

融合微分熵的高泛化能力脑电情绪识别模型

李争平, 李汉文, 王立军

引用本文

李争平, 李汉文, 王立军. [融合微分熵的高泛化能力脑电情绪识别模型](#)[J]. 计算机科学, 2024, 51(11A): 231200066-7.

LI Zhengping, LI Hanwen, WANG Lijun. [High-generalization Ability EEG Emotion Recognition Model with Differential Entropy](#) [J]. Computer Science, 2024, 51(11A): 231200066-7.

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)

[基于多模态融合的动态恶意软件检测方法](#)

Multimodal Fusion Based Dynamic Malware Detection

计算机科学, 2024, 51(11A): 240200098-7. <https://doi.org/10.11896/jsjcx.240200098>

[基于开放集的入侵检测方法研究](#)

Study on Open Set Based Intrusion Detection Method

计算机科学, 2024, 51(11A): 231000033-6. <https://doi.org/10.11896/jsjcx.231000033>

[基于CNN结合BiGRU的恶意流量分类算法研究](#)

Study on Malicious Traffic Classification Algorithm Based on CNN Combined with BiGRU

计算机科学, 2024, 51(11A): 231100106-9. <https://doi.org/10.11896/jsjcx.231100106>

[基于深度学习智能反射面辅助通信系统的联合波束成形](#)

Deep Learning Based Joint Beamforming in Intelligent Reflecting Surface Enhanced Wireless Communication Systems

计算机科学, 2024, 51(11A): 231200125-5. <https://doi.org/10.11896/jsjcx.231200125>

[基于因果关系的领域泛化长尾学习](#)

Domain Generalization and Long-tailed Learning Based on Causal Relationships

计算机科学, 2024, 51(11A): 240300041-8. <https://doi.org/10.11896/jsjcx.240300041>

融合微分熵的高泛化能力脑电情绪识别模型

李争平 李汉文 王立军

北方工业大学信息学院 北京 100144

(lizp@ncut.edu.cn)

摘要 深度学习的出现,使得脑电信号研究得到进一步发展。常用的基于深度学习对情绪分类的方法有人工神经网络(Artificial Neural Network, ANN)与深度学习(Deep Learning, DL)等。但脑电信号属于有限样本数据,对于深度学习这类需要大量数据驱动训练从而完成分类任务的网络来说,如何在有限的数量下提升分类任务的效果和泛化性能是一个研究重点。针对脑电研究中真实环境对脑电信号的影响以及神经网络模型泛化性问题,充分挖掘脑电信号包含的信息,提出了同时考虑原始脑电信号和 DE 特征的深度学习模型,并设计实验的数据采集过程和处理过程。在 DEAP 数据集、SEED 数据集和实验采集的数据上进行实验,评估所搭建网络的性能效果和泛化能力,探索深度学习网络在脑电信号上的情绪分类关联关系。使用本文构建的网络模型与特征处理办法,在 SEED 数据集的情绪三分类上获得了 85.62% 的准确率,在 DEAP 数据集原始脑电的效价和唤醒两个维度的情绪二分类上分别获得了 59.38% 和 61.70% 的准确率。

关键词: 情绪识别; 情绪分类; 脑电信号; 微分熵(DE); 深度学习

中图分类号 TP183

High-generalization Ability EEG Emotion Recognition Model with Differential Entropy

LI Zhengping, LI Hanwen and WANG Lijun

School of Information, North China University of Technology, Beijing 100144, China

Abstract With the advent of deep learning, the study of EEG signals has been further developed, and the commonly used methods for classification of emotions based on deep learning include artificial neural network(ANN) and deep learning(DL). However, EEG signals are limited sample data, and for networks such as deep learning, which require a large amount of data-driven training to complete classification tasks, how to improve the effect and generalization performance of classification tasks with a limited amount of data is a research focus. In order to solve the problem of the influence of the real environment on the EEG signal and the generalization of the neural network model in EEG research, this paper fully excavates the information contained in the EEG signal, proposes a deep learning model that considers both the original EEG signal and the DE feature, and designs the data acquisition process and processing process of the experiment. Experiments are carried out on DEAP dataset, SEED dataset and experimental data to evaluate the performance effect and generalization ability of the built network, and to explore the correlation between deep learning networks in emotion classification on EEG signals. The network model and feature processing method constructed in this paper obtain an accuracy of 85.62% in the sentiment tri-classification on the SEED dataset. The accuracy of 59.38% and 61.70% is obtained in the emotional binary classification of the two dimensions of valence and arousal of the original EEG on the DEAP dataset, respectively.

Keywords Emotion recognition, Emotion classification, Electroencephalogram (EEG) signals, Differential entropy (DE), Deep learning

1 引言

相比面部特征分析,利用脑电信号特征来分析人的情绪更具准确性。随着深度学习的进步,人们正在采用各种方法来完成这项任务。如何进一步研究人体脑电与情绪的关联关系,成为了脑电信号信息挖掘的关键环节。

大多数研究方法是通过卷积层提取特征信息,将脑电通道赋予不同权重,最后利用卷积神经网络对情绪进行分类等^[1-3],这些方法是从数据的角度出发。但脑电信号属于有限

样本数据,对于深度学习这类需要大量数据驱动训练从而完成分类任务的网络来说,如何在有限的数量下提升分类任务的效果和泛化性能是一个研究的重点。

综合以上研究现状,本文设计了一个用于脑电信号情绪分类的深度学习网络模型。它通过多尺度的卷积核^[4]学习原始脑电信号与相应 DE 特征的多样化特征表示,并重点关注有用的特征,提升了在有限数据下分类任务的效果和泛化性能,能更好地研究脑电信号与情绪的分类关联关系。

基金项目:国家重点研发计划课题(2020YFC0811004)

This work was supported by the National Key R&D Program of China(2020YFC0811004).

通信作者:李汉文(lhw_13171582467@163.com)

2 相关工作

早期利用机器学习的方法分析脑电信号实现情绪识别的模型有 k 最近邻算法^[5] (k -Nearest Neighbour, k -NN)、线性判别分析^[6] (Linear Discriminant Analysis, LDA)、支持向量机^[7] (Support Vector Machine, SVM) 和朴素贝叶斯^[8] (Naive Bayes, NB) 等。为了摆脱特征工程提取特征信息的步骤,应用深度学习神经网络自身的学习能力使脑电信号情绪分类得到进一步发展。

Ahmed 等^[9] 根据脑电信号的时序性进行网络构建,选取了 3 种 LSTM 模型,通过研究网络包含不同的记忆细胞数量和脑电数据的不同分段大小,在效价和唤醒两个维度的四分类任务上进行了实验,实验表明 128 个记忆细胞的 LSTM 网络准确率最高,并得出了数据分段较小时可以得到较高分类准确率的结论。Li 等^[10] 为了充分利用不同通道间的相关信息,将 CNN 和 RNN 进行网络混合,得到了新的深度学习模型,将数据转换为二维的表示形式,从空间的角度提取了不同通道的关联性,从时间的角度联系了上下文信息。Yang 等^[11] 使用 CNN 和 RNN 的混合神经网络,学习原始脑电信号的时间和空间表示,在预处理上采用脑电信号和基线信号相减这一方法得到网络的输入,有效地提高了识别的精度。Tao 等^[12] 在结合卷积神经网络和循环神经网络的基础上添加了通道注意力机制和自注意力机制,组成了基于注意力的卷积循环神经网络 (ACRNN),并分别在 DEAP 和 DREAMER 数据集^[13] 上进行了效价、唤醒和支配维度的分类任务实验,得到了出色的效果。

现有的情绪识别方法虽然有着较为不错的准确率,但大多数都只考虑了单一的特征提取或者仅使用原始脑电的数据作为输入。如 Yang 等^[14] 使用 5 个频带的 DE 特征,Zheng 等^[15] 使用 PSD, DE, DASM 等特征分别进行了分类实验。但是脑电信号属于有限样本数据,对于深度学习这类需要大量数据驱动训练从而完成分类任务的网络来说,如何在有限的数量下提升分类任务的效果和泛化性能是本文研究的重点。

3 实验设计与深度学习模型

3.1 实验设计

实验中,在 DEAP 数据集原始脑电信号上来验证本文所构建的深度学习网络模型的性能。之后为了更好地评估本文所构建的深度学习网络模型并研究脑电信号与情绪的分类关系,进行了脑电信号的采集实验。最后将原始脑电信号与对应的微分熵特征进行结合,并分别在 SEED 数据集、DEAP 数据集和实验采集的数据集上评估了模型的性能。实验流程如图 1 所示。




图 1 实验流程图

Fig. 1 Experimental flowchart

3.2 数据集与数据预处理

3.2.1 数据集

实验采集数据集参考了 SEED 数据集^[16] 的采集办法,设计并实现脑电信号诱发和脑电情绪数据的采集。本实验所使用的电影片段参考了 SEED 数据集并精心挑选了更能诱发相应情绪的电影片段。考虑受试者佩戴电极帽的舒适性会随着时间的增加而减弱,为避免影响脑电信号的采集,电影片段的时间设置为 1 min。实验在一个单独的房间里进行,有柔和的照明,且不会被外界干扰。实验刺激视频显示在被试者前 0.5 m 处。实验开始前,告知被试者在实验过程中尽量避免不必要的动作,减少眨眼次数和吞咽次数。实验使用的脑电采集装置是 Neuroscan 64-256 导脑电采集系统^[17]。实验的采样频率是 1000 Hz,收集 62 个电极通道的脑电信号数据,采集了 10 组包含积极、消极和中性的脑电数据。

在 DEAP 数据集、SEED 数据集和实验采集的数据上进行实验,评估所搭建网络的性能效果和泛化能力,探索深度学习网络在脑电信号上的情绪分类关联关系。

3.2.2 数据预处理

对脑电数据的处理包括预处理和特征融合处理^[18]。预处理主要分为重参考、滤波、降采样、ICA 去除眼电干扰^[19] 等处理步骤。

重参考的目的是根据后续实验的不同任务,选取适当的参考电极以符合实验任务的要求。本实验使用的是 Neuroscan 设备的默认参考电极 REF,故不需要选取参考电极。

滤波的目的是初步确保采集的信号大部分是脑电信号,减少其他无用的高频信号对后续实验效果的干扰。本实验根据需要使用 FIR 滤波器进行 0.5~75 Hz 的带通滤波,进行滤波后的脑电数据对比如图 2 所示。可以明显地看出,脑电信号在进行滤波后的数据表现波形更为清晰,毛刺更少。滤波是分离脑电信号和其他噪声干扰的重要处理步骤,是对后续实验研究的保障。




图 2 滤波前后对比

Fig. 2 Comparison before and after filtering

独立成分分析的作用是利用脑电信号和眼电信号互相独立的特点,通过 ICA 算法对眼电信号进行去除。

本文使用 EEGLAB 对脑电数据进行 ICA 处理,图 3 给出了使用 ICA 对数据进行分解的过程。然后标记 ICA 的不同成分,如图 4 所示,图中红框的部分是明显的眼电干扰,应被去除。

最后,删除相应的伪迹后,所获得的脑电信号前后对比如图 5 所示。可以看出图中的波峰在经过 ICA 处理后变得平滑,这也说明了眼电信号的干扰被去除。

本文对 SEED 和 DEAP 数据集采取相同的预处理方式降采样到 200 Hz,使用了 0~75 Hz 的带通滤波器去除低频和高频噪声,并去除了眼电伪迹。之后对预处理后的脑电数据进行特征融合处理,主要处理流程如图 6 所示。

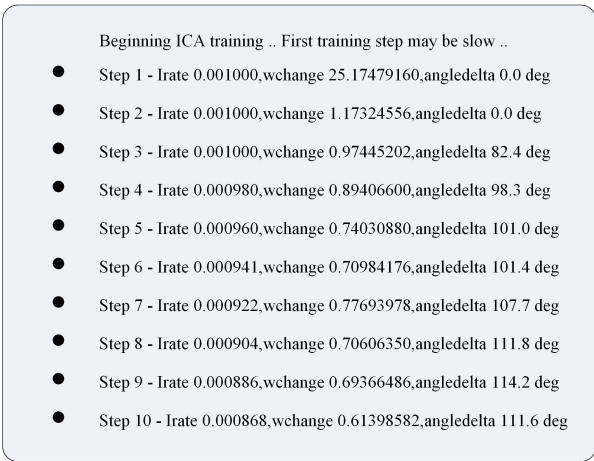


图3 ICA分解过程

Fig. 3 ICA decomposition process

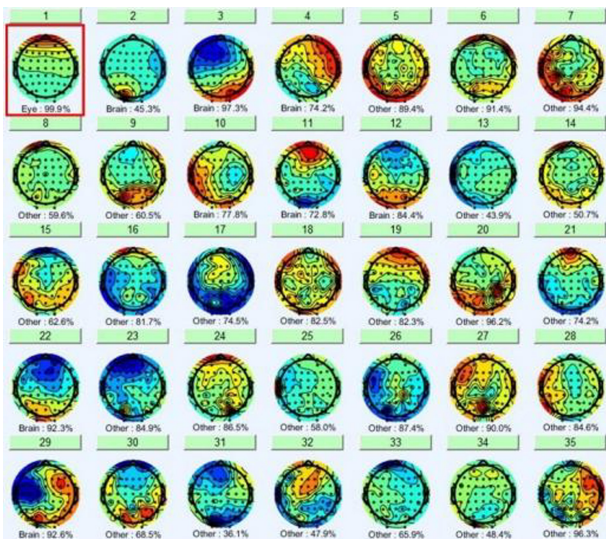


图4 ICA成分

Fig. 4 ICA ingredients




图5 ICA处理前后对比

Fig. 5 Comparison before and after ICA treatment

针对滤波后的脑电信号,提取其5个频带^[20]Delta, Theta, Alpha, Beta, Gamma的微分熵特征。对于各数据集,提取其每200个采样点的DE特征,并和对应的原始脑电信号进行融合,以此作为最终的输入数据。由于采集的是62个通道的电极,因此得到了62×205的输入数据格式。

微分熵是对香农熵思想的拓展,在测量连续随机变量的

复杂度上有较好的应用,对于脑电这类具有低频和低频能量的信号具有区分的平衡能力^[21]。微分熵的原始计算如式(1)所示:

$$h(X) = - \int f(x) \log(f(x)) dx \quad (1)$$

随机变量服从高斯分布 $N(\mu, \sigma^2)$,其微分熵计算如式(2)所示:

$$h(X) = - \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \log\left(\frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)\right) dx$$

$$= \frac{1}{2} \log(2\pi e \sigma^2) \quad (2)$$

之后将原始脑电数据和对应的微分熵特征按行拼接,如式(3)所示:

$$F_{\text{fusion}} = [F_R, F_{DE}] \quad (3)$$

其中, F_R 表示原始脑电数据, F_{DE} 表示微分熵特征, F_{fusion} 表示融合后的数据。

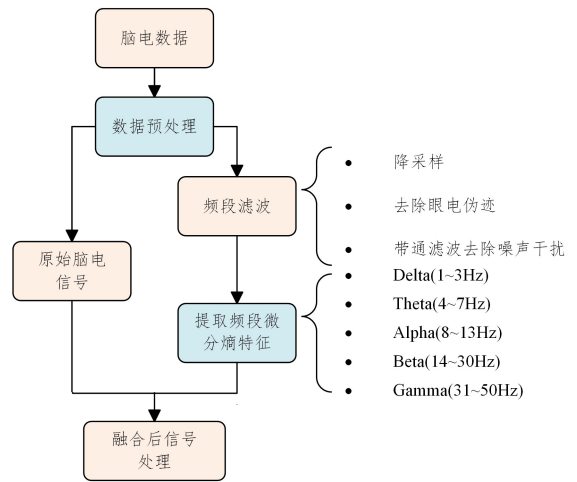


图6 数据处理流程

Fig. 6 Data processing processes

3.3 深度学习模型

本文所构建的网络模型软件借助 Pytorch 框架,硬件GPU为 GTX 1060。此网络模型从时间的角度上重点关注有用的特征,使用多个尺度卷积核学习原始脑电信号和对应DE特征的多样化特征表示。

为进一步判断模型的收敛性,使用交叉熵作为损失函数。如图7所示,迭代50次损失值降为0.14,表示模型已经收敛。模型准确性将会在评价指标中以比较的形式呈现。




图7 Loss曲线变化图

Fig. 7 Loss curve changes

网络模型总体结构如图8所示,包括压缩和激励网络层 (SENet)、动态时间层 (Tception)、瓶颈层 (Bottleneck)、双向长期记忆网络层 (BiLSTM) 和最后的输出层。

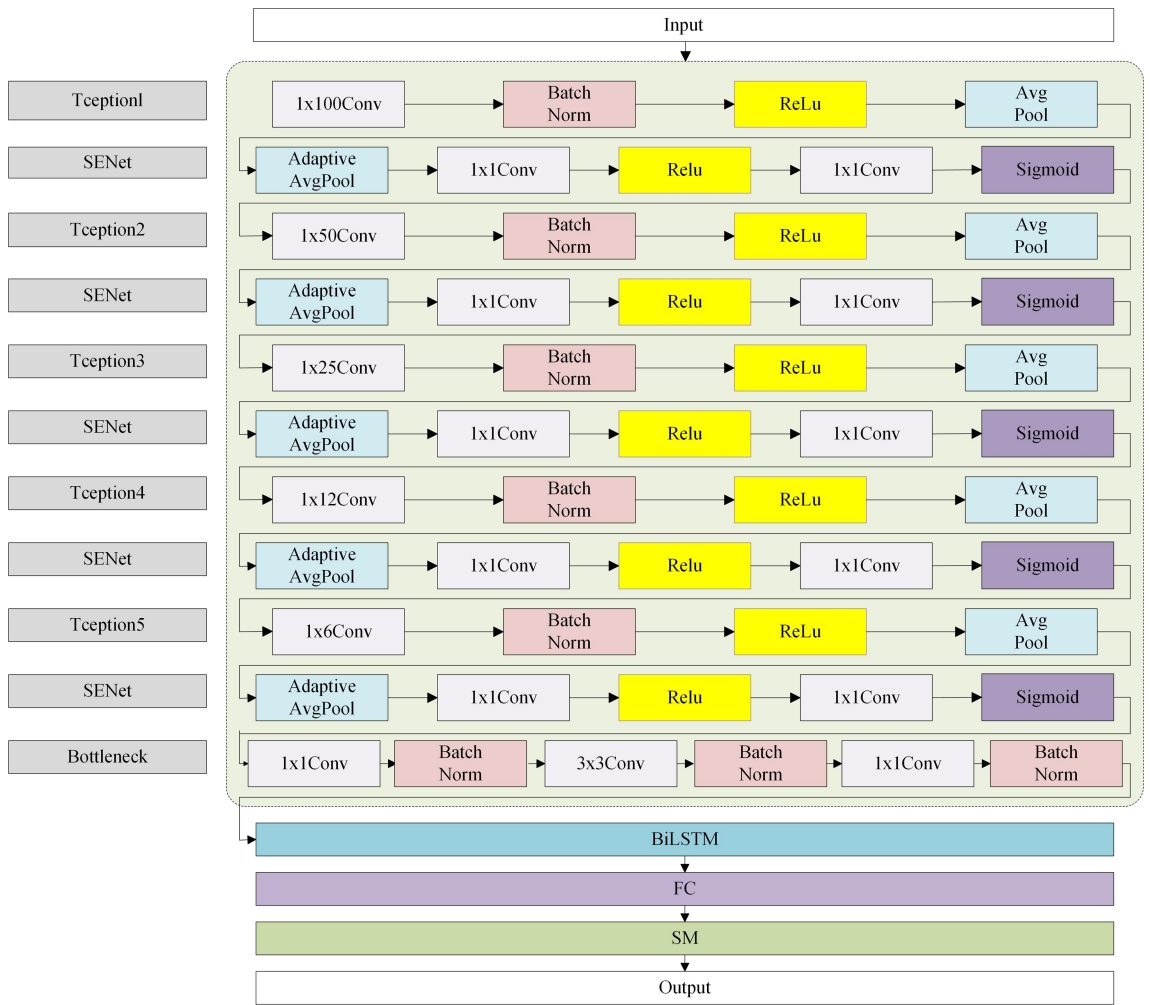


图 8 网络模型总体结构图

Fig. 8 Overall structure diagram of network model

3.3.1 压缩和激励网络层

SENet层是为了得到每个通道的权重信息,即通过自学习的方式,在每次卷积后,使用当前卷积压缩形成的高维特征权重参数来自适应地调整通道的特性响应,对有用的特征赋予较高的权重,对与任务无关的特征加以抑制。

SE模块有两个主要部分^[22],分别是压缩(Squeeze)和激励(Excitation)。压缩的作用是全局平均池化,进行特征压缩。对于任意给定的变换,将输入 X 映射到 U 的特征映射,通过压缩操作来进行特征 U 的传递,如式(4)所示:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_i^H \sum_j^W u_c(i, j) \quad (4)$$

式(4)说明,对 U 进行空间维度($H \times W$)上的压缩,从而得到一个统计量 z_c 。激励的作用是用两个全连接层得到特征图中每个通道的权值,将加权后的特征映射 U 作为下一层网络的输入。这里sigmoid激活函数作为门控机制,如式(5)所示:

$$s = F_{ex}(z_c, W) = \sigma(g(z_c, W)) = \sigma(W_2 \delta(W_1 z_c)) \quad (5)$$

其中, δ 为ReLU函数, $W_1 \in R^{\frac{C}{r} \times C}$, $W_2 \in R^{C \times \frac{C}{r}}$, r 是压缩的比例。先将 C 个通道压缩成 C/r 个通道,再恢复回 C 个通道,经过sigmoid后得到权重 s 。最后在通道维度重新标定原始特征,即将学习到的各个通道的激活值 s_c 乘 U 上的原始特征 u_c ,如式(6)所示:

$$\tilde{x} = F_{scale}(u_c, s_c) = s_c \cdot u_c \quad (6)$$

3.3.2 动态时间层

动态时间层包含多尺度一维卷积核,其是在TSception的动态时间层^[23]基础上扩充到5个不同长度的卷积核,以保证更好地学习动态时间表示。它们的长度与EEG信号^[24]的采样频率 f_s 成特定比值关系。比值系数定义为 $\alpha^i \in R$,其中 i 是动态时间层的层数。多尺度的一维卷积核将根据动态时间层的5个层数,从1到5变化,可以得到5种不同长度的卷积核,其第 i 层的卷积核大小可以定义为:

$$S_T^i = (1, f_s \cdot \alpha^i), i \in [1, 2, 3, 4, 5] \quad (7)$$

其中, $\alpha = 0.5$,比值系数为 $[0.5, 0.25, 0.125, 0.0625, 0.03125]$ 。

多尺度一维卷积核扩展了时间感受野,通过长核学习长时间和低频率的特征表示,短核学习短时间和高频率的特征表示,来实现更多样化的特征表示,从而获得与情绪脑电信号相关的多频率表征。

3.3.3 瓶颈层

瓶颈层结构的作用是降低参数量,结构如图9所示,其中 $a > b$ 。其结构类似沙漏的形状,对数据的操作包括3个步骤:降低数据维度,进行常规卷积,升高数据维度。通过两个 1×1 的滤波器对特征维度进行降低和升高,减小训练的参数量和网络的计算量,而且降维能够让网络模型的训练和特征提取更加直观和充分。




图9 Bottleneck 结构图

Fig.9 Bottleneck structure diagram

3.3.4 双向长短期记忆网络层

长短期记忆网络层 LSTM^[25]是循环神经网络 RNN 的进一步发展和改进,它主要由遗忘门、输入门和输出门组成,结构如图 10 所示。通过对信息的保留和遗忘操作,根据内置权重有选择地更新信息,来改善 RNN 梯度消失的问题。

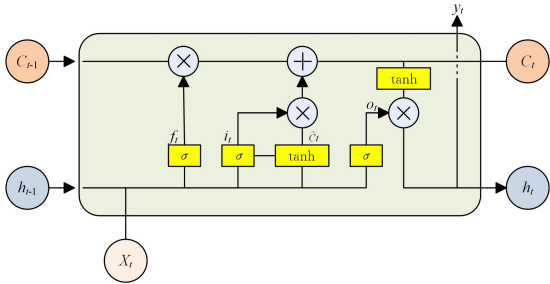


图 10 LSTM 结构图^[25]

Fig.10 LSTM structure diagram^[25]

双向 LSTM 可以对脑电信号这类序列信息进行很好的处理,并且学习在时间序列上前后特征之间的关联性。

3.3.5 输出层

网络模型的分类输出结果依靠全连接层(Fully Connected Layers,FC)和 softmax 完成。全连接层为了得到全局特征,将前面几层获得的特征连接起来。之后在网络判别样本的对应类别时,通过引入 softmax 获得样本判别为对应类别的概率。将其用于归一化全连接层的全局输出操作,输出整个神经网络的最终输出。

3.4 研究细节

针对 Ding 等^[4]所提出的 TSception 多尺度卷积神经网络模型的泛化性提升,本文使用标签平滑这一标签正则化技术,对训练过程进行优化,初始学习率为 1×10^{-3} ,dropout 为 0.5,使用十折交叉验证以防止潜在的数据泄露问题。本实验脑电采集电极的放置使用的是国际 10-20 系统。输入数据包含电极通道共 32 个:FP1,AF3,F3,F7,FC5,FC1,C3,T7,CP5,CP1,P3,P7,PO3,O1,OZ,PZ,FP2,AF4,FZ,F4,F8,FC6,FC2,CZ,C4,T8,CP6,CP2,P4,P8,PO4,O2。

在原始脑电信号与情绪的分类关联关系研究上,首先将中间 4 个电极通道 FZ,CZ,PZ,OZ 去除,将剩下 28 个对称电极通道两两配对,共得到 14 组左右对称电极通道,如表 1 所列。将这 14 组左右对称电极通道的原始脑电信号数据依次作为输入,进行在效价和唤醒两个维度上的脑电情绪分类关联关系研究。

表 1 对称电极

Table 1 Symmetrical electrodes

组别	对称电极	组别	对称电极
1	FP1,FP2	8	T7,T8
2	AF3,AF4	9	CP5,CP6
3	F3,F4	10	CP1,CP2
4	F7,F8	11	P3,P4
5	FC5,FC6	12	P7,P8
6	FC1,FC2	13	PO3,PO4
7	C3,C4	14	O1,O2

然后将这 28 个电极通道按所在左右脑半球分为 2 组,每组各有 14 个电极通道,如表 2 所列。将这 2 组左右半球电极通道的原始脑电信号数据依次作为输入,进行在效价和唤醒两个维度上的脑电情绪分类关联关系研究。

表 2 左右半球电极

Table 2 Left and right hemisphere electrodes

组别	电极
左半球电极	FP1,AF3,F3,F7,FC5,FC1,C3,T7,CP5,CP1,P3,P7,PO3,O1
右半球电极	FP2,AF4,F4,F8,FC6,FC2,C4,T8,CP6,CP2,P4,P8,PO4,O2

4 实验及结果分析

4.1 评价指标

本文将分类准确率作为评价指标,其三分类的定义如式(8)所示:

$$Accuracy = \frac{TPo + TNe + TNu}{Po + Ne + Nu} \quad (8)$$

其中, Po, Ne 和 Nu 表示积极、消极和中性情绪的总样本数, TPo, TNe, TNu 分别代表这 3 种情绪被正确分类的个数。

4.2 参数设置

为了使网络在最佳性能上得到更准确的唤醒度和效价,对网络模型的一些重要参数进行了比较,从中列举了批次大小、优化器选取的参数比较,如图 11 和图 12 所示。




图 11 批次大小

Fig.11 Batch size




图 12 优化器

Fig.12 Optimizer

训练过程采用 Adam 优化器,学习率设置为 0.00008。

Batchsize 大小为 128, Dropout 为 0.7。实验采用早停法以防止过拟合, 设置为 25。采用交叉熵损失作为损失函数来指导训练过程。采用 10 折交叉验证, 训练集与测试集比例为 9:1。

4.3 结果分析

本文所提出的网络模型在 DEAP 数据集^[26]的效价和唤醒两个维度上的情绪分类准确率结果如图 13 所示, 与 TSception 网络的性能对比如表 3 所列。




图 13 每名被试者的分类准确率与均值

Fig. 13 Classification accuracy and mean of each participant

表 3 基于 DEAP 数据集的脑电情绪分类性能

Table 3 EEG emotion classification performance based on DEAP dataset

(%)		
网络模型	效价维度	唤醒维度
TSception 网络	59.14	61.57
本文	59.38	61.70

在 DEAP 数据集的原始脑电信号上进行实验, 本文模型在效价维度上二分类的分类准确率是 59.38%, 在唤醒维度上二分类的分类准确率是 61.70%。与 TSception 网络的结果相比, 本文所提出的网络模型在分类准确率上略有提升。结果说明, 我们所构建的网络模型保证了分类的准确性, 并具有一定的分类性能。

在 SEED 数据集上, 将本文所提出的网络模型与支持向量机 SVM^[27]、组稀疏典型相关分析 GSCCA^[28]、简单循环单元网络 SRU^[29] 和深度置信网络 DBN^[20] 进行了对比, 对比结果如表 4 所列。

表 4 基于 SEED 数据集的脑电情绪分类性能

Table 4 EEG emotion classification performance based on SEED dataset

(%)		
方法	准确率	标准差
SVM	83.99	9.72
GSCCA	82.96	9.95
SRU	83.13	1.67
DBN	86.08	8.34
本文	85.62	1.58

从表 4 中可以得出, 本文构建的网络模型在情绪的三分类上获得了 85.62% 的准确率, 优于非深度学习方法的 SVM, 且准确率提升了 1.63%。SVM 是一个线性分类器, 属于有监督学习算法。线性分类器的数据拟合能力不强, 但深度学习使用神经网络训练任务, 加入了 ReLU 和 tanh 等激活函数, 提升了网络的性能。我们采用的 DE 特征和原始脑电信号结合的方法, 相比于组稀疏典型相关分析的方法准确率提升了 2.66%。GSCCA 是对典型相关性分析 (Canonical Correlation Analysis, CCA) 方法的一种群稀疏扩展, 主要用于

建模脑电图中情感类标签向量和相应脑电特征向量之间的线性关系。本文从原始脑电出发, 结合了其频域的 DE 特征, 考虑到了原始脑电中包含的情绪信息和频域信息。对于深度学习网络 SRU 与 DBN, SRU 网络处理序列问题, 是对 RNN 网络的改进, 和 LSTM 一样能起到解决 RNN 长期依赖问题的作用^[9]。DBN 是一种建立了数据和类别的联合概率分布的概率生成模型, 用于解决神经网络模型的优化问题, 在脑电的研究中重点关注频带和信道。我们的网络模型优于 SRU 网络, 与 DBN 网络的分类准确率接近且标准差更小, 稳定性更好。为了更好地研究脑电信号与情绪的分类关联关系, 根据 SEED 数据集的采集办法, 建立了积极、消极和中性 3 种不同类型的情绪数据集。实验采集到的数据包含 10 组积极、消极和中性的脑电数据。然后进行了效果评估。经过 10 折交叉验证后, 其结果如图 14 所示。




图 14 实验采集数据的准确率

Fig. 14 Accuracy of data collected in experiment

由图 14 可以得出, 实验采集数据的平均准确率是 78.4%, 标准差是 1.9%, 说明本文使用电影片段诱发被试者产生相应情绪的实验是成功的, 我们所进行的脑电情绪诱发实验能够较好地诱导被试者产生特定情绪。实验数据也能够说明脑电信号与情绪在分类上具有一定的关联关系, 同时说明了我们的网络具有较好的泛化性能。

结束语 本文首先使用 DEAP 数据集验证了该网络模型的性能。随后, 与 SVM, GSCCA, SRU 以及 DBN 方法进行了比较, 结果显示本文方法的分类准确率超过前 3 种方法, 且接近 DBN 的结果。为进一步评估效果, 实验收集了 10 组关于积极、消极和中性情绪的脑电信号, 并将其输入本文的网络模型。结果显示, 本文的网络表现出良好的分类性能和泛化性能, 实验证明了不同情绪类别与相应脑电信号之间存在一定的关联关系, 考虑原始脑电信号和 DE 特征的深度学习模型能够提高网络模型的性能和泛化性能。

参考文献

- [1] KAMBLE K, SENGUPTA J. A comprehensive survey on emotion recognition based on electroencephalograph (EEG) signals [J]. Multimedia Tools and Applications, 2023, 82: 1-36.
- [2] PATLAR AKBULUT F. Hybrid deep convolutional model-based emotion recognition using multiple physiological signals [J]. Computer Methods in Biomechanics and Biomedical Engineering, 2022, 25(15): 1678-1690.
- [3] YUVARAJ R, THAGAVEL P, THOMAS J, et al. Comprehensive Analysis of Feature Extraction Methods for Emotion Recognition from Multichannel EEG Recordings [J]. Sensors, 2023, 23(2): 915.
- [4] DING Y, ROBINSON N, ZHANG S, et al. TSception: Capturing temporal dynamics and spatial asymmetry from EEG for emo-

- tion recognition[J]. *IEEE Transactions on Affective Computing*, 2023, 14(3):1-13.
- [5] CUNNINGHAM P, DELANY S J. k-Nearest neighbour classifiers-A Tutorial[J]. *ACM computing surveys (CSUR)*, 2021, 54(6):1-25.
- [6] THARWAT A, GABER T, IBRAHIM A, et al. Linear discriminant analysis: A detailed tutorial[J]. *AI Communications*, 2017, 30(2):169-190.
- [7] NOBLEW S. What is a support vector machine? [J]. *Nature Biotechnology*, 2006, 24(12):1565-1567.
- [8] RISHI. An empirical study of the naive Bayes classifier[C]// *Workshop on Empirical Methods in Artificial Intelligence (IJCAI 2001)*. 2001:41-46.
- [9] AHMED M Z I, SINHA N. EEG-based emotion classification using LSTM under new paradigm[J]. *Biomedical Physics & Engineering Express*, 2021, 7(6):065018.
- [10] LI X, SONG D, ZHANG P, et al. Emotion recognition from multi-channel EEG data through convolutional recurrent neural network[C]// *2016 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*. IEEE, 2016:352-359.
- [11] YANG Y, WU Q, QIU M, et al. Emotion recognition from multi-channel EEG through parallel convolutional recurrent neural network [C] // *2018 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2018:1-7.
- [12] TAO W, LI C, SONG R, et al. EEG-based emotion recognition via channel-wise attention and self attention[J]. *IEEE Transactions on Affective Computing*, 2023, 14(1):382-393.
- [13] WANG F, ZHONG S, PENG J, et al. Data augmentation for EEG-based emotion recognition with deep convolutional neural networks[C]// *MultiMedia Modeling: 24th International Conference (MMM 2018)*. Bangkok, Thailand, Part II 24. Springer International Publishing, 2018:82-93.
- [14] YANG Y, WU Q, QIN M, et al. Emotion recognition from multi-channel EEG through parallel convolutional recurrent neural network [C] // *2018 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2018:1-7.
- [15] ZHENG W L, LUB L. 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.
- [16] ULLAH I, HUSSAIN M, ABOALSAMH H. An automated system for epilepsy detection using EEG brain signals based on deep learning approach[J]. *Expert Systems with Applications*, 2018, 107:61-71.
- [17] BIGDELY-SHAMLO N, TOURYAN J, OJEDA A, et al. Automated EEG mega-analysis I: Spectral and amplitude characteristics across studies[J]. *NeuroImage*, 2020, 207:116361.
- [18] WANG X Q. Emotion recognition based on multiple features of EEG signals[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020.
- [19] LI J Q, LI H F, BAI Y F, et al. Research on Automatic Identification and Removal Method of Ocular Electrographic Artifacts in EEG Signals[J]. *Computer Engineering and Applications*, 2018, 54(13):148-152, 167.
- [20] YANG Y, WU Q M J, ZHENG W L, et al. EEG-based emotion recognition using hierarchical network with subnetwork nodes [J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2017, 10(2):408-419.
- [21] ZHENG W L, LU B L. 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.
- [22] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-Excitation Networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 42(8):1-1.
- [23] DING Y, ROBINSON N, ZHANG S, et al. Tsception: Capturing temporal dynamics and spatial asymmetry from EEG for emotion recognition [J]. *IEEE Transactions on Affective Computing*, 2023, 14(3):2238-2250.
- [24] PAN C, SHI C, MU H, et al. EEG-based emotion recognition using logistic regression with Gaussian kernel and Laplacian prior and investigation of critical frequency bands[J]. *Applied Sciences*, 2020, 10(5):1619.
- [25] MAHADEVASWAMY U B, SWATHI P. Sentiment analysis using bidirectional LSTM network[J]. *Procedia Computer Science*, 2023, 218:45-56.
- [26] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018:7132-7141.
- [27] JAKKULA V. Tutorial on support vector machine (svm) [J]. *School of EECS, Washington State University*, 2006, 37(2.5):3.
- [28] ZHENG W. Multichannel EEG-based emotion recognition via group sparse canonical correlation analysis [J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2016, 9(3):281-290.
- [29] WEI C, CHEN L, SONG Z, et al. EEG-based emotion recognition using simple recurrent units network and ensemble learning [J]. *Biomedical Signal Processing and Control*, 2020, 58:101756.



LI Zhengping, born in 1975, Ph.D, associate professor. His main research interests include media access control technology, wireless positioning technology and the application of virtual reality in medical rescue.



LI Hanwen, born in 2000, postgraduate. His main research interests include deep learning, emotion recognition and analog storage and computing integrated chip design.