



基于数据增广和模型集成策略的图神经网络在抑郁症识别上的应用

杨炳新, 郭艳蓉, 郝世杰, 洪日昌

引用本文

杨炳新, 郭艳蓉, 郝世杰, 洪日昌. 基于数据增广和模型集成策略的图神经网络在抑郁症识别上的应用[J]. 计算机科学, 2022, 49(7): 57-63.

YANG Bing-xin, GUO Yan-rong, HAO Shi-jie, Hong Ri-chang. Application of Graph Neural Network Based on Data Augmentation and Model Ensemble in Depression Recognition [J]. Computer Science, 2022, 49(7): 57-63.

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)

基于概率元学习的矩阵补全预测融合算法

Fusion Algorithm for Matrix Completion Prediction Based on Probabilistic Meta-learning
计算机科学, 2022, 49(7): 18-24. <https://doi.org/10.11896/jsjkx.210600126>

嵌入典型时间序列特征的随机 Shapelet 森林算法

Random Shapelet Forest Algorithm Embedded with Canonical Time Series Features
计算机科学, 2022, 49(7): 40-49. <https://doi.org/10.11896/jsjkx.210700226>

视频理解中的动作质量评估方法综述

Survey on Action Quality Assessment Methods in Video Understanding
计算机科学, 2022, 49(7): 79-88. <https://doi.org/10.11896/jsjkx.210600028>

基于注意力机制和多任务学习的阿尔茨海默症分类

Alzheimer's Disease Classification Method Based on Attention Mechanism and Multi-task Learning
计算机科学, 2022, 49(6A): 60-65. <https://doi.org/10.11896/jsjkx.201200072>

自然语言处理在简历分析中的应用研究综述

Survey of the Application of Natural Language Processing for Resume Analysis
计算机科学, 2022, 49(6A): 66-73. <https://doi.org/10.11896/jsjkx.210600134>

基于数据增广和模型集成策略的图神经网络在抑郁症识别上的应用

杨炳新 郭艳蓉 郝世杰 洪日昌

合肥工业大学计算机与信息学院 合肥 230601

(yangbingxin0101@163.com)

摘要 目前对抑郁症的主流诊断方式是通过医生和患者之间的沟通交流来填写相关的问卷量表,这需要相应的临床知识并且诊断结果存在主观性,给抑郁症诊断带来了很多挑战。利用信息处理技术对生理信号进行分析,构建精准客观的辅助诊断模型具有重要价值,然而目前抑郁症辅助诊断的公共数据集普遍存在样本偏少的情况,使得辅助诊断的精度普遍偏低。基于此,文中提出了一种基于数据增广和模型集成策略的图神经网络的抑郁症识别方法,该方法利用 53 位受试者的 128 通道脑电信号(EEG),对采集到的脑电信号进行数据切分并将其用于数据增广后,利用皮尔逊相关系数计算不同通道之间的相关度,从而构造脑网络,并利用图神经网络学习脑网络的特征,然后将得到的预测结果利用模型集成策略进行多数投票,得到受试者最终的预测结果。经过实验证明,所提方法提高了网络的分类能力,解决了因样本小而带来的分类能力差的问题,在兰州大学普适感知与智能系统实验室提供的 MODMA 数据集(包含 24 名抑郁症患者和 29 名正常对照组)上取得了 77% 的分类准确率,与其他方法相比,所提方法的分类准确率有明显的提升。

关键词: 抑郁症识别;分类;图神经网络;脑电信号;数据增广;模型集成

中图法分类号 TP391

Application of Graph Neural Network Based on Data Augmentation and Model Ensemble in Depression Recognition

YANG Bing-xin, GUO Yan-rong, HAO Shi-jie and Hong Ri-chang

School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China

Abstract At present, the mainstream diagnosis of depression is through the communication between doctors and patients, filling in the relevant questionnaire, which needs corresponding clinical knowledge and is subjective. It brings a lot of challenges to the diagnosis of depression. Using information processing technology to analyze physiological signals and build an accurate and objective auxiliary diagnosis model is of great value. However, the sample size of the public data set of depression auxiliary diagnosis is generally small, which makes the accuracy of auxiliary diagnosis is generally low. On this basis, this paper proposes a graph neural network (GNN) method for depression recognition based on data augmentation and model ensemble strategy. The method uses 128 channel EEG signals of 53 subjects and segments the collected EEG data. After data augmentation, Pearson correlation coefficient is used to calculate the correlation between different channels to construct a brain network, graph neural network is used to learn the features of brain network, and the final prediction results are obtained by majority voting with model ensemble strategy. Experimental results show that the proposed method improves the classification ability of the network and solves the problem of poor classification performance caused by small sample size. The proposed method achieves 77% classification accuracy on the MODMA data set(including 24 patients with depression and 29 normal controls) provided by the Pervasive Sensing and Intelligent Systems Laboratory of Lanzhou University. The classification accuracy of the proposed method is significantly improved compared to other methods.

Keywords Depression recognition, Classification, Graph neural network, EEG, Data augmentation, Model ensemble

到稿日期:2021-08-08 返修日期:2022-03-02

基金项目:国家重点研发计划(2019YFA0706200);国家自然科学基金(62072152);安徽省自然科学基金(1808085QF188);中央高校基本科研业务费专项资金(PA2020GDKC0023,PA2019GDZC0095)

This work was supported by the National Key R & D Program of China (2019YFA0706200), National Nature Science Foundation of China (62072152), Natural Science Foundation of Anhui Province, China(1808085QF188) and Fundamental Research Funds for the Central Universities of Ministry of Education of China(PA2020GDKC0023,PA2019GDZC0095).

通信作者:郭艳蓉(yrguo@hfut.edu.cn)

1 引言

抑郁症是一种常见的心理障碍疾病,主要临床特征为持续性情绪低落和认知功能障碍,症状包括情绪焦虑、睡眠困难、负罪感,甚至有自杀的念头等。世界卫生组织 2017 年的统计数据显示,目前全球已经有超过 3 亿人患有抑郁症,而且抑郁症存在复发和持续发病的现象,严重影响到患者的个人生活。目前对于抑郁症的诊断,临幊上常见的方法是医生临幊经验并结合抑郁自评量表(Self-Rating Depression Scale, SDS)^[1]、汉密尔顿抑郁量表(Hamilton Depression Rating Scale, HDRS)^[2]、贝克抑郁自评问卷(Beck Depression Inventory Scale, BDI)^[3]等问卷量表和精神疾病诊断与统计手册第四版(DSM-IV)^[4],其准确性往往受到医生的熟练程度、临幊经验丰富程度和患者配合程度的影响,具有很强的主观性,给抑郁症诊断带来了很多挑战。随着信息技术的发展,计算机辅助诊断技术在医学上的应用越来越广泛。其中,EEG 具有时间分辨率高、具备非侵入性和无创性、成本相对较低、操作简单、易于记录等优点。因为脑电包含了丰富的特征,所以被广泛应用于神经科学、认知科学以及心理学的研究中,并且在临幊上已经被用来辅助诊断一些疾病。但是抑郁症患者的脑电数据采集存在样本获取难、采集难度大等问题,尤其是经过临幊诊断的抑郁症患者脑电数据更加稀缺,因为一些人的抑郁评估结果虽然显示有一定的抑郁倾向,但是并没有经过专业全面的临幊诊断,而经专业诊断后抑郁症患者的有效脑电数据又难以采集,所以现有的公开抑郁症脑电数据集非常少。

在 EEG 分析与处理方面,传统的分类方法如支持向量机(Support Vector Machine, SVM)^[5]、K 近邻算法(K-Nearest Neighbor, KNN)^[6]等依赖于手动从脑电信号中提取指定生物特征,才能获得相对较高的准确率^[7],这些方法无法直接利用原始信号提取深度特征用于分类,费时费力,而且手工提取的脑电特征也因为脑电数据样本数据量小、数据采集难度大等因素出现误差较大的情况。图神经网络(Graph Neural Network, GNN)可以结合图论中节点之间的依赖关系,对非欧几里得数据进行建模,深入挖掘结构之间的特征和规律,学习不同图的特征,并将其广泛应用于分类任务。对于较小的数据集,使用图神经网络进行建模,容易出现欠拟合和过拟合的情况,而使用集成学习可以改善分类效果。鉴于以上情况,本文提出了一种基于数据增广策略和模型集成策略的图神经网络的分类方法。该方法利用图神经网络来提取 EEG 中的特征,用于抑郁症患者与正常人的分类,从而降低人为诊断的主观性。本文方法首先对采集到的受试者在静息状态下的 EEG 进行划分并用于数据增广,对于数据增广之后的 EEG,将脑电通道作为图中节点,根据不同脑电通道之间的关系可以构造出对应的图(Graph),将该图输入到图神经网络中学习数据的深度特征,从而获得数据增广后样本的预测结果,最后基于模型集成策略,利用多数投票算法进行投票,综合预测得到最后的预测结果。实验结果表明,本文方法可以进一步提升分类结果。

2 相关工作

近年来,许多学者正在研究基于生理信号的抑郁症识别

方法^[8-14]。其中,EEG 作为一种低成本、小尺寸、高时间分辨率的信号,采集通道数量多,包含生物信息量大,引起了越来越多研究者的关注^[15-20]。抑郁症患者与正常人 EEG 之间存在的特征差异可以用来识别抑郁症患者,但是 EEG 信号在本质上是复杂的,因此找到可利用的特征非常重要。

Cai 等^[21]采集了 213 位应试者(92 名抑郁症患者和 121 名正常对照组)身上的 Fp1, Fp2 和 Fpz 三电极静息状态下和声音刺激状态下的 EEG, 使用 FIR 滤波器、离散小波变换以及自适应滤波器处理脑电数据后, 提取了 270 个线性特征和非线性特征, 并利用最小冗余最大相关(mRMR)算法对提取的特征进行降维, 最后利用 KNN 算法作为分类器进行分类。Akbari 等^[22]利用 22 个正常对照组和 22 个抑郁症受试者的 EEG 信号, 计算二维几何特征之后重建相空间, 并根据它们的形状提取 34 个几何特征之后选用不同分类器进行分类。Zhang 等^[23]采集了 13 名抑郁症女性患者和 12 名女性对照组在闭眼静息状态下的脑电信号, 并从脑电信号中提取到了一系列线性特征和非线性特征。经过实验分析, 抑郁症患者组和正常对照组的脑电特征存在显著差异($p < 0.05$), 最后用 BP 神经网络和 KNN 算法作为分类器进行分类。Hosseini-fard 等^[24]采集了 40 位抑郁症患者和 40 位对照受试者的脑电信号, 分别计算了脑电信号 alpha 波段、beta 波段、theta 波段和整个波段的脑电信号功率作为特征, 利用逻辑回归(Logistic Regression, LR)和支持向量机(SVM)算法作为分类器进行分类。Liao 等^[25]将脑电信号处理成 5 个脑电波段(delta, theta, alpha, beta 和 gamma), 并计算二维功能连通矩阵, 然后将其中 3 个 EEG 波段的功能连通矩阵合并到三通道图像中, 利用卷积神经网络(CNN)对抑郁症患者 EEG 信号和对照组 EEG 信号进行分类。上述研究基于受试者在静息状态或者声音刺激状态下的脑电信号, 通过手动方式提取脑电特征, 利用不同的分类器对提取的脑电特征进行分类。但手动提取的特征耗时较多, 而且手提特征对分类并不一定都起到正向作用。

图神经网络对于脑网络具有非常高的适配性。Zhong 等^[26]用 RGNN 算法对 EEG 数据集 SEED 和 SEED-IV 进行情感分类, 其中在 SEED 全波段 EEG 数据集和 SEED-IV 全波段数据集上取得了良好的分类效果。Song 等^[27]提出了一种新的实例自适应图形方法(Instance-adaptive Graph Method, IAG), 并在 EEG 情绪识别数据集上进行了实验, 取得了较高的准确率。Sun 等^[28]利用图论知识, 结合 128 通道脑电信号构建脑网络结构, 对抑郁症患者的脑网络功能连接性进行分析, 用于研究抑郁症患者脑网络与抑郁严重程度的关系。

抑郁症患者脑电数据的采集环节必须要在服用药物之前, 因为服用药物会导致大脑活动发生变化, 从而影响脑电数据的采集, 同时还要考虑抑郁症患者在数据采集过程中是否有充分的精力和注意力配合实验采集, 因此现有的公开抑郁症 EEG 数据非常少, 导致利用计算机技术辅助诊断抑郁症会出现偏差。基于以上情况, 本文提出了基于数据增广策略和模型集成策略的图神经网络。该网络结合脑网络结构, 提取脑电信号的深度特征, 并将其应用于抑郁症分类研究, 相比手工提取特征的方式, 所提方法的效率更高。

3 方法介绍

3.1 基于数据增广策略和模型集成策略的抑郁症分类方法

基于数据增广策略和模型集成策略的抑郁症分类方法由数据增广策略、图神经网络和模型集成策略组成。首先将预处理后的 EEG 数据通过数据增广策略进行扩充后计算脑网络

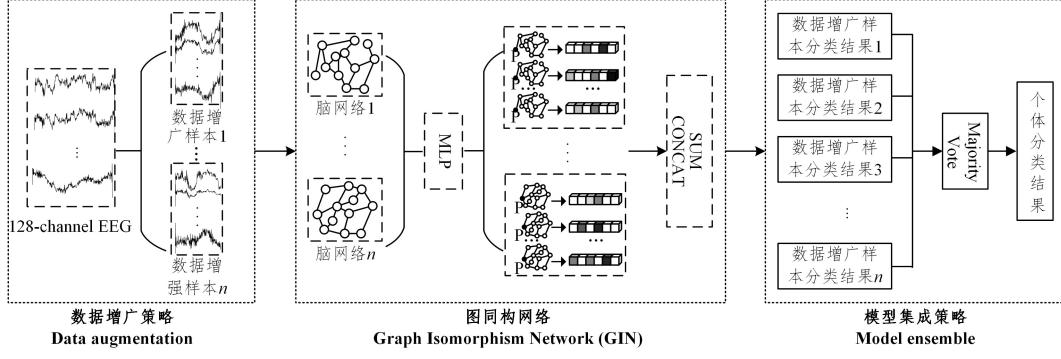


图 1 基于数据增广策略和模型集成策略的图神经网络模型流程图

Fig. 1 Flow chart of GIN based data augmentation and model ensemble strategies

3.2 数据增广策略

脑电数据存在采集难度大、采集样本少等因素,但受试者在静息状态下的脑电信号相对平稳,并且可以采集较长时间的静息脑电信号。为了提高脑电信号数据的利用率,学习脑电数据的特征,增强网络的分类能力,本文提出了数据增广策略。假设采集到的某一受试者的 128 通道 EEG 数据为 $D = [D_1; D_2; \dots; D_i; \dots; D_{128}]$, 其中 D_i 为某一通道的脑电时序数据, 脑电数据的时序长度为 m , n 为数据增广策略中数据扩充的倍数, 数据增广策略为将每一通道的脑电数据按照时间顺序平均分为 n 份, 则数据增广后的脑电数据时序长度为 $\frac{m}{n}$, 数据增广之后的数据如式(1)所示:

$$\begin{aligned} \mathbf{D} &= \text{CONCAT}(D_j), j=1, 2, \dots, n \\ D_j &= [D_{1,j}; D_{2,j}; \dots; D_{i,j}; \dots; D_{128,j}], j=1, 2, \dots, n \end{aligned} \quad (1)$$

数据增广策略的流程如图 2 所示。

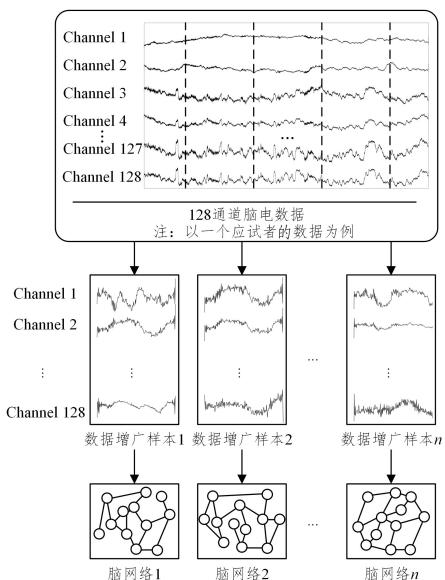


图 2 脑电数据增广策略的流程图

Fig. 2 Flow chart of EEG data augmentation strategy

矩阵, 即将受试者的 EEG 数据扩充为 n 份, 从而计算得到 n 个脑网络矩阵, 将数据扩充计算后的脑网络矩阵输入图神经网络, 每位受试者的脑电数据都可以得到 n 次分类预测结果, 最后利用模型集成策略将 n 次预测结果进行集成, 计算得到受试者的最终预测结果。这个过程提高了脑电数据的利用率, 增强了网络的分类能力。模型的计算过程如图 1 所示。

数据增广策略可以将 EEG 数据 \mathbf{D} 扩充为原来的 n 倍, 扩充前的 EEG 数据 \mathbf{D} 只能构造出一个脑网络矩阵, 那么数据增广之后的脑电数据 $D_j (j=1, 2, \dots, n)$ 可以构造出 n 个脑网络矩阵用于图神经网络, 从而达到数据增广的目的。

3.3 脑网络矩阵构造

每位受试者预处理后的 EEG 数据为包含 128 通道的时序脑电信号, 为将不同通道的时序脑电信号构建脑网络矩阵用于深度学习, 本节利用皮尔逊相关系数来计算两两通道之间的相关系数。

假设有两个长度均为 m 的时序信号 $X = [x_1, x_2, \dots, x_m]$ 和 $Y = [y_1, y_2, \dots, y_m]$, 皮尔逊相关系数计算式如式(2)所示:

$$\rho_{X,Y} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y} \quad (2)$$

受试者的 128 通道脑电数据经过相关度计算之后可以得到一个大小为 128×128 的矩阵 \mathbf{A} , 如式(3)所示:

$$\mathbf{A} = \begin{pmatrix} a_{(1,1)} & \cdots & a_{(1,128)} \\ \vdots & \ddots & \vdots \\ a_{(128,1)} & \cdots & a_{(128,128)} \end{pmatrix} \quad (3)$$

矩阵 \mathbf{A} 中的每个元素 $a_{(i,j)}$ ($i=1, 2, \dots, 128; j=1, 2, \dots, 128$) 根据通道之间的相关度不同, 其值介于 -1 和 1 之间, 本节将每个通道与其他通道计算出的相关度排序, 比第 5 位元素大的置为 1, 否则为 0, 计算式如式(4)所示, 从而得到更新之后的 $a_{(i,j)}$ 更新矩阵 \mathbf{A} 。

$$a_{(i,j)} = \begin{cases} 1, & a_{(i,j)} \geq \text{top5 max value} \\ 0, & a_{(i,j)} < \text{top5 max value} \end{cases} \quad (4)$$

为了确保得到的脑网络矩阵为对称矩阵, 保证不同脑电通道之间的连接对称性, 最后的脑网络矩阵 \mathbf{E} 的计算式如式(5)所示:

$$E(i,j) = \begin{cases} 1, & (A(i,j) + A(j,i))' / 2 \geq 1 \\ 0, & (A(i,j) + A(j,i))' / 2 < 1 \end{cases} \quad (5)$$

3.4 图神经网络

图神经网络(Graph Neural Network, GNN)对于图的一般定义为 $G = (V, E)$, 其中 V 为图的点集合, E 为图的边集

合, $\mathbf{h}_v^{(k)}$ 为图 G 的节点 v 在第 k 次迭代时的特征向量, $N(v)$ 为节点 v 的所有相邻节点。GNN 是循环聚合相邻节点的过程^[29], 假设节点 v 在第 k 次循环的特征 $\mathbf{h}_v^{(k)}$ 取决于前一次循环的特征 $\mathbf{h}_v^{(k-1)}$ 和前一次循环的所有邻居节点特征 $\mathbf{h}_u^{(k-1)}$, $u \in N(v)$, 将所有节点的特征综合之后作为整个图的表示, 上述过程可以用式(6)~式(8)表示, 式(6)表示聚合一阶邻域节点的特征。

$$a_v^{(k)} = \text{AGGREGATE}^{(k)}(\mathbf{h}_u^{(k-1)}; u \in N(v)) \quad (6)$$

式(7)表示将相邻节点特征和自身特征相结合得到新的特征。

$$\mathbf{h}_v^{(k)} = \text{COMBINE}^{(k)}(\mathbf{h}_v^{(k-1)}, a_v^{(k)}) \quad (7)$$

式(8)表示综合所有节点特征得到图的特征表示。

$$h_G = \text{READOUT}(\mathbf{h}_v^{(k)} | v \in G) \quad (8)$$

与 Weisfeiler-Lehman 测试^[30]相比, 一个高效的 GNN 也可以将两个不同的图结构映射到不同的表示, 即 GNN 的聚合模式是单射的, 从而可以对图进行区分。Xu 等^[31]提出了一种 Graph Isomorphism Network (GIN) 图同构网络, 当邻域特征集 \mathbf{X} 可数时, 且式(6)中 AGGREGATE 函数为 sum 函数、式(7)的 COMBINE 函数中自身节点对应的系数为 $(1+\epsilon)$ 时, 会存在 $f(x)$ 函数, 使得 $h(c, \mathbf{X})$ 为单射函数, 如式(9)所示:

$$h(c, \mathbf{X}) = (1+\epsilon) \cdot f(c) + \sum_{x \in \mathbf{X}} f(x) \quad (9)$$

其中, c 为自身节点特征, 参数 ϵ 可通过预设或者学习得到。对于任意 $g(c, \mathbf{X})$, 可以分解成以下形式, 其中 f, φ 满足单射性:

$$g(c, \mathbf{X}) = \varphi((1+\epsilon) \cdot f(c) + \sum_{x \in \mathbf{X}} f(x)) \quad (10)$$

即学习到单射函数 f 和 φ 即可满足单射性要求。因为多层感知器(MLP)可以拟合任意函数, 引入 MLP 来学习函数 f 和 φ , 即得到 GIN 最终基于 SUM+MLP 的聚合函数, 如式(11)所示:

$$\mathbf{h}_v^{(k)} = \text{MLP}^{(k)}((1+\epsilon^{(k)}) \cdot h_v^{(k-1)} + \sum_{u \in N(v)} h_u^{(k-1)}) \quad (11)$$

式(6)为 GIN 中的聚合节点特征函数。在图神经网络中, READOUT 函数的作用是将图中节点的特征表示映射成整张图的特征表示, 学习到节点的嵌入表示可用于节点分类, 用于图分类任务。对于 GIN, 使用 CONCAT 和 SUM 模块作为 READOUT 函数计算每次迭代得到的所有节点特征, 从而得到整个图的特征表示, 如式(12)所示:

$$h_G = \text{CONCAT}(\text{SUM}(\mathbf{h}_v^{(k)} | v \in G)), k=0, 1, \dots, K \quad (12)$$

3.5 模型集成策略

数据增广策略, 将每个受试者的脑电数据扩充为原来的 n 倍, 再通过模型集成策略来获得比单一学习更显著的分类性能, 即数据增广策略下先产生一组含有 n 个个体的学习结果, 得到 n 个个体预测标签, 再利用多数投票算法^[32]综合个体结果, 得到总体预测结果。

在二分类中, 多数投票算法可以用 hash 或者 map 来统计每个元素(预测标签)的出现次数, 找出出现次数最多的元素, 即实现了二分类中的多数投票算法。

4 实验结果与分析

4.1 实验平台及环境

本次实验在 PC 上运行, 实验环境为 Ubuntu16.04(64位), Intel(R) Core(TM) i9-7960X CPU, 128 GB RAM, NVIDIA GTX 1080Ti GPU, 模型基于 Pytorch 深度学习框架, 版本为 1.5.0。

4.2 数据集介绍

本文采用兰州大学 UAIS 实验室提供的 MODMA 数据集^[33], 数据集记录了 53 位受试者在静息状态下 128 通道的 EEG 信号。53 位受试者包含 24 位抑郁症患者(13 位男性患者和 11 位女性患者, 年龄在 16 岁到 56 岁之间)和 29 位正常对照组(20 名男性和 9 名女性, 年龄在 18 岁到 55 岁之间)。所有的受试者都在实验开始前签署了知情同意书, 其中抑郁症患者都经过了基于 DSM-IV 的诊断标准, 并且抑郁自我评估量表(PHQ-9)得分都大于或者等于 5 分, 且排除了具有抑郁症之外的其他精神类疾病, 无脑器官损害、严重的身体疾病和严重的自杀趋势等情况。对于正常对照组来说, 排除有个人或家族史的精神障碍的情况, 且在过去一年里无滥用或依赖酒精和精神药物的情况, 排除怀孕和哺乳期的妇女或服用避孕药的情况。

EEG 数据采集设备为 128-channel HydroCel Geodesic Sensor Net(Electrical Geodesics Inc., Oregon Eugene, USA), 数据记录软件为 Net Station acquisition software, 其中数据采样频率为 250 Hz, 电极阻抗在 50 kΩ 以下。

4.3 数据采集过程及数据预处理

采集过程记录了受试者在 5 min 闭眼状态下的静息脑电, 被试者在采集过程中保持清醒, 没有任何身体运动, 同时避免不必要的眼睛运动, 包括扫视和眨眼。

采集到的原始数据利用 MATLAB 软件中的 EEGLAB toolbox 处理原始文件, 补充坏道; 用 Trim Outlier 插件去除 EEG 中的肌电和眼电等噪声; 采用 REST 方法对 EEG 信号进行重参考; 用 ASR 插件去除 EEG 中包含高频噪声成分的数据点。

4.4 不同算法对比下的实验结果

本文采用基于脑电数据增广策略和模型集成策略的图神经网络算法对抑郁症进行分类, 同时以谱聚类(Spectral Clustering, SC)、 K 均值聚类(K -means)、支持向量机(SVM)算法、 K 最近邻(KNN)算法、U2GNN 算法^[34]、图同构网络(GIN)算法、HGP-SL^[35]算法与本文模型的预测结果进行对比, 结果如表 1 所列。

表 1 不同对比算法下的预测准确率

Table 1 Prediction accuracy of different comparison algorithms

	Algorithm	Accuracy/%
Baseline	SC	58.49
	K -means	56.60
	SVM	64.15
	KNN	60.37
	U2GNN	69.81
	HGP-SL	71.69
Ours	GIN	67.92
	Ensembled GIN	77.35

通过表 1 可以看出,直接利用 EEG 数据使用传统的聚类算法和分类算法进行分类,分类准确率偏低,说明传统的分类器难以聚合 EEG 数据的特征,分类效果差,需要依赖手动提取 EEG 特征才能取得较高的准确率。从结果来看,利用神经网络对 EEG 数据进行分类的准确率普遍高于传统的分类算法,说明神经网络能有效提取 EEG 信号的深度特征,可用于区分正常人与抑郁症患者。

相比其他图神经网络模型,本文提出的基于数据增广和模型集成策略的图神经网络模型取得了更高的分类准确率,说明数据增广和模型集成策略对小样本数据集的分类起到了改善作用。在学习到脑电数据深度特征的基础上,通过数据增广策略可以提高神经网络模型的分类能力,充分利用了脑电数据,获得了更高的分类准确率,在数据量较少的情况下,对分类模型的构建是非常有意义的。

4.5 在不同网络下基于数据增广和模型集成策略的实验结果

从 4.4 节中的结果可以看出,数据增广和模型集成策略对图同构网络的分类能力有了一定的改善。为了验证数据增广和模型集成策略对其他图神经网络分类能力的改善,本节对使用数据增广和模型集成策略与未使用数据增广和模型集成策略的 U2GNN 算法和 HGP-SL 算法做了分类结果对比,用于验证数据增广和模型集成策略在提升图神经网络分类效果方面的能力,实验结果如表 2 所列。

表 2 基于数据增广和模型集成策略的分类效果对比

Table 2 Comparison of classification performance based on data augmentation and model ensemble strategies

(单位:%)

Algorithm	Without data augmentation and model ensemble (Accuracy)	With data augmentation and model ensemble (Accuracy)
U2GNN	69.81	73.58
HGP-SL	71.69	75.47

由实验结果可知,数据增广和模型集成策略对 U2GNN 和 HGP-SL 的分类能力也有了一定的提升,说明数据增广和模型集成策略在小样本数据集上能够提高网络的分类能力。但是从结果可以看出,数据增广和模型集成策略对 U2GNN 和 HGP-SL 算法的分类能力的提升略差于 GIN 算法。出现这个结果的原因可能是原始数据构造出的脑网络,利用 U2GNN 和 HGP-SL 算法对其的分类效果优于 GIN 算法,但是经过数据增广之后构造出的脑网络受数据和参数的影响,U2GNN 和 HGP-SL 算法对数据增广后的脑网络的分类能力略差于 GIN 算法,最终经模型集成策略后,U2GNN 和 HGP-SL 算法的分类能力的提升略低于 GIN 算法。

4.6 不同训练次数下的实验结果

当一份完整的数据集通过了神经网络并且反向传播一次时,该过程被称为一次 epoch。所有的训练样本在神经网络中都进行了一次正向与反向传播,即一个 epoch 就是将所有训练样本训练一次的过程。为了更好地学习样本,增强神经网络的普适性,在神经网络中将完整的数据集传递一次是不够的,需要将完整的数据集在同样的神经网络中传递多次。

但是随着训练次数的增加,神经网络的更新次数也在增加,这样容易造成过拟合的情况。图 3 给出了基于数据增广策略的图神经网络模型在不同 epoch 下的预测准确率。

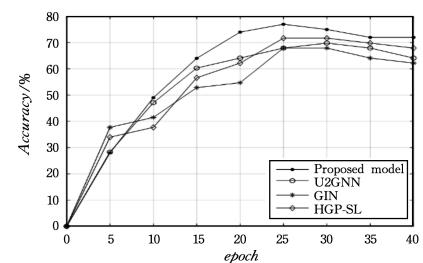


图 3 不同训练次数下的预测准确率

Fig. 3 Prediction accuracy with different epochs

由图 3 可知,模型的准确率随着 epoch 的增加而提高,尤其是在前 20 个 epoch,模型的预测准确率有明显的提高,后期趋向于平稳。

过拟合现象指模型对训练数据的准确率提高,但是泛化能力减弱,导致测试的准确率降低。为了保证较高的预测准确率,本文选用 epoch 为 25 时进行训练,得到了较高的模型性能。

网络参数设置如下:learning rate 为 0.0015,dropout 为 0.6,MLP 层数为 2。由于数据集较小,本文采用 10 折交叉验证。

4.7 数据增广策略在不同扩充倍数下的结果

本文对 MODMA 数据集进行扩充,用于数据增广,在对脑电数据分别进行了 3 倍、5 倍、7 倍、9 倍、11 倍、13 倍数据扩充后,实验结果如图 4 所示。

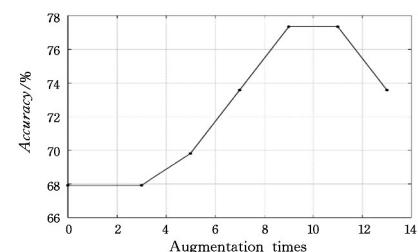


图 4 不同增广倍数下的分类结果

Fig. 4 Classification results with different augmentation times

由图 4 可知,脑电数据在一定范围内的数据增广可以提高分类的准确率,原因是脑电数据集的采集长度是一定的,合理地选择数据扩充倍数,才能利用脑电数据中的特征。如果扩充倍数过小,则起不到数据增广的作用;如果扩充倍数过大,则数据增广后的脑电数据学习特征少,难以起到数据增广的作用。本研究对 MODMA 数据集采用 9 倍或者 11 倍扩充,可以起到较好的数据增广作用。

4.8 不同数据增广策略下能力提升对比

Yang 等^[36]提出了一种基于 128 通道静息状态下 EEG 数据切分投票的抑郁症识别方法(RseVsm)。该方法首先处理脑电信号,得到 alpha, beta, theta 波段,并将数据集划分为 3 个子集,进行分类投票研究。表 3 列出了两种数据增广策略下分类能力提升效果的对比结果。由表 3 可知,本文提出的数据增广和模型集成策略对分类能力的提升效果更优。

表3 不同增广策略下分类能力提升效果对比

Table 3 Comparison of classification performance improvement with different augmentation strategies

Augmentation strategies	Classification performance improvement (Accuracy/%)
RseVsm	7.48
Ours	9.43

结束语 抑郁症的诊断较大程度地受到了医生的主观判断和病人配合程度的影响。随着计算机技术的发展,利用生理数据辅助诊断抑郁症是生理计算研究的热点之一,从生理数据中学习深度特征用于疾病的辅助诊断,排除了人为因素,能客观反映出人的变化。针对抑郁症患者脑电数据采集样本少的问题,本文提出了一个基于EEG数据增广和模型集成策略的图神经网络模型。所提模型首先将脑电数据进行数据增广,然后用图神经网络进行训练,最后利用模型集成策略集成预测结果。实验结果表明,在脑电数据样本数量较少的情况下,所提模型可以有效地提高脑电数据的利用率和模型的分类准确率。在目前的工作中,考虑到抑郁症患者脑电公开数据集少,本文只在兰州大学UAIS实验室提供的MODMA数据集中53位受试者在静息状态下128电极的脑电数据上做了实验。接下来的工作重点是,借助不同状态下采集到的受试者脑电数据,通过对脑电数据进行如脑电分频、模态融合等不同方式的预处理,结合数据增广策略和模型集成策略进行抑郁症分类研究。

参 考 文 献

- [1] ZUNG W W. A Self-Rating Depression Scale [J]. Archives of General Psychiatry, 1965, 12(1): 63-70.
- [2] EHDE D M. Hamilton Depression Rating Scale [M] // Encyclopedia of Clinical Neuropsychology. New York: Springer, 2011: 1205-1207.
- [3] BECK A T, STEER R A, CARBIN M G. Psychometric properties of the Beck Depression Inventory: Twenty-five years of evaluation [J]. Clinical Psychology Review, 1988, 8(1): 77-100.
- [4] SEGAL D L. Diagnostic and Statistical Manual of Mental Disorders(DSM-IV-TR) [M] // The Corsini Encyclopedia of Psychology. John Wiley & Sons, Ltd, 2010: 1-3.
- [5] CHANG C C, LIN C J. LIBSVM: a library for support vector machines [J]. ACM transactions on intelligent systems and technology(TIST), 2011, 2(3): 1-27.
- [6] PETERSON L E. K-nearest neighbor [J]. Scholarpedia, 2009, 4(2): 1883-1895.
- [7] CAI H, QU Z, LI Z, et al. Feature-level Fusion Approaches Based on Multimodal EEG Data for Depression Recognition [J]. Information Fusion, 2020, 59: 127-138.
- [8] HU B, RAO J, LI X, et al. Emotion regulating attentional control abnormalities in major depressive disorder: an event-related potential study [J]. Scientific Reports, 2017, 7(1): 1-21.
- [9] JIANG H, HU B, LIU Z, et al. Investigation of different speech types and emotions for detecting depression using different classifiers [J]. Speech Communication, 2017, 90: 39-46.
- [10] LI X, TONG C, SUN S, et al. Classification study on eye move-
- ment data: Towards a new approach in depression detection [C] // 2016 IEEE Congress on Evolutionary Computation (CEC). IEEE, 2016: 1227-1232.
- [11] LU S, XU J, LI M, et al. Attentional bias scores in patients with depression and effects of age: a controlled, eye-tracking study [J]. Journal of International Medical Research, 2017, 45(4): 1518-1527.
- [12] BAILEY N W, KREPEL N, DIJK H V, et al. Resting EEG theta connectivity and alpha power to predict repetitive transcranial magnetic stimulation response in depression: A non-replication from the ICON-DB consortium [J]. Clinical Neurophysiology, 2021, 132(2): 650-659.
- [13] ZHU J, WANG Z, GONG T, et al. An Improved Classification Model for Depression Detection Using EEG and Eye Tracking Data [J]. IEEE Transactions on Nano Bioscience, 2020, 19(3): 527-537.
- [14] CHEN F, ZHAO L, LI B, et al. Depression evaluation based on prefrontal EEG signals in resting state using fuzzy measure entropy [J/OL]. Physiological Measurement, 2020, 41(9): 095007. https://www.researchgate.net/publication/343799441_Depression_evaluation_based_on_the_prefrontal_EEG_signal_in_resting_state_using_the_fuzzy_measure_entropy.
- [15] LI X W, HU B, SUN S T, et al. EEG-based mild depressive detection using feature selection methods and classifiers [J]. Computer Methods & Programs in Biomedicine, 2016, 136(C): 151-161.
- [16] LI P, SONG X, JING W, et al. Reduced sensitivity to neutral feedback versus negative feedback in subjects with mild depression: Evidence from event-related potentials study [J]. Brain & Cognition, 2015, 100(NOV.): 15-20.
- [17] ACHARYA U R, SUDARSHAN V K, ADELI H, et al. A Novel Depression Diagnosis Index Using Nonlinear Features in EEG Signals [J]. European Neurology, 2016, 74: 79-83.
- [18] KAUR C, SINGH P, BISHT A, et al. EEG Signal denoising using hybrid approach of Variational Mode Decomposition and wavelets for depression [J]. Biomedical Signal Processing and Control, 2020, 65(4): 102337.
- [19] MAHATO S, GOYAL N, RAM D, et al. Detection of Depression and Scaling of Severity Using Six Channel EEG Data [J]. Journal of Medical Systems, 2020, 44(7): 118.
- [20] BOCHAROV A V, KNYAZEV G G, Savostyanov A N, et al. Relationship of Depression, Anxiety, and Rumination Scores with EEG Connectivity of Resting State Networks [J]. Human Physiology, 2021, 47(2): 123-127.
- [21] CAI H, HAN J, CHEN Y, et al. A Pervasive Approach to EEG-Based Depression Detection [J/OL]. Complexity, 2018(1): 13. <https://www.hindawi.com/journals/complexity/2018/5238028/>.
- [22] AKBARI H, SADIQ M T, REHMAN A U, et al. Depression recognition based on the reconstruction of phase space of EEG signals and geometrical features [J]. Applied Acoustics, 2021, 179: 1-16.
- [23] ZHANG X, HU B, ZHOU L, et al. An EEG based pervasive depression detection for females [C] // Joint International Conference on Bio-inspired Computing: Theories and Applications (BIC-TA 2018) and International Conference on Bio-inspired Computing: Theories and Applications (BIC-TA 2018). Springer, 2019: 103-114.

- rence on Pervasive Computing and the Networked World. Berlin: Springer, 2012: 848-861.
- [24] HOSSEINIFARD B, MORADI M H, ROSTAMI R. Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal[J]. Computer Methods and Programs in biomedicine. 2013, 109 (3): 339-345.
- [25] LIAO S C, WU C T, HUANG H C, et al. Major Depression Detection from EEG Signals Using Kernel Eigen-Filter-Bank Common Spatial Patterns[J]. Sensors, 2017, 17(6): 1385-1402.
- [26] ZHONG P, WANG D, MIAO C. EEG-Based Emotion Recognition Using Regularized Graph Neural Networks[J/OL]. IEEE Transactions on Affective Computing, 2020. <https://ieeexplore.ieee.org/document/9091308/>.
- [27] SONG T, LIU S, ZHENG W, et al. Instance-Adaptive Graph for EEG Emotion Recognition[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2020; 2701-2708.
- [28] SUNS T, LI X W, ZHU J, et al. Graph Theory Analysis of Functional Connectivity in Major Depression Disorder with High-Density Resting State EEG Data[J]. IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society, 2019, 27(3): 429-439.
- [29] SCARSELLI F, GORI M, AC TSOI, et al. The Graph Neural Network Model[J]. IEEE Transactions on Neural Networks, 2009, 20(1): 61-80.
- [30] DOUGLAS B L. The Weisfeiler-Lehman Method and Graph Isomorphism Testing[J]. arXiv: 1101.5211, 2011.
- [31] XU K, HU W, LESKOVEC J, et al. How powerful are graph neural networks? [J]. arXiv: 1810.00826, 2018.
- [32] WIENER G. Search for a majority element[J]. Journal of Statistical Planning & Inference, 2002, 100(2): 313-318.
- [33] CAI H, GAO Y, SUN S, et al. MODMA dataset: a Multi-model Open Dataset for Mental-disorder Analysis[J]. arXiv, 2020, 09283, 2020.
- [34] NGUYEN D Q, NGUYEN T D, PHUNG D. Unsupervised Universal Self-Attention Network for Graph Classification[J]. arXiv: 1909.11855, 2019.
- [35] ZHANG Z, BU J, ESTER M, et al. Hierarchical Graph Pooling with Structure Learning[J]. arXiv: 1911.05954, 2019.
- [36] YANG J, NIU J, ZENG S, et al. Resting state EEG based depression recognition research using voting strategy method [C]// 2018 IEEE International Conference on Bioinformatics and Biomedicine(BIBM). IEEE, 2018: 2666-2673.



YANG Bing-xin, born in 1995, postgraduate. His main research interests include machine learning and computer vision.



GUO Yan-rong, born in 1984, professor. Her main research interests include biomedical image segmentation and analysis.

(责任编辑:喻黎)