

李浩, 张学军. 动态图卷积联合记忆网络情绪脑电识别方法[J]. 智能计算机与应用, 2025, 15(1): 203-210. DOI: 10. 20169/ j. issn. 2095-2163. 250130

动态图卷积联合记忆网络情绪脑电识别方法

李浩¹, 张学军^{1,2}

(1 南京邮电大学 电子与光学工程学院、柔性电子(未来技术)学院, 南京 210023;

2 南京邮电大学 射频集成与微组装技术国家地方联合工程实验室, 南京 210023)

摘要: 针对无法有效利用脑电通道拓扑结构学习更有鉴别性的脑电特征问题, 本文基于长短期记忆网络和图卷积神经网络, 提出动态图卷积联合记忆网络(Dynamic Graph Convolutional Joint Long Short Term Memory Network, DGCJMN)方法。首先将脑电通道作为图的节点, 微分熵作为节点特征, 利用动态参数学习最优的脑电通道拓扑结构, 构建特征图; 之后, 由图卷积神经网络提取图域特征, 并结合长短期记忆网络和池化进一步提取特征; 最后将图卷积网络、长短期记忆网络和池化提取的特征融合后进行情绪分类。所提方法在 SEED 数据集上针对积极、中性和消极 3 种情绪取得的平均准确率为 95.93%, 精确率、召回率和 F1 值分别为 96.11%、95.93% 和 0.96, Kappa 系数为 0.939。混淆矩阵表明, 模型对于 3 种情绪都达到了较好的分类效果。

关键词: 情绪识别; 脑电图; 图卷积神经网络; 长短期记忆网络; 微分熵

中图分类号: TP274; R318 文献标志码: A 文章编号: 2095-2163(2025)01-0203-08

EEG-based emotion recognition using fusion model of graph convolutional neural networks and LSTM

LI Hao¹, ZHANG Xuejun^{1,2}

(1 College of Electronic and Optical Engineering, College of Flexible Electronics (Future Technology), Nanjing University of Posts and Telecommunications, Nanjing 210023, China; 2 National and Local Joint Engineering Laboratory of RF Integration and Micro-Assembly Technology, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Aiming at the problem that the topology structure of EEG channels cannot be effectively used to learn more discriminative EEG features, this paper proposes the dynamic graph convolutional joint memory network (Dynamic Graph Convolutional Joint Long Short Term Memory Network, DGCJMN) based on the long and short term memory network and the graph convolutional neural network. First, the EEG channel is taken as the node of the graph, and the differential entropy is taken as the node feature, and the optimal EEG channel topology is learned by dynamic parameters to construct the feature graph. After that, the features of the graph domain are extracted by the convolutional neural network, and further extracted by combining the long short-term memory network and pooling. Finally, the features extracted by Graph Convolutional Network, Long Short-term Memory network and pooling were fused for emotion classification. The proposed method achieved an average accuracy of 95.93% for positive, neutral and negative emotions in SEED dataset; accuracy, recall and F1 scores were 96.11%, 95.93% and 0.96; Kappa coefficient was 0.939; confusion matrix indicated that the model achieved a good classification effect for the three emotions.

Key words: emotion recognition; EEG; Graph Convolutional Neural Network; Long Short-Term Memory network; differential entropy;

0 引言

为了让机器能够理解、表达人的情感, 进行更加

智能化的人机交互, 研究人员提出了情感计算^[1]的概念。情绪识别为情感计算的研究方向之一, 由情绪诱导、信号采集、信号预处理、特征提取、情绪模式

基金项目: 国家自然科学基金(61977039)。

作者简介: 李浩(1997—), 男, 硕士研究生, 主要研究方向: 智能信号处理。

通信作者: 张学军(1969—), 男, 博士, 教授, 主要研究方向: 深度学习, 智能信号处理, 无线射频识别关键技术研究等。Email: zhxj@njupt.edu.cn。

收稿日期: 2023-08-06

学习和分类组成。研究者通过面部特征、肢体语言、生理信号^[2]等多种形式,获取目标的情绪信息。其中,脑电图(Electroencephalogram, EEG)^[3]等生理信号较为常用。

传统的特征提取方法高度依赖于人为设计的特征,常用方法有统计特征、分形维数、非平稳指数、功率谱密度和微分熵(Differential Entropy, DE)^[4],但这些方法受限于特定的知识和经验,识别精确度的提高受到了极大的限制。传统的分类模型有决策树(Decision Tree, DT)、K近邻(K-Nearest Neighbor, KNN)、支持向量机(Support Vector Machine, SVM)等。Petrantonakis等^[5]采用高阶过零分析提取自采脑电数据集特征,在SVM分类器上对6种情绪的平均分类准确率达到83.33%。Kusumaningrum T D等^[6]将9个时频脑电图特征联合输入到随机森林分类器中进行情绪识别,优化了单个特征的分类性能。

深度学习出现之后,大量有关机器学习的信号处理方法被应用在脑电图情绪识别领域中。研究人员发现神经网络可以训练出本质的特征进行分类,分类正确率得到了较大的提高。Yanling A等^[7]将不同频带的微分熵特征融合成三维特征,输入到卷积自动编码器中进行分类,在DEAP数据集中获得90.76%的准确率。Liu等^[8]提出动态经验卷积神经网络方法,结合经验模态分解(Empirical Mode Decomposition, EMD)与微分熵两者的优势,构建动态微分熵算法,在SEED数据集上取得97.56%的准确率。Anubhav等^[9]提取脑电信号的频带功率,输入到长短期记忆网络(Long Short-Term Memory network, LSTM)模型中,在DEAP数据集的效价和唤醒度两个维度上分别取得94.69%和93.13%的分类准确率。廉小亲等^[10]提出基于卷积神经网络的情绪4分类的方法,在DEAP数据集上取得96.2%的准确率。张学军等^[11]提出基于卷积神经网络(Convolutional Neural Network, CNN)的脑电情绪识别方法,采用一维微分熵特征作为CNN输入,在SEED数据集上取得98.73%的准确率。

2009年,Scarselli等^[12]提出了图卷积神经网络(Graph Convolutional Neural Network, GCN)的概念,这是一种结合CNN和谱理论的深度学习方法。为了充分利用脑电通道的拓扑结构,GCNN开始应用于情绪识别领域中。Wang等^[13]提出基于相位锁定值^[14]的图卷积神经网络,利用锁相值表征不同节点之间的连接,在SEED数据集上取得84.35%的准确率。Song等^[2]提出动态图卷积神经网络(Dynamical

Graph Convolutional Neural Networks, DGCNN)方法,该方法借助损失函数动态地学习邻接矩阵,利用脑电通道之间的内在关系,提取脑电信号,在SEED数据集的准确率为79.95%。Li等^[15]提出自组织图神经网络模型,该方法不需要预先构造固定图结构,而是根据输入的脑电信号构造图模型,在SEED数据集上的准确率为86.15%。李景聪等^[16]采用基于图注意力网络的脑电情绪识别方法,在SEED数据集的分类正确率为86.3%。高越等^[17]提出基于时空自适应图卷积神经网络的情绪识别方法,引入时空注意力机制解决了情绪的稀疏性问题,在SEED数据集上的平均准确率为85.65%。

考虑到脑电图的特殊结构和长时间序列特性,结合图卷积神经网络和长短期记忆网络处理长时间序列的优势,本文提出动态图卷积联合记忆网络(Dynamic Graph Convolutional Joint Long Short Term Memory Network, DGCJMN)方法,在SEED数据集上进行了验证。SEED数据集共取得数据样本1350个,其中80%用于训练,其余用于测试,训练集准确率高达99.81%,测试集准确率达到95.93%。

1 数据及处理方法

1.1 数据集

本文选用上海交通大学BCMI实验室提供的EEG数据集——SEED数据集。该实验共有15名中国受试者参加,其中男性7名,女性8名,平均年龄23.27。选择15个电影片段作为情绪的刺激材料,对应积极、中性和消极3种情绪。电影片段时长为4 min,每名受试者采集3个时间段的实验数据,每个时间段进行15组实验,共45组实验。采集脑电信号的过程如图1所示,采集电极通道数为62的脑电信号,并经过200 Hz的降采样和0~75 Hz的带通滤波。

1.2 数据处理

微分熵(Differential Entropy, DE)作为脑电情绪识别中较为常用的脑电特征,源于香农信息熵在连续变量上的延伸,计算公式如下:

$$DE = - \int p(x) \log(p(x)) dx \quad (1)$$

运用MA和LDS进行特征平滑后,对提取出的微分熵特征进行降维,如图2所示。首先,将5个不同频带的特征截取为同样大小,保证不同实验数据的统一性;然后,按照频率从小到大的顺序按列进行排序,实现三维特征到二维的转变。




图 1 脑电信号采集过程

Fig. 1 Acquisition process of EEG



图 2 特征平滑和降维

Fig. 2 Feature smoothing and dimensionality reduction

1.3 电极选择

为了降低训练难度,减少不相关电极对实验结果的影响,本文仅选用已有成果中与情绪相关的电极。文献[18]研究结果表明,选择 FT7、FT8、T7、T8、C5、C6、TP7、TP8、CP5、CP6、P7 和 P8 电极时,情绪识别效果超过了选择 62 个全电极时的效果;文献[19]结果表明,识别效果较好的电极组合为 FP1、AF3、F3、F7、C3、P3、PO3、F4、F8、C4、P4 和 PO4。本文经实验后,以准确率作为判断依据,文献[18]电极组合为 91.85%,文献[19]电极组合为 89.63%,但二者结合的准确率为 95.93%,故将二者结合使用。图 3 为国际 10-20 标准系统电极位置分布图,所用电极用不同颜色进行标记。

2 DGCJMN 模型

2.1 图与稀疏矩阵

根据图论知识,构建图 $G = \{V, E, C\}$ 。其中, V 为顶点集, E 为边集, C 为稀疏矩阵。每个脑电通道对应一个顶点,稀疏矩阵以坐标的方式描述不同顶点之间的连接情况,格式为 $[2, \text{num_edge}]$ 。本文根据动态参数 Z 学习最优的稀疏矩阵,并根据二维微分熵特征构建 24 节点的图结构,作为图卷积神经网络的输入,图结构如图 4 所示。



图 4 特征图

Fig. 4 Characteristic map

参数 Z 的更新公式:

$$Z = (1 - \rho)Z + \rho \frac{\partial Loss}{\partial Z} \quad (2)$$

其中, $Loss$ 为交叉熵损失函数, ρ 为学习率。

2.2 批归一化

批归一化 (Batch Normalization, BN), 可以对一批数据进行归一化操作,简化参数搜索问题,通常出现在网络的中间层。本文将二维微分熵特征在输入网络之前进行一维批归一化,并在网络中加入二维批归一化层。批归一化操作使每层输入数据的分布相对稳定,加快网络的收敛速度;一方面抑制了参数的微小变化随着网络层数加深被放大的问题,使得模型更加稳定;另一方面激活函数的输入数据可以保持在梯度非饱和区,对于深层网络的梯度消失问

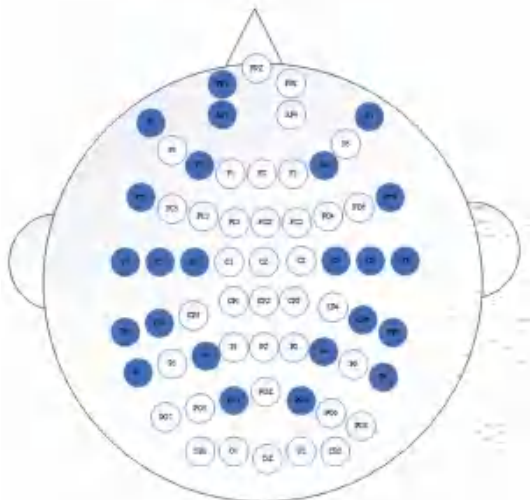


图 3 国际 10-20 标准系统电极分布图 (暗色表明在实验中使用的电极)

Fig. 3 International 10-20 standard system electrode distribution diagram (dark color indicates the electrode used in the experiment)

题也有一定的缓解。同时,不同的批大小 (Batch_size) 数据带来了不同的均值与方差,为神经网络在学习过程中增加了随机噪声,起到了正则化的作用。BN 变换如下所示:

$$\mathbf{I}_{\text{norm}} = \frac{\mathbf{I} - \boldsymbol{\mu}}{\sqrt{\sigma^2 + \varepsilon}} \quad (3)$$

$$\mathbf{I}_{\text{out}} = \text{BN}(\mathbf{I}) = \gamma \mathbf{I}_{\text{norm}} + \beta \quad (4)$$

其中, \mathbf{I} 为 BN 层的输入; \mathbf{I}_{out} 为 BN 层的输出; ε 为一个小数值参数; γ 和 β 是通过学习得到的比例参数。均值 $\boldsymbol{\mu}$ 和方差 σ^2 如下所示:

$$\boldsymbol{\mu} = \frac{1}{m} \sum_{i=1}^m \mathbf{I}_i \quad (5)$$

$$\sigma^2 = \frac{1}{m} \sum_{i=1}^m (\mathbf{I}_i - \boldsymbol{\mu})^2 \quad (6)$$

2.3 图卷积

图卷积分为谱域图卷积和空域图卷积。前者是在图论的基础上发展而来^[20],其中图傅里叶变换 (GFT) 就是一个典型的应用。

图卷积的分层传播规则:

$$\mathbf{H}^{(l+1)} = \sigma(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{H}^{(l)} \mathbf{W}^{(l)}) \quad (7)$$

其中, $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_n$ 为添加了自连接的无向图 G 的邻接矩阵; \mathbf{I}_n 为单位矩阵; $\tilde{\mathbf{D}}_{ii} = \sum_j \tilde{\mathbf{A}}_{ij}$ 及 $\mathbf{W}^{(l)}$ 为可学习的权重矩阵; $\sigma(\cdot)$ 为激活函数。本文采用 ReLU 激活函数,定义如下:

$$\text{ReLU}(x) = \max(0, x) \quad (8)$$

$\mathbf{H}^{(l)}$ 是第 l 层的激活矩阵 (即第 l 层的输入), $\mathbf{H}^{(0)} = \mathbf{X}$ 。

设 \mathbf{L} 为图 G 的拉普拉斯矩阵,

$$\mathbf{L} = \mathbf{D} - \mathbf{W} \in \mathbf{R}^{N \times N} \quad (9)$$

其中, \mathbf{W} 为邻接矩阵; \mathbf{D} 为对角矩阵; $\mathbf{D}_{ii} = \sum_j w_{ij}$ 。

对于一个给定的空间信号 x , 其 GFT 如下:

$$\hat{x} = \mathbf{U}^T x \quad (10)$$

其中, \hat{x} 为频域的转换信号, \mathbf{U} 通过 \mathbf{L} 的奇异值分解得到为标准正交矩阵。

$$\mathbf{L} = \mathbf{U} \mathbf{A} \mathbf{U}^T \quad (11)$$

$\mathbf{A} = \text{diag}([\lambda_0, \lambda_1, \dots, \lambda_{N-1}])$ 为对角矩阵。由 (9) 可以得到逆 GFT 的变换式:

$$x = \mathbf{U} \mathbf{U}^T x = \mathbf{U} \hat{x} \quad (12)$$

两个信号 x 和 y 在图上的卷积可以表示如下:

$$x * y = \mathbf{U}((\mathbf{U}^T x) \circ (\mathbf{U}^T y)) \quad (13)$$

\circ 表示哈达玛积。

设 $g(\cdot)$ 为一个滤波函数, 信号 x 经过 $g(L)$ 可以表示如下:

$$y = g(L)x = g(\mathbf{U} \mathbf{A} \mathbf{U}^T)x = \mathbf{U} g(\mathbf{A}) \mathbf{U}^T x \quad (14)$$

其中, $g(\mathbf{A})$ 可表示如下:

$$g(\mathbf{A}) = \text{diag}([g(\lambda_0), g(\lambda_1), \dots, g(\lambda_{N-1})]) \quad (15)$$

可以看出, 式 (14) 的滤波操作等同于信号 x 与向量 $\mathbf{U} \text{diag}(g(\mathbf{A}))$ 的图卷积, 根据下面的推导:

$$\begin{aligned} y &= g(L)x = \\ & \mathbf{U} g(\mathbf{A}) \mathbf{U}^T x = \\ & \mathbf{U} (\text{diag}(g(\mathbf{A})) \circ (\mathbf{U}^T x)) = \\ & \mathbf{U} ((\mathbf{U}^T (\mathbf{U} \text{diag}(g(\mathbf{A})))) \circ (\mathbf{U}^T x)) = \\ & x * g(\text{diag}(g(\mathbf{A}))) \end{aligned} \quad (16)$$

由于 $g(\mathbf{A})$ 直接计算比较困难, 故使用 K 阶切比雪夫多项式简化该计算, 本文中选取 $K = 3$ 。设 λ_{\max} 为对角矩阵 \mathbf{A} 中的最大值, $\tilde{\mathbf{A}} = \frac{2\mathbf{A}}{\lambda_{\max}} - \mathbf{I}_N$ 为 \mathbf{A} 的归一化, \mathbf{I}_N 为 $N \times N$ 的单位矩阵。

在 K 阶切比雪夫多项式的框架下:

$$g(\mathbf{A}) = \sum_{k=0}^K \theta_k T_k(\tilde{\mathbf{A}}) \quad (17)$$

其中, θ_k 为切比雪夫多项式系数, 而 $T_k(x)$ 可根据以下规则进行递归运算。

$$\begin{cases} T_0(x) = 1, T_1(x) = x \\ T_k(x) = 2xT_{k-1}(x) - T_{k-2}(x), k \geq 2 \end{cases} \quad (18)$$

故式 (16) 的卷积操作可表示如下:

$$\begin{aligned} y &= \mathbf{U} g(\mathbf{A}) \mathbf{U}^T x = \sum_{k=0}^K \mathbf{U} \text{diag}([\theta_k T_k(\tilde{\lambda}_0), \\ & \theta_k T_k(\tilde{\lambda}_1), \dots, \theta_k T_k(\tilde{\lambda}_{N-1})]) \mathbf{U}^T x = \\ & \sum_{k=0}^K \theta_k T_k(\tilde{\mathbf{L}}) x \end{aligned} \quad (19)$$

其中, $\tilde{\mathbf{L}} = \frac{2\mathbf{L}}{\lambda_{\max}} - \mathbf{I}_N$ 。

2.4 长短期记忆 (LSTM) 网络

循环神经网络 (Recurrent Neural Network, RNN) 由具有反馈连接的神经元组合而成, 针对序列输入的非线性特征进行学习。但是, 在处理输入的时间序列较长时, 易出现梯度消失或者梯度爆炸的问题。为解决 RNN 的长距离依赖问题, Hochreiter 和 Schmidhuber 提出了长短期记忆网络 (Long Short-Term Memory networks, LSTM)^[21], 如图 5 所示。LSTM 引入了细胞状态变量, 结合遗忘门、输入门、输出门 3 种门控单元和 tanh 激活函数, 决定了如何舍弃、保持和更新信息。




图 5 LSTM 网络结构

Fig. 5 LSTM network structure

2.5 网络模型

本文提出的 DGCJMN 模型如图 6 所示, 该模型

由批归一化层、图卷积层、LSTM 网络层、池化层、全连接层以及拼接层构成。模型的具体参数见表 1。

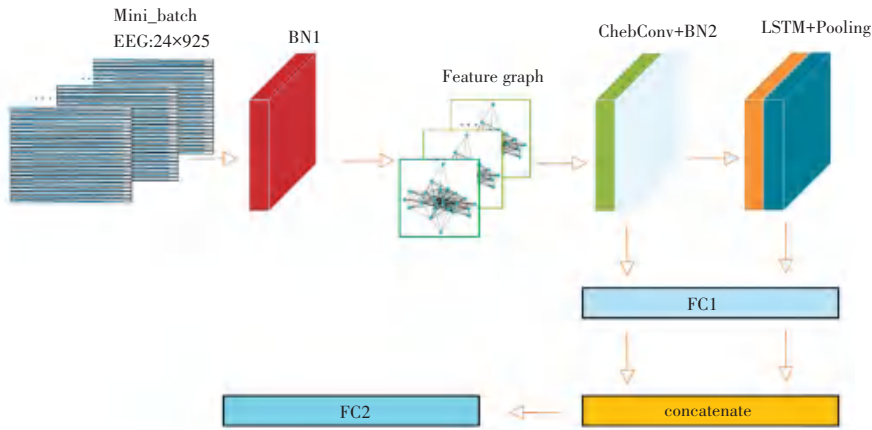


图 6 DGCJMN 模型

Fig. 6 DGCJMN model

表 1 模型参数

Table 1 Model parameter

层名	具体参数
BatchNorm1d	num_feature = 925
ChebConv	in_channel = 925, out_channel = 256, K = 3
BatchNorm2d	num_features = 1
LSTM	input_size = 256, hidden_size = 128, num_layers = 2, batch_first = True
Pooling	kernel_size = 2, stride = 2
FC1	Flatten(function)
concatenate	cat(function)
FC2	Linear(function)

3 实验结果与分析

3.1 与传统算法比较

将 DGCJMN、GCJMN (Graph Convolutional Joint Long Short Term Memory Network, GCJMN) 与传统的

决策树 (Decision Tree, DT)、K 近邻 (K - Nearest Neighbor, KNN) 和支持向量机 (Support Vector Machine, SVM) 分类方法在 SEED 数据集上进行对比分析。GCJMN 采用信道间熵值的皮尔逊相关系数生成稀疏矩阵, 模型与 DGCJMN 一致。通过分类准确率和 Kappa 系数进行评估, 结果见表 2。

表 2 不同算法的分类准确率与 Kappa 系数

Table 2 Classification accuracy and Kappa coefficient of different algorithms

算法	准确率 / %	Kappa 系数
Decision Tree	58.52	0.377
KNN	69.63	0.544
SVM	82.22	0.733
GCJMN	92.59	0.889
DGCJMN	95.19	0.928

利用决策树算法对本文的数据进行情绪分类, 得到准确率为 58.52%, Kappa 系数为 0.377; KNN


算法作为分类问题中应用较多的方法,得到的准确率为 69.63%, Kappa 系数为 0.544, SVM 采取多项式核函数,如下式所示:

$$K(x, y) = (ax^T y + c)^d \quad (20)$$


得到的准确率为 82.22%, Kappa 系数为 0.733。而 GCJMN 与 DGCJMN 无论是准确率还是 Kappa 系数均优于传统算法。

3.2 GCJMN 与 DGCJMN 对比分析


在时钟周期为 300,批大小为 64 的条件下。GCJMN 与 DGCJMN 的准确率、精确率、召回率、F1 分数以及 Kappa 系数对比如图 7 所示。



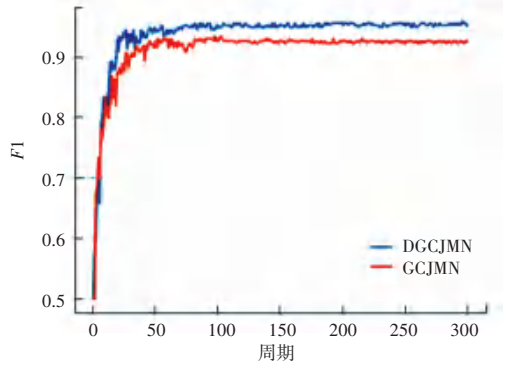
(a) 准确率



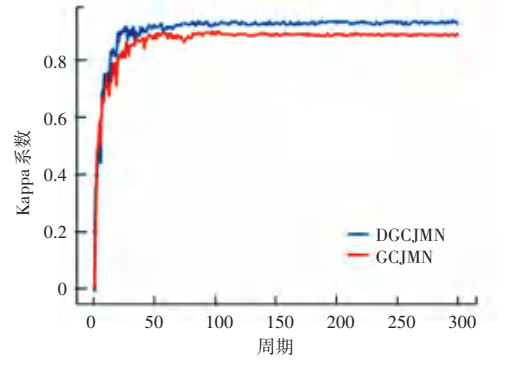
(b) 精确率



(c) 召回率



(d) F1 分数



(e) Kappa 系数

图 7 评价指标对比

Fig. 7 Comparison of evaluation index

由图 7 可知,DGCJMN 方法在准确率、精确率、召回率、F1 分数以及 Kappa 系数评价指标上均优于 GCJMN。准确率方面,DGCJMN 为 95.18%,GCJMN 为 92.59%;精确率方面,前者为 95.23%,后者为 92.63%;召回率方面,前者为 95.19%,后者为 92.59%;F1 分数方面,前者为 0.952,后者为 0.926;Kappa 系数方面,前者为 0.928,后者为 0.889。

3.3 DGCJMN 主要参数

为了减少网络训练的时间并获取最佳实验结果,主要针对批大小、学习率和运行周期三者进行调整。设置批大小为 16、32、64 和 128,周期(Epoch)为 80、120 和 160。其中,一个周期是指运行整个数据集的时间。实验结果见表 3。

表 3 批大小和时间对准确率的影响

Table 3 Effect of batch size and time on accuracy

时间	批大小			
	16	32	64	128
80	93.33%	94.44%	94.81%	94.44%
120	93.70%	95.93%	95.19%	94.81%
160	94.07%	94.44%	95.19%	95.18%

综合考虑各种评价指标的结果,确定批大小为 32,时间周期为 120 最合适。学习率方面,本文采用的优化器为 Adam 优化器,初始学习率设定为 0.01。

为解决测试集收敛问题, 设定学习率每经过 5 个周期衰减 20%。

3.4 DGCJMN 模型结果分析

图 8 与图 9 分别是 DGCJMN 模型的损失函数与准确率曲线。由图 8 可知, 模型在周期为 100 时开始逐渐收敛, 在 120 时准确率逐渐达到最佳, 其他的评价指标如图 10 所示。本文方法对积极、中性和消极 3 种情绪的平均分类准确率达到 95.93%。精确率、召回率、F1 分数和 Kappa 系数分别是 96.11%、95.3%、0.96 和 0.939。图 11 为情绪的混淆矩阵, 数字 0、1、2 分别对应于消极、积极、中性 3 种情绪, 表明模型对于消极和积极两类情绪的识别率较高, 中性情绪识别准确率略低。




图 8 模型的损失函数曲线

Fig. 8 Curve of model's loss function






图 9 模型的准确率曲线


Fig. 9 Curve of model's accuracy




(a) 精确率



(b) 召回率



(c) F1 分数



(d) Kappa 系数

图 10 其他评价指标

Fig. 10 Other evaluation indicators




图 11 混淆矩阵

Fig. 11 Confusion matrix

3.5 图神经网络比较

将本文的 DGCJMN 模型与部分文献的研究成果在 SEED 数据集的效果进行比较, 结果见表 4。文献

[2]提出了一种动态图卷积网络模型,在 SEED 数据集全频带上取得了 90.40% 的准确率;文献[22]提出将动态图卷积神经网络与宽度学习系统相结合的方法,SEED 数据集的受试者取得 93.66% 的平均准确率;文献[4]结合图卷积宽度网络与宽度学习系统,SEED 数据集上的分类精度达到了 94.24%;文献[23]提出了基于学习电极相关性的图卷积神经网络模型,在 SEED 数据集上的准分类准确率为 94.72%。

表 4 图神经网络模型比较

Table 4 Comparison of GNN models

文献	方法	准确率/%
文献[2]	DGCN	90.40
文献[22]	DGCN+BLS	93.66
文献[4]	GCB+net	92.30
文献[4]	GCB-net+BLS	94.24
文献[23]	LR-GCN	94.72
本文	DGCJMN	95.93

本文针对 SEED 数据集提取出的微分熵特征,提出 DGCJMN 模型对脑电信号进行三分类的情绪识别,平均准确率达到 95.93%,较之现有的图卷积网络模型有一定提高。

4 结束语

对于情绪的精确判别,可以为心理疾病的检测提供理论指导与实践方法。本文提出 DGCJMN 模型,利用 SEED 数据集对积极、消极和中性 3 种类别进行了分析研究。模型由批归一化层、图卷积层、LSTM 网络层、池化层、全连接层以及拼接层构成,对 3 种情绪类别的平均准确率达到 95.93%,精确率、召回率、 $F1$ 分数以及 Kappa 系数分别为 96.11%、95.93%、0.96 和 0.939,与传统决策树、KNN 和 SVM 分类器相比具有较高的准确率,证明了方法的有效性。

参考文献

- [1] 李贤哲, 暴伟, 谢能刚. 基于脑电信号的情绪识别[J]. 北京生物医学工程, 2022, 41(1): 8-16.
- [2] SONG T, ZHENG W, SONG P, et al. EEG emotion recognition using dynamical graph convolutional neural networks[J]. IEEE Transactions on Affective Computing, 2020, 11(3): 532-541.
- [3] YANG H, HAN J, MIN K. A multi-column CNN model for emotion recognition from eeg signals[J]. Sensors(Basel), 2019, 19(21): 4736.
- [4] ZHANG T, WANG X, XU X, et al. GCB-Net: Graph convolutional broad network and its application in emotion recognition[J]. IEEE Transactions on Affective Computing, 2022, 13(1): 379-388.
- [5] PETRANTONAKIS P C, HADJILEONTIADIS L J. Emotion recognition from EEG using higher order crossings[J]. IEEE Transactions on Information Technology in Biomedicine, 2010, 14(2): 186.
- [6] KUSUMANINGRUM T D, FAQIH A, KUSUMOPUTRO B. Emotion recognition based on DEAP database using EEG time-frequency features and machine learning methods[J]. Journal of Physics: Conference Series, 2020, 1501(1): 012020.
- [7] YAN L, HU S H, DUAN X Y, et al. Electroencephalogram emotion recognition based on 3D feature fusion and convolutional autoencoder[J]. Frontiers in Computational Neuroscience, 2021, 15: 743426.
- [8] LIU S, WANG X, ZHAO L, et al. Subject-independent emotion recognition of EEG signals based on dynamic empirical convolutional neural network[J]. IEEE/ACM Transactions Computational Biology and Bioinformatics, 2021, 18(5): 1710-1721.
- [9] ANUBHAV, NATH D, SINGH M, et al. An efficient approach to EEG-based emotion recognition using LSTM network[C]// Proceedings of 2020 16th IEEE International Colloquium on Signal Processing & Its Applications (CSPA). Piscataway, NJ: IEEE, 2020: 28-29.
- [10] 廉小亲, 罗志宏, 蔡沫豪, 等. 基于卷积神经网络的脑电情绪识别方法[J]. 计算机仿真, 2022, 39(8): 268-274.
- [11] 张学军, 陈都, 孙知信. 基于卷积神经网络的脑电信号情绪分类方法[J]. 电子测量技术, 2022, 45(1): 1-7.
- [12] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. IEEE Transactions Neural Networks, 2009, 20(1): 61-80.
- [13] WANG Z M, TONG Y, HENG X. Phase-locking value based graph convolutional neural networks for emotion recognition[J]. IEEE Access, 2019, 7: 93711-93722.
- [14] 王忠民, 赵玉鹏, 郑榕林, 等. 脑电信号情绪识别研究综述[J]. 计算机科学与探索, 2022, 16(4): 760-774.
- [15] LI J, LI S, PAN J, et al. Cross-subject EEG emotion recognition with self-organized graph neural network[J]. Frontiers in Neuroscience, 2021, 15: 611653.
- [16] 李景聪, 潘伟健, 林镇远, 等. 采用多路图注意力网络的情绪脑电信号识别方法[J]. 智能系统学报, 2022, 17(3): 531-539.
- [17] 高越, 傅湘玲, 欧阳天雄, 等. 基于时空自适应图卷积神经网络的脑电信号情绪识别[J]. 计算机科学, 2022, 49(4): 30-36.
- [18] ZHENG Weilong, LU Baoliang. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks[J]. IEEE Transactions on Autonomous Mental Development, 2015, 7(3): 162-175.
- [19] ZHANG Y, CHEN J, TAN J H, et al. An investigation of deep learning models for EEG-based emotion recognition[J]. Frontiers in Neuroscience, 2020, 14: 622759.
- [20] 许学添, 蔡跃新. 基于图卷积网络的运动想象识别[J]. 计算机工程与应用, 2022, 58(4): 186-191.
- [21] 张小旭. 基于图卷积神经网络的脑电学习情绪识别研究[D]. 武汉: 华中师范大学, 2022.
- [22] WANG X H, ZHANG T, XU X M, et al. EEG emotion recognition using dynamical graph convolutional neural networks and broad learning system[C]// Proceedings of IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Piscataway, NJ: IEEE, 2018: 1240-1244.
- [23] JIN M, CHEN H, LI Z N, et al. EEG-based emotion recognition using graph convolutional network with learnable electrode relations[C]// Proceedings of 43rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Piscataway, NJ: IEEE, 2021: 5953-5957.