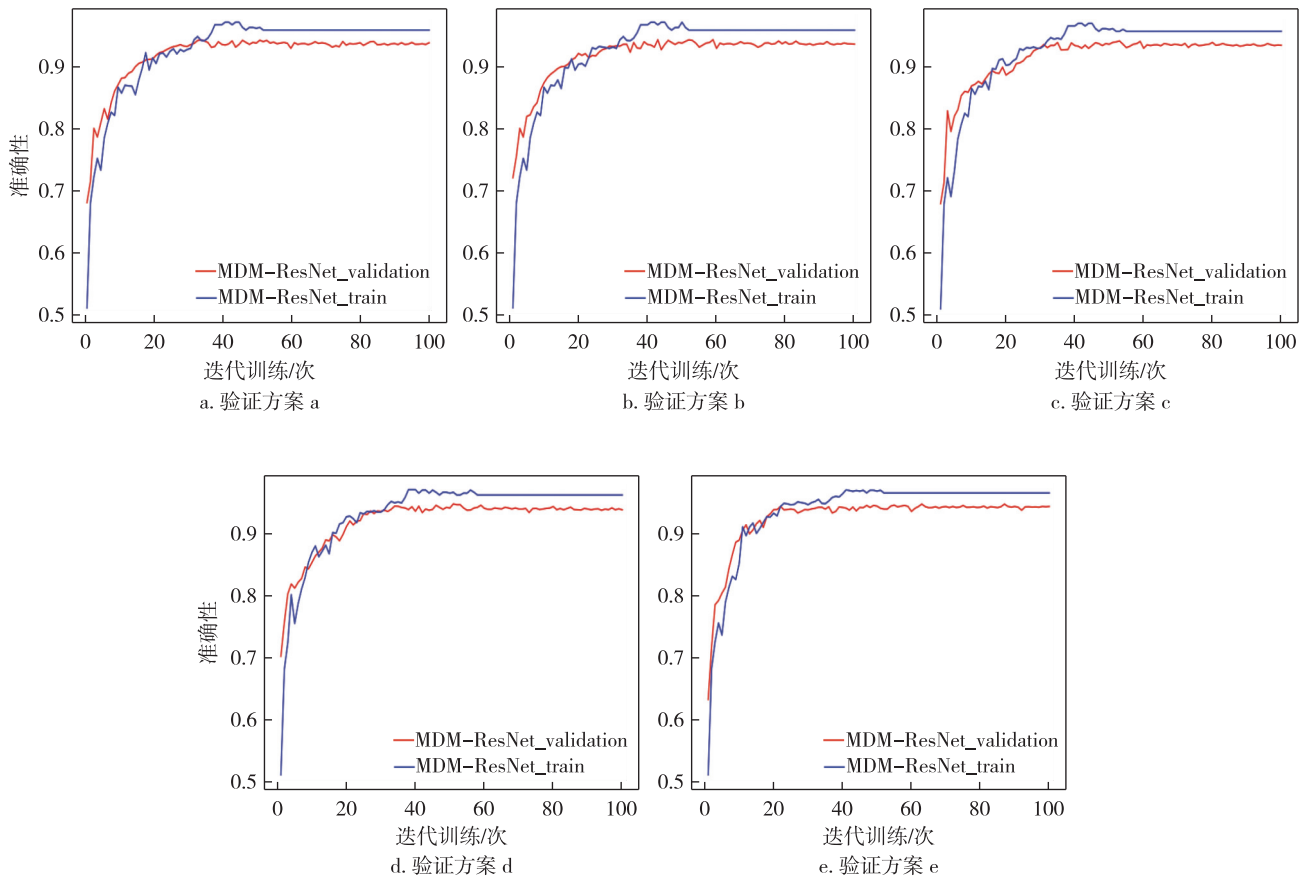


图6 MDM-ResNet网络分类准确性训练与验证的可视化过程

Fig. 6 Visualization process of training and validation of MDM-ResNet network classification accuracy on five validation schemes

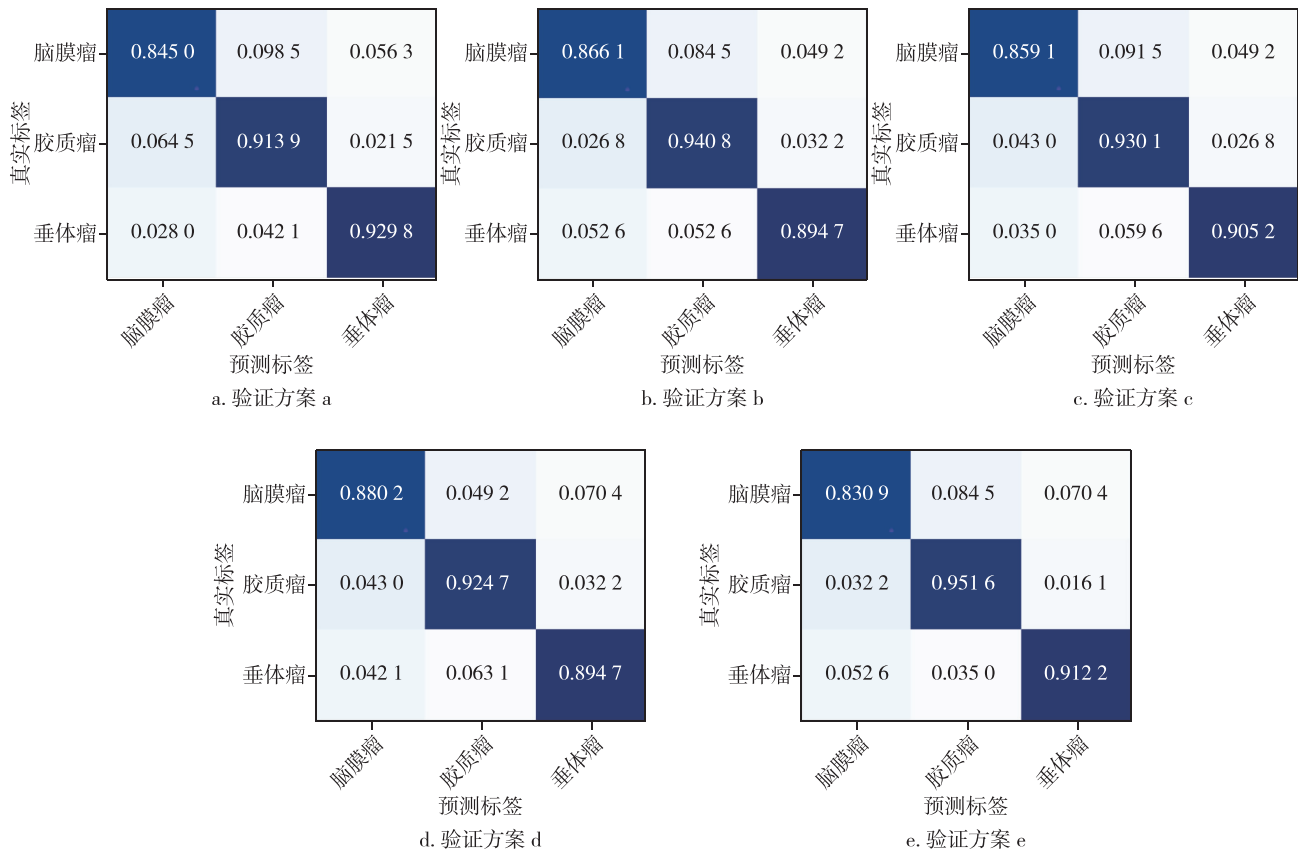


图7 5次验证中的混淆矩阵

Fig. 7 Confusion matrix of five validation schemes

肿瘤。

为了更详细地展现 MDM-ResNet 的分类效果,本文在平均分类准确性最高的验证方案 a 上,取脑膜瘤、胶质瘤和垂体瘤在 Accuracy、Precision、Recall 和 F1 Score 4 项评价指标上的表现做详细分析,各项指标数据如表 4 所示。

表 4 验证方案 a 上 MDM-ResNet 的评价指标值

Table 4 The evaluation index value of MDM-ResNet on validation scheme a

类别	Accuracy	Precision	Recall	F1 Score
脑膜瘤	93.14	85.71	84.50	85.09
胶质瘤	93.14	86.73	91.39	88.99
垂体瘤	94.77	95.66	92.98	94.29
均值	93.68	89.36	89.62	89.45

由表 4 可知,MDM-ResNet 对脑膜瘤、胶质瘤和垂体瘤的分类准确性分别为 93.14%、93.14% 和 94.77%,平均分类准确性为 93.68%。MDM-ResNet 在 Precision、Recall 和 F1 Score 上的平均值也分别达到了 89.36%、89.62% 和 89.45%。

本文将 MDM-ResNet 与其他文献中使用相同数据集的方法进行了对比,对比结果如表 5 所示。

表 5 不同方法的平均分类准确性对比

Table 5 Comparison of average classification accuracy between different methods

方法	平均分类准确性/%
文献[19]	93.01
文献[27]	91.28
MDM-ResNet	93.51

Cheng 等^[27]将图像放大后的增强肿瘤区域作为感兴趣区域(ROI),然后再将 ROI 分割成更细致的环状区.他们使用强度直方图、GLCM 和字袋模型(BoW)3 种特征提取方式来分别对提出的模型进行验证,该方法使用环形区作为输入获得的最高平均分类准确性为 91.28%.但是该方法是利用传统的机器学习方式对肿瘤进行分类,且通过手工方法提取特征,非常损耗时间.Ghassemi 等^[19]提出了一种新的多类脑肿瘤分类模型,该方法首先在不同数据集上预训练一个 DNN 作为 GAN 的鉴别器,然后用

softmax 层替代网络的全连接层,将整个网络训练成分类器,该方法获得了 93.01% 的平均分类准确性,不过由于 GAN 的限制,输入图像的大小必须是 64×64 。本文 MDM-ResNet 获得的平均分类准确性为 93.51%。实验结果表明 MDM-ResNet 中的多尺寸卷积核模块和多深度融合残差块能够提取丰富的特征,且该网络有效地结合了最大值池化和平均池化的优点,使两者提取到的信息得以相互补充,因此本文网络在分类准确性上表现较好。

4 结语

针对脑膜瘤、胶质瘤和垂体瘤的分类问题,本文提出了一种 MDM-ResNet 网络,该网络由多尺寸卷积核模块、双通道池化层和多深度融合残差块组成。其中多尺寸卷积核模块由包含不同大小卷积核的卷积分支构成,从而能够提取到输入图像中丰富的特征信息;双通道池化层结合了最大值池化和平均池化的优点,使两者提取到的细节信息和背景信息可以相互补充;多深度融合残差块通过将不同 ResNet 中残差块内的卷积单元结合,在利用多种卷积模式提取信息的同时也增加了残差块的宽度,使得网络在进行反向传播时能够保证更多的 weights 参与到学习训练中。本文实验在 Figshare 数据集上展开,使用 Accuracy、Precision、Recall 和 F1 Score 作为网络性能的评价指标并采用 5 倍交叉验证方法来分析网络的分类效果,最终 MDM-ResNet 对脑膜瘤、胶质瘤和垂体瘤的平均分类准确性为 93.51%。

参考文献

References

- [1] 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: 1-10. DOI: 10. 1007/s11042-020-10335-4
- [2] 葛婷,詹天明,牟善祥.基于多核协同表示分类的脑肿瘤分割算法[J]. *南京理工大学学报*, 2019, 43(5): 578-585
GE Ting, ZHAN Tianming, MOU Shanxiang. Brain tumor segmentation algorithm based on multi-kernel collaborative representation classification[J]. *Journal of Nanjing University of Science and Technology*, 2019, 43(5): 578-585
- [3] Muhammad K, Ahmad J, Lv Z, et al. Efficient deep CNN-based fire detection and localization in video surveillance applications[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2019, 49(7): 1419-1434
- [4] Ullah A, Ahmad J, Muhammad K, et al. Action recognition in video sequences using deep bi-directional LSTM with CNN features[J]. *IEEE Access*, 2018, 6: 1155-1166
- [5] Muhammad K, Ahmad J, Baik S W. Early fire detection using convolutional neural networks during surveillance for effective disaster management[J]. *Neurocomputing*, 2018, 288: 30-42
- [6] Ahmad J, Muhammad K, Lloret J, et al. Efficient conversion of deep features to compact binary codes using Fourier decomposition for multimedia big data[J]. *IEEE Transactions on Industrial Informatics*, 2018, 14(7): 3205-3215
- [7] Ahmad J, Muhammad K, Baik S W. Medical image retrieval with compact binary codes generated in frequency domain using highly reactive convolutional features[J]. *Journal of Medical Systems*, 2017, 42(2): 24. DOI: 10. 1007/s10916-017-0875-4
- [8] Sajjad M, Khan S, Hussain T, et al. CNN-based anti-spoofing two-tier multi-factor authentication system[J]. *Pattern Recognition Letters*, 2019, 126: 123-131
- [9] Ahmad J, Muhammad K, Kwon S I, et al. Dempster-Shafer fusion based gender recognition for speech analysis applications[C]// *2016 International Conference on Platform Technology and Service (PlatCon)*. February 15 - 17, 2016, Jeju, Korea (South). IEEE, 2016: 1-4. DOI: 10. 1109/PlatCon.2016. 7456788
- [10] Badshah A M, Rahim N, Ullah N, et al. Deep features-based speech emotion recognition for smart affective services[J]. *Multimedia Tools and Applications*, 2019, 78(5): 5571-5589
- [11] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444
- [12] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90
- [13] Qiao S Y, Zhang Z S, Shen W, et al. Gradually updated neural networks for large-scale image recognition[J]. *arXiv e-print*, 2017, arXiv: 1711. 09280
- [14] 周祥全,张津.深层网络中的梯度消失现象[J]. *科技展望*, 2017(27): 284
ZHOU Xiangquan, ZHANG Jin. Gradient vanishing in deep networks[J]. *Technology Outlook*, 2017(27): 284
- [15] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]// *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 770-778
- [16] Cheng D, Zhang H, Sang Y. Brain CT image classification with deep neural networks[C]// *Proceedings of the 18th Asia Pacific Symposium on Intelligent and Evolutionary Systems*, 2015, 1: 653-662. DOI: 10. 1007/978-3-319-13359-1_50
- [17] Abd-Allah M K, Awad A I, Khalaf A A M, et al. Two-phase multi-model automatic brain tumour diagnosis system from magnetic resonance images using convolutional neural networks[J]. *EURASIP Journal on Image and Video Processing*, 2018, 2018(1): 1-10
- [18] Abiwinanda N, Hanif M, Hesaputra S T, et al. Brain tumor classification using convolutional neural network[M]// *IFMBE Proceedings*. Singapore: Springer Singapore,

- 2018:183-189
- [19] 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.DOI:10.1016/j.bspc.2019.101678
- [20] Sengupta A,Ye Y,Wang R,et al.Going deeper in spiking neural networks: VGG and residual architectures [J].Frontiers in Neuroscience,2019,13:95.DOI:10.3389/fnins.2019.00095
- [21] Szegedy C,Liu W,Jia Y Q,et al.Going deeper with convolutions [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).June 7-12,2015,Boston,MA,USA.IEEE,2015:1-9
- [22] Chang J,Zhang L M,Gu N J,et al.A mix-pooling CNN architecture with FCRF for brain tumor segmentation[J].Journal of Visual Communication and Image Representation,2019,58:316-322
- [23] 蒋行国,苏欣欣,蔡晓东.改进残差网络的多角度车型识别方法[J].电视技术,2018,42(6):93-98
- JIANG Xingguo,SU Xinxin,CAI Xiaodong.Improved residual network for multi-angle vehicles recognition [J].Video Engineering,2018,42(6):93-98
- [24] Zeiler M D,Fergus R.Visualizing and understanding convolutional networks[C] // Computer Vision-ECCV 2014,2014:818-833
- [25] Zhang Y D,Dong Z C,Chen X Q,et al.Image based fruit category classification by 13-layer deep convolutional neural network and data augmentation [J].Multimedia Tools and Applications,2019,78(3):3613-3632
- [26] Li H,Zhuang S S,Li D A,et al.Benign and malignant classification of mammogram images based on deep learning[J].Biomedical Signal Processing and Control,2019,51:347-354
- [27] Cheng J,Huang W,Cao S L,et al.Enhanced performance of brain tumor classification via tumor region augmentation and partition [J].PLoS One,2015,10(10):e0140381.DOI:10.1371/journal.pone.0140381

Brain tumors classification based on MDM-ResNet

XIA Jingming¹ XING Luping¹ TAN Ling² XUAN Dawei¹

¹ School of Artificial Intelligence,Nanjing University of Information Science & Technology,Nanjing 210044

² School of Computer and Software,Nanjing University of Information Science & Technology,Nanjing 210044

Abstract Brain tumor is one of the most fatal cancers in the world.Its image classification has become the hot spot due to the diverse characteristics of brain tumors.In recent years,Deep Neural Networks (DNN) are commonly used for medical image classification,but the problem of gradient vanishing and over fitting will appear with the increase of depth,while the Residual Network (ResNet) can solve this problem by introducing identity mapping.Therefore,this paper proposes an MDM-ResNet approach for brain tumor classification,which is composed of multi-size convolution kernel module,dual-channel pooling layer and multi-depth fusion residual block.The experiment was carried out on Figshare dataset,the image was preprocessed by data enhancement operation,and the performance of network was evaluated based on five-fold cross validation.The experimental results prove that the MDM-ResNet approach can effectively classify meningioma,glioma and pituitary tumor.

Key words brain tumor;deep neural network (DNN);residual network (ResNet);multi-size convolution kernel module;dual-channel pooling layer;multi-depth fusion residual block