

基于迁移学习和3D-WGMobileNet的青年抑郁症辅助诊断

郭朝晖,王瑜,马慧鋈,田恒屹

北京工商大学计算机与人工智能学院, 北京 100048

【摘要】提出一种基于3D-WGMobileNet和迁移学习的网络模型,实现对青年抑郁症不同阶段患者的正确分类。首先,对功能磁共振成像(fMRI)数据进行预处理,并通过局部一致性分析将4D fMRI数据转换为3D,进行降维处理。然后,使用迁移学习方法将阿尔茨海默症的特征迁移到提出的3D-WGMobileNet中。利用动态分组卷积构建卷积核的专家权重矩阵,提高模型的表达能力;利用滑动窗口分组卷积来压缩模型的参数量,增强模型的计算能力。最后,利用3D-WGMobileNet对抑郁症患者图像进行特征提取和分类。在人类连接组项目数据库上的实验结果表明结合迁移学习、动态分组卷积和滑动窗口分组卷积的3D-WGMobileNet获得较好的分类效果,其中,抑郁症和健康对照组、轻度抑郁症和健康对照组、轻度抑郁症和轻度抑郁症的分类准确率分别达到89.00%、85.15%、87.90%,证明本文方法的可行性和有效性。

【关键词】抑郁症;3D-WGMobileNet;动态分组卷积;滑动窗口分组卷积;迁移学习;功能磁共振成像

【中图分类号】R318;TP181

【文献标志码】A

【文章编号】1005-202X(2024)04-0455-08

Diagnosis of youth depression based on transfer learning and 3D-WGMobileNet

GUO Zhaohui, WANG Yu, MA Huijun, TIAN Hengyi

School of Computer and Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

Abstract: A novel network model is proposed based on 3D-WGMobileNet and transfer learning to accurately diagnose the stage of youth depression. After functional magnetic resonance imaging (fMRI) data preprocessing and dimensionality reduction by converting 4-dimensional fMRI data into 3-dimension through regional homogeneity approach, transfer learning method is employed to transfer the characteristics of Alzheimer's disease to the proposed 3D-WGMobileNet. The expert weight matrix of convolutional kernel is constructed using dynamic grouping convolution for improving the expression ability of the model. The sliding window grouping convolution is used to reduce the quantity of model parameters and enhance the computing capability. Finally, 3D-WGMobileNet is used for the image feature extraction and classification of youth depression. Experimental results on the dataset of human connectome projects show that the 3D-WGMobileNet incorporating transfer learning, dynamic grouping convolution and sliding window grouping convolution exhibit superior performance in classification, achieving 89.00%, 85.15% and 87.90% accuracies in classifying depression and healthy controls, mild depression and healthy controls, mild depression and moderate depression, which verifies the feasibility and effectiveness of the proposed method.

Keywords: depression; 3D-WGMobileNet; dynamic grouping convolution; sliding window grouping convolution; transfer learning; functional magnetic resonance imaging

前言

抑郁症通常指情绪障碍,是一种以心境低落为主要特征的综合征^[1],其临床表现主要为情绪、兴趣、认知、思维、意志活动低下以及生理功能紊乱,部分患者出现自杀,甚至发生攻击行为。《2022年中国抑郁症蓝皮书》数据显示,目前我国抑郁症患者将近1亿左右,仅有9.5%的患者接受过相关治疗。新冠疫情后,精神疾病患病风险增大,抑郁症患者激增28%,青年患者尤其是22~36岁患者占比为32%。早期抑郁症的诊断主要依据临床症状、病史、病程以及体格

【收稿日期】2023-12-03

【基金项目】北京市自然科学基金-北京市教育委员会科技计划重点项目(KZ202110011015);北京工商大学2023年研究生科研能力计划提升项目

【作者简介】郭朝晖,硕士,研究方向:图像处理、机器学习, E-mail: 15701573421@163.com

【通信作者】王瑜,博士后,教授,博士生导师,研究方向:图像处理与模式识别, E-mail: wangyu@btbu.edu.cn; 马慧鋈,在读博士,高级实验师,研究方向:大数据分析, E-mail: mahuijun@btbu.edu.cn

检查,还有实验室检查综合判断,缺乏定量的生理指标^[2]。因此,如何深度探索抑郁症诊断的影像学标志,突破现代医疗技术在抑郁症临床诊断时所面临的过于主观、无量化指标等瓶颈问题具有重大意义。

近几年医学影像技术和深度学习的迅速发展为脑部疾病的研究提供新思路^[3-4]。功能磁共振成像(functional Magnetic Resonance Imaging, fMRI)是一种近年来流行的神经影像学技术,其原理是利用磁共振造影来反映大脑神经元血氧含量变化,图像具有高时间分辨率,能动态反映大脑脑区信号强弱变化^[5]。深度学习是一个新的领域,其动机在于建立模拟人脑进行分析学习的神经网络,模仿人脑机制来解释数据,如图像、声音和文本。近年来,越来越多的研究者结合深度学习与医学影像,辅助医生诊断病情^[6-8]。王茵等^[9]针对抑郁症3D原始图像数据不足导致模型容易过拟合以及普通分类模型泛化能力不强等问题,使用卷积神经网络(Convolutional Neural Network, CNN)对抑郁症进行分类,但是CNN本身结构简单,无法同时提取图像的浅层和深层信息。Abdul Hamid等^[10]提出一种深度学习双向长短期记忆的方法,融合脑电图数据和人脸面部特征来检测抑郁症,但脑电数据是2D数据,无法观测患者脑损伤程度。Jan等^[11]提出一种动态视觉运动特征提取算法,根据个人的视觉和声音特征来预测抑郁症程度,最后利用偏最小二乘法回归模型,得出视觉特征和抑郁症的相关性,但基于动态视觉特征的方法具有不稳定性,因此无法对抑郁症做出诊断。de Melo等^[12]提出基于ResNet-50的分布式学习方法,通过识别面部表情来判断被试是否患有抑郁症,但其参数量和计算量巨大,不容易训练。陶然等^[13]使用ViT-Transformer编码网络,结合脑电信号数据对抑郁症患者进行分类,取得较好的分类结果。Al Jazaery等^[14]使用RNN-C3D网络,从连续的面部表情中提取有用的特征信息,得到抑郁症的预测结果。段逸凡等^[15]通过改进3D-DesNet结合fMRI与结构磁共振成像数据,并使用软件投票法对图像特征进行融合,最后得到94%的分类结果。上述研究均只对健康对照者(Healthy Control, HC)和抑郁症患者进行分类,未能准确诊断抑郁症的病程,如轻度、中度和重度。

本研究对抑郁症患者进行一个更细致的分类,提出一种基于迁移学习和改进3D-WGMobileNet的深度学习模型,对抑郁症患者的fMRI图像进行准确分类。其中,局部一致性(Regional Homogeneity, ReHo)分析方法将4D图像转换成3D图像,便于后期深度学习模型的有效处理;迁移学习用来解决由于医学数据不足而导致的泛化能力差的问题;

3D-WGMobileNet利用动态分组卷积(Dynamic Grouping Convolution, DGConv)平衡权重分配,提取图像的细节特征,并降低参数量,通过滑窗分组卷积(Sliding Window Grouping Convolution, SGConv)来加快模型的训练速度,达到提高模型精度的同时提高实时性,最终实现抑郁症患者的正确分类。

1 数据预处理

目前的特征提取算法难以直接提取fMRI的4D数据特征,因此本研究将对fMRI图像进行ReHo分析,通过分析患者脑区血氧含量来提取大脑局部活动信息,将高维数据转换为可用深度学习方法处理的低维数据,然后进行分析。

1.1 数据信息统计分析与预处理

本研究使用104例被试者的fMRI图像,其中轻度抑郁症(Mild Depression, MID)25例、中度抑郁症(Moderate Depression, MOD)41例、重度抑郁症(Major Depression, MAD)8例、HC 30例。所有数据均按照7:3划分训练集和测试集。上述抑郁症数据均来自人类连接组项目数据库,每个被试者的fMRI数据均是从左到右扫描的33层头部图像,共扫描1200个时间点的图像数据,数据信息如表1所示。

表1 被试者基本信息
Table 1 Basic information of the subjects

数据集	<i>n</i>	性别(男/女)	年龄/岁	DSM抑郁值
HC	30	15/15	28.7±3.7	45.6±1.3
MID	25	5/20	28.2±4.1	56.8±1.0
MOD	41	18/23	28.7±3.9	63.5±2.2
MAD	8	3/5	29.8±3.6	74.1±4.5

由于被试者大脑形态、大小以及位置差异较大,且原始fMRI图像中存在头动和噪声等干扰因素,因此使用预处理将原始图像进行标准化,方便后续进行特征提取。预处理fMRI数据使用FSL软件实现。fMRI预处理流程图如图1所示,前连合后缘中点至后连合前缘(Anterior Commissure-Posterior Commissure, AC-PC)中点的连线校正,由于被试图像是4D图像,可将图像原点校正到AC-PC位置,方便后续图像配准;颅骨剥离,去除图像中头皮和颅骨等无关因素;偏置场校正,调整图像的磁场不均匀;去伪影,去除设备不稳定造成的伪影;去除前10个时间点,去除因为设备刚启动或者患者调整拍摄位置造成的误差;时间层校正,以第16扫描层的图像为参考

层,消除层间扫描时间差;头动校正,消除被试头动造成的伪影;空间标准化,对被试脑部图像进行标准化,统一被试者脑部图像大小,方便计算;去线性飘

移,消除设备产生的噪音,降低对图像质量的影响。fMRI图像预处理前后的对比图如图2所示。




图1 fMRI 图像预处理流程
Figure 1 fMRI image preprocessing




图2 fMRI 图像预处理前后对比图
Figure 2 Comparison of fMRI images before and after preprocessing

1.2 ReHo 图像降维分析方法

ReHo 方法用来描述某一体素的BOLD信号与其附近体素的BOLD信号(时间序列)的一致性,用肯德尔一致性系数^[16] (Kendall Consistency Coefficient, KCC)度量。ReHo 方法最早由 Zang 等^[17]提出,用来计算 fMRI 过程中时间序列的区域血氧水平同步程度。

假设用 $F(X, Y, Z, M)$ 表示一个 fMRI 数据,其中 X 为矢状面即行数, Y 为冠状面即列数, Z 为横轴面即层数, M 为当前体素的时间点数(BOLD 信号的长度),数据中

包含 $X_o \times Y_o \times Z_o$ 个体素点, 其中第 m 个体素 $V_m(x, y, z)$ ($1 \leq x_m \leq X_o, 1 \leq y_m \leq Y_o, 1 \leq z_m \leq Z_o$) 的时间序列 T_m 与 K_m (6、18、26) 个最近邻域体素 BOLD 信号序列的 ReHo 计算方法如下: (1) 将 T_m 和 K_m 个体素的时间序列排列成 $m \times (k+1)$ 的矩阵 $C_{m, k+1}(i, j)$, 其中 $C(i, j)$ 表示第 j_m 个体素的第 i_m 个时间点。 (2) 将第 j_m 列的元素用其所在列中值的排序来填充, 得到形状为 $m \times (k+1)$ 的矩阵 $S_{m, k+1}(i, j)$, 其中 $S(i, j)$ 表示第 j_m 个体素的第 i_m 个时间点的数据值 F 在这一列 m 个时间点数据的大小排序号, $1 \leq i \leq m, 1 \leq j \leq k+1$ 。矩 阵

$S_{m,k+1}(i,j)$ 的特点是每一列的元素都是从1到 m 的无重复的正整数。(3)计算 T_m 和邻近的 K_m 个体素的BOLD信号序列KCC,计算如式(1)所示:

$$W = \frac{\sum_{i=1}^m (S_i)^2 - m(\bar{S})^2}{\frac{1}{12} (K+1)^2 (m^3 - m)} \quad (1)$$

其中, m 表示时间点个数, K 表示计算时所选邻域大小, S_i 表示矩阵 $S_{m,k+1}(i,j)$ 中第 i 行和, $\bar{S}=(m+1)(k+1)/2$ 表示 S_i 的均值。 W 表示该体素的KCC值,亦称ReHo值, W 的取值范围为0~1。 W 的值越大,表明该体素 $V_m(x,y,z)$ 的ReHo越高; W 的值越小,说明ReHo越低。

ReHo分析方法中KCC越大,代表这些邻近体素的时间序列越相似,通过归一化方法得到均值化ReHo(mReHo)图像,经过平滑处理,变换结果如图3所示。




图3 mReHo变换结果
Figure 3 mReHo transformation results

2 方法

2.1 3D-WGMobileNet

本研究提出的改进3D-WGMobileNet是在原有的2D-MobileNet^[18]基础上,将其卷积核改为DGConv核,并在深度可分离卷积块后添加SGConv层,用来融合特征,最后通过全连接层进行输出。模型的输入为大小是 $C \times X \times Y \times Z$ 的 N 幅mReHo转换后的图像,依次通过DGConv和深度可分离卷积组提取图像的全局信息,构建专家权重衡量矩阵,更细致地分配每个卷积核的权重信息,提高卷积核的效率;随后将提取到的特征信息经过SGConv进行拼接融合,细化提取的特征,减少信息冗余;最后通过全连接层对抑郁症进行四分类。其方法流程图如图4所示。

3D-WGMobileNet模型结构共有16个模块,包括2个3D-DGConv模块、11个3D-WGBlock模块、1个3D-Avg_pool模块和2个FC模块,整体网络结构框架如图5所示。其中,3D-WGBlock模块是改进的Block组,其具体结构如图6所示。BN是批量归一化,SE表示注意力机制^[19]模型,RE表示ReLU6激活函数,HS表示H-Switch激活函数。

2.2 DGConv

传统深度学习网络模型的卷积核都是2D静态卷积核,即设置固定的卷积核大小,根据每次输入图像的尺寸来进行卷积,经过池化和激活函数来提取图像的特征,但静态卷积核权重共享,容易提取到重复的特征。本研究提出利用DGConv代替原有的静态卷积,通过注意力机制原理构建专家权重衡量矩阵,将静态卷积核组转化为动态的卷积核,提升模型的表达能力,该模块输入特征图和输出特征图均为 $N \times C \times X \times Y \times Z$ 维度,经过DGConv,图像尺寸保持不变。具体计算方法过程如下。




图4 本文方法流程图
Figure 4 Flowchart of the proposed method

(1)定义一个专家权重组函数,包括全局平均池化层、全连接层和RE激活函数,如式(2)所示:

$$\begin{aligned} \alpha_i &= r_i(x) \\ r(x) &= \sigma(\text{GAP}(x)R) \end{aligned} \quad (2)$$

其中, α_i 是最终权重系数, R 是专家权重系数,GAP是全局平均池化, σ 是激活函数。

(2)在专家权重组上构建动态卷积^[20],其结构包括1个全局平均池化层、2个全连接层和1个激活函



图5 3D-WGMobileNet结构图
Figure 5 3D-WGMobileNet structure




图6 3D-WGBlock模块结构图
Figure 6 Structure of 3D-WGBlock module

数,如式(3)所示:

$$\alpha_{out} = \sigma(W_{fc1} \times W_{fc2} \times \frac{1}{hw} \sum_{i,j,k} X_{c,i,j,k}) \tag{3}$$

$$W_{fc1} = \alpha_1 w_1 + \alpha_2 w_2 + \dots + \alpha_l w_l$$

其中, l 是专家数量, α_{out} 是输出的卷积核权重, σ 是激活函数, W_{fc1} 和 W_{fc2} 是全连接层。

(3)构建 DGConv,在动态卷积后面连接1个分组全连接层,将卷积核权重进行分组卷积,如式(4)所示:

$$\alpha_{Gout} = W_{fc3} \times \alpha_{out} \tag{4}$$

其中, α_{out} 是一个 $(N \times C)$ 维的向量; α_{Gout} 是一个 $C \times$

$C \times K_x \times K_y \times K_z$ 维的向量; W_{fc3} 是分组全连接层,分为 $G \times C$ 组, G 是分组数量,是可调参数。

DGConv 通过对每层每个卷积核的权重进行重新计算,在内核空间上节约内存空间占用,模型更易于训练,泛化能力强。DGConv 的整体结构模块如图7所示。

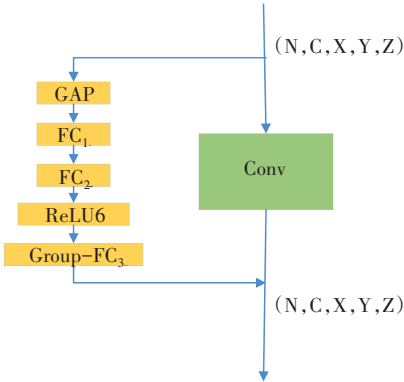


图7 动态分组卷积
Figure 7 Dynamic grouping convolution

2.3 SGConv

2D-MobileNet 中包含深度可分离卷积模块,深度可分离卷积能减少网络的计算量和参数量,本研究使用改进的 3D-WGMobileNet,虽然更容易提取 3D 图像的特征,但由于网络维度的增加,整体网络结构参数量十分庞大,并且由于输出权重共享,导致训练缓慢。因此本研究提出在深度可分离卷积后面添加 SGConv 层,用来融合特征。SGConv 通过使用步长为 s 的卷积核在输入上滑动提取特征,将输入输出的连接稀疏化,减少参数量的同时保证提取一定程度的邻近通道的信息,原理结构如图8所示。




图8 滑窗分组卷积原理图
Figure 8 Schematic diagram of sliding window grouping convolution

假设SGConv的卷积核大小为 d_k ,输入图像大小 $X \times Y \times Z$ 体素,维度为 M ,输出的通道数为 h ,将输入分为 g 组,使用步长为 s 的卷积核对输入图像进行卷积,会产生 d_c 个窗口,其参数量为 $d_c \times d_k \times d_k \times d_k$,计算量为 $d_c \times d_k \times d_k \times d_k \times x \times y \times z \times h$,相较于普通卷积的参数量减少了 $m \times h$ 个量级,计算量减少了 m 个量级。其中 d_c 的计算方法和普通卷积计算方法一致,在 X 维度的计算如式(5)所示:

$$d_c = \frac{X - d_k + 2P}{s} + 1 \quad (5)$$

在此基础上,为方便模型训练,在深度可分离卷积块里添加跳跃连接,以生成全局信息的分组特征。

2.4 迁移学习模块

随着人工智能和深度学习在图像处理方面的深入应用,监督学习和无监督学习迅速发展,如RNN和DC-Gan^[21]网络等,但这些方法都需要质量极高的数据集才能训练,并且需要大量有标注数据来进行训练。迁移学习的提出有效解决由于数据量小等原因导致模型过拟合的问题。Tajbakhsh等^[22]发现在医学影像中使用深度学习诊断的方法里,相较于零初始化训练网络,通过迁移学习获取初始图像信息后再对网络进行微调效果更好。医学影像由于实验设备等问题导致影像数据难以获取,数据量小,尤其是标注好的数据,直接使用深度学习来进行特征提取及分类效果不佳,故可以使用迁移学习来进行模型预训练,解决抑郁症图像数据不充足问题,提高3D-WGMobileNet的泛化能力。

本研究使用大型公开的同类型疾病阿尔茨海默症数据库(Alzheimer's Disease Neuroimaging Initiative, ADNI)作为预训练数据,通过迁移学习方法对模型预训练。基于ADNI的迁移学习预训练方法步骤如下:首先从ADNI数据库中筛选出无其他疾病的670个阿尔茨海默症被试者的fMRI原始图像,包含阿尔茨海默症患者、轻度认知障碍患者以及HC三类,经过与抑郁症被试者图像相同的预处理步骤进行图像预处理,并保存;然后用该数据对3D-WGMobileNet模型进行训练,使模型学习阿尔茨海默症的fMRI图像特征,并保存模型的训练权重文件;最后,将模型的主干部分训练权重迁移到3D-WGMobileNet抑郁症辅助诊断模型中,对模型输出的特征进行分类。

3 实验与结果分析

3.1 模型评价指标

为更好地评价模型性能,使用准确率(Accuracy,

ACC)、F1值和受试者工作特征(Receiver Operating Characteristic, ROC)曲线覆盖的区域面积(Area Under Curve, AUC)等作为模型评测指标^[24],计算如式(6~8)所示:

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

$$\begin{cases} Pre = \frac{TP}{TP + FP} \\ Sen = \frac{TP}{TP + FN} \\ F1 = \frac{2 \times Pre \times Sen}{(Pre + Sen)} \end{cases} \quad (7)$$

$$AUC = \frac{\sum_{ins_i \in \text{positive class}} rank_{ins_i} - \frac{M \times (M + 1)}{2}}{M \times N} \quad (8)$$

其中,TP和TN表示真正负类被试者数量,FP和FN表示假正负类被试者数量^[23-24];准确率通过计算预测正样本与所有样本的比例得到,反映神经网络分类结果的好坏;F1值是一个综合评测指标,结合了精确度和敏感度; $rank_{ins_i}$ 表示第 i 个样本的编号, M 、 N 分别表示正样本和负样本的数量, $\sum_{ins_i \in \text{positive class}}$ 表示仅对正样本的序号求和,AUC值越大,表示分类器性能越好。

3.2 实验结果及分析

本研究设计了2组对照实验,用来验证本文方法对抑郁症诊断的有效性。

3.2.1 对照实验一 为验证改进的3D-WGMobileNet中添加的迁移学习模块、DGConv、SGConv的有效性,对网络进行消融实验,结果如表2所示。通过迁移学习方法学习ADNI数据集的fMRI图像特征作为本研究设计的3D-WGMobileNet的预训练权重矩阵,优化了网络的学习效率,提高了网络整体性能;添加DGConv模块能提高卷积核的特征提取能力,但相应地增加了计算量;添加SGConv能融合特征,降低网络的参数量,提高模型的计算效率。相比单一的3D-MobileNet网络,本文方法在抑郁症和HC的识别上准确率达到89.00%,提高7.98%,在MID vs HC的分类上提高4.82%,有效地证明增加迁移学习、细分卷积模块的权重和改变全连接层权重共享有助于捕捉更为细小的特征信息,虽然没能提高分类效果,但在节约计算量和内存空间上表现出了更好的效果。

3.2.2 对照实验二 使用经典的2D深度学习和2D-MobileNet分别对经过mReHo变换的抑郁症图像进行特征提取并分类,再与3D-MobileNet进行比较,验证3D网络对医学图像特征提取的有效性。实验结果如表3所示。在2D轻量模型网络中,随着网络层数的增加,模型分类结果有一定的提升,MobileNetV1添加了深

表2 不同网络实验结果

Table 2 Experimental results of different networks

方法	指标	HC vs MID	MID vs MOD	MOD vs MAD	HC vs 抑郁症
3D-MobileNet	准确率	0.803 3	0.828 9	0.791 2	0.810 2
	F1 值	0.823 5	0.865 0	0.819 1	0.838 7
	AUC	0.812 5	0.807 5	0.800 1	0.783 3
3D-MobileNet+迁移学习	准确率	0.828 3	0.818 0	0.805 5	0.834 0
	F1 值	0.837 5	0.819 4	0.786 2	0.863 1
	AUC	0.804 2	0.799 3	0.840 0	0.794 7
3D-MobileNet+迁移学习+DGConv	准确率	0.840 4	0.812 0	0.805 6	0.836 0
	F1 值	0.815 6	0.828 6	0.817 6	0.857 1
	AUC	0.805 9	0.792 0	0.862 5	0.796 7
3D-MobileNet+迁移学习+SGConv	准确率	0.847 3	0.826 0	0.811 1	0.837 1
	F1 值	0.807 2	0.816 9	0.825 9	0.852 5
	AUC	0.846 7	0.785 3	0.818 8	0.790 7
本文方法	准确率	0.851 5	0.879 0	0.825 7	0.890 0
	F1 值	0.823 7	0.858 1	0.817 9	0.877 8
	AUC	0.845 9	0.822 6	0.832 8	0.840 7

度可分离卷积架构,减少了卷积层的内存占用和运算复杂度,而MobileNetV3^[25]相对于V1使用了神经架构搜索,并且在深度可分离卷积中加入SE模块,增强网络各个模块的计算能力,提高图像重要特征的表达能力,表现出较好的性能。在3D与2D-MobileNetV3的对比实验中,3D-MobileNetV3在提取3D图像特征

时能直接对3个维度的特征进行编码,提高对抑郁症图像特征提取的能力。因此,3D-MobileNetV3网络在不同阶段之间的分类性能显著提升,尤其是MID vs MOD的分类结果,准确率相比2D网络提高7.33%,F1值提升10.2%,AUC提升4.75%。

表3 不同深度学习网络实验结果

Table 3 Experimental results of different deep learning networks

网络	指标	HC vs MID	MID vs MOD	MOD vs MAD	HC vs 抑郁症
2D-Vgg16	准确率	0.622 2	0.611 1	0.630 0	0.656 0
	F1 值	0.728 5	0.517 9	0.635 2	0.771 4
	AUC	0.612 5	0.538 8	0.621 0	0.528 0
2D-Resnet50	准确率	0.627 8	0.600 0	0.625 0	0.632 0
	F1 值	0.731 3	0.400 8	0.636 1	0.712 1
	AUC	0.466 3	0.562 5	0.645 0	0.580 0
2D-MobileNetV1	准确率	0.705 6	0.721 7	0.605 0	0.730 4
	F1 值	0.717 6	0.711 7	0.509 3	0.785 6
	AUC	0.762 5	0.718 8	0.542 0	0.755 9
2D-MobileNetV3	准确率	0.781 1	0.755 6	0.550 0	0.776 1
	F1 值	0.765 9	0.763 0	0.412 9	0.875 0
	AUC	0.798 8	0.760 0	0.475 0	0.779 2
3D-MobileNetV3	准确率	0.803 3	0.828 9	0.791 2	0.810 2
	F1 值	0.823 5	0.865 0	0.819 1	0.838 7
	AUC	0.812 5	0.807 5	0.800 1	0.783 3

4 结 论

为充分地提取抑郁症图像的局部和全局特征信息,提高网络对3D医学数据的分类性能,本研究提出一种基于轻量级深度学习网络的抑郁症辅助诊断算法。首先,对fMRI图像数据进行预处理,利用ReHo分析获取图像时间序列信息。其次,通过迁移学习方法将ADNI数据库的fMRI图像数据作为预训练数据迁移到本文模型,学习fMRI图像特征,增强模型的效果。设计了一个DGConv模块,通过动态计算卷积核权重,提高卷积核的计算能力,分组分配每个通道的权重矩阵来压缩卷积核的计算量,有效地增强卷积核的特征提取能力;在网络中增加SGConv和跳跃连接,提取特征的局部信息和全局信息,避免内核空间和特征空间的信息冗余。最后,将图像输入到改进的3D-WGMobileNet网络中,得到分类结果。不同程度的抑郁症患者与HC分类实验结果表明,抑郁症 vs HC的分类准确率达到89.00%,MID vs HC、MID vs MOD、MOD vs MAD的分类准确率分别达到85.15%、87.90%和82.57%。综上所述,本文方法能对抑郁症不同阶段患者进行分类,为抑郁症的辅助治疗提供一定的理论依据;但由于MAD数据过少,所以MOD和MAD分类效果表现不佳,接下来工作会对现有的方法进一步完善,考虑将多模态抑郁症数据特征融合,以提取到更多的细节特征,提高分类准确率。

【参考文献】

- [1] 马淑然, Tian Y. 谈谈抑郁症的防治与调养[J]. 生命世界, 2017(11): 54-59.
Ma SR, Tian Y. Talking about the prevention, treatment, and rehabilitation of depression[J]. Life World, 2017(11): 54-59.
- [2] 付常洋, 王瑜, 肖洪兵, 等. 基于多尺度功能脑网络融合特征的抑郁症分类算法[J]. 中国医学物理学杂志, 2020, 37(4): 439-444.
Fu CY, Wang Y, Xiao HB, et al. Classification of depression using fusion features based on multi-scale functional brain network[J]. Chinese Journal of Medical Physics, 2020, 37(4): 439-444.
- [3] Chen Z, Zhao R, Wang Q, et al. Functional connectivity changes of the visual cortex in the cervical spondylotic myelopathy patients: a resting-state fMRI study[J]. Spine (Phila Pa 1976), 2020, 45(5): E272-E279.
- [4] Ju RH, Hu CH, Zhou P, et al. Early diagnosis of Alzheimer's disease based on resting-state brain networks and deep learning[J]. IEEE/ACM Trans Comput Biol Bioinform, 2019, 16(1): 244-257.
- [5] Jun E, Na KS, Kang W, et al. Identifying resting-state effective connectivity abnormalities in drug-naïve major depressive disorder diagnosis via graph convolutional networks[J]. Hum Brain Mapp, 2020, 41(17): 4997-5014.
- [6] Lian CF, Liu MX, Zhang J, et al. Hierarchical fully convolutional network for joint atrophy localization and Alzheimer's disease diagnosis using structural MRI[J]. IEEE Trans Pattern Anal Mach Intell, 2020, 42(4): 880-893.
- [7] Hosseini-Asl E, Ghazal M, Mahmoud A, et al. Alzheimer's disease diagnostics by a 3D deeply supervised adaptable convolutional network[J]. Front Biosci (Landmark Ed), 2018, 23(3): 584-596.
- [8] Lao H, Zhang XJ, Tang YY, et al. Alzheimer's disease diagnosis based on the visual attention model and equal-distance ring shape context features[J]. IET Image Process, 2021, 15(10): 2351-2362.
- [9] 王茜, 郑国威, 顾瑞, 等. 一种基于卷积神经网络的重度抑郁症辅助诊断方法[J]. 兰州大学学报(医学版), 2022, 48(8): 5-10.
Wang Y, Zheng GW, Jie R, et al. An auxiliary diagnosis method for major depression disorder based on convolutional neural network[J]. Journal of Lanzhou University (Medical Sciences), 2022, 48(8): 5-10.
- [10] Abdul Hamid DS, Goyal SB, Bedi P. Integration of deep learning for improved diagnosis of depression using EEG and facial features[J]. Mater Today Proc, 2023, 80(Part 3): 1965-1969.
- [11] Jan A, Meng HY, Gaus YF, et al. Artificial intelligent system for automatic depression level analysis through visual and vocal expressions[J]. IEEE Trans Cogn Dev Syst, 2018, 10(3): 668-680.
- [12] de Melo WC, Granger E, Hadid A. Depression detection based on deep distribution learning[C]//2019 IEEE International Conference on Image Processing (ICIP). Piscataway, NJ, USA: IEEE, 2019: 4544-4548.
- [13] 陶然, 丁胜男, 陈洁, 等. 基于睡眠脑电信号和深度学习的抑郁症识别研究[J]. 四川大学学报(医学版), 2023, 54(2): 287-292.
Tao R, Ding SN, Chen J, et al. Identifying depressive disorder with sleep electroencephalogram data: a study based on deep learning[J]. Journal of Sichuan University (Medical Sciences), 2023, 54(2): 287-292.
- [14] Al Jazaery M, Guo GD. Video-based depression level analysis by encoding deep spatiotemporal features[J]. IEEE Trans Affect Comput, 2021, 12(1): 262-268.
- [15] 段逸凡, 王瑜, 付常洋, 等. 基于双模态磁共振成像和决策层融合的抑郁症辅助诊断[J]. 中国医学物理学杂志, 2022, 39(3): 378-383.
Duan YF, Wang Y, Fu CY, et al. Auxiliary diagnosis of depression based on bimodal magnetic resonance imaging and decision level fusion[J]. Chinese Journal of Medical Physics, 2022, 39(3): 378-383.
- [16] Harada A, Bollegala D, Chandrasiri NP. Discrimination of human-written and human and machine written sentences using text consistency [C]//2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS). Piscataway, NJ, USA: IEEE, 2021: 41-47.
- [17] Zang YF, Jiang TZ, Lu YL, et al. Regional homogeneity approach to fMRI data analysis[J]. Neuroimage, 2004, 22(1): 394-400.
- [18] Zhang C, Yang T, Yang J. Image recognition of wind turbine blade defects using attention-based MobileNetV1-YOLOv4 and transfer learning[J]. Sensors (Basel), 2022, 22(16): 6009.
- [19] Luo Y, Zhu KL, Wang WH, et al. A speaker recognition method based on dynamic convolution with dual attention mechanism[J]. Eng Lett, 2023, 31(2): EL_31_2_41.
- [20] Roy SK, Dubey SR, Chatterjee S, et al. FuSENet: fused squeeze-and-excitation network for spectral-spatial hyperspectral image classification[J]. IET Image Process, 2020, 14(8): 1653-1661.
- [21] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks[EB/OL]. (2016-01-07)[2023-10-25]. <https://arxiv.org/abs/1511.06434>.
- [22] Tajbakhsh N, Shin JY, Gurudu SR, et al. Convolutional neural networks for medical image analysis: full training or fine tuning?[J]. IEEE Trans Med Imaging, 2016, 35(5): 1299-1312.
- [23] 贾洪飞, 刘茜, 王瑜, 等. 3DPCANet在阿尔茨海默症功能磁共振成像图像分类中的应用[J]. 计算机应用, 2022, 42(1): 310-315.
Jia HF, Liu X, Wang Y, et al. Application of 3DPCANet in image classification of functional magnetic resonance imaging for Alzheimer's disease[J]. Journal of Computer Applications, 2022, 42(1): 310-315.
- [24] 贾洪飞, 王瑜, 肖洪兵, 等. 基于功能磁共振图像转换在阿尔茨海默症分类中的应用[J]. 中国医学物理学杂志, 2022, 39(4): 448-452.
Jia HF, Wang Y, Xiao HB, et al. Functional magnetic resonance imaging transformation for classification of Alzheimer's disease[J]. Chinese Journal of Medical Physics, 2022, 39(4): 448-452.
- [25] 常江, 管声启, 师红宇, 等. 基于改进生成对抗网络和MobileNetV3的带钢缺陷分类[J]. 激光与光电子学进展, 2021, 58(4): 213-218.
Chang J, Guan SQ, Shi HY, et al. Strip defect classification based on improved generative adversarial networks and MobileNetV3[J]. Laser and Optoelectronics Progress, 2021, 58(4): 213-218.

(编辑:谭斯允)