

基于3D特征融合与轻量化CNN的情绪EEG识别

陈紫扬, 随力, 胡磊

(上海理工大学健康科学与工程学院, 上海 200093)

摘要: 情绪变化可引起头皮脑电信号的改变, 基于脑电信号的情绪识别是近年来情绪研究的一个重要方向。为此, 提出一种基于3D特征融合与轻量化卷积神经网络的情绪EEG识别方法, 使用2s窗口的3D特征图作为输入, 并根据效价和唤醒提供情绪状态作为输出。在DEAP公开数据集上对所提方法进行受试者依赖实验, 结果表明情绪识别性能评估效价和唤醒识别准确率分别为 $(97.08 \pm 0.32)\%$ 和 $(96.78 \pm 0.34)\%$ 。所提方法具有较高的情绪识别准确度和较低的计算复杂度, 适用于实际场景中的情绪识别。

关键词: 情绪识别; 卷积神经网络; 脑电信号; 特征融合; 轻量化模型

DOI: 10.11907/rjdk.231510

开放科学(资源服务)标识码(OSID):



中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2024)006-0038-06

EEG Emotion Recognition Based on 3D Feature Fusion and Lightweight CNN

CHEN Ziyang, SUI Li, HU Lei

(School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Emotional changes can cause changes in scalp EEG signals, and emotion recognition based on EEG signals has become an important direction in emotional research in recent years. To this end, a sentiment EEG recognition method based on 3D feature fusion and lightweight convolutional neural network is proposed, using a 2D window 3D feature map as input and providing emotional states as output based on valence and arousal. A subject dependent experiment was conducted on the DEAP public dataset, and the results showed that the evaluation validity of emotion recognition performance and the accuracy of wake-up recognition were $(97.08 \pm 0.32)\%$ and $(96.78 \pm 0.34)\%$, respectively. The proposed method has high accuracy in emotion recognition and low computational complexity, making it suitable for emotion recognition in practical scenarios.

Key Words: emotion recognition; convolutional neural networks; EEG signals; feature fusion; lightweight model

0 引言

情绪是人类思维、情感与行动的结合, 在社会技能获取和世界感知中起到了重要作用。随着人工智能的发展, 情感计算得到了广泛研究, 并衍生出许多应用, 如犯罪检测、残疾人辅助等^[1]。此外, 情绪识别在人机交互领域的应用也越来越广泛, 其可使机器以更像人类的方式工作。然而, 如何准确识别人类的情绪状态仍然是一个开放问题。目前, 用于检测情绪状态的信号主要分为两类: ①外

部行为信号, 如语音、文字、面部表情^[2]; ②内部生理信号, 如头皮脑电信号(Electroencephalography, EEG)、皮肤电反应等。这两类信号都具有突出的人类情绪特征, 但外部行为信号容易受到参与者的主观影响, 即参与者可以故意隐瞒自己的情绪。EEG是大脑活动产生的电位改变, 蕴含了脑情绪状态的变化信息^[3], 相较情绪的言语表达信号和面部信号更为客观和可靠^[4]。近年来, 深度学习算法已广泛应用于情绪EEG的识别中, 但以往研究主要集中在提高情绪EEG识别准确率方面, 没有考虑到模型的轻量化, 这限制了其在真实场景中的应用。因此, 设计一种轻量化的基

收稿日期: 2023-05-17

基金项目: 上海理工大学科技发展项目(2019KJFZ239, 2020KJFZ232)

作者简介: 陈紫扬(1998-), 女, 上海理工大学健康科学与工程学院硕士研究生, 研究方向为脑电信号处理; 随力(1970-), 女, 博士, 上海理工大学健康科学与工程学院教授、博士生导师, 研究方向为神经工程; 胡磊(1996-), 男, 上海理工大学健康科学与工程学院硕士研究生, 研究方向为医学信号处理。本文通讯作者: 随力。

于深度学习的情绪EEG识别算法具有重要现实意义。

1 相关研究

目前,基于EEG的情绪识别研究主要集中在特征提取与分类模型构建方面。在特征提取方面,Duan等^[5]提出一种基于单通道EEG的微分熵(Differential Entropy, DE)进行特征提取,在情绪识别任务中取得了良好效果;Zheng等^[6]将DE和功率谱密度(Power Spectral Density, PSD)特征输入多模态深度神经网络识别人类情绪,对快乐、悲伤、恐惧和中性4种情绪的最佳平均准确率达到85.11%;陈景霞等^[7]提取了6个频带的PSD特征,并将其按照大脑电极位置分布转换为 9×9 矩阵,实验结果表明,相较于目前较优的人工特征方法,该方法对情绪的平均分类准确率有一定提高。然而,以上特征提取方法存在一些局限性。例如,有些方法只能反映单一EEG通道的神经活动,忽略了EEG通道之间的空间信息;有些方法只使用单一特征作为输入,忽略了特征融合。因此,在选择特征提取方法时需要综合考虑多个方面的因素,以充分利用EEG数据中包含的信息,提高分类或预测任务的准确性。

在分类模型构建方面,作为目前最成功的判别型深度模型之一,卷积神经网络(Convolutional Neural Networks, CNN)已被广泛应用于情绪EEG识别中。例如,Li等^[8]提出分层CNN,其识别效果超过堆叠式自动编码器、支持向量机以及K最近邻算法;Yang等^[9]将CNN与循环神经网络(Recurrent Neural Network, RNN)并行处理应用于情绪EEG识别中,其中CNN用于挖掘通道间相关性,LSTM用于挖掘上下文信息;张静等^[10]将CNN与注意力机制相结合用于情绪识别,其中注意力机制根据情绪状态在特定时刻出现峰值时为特征分配权重;Song等^[11]基于动态图CNN模型学习EEG通道之间的关系。尽管以上方法获得了不错的识别准确率,但忽略了模型轻量化的重要性,导致其计算复杂度较高且在实时性方面表现不佳。

为提高单模态EEG数据的情绪识别准确率并兼顾模型轻量化与实时性需求,本文提出一种基于PSD与DE特征融合的轻量化CNN模型。与现有方法相比,该模型不仅可以充分利用EEG通道间的空间信息,而且可以对多种特征进行有效融合。同时,轻量化设计使该模型在实际应用方面表现更加优秀。


2 模型构建

2.1 情绪EEG数据集与预处理

DEAP是一个多通道情绪数据集,被广泛用于分析人类的情绪状态,其包括32名受试者的情绪EEG数据^[12]。当受试者观看40个1 min长的音乐电影片段节选时,采用一个32通道的电极帽以512 Hz的采样率记录受试者的


EEG。测试人员从每名受试者身上收集了63 s的生理信号,包括在没有接受情绪刺激状态下产生的3 s基线信号和接受刺激状态下产生的60 s实验信号。在数据预处理过程中,原始EEG被下采样为128 Hz并去除眼动伪影。

在DEAP中,效价和唤醒被用于表达人类的情绪状态。每名受试者在每次试验后都被要求填写一份自我评估表,在1~9的连续值范围内进行评分。在由效价和唤醒组成的二维情绪模型中,效价维度代表不愉快到愉快,而唤醒维度的心理状态为从不活跃到活跃^[13]。该情绪模型结构如图1(a)所示。考虑到情绪的模糊边界与受试者的评分差异,本研究放弃效价和唤醒评分在4.8~5.2之间的EEG数据,以确保受试者情绪评分的准确性。根据情绪模型对EEG数据重新标注标签,如图1(b)所示,LV被定义为低效价(评分<4.8),HV被定义为高效价(评分>4.8),LA被定义为低唤醒(评分<4.8),HA被定义为高唤醒(评分>4.8)。同时,为了增加数据量,使用2 s非重叠窗口将60 s实验信号划分成30个不重叠的片段作为新样本,并为每个样本分配原始试验的标签。



(a) Two dimensions emotion model

(a) 两维情感模型



(b) Label setting rules

(b) 标签设置规则

Fig. 1 Emotion model based on valence and arousal

图1 基于效价与唤醒的情绪模型

2.2 特征提取

以前研究表明,PSD特征和DE特征对于情绪EEG识别是有效的^[14-15]。PSD指单位时间内的频谱能量分布,描述了一个信号或时间序列相对于频率的功率分布,是频域

中最常用的特征之一^[16];DE特征对连续性随机变量概率分布的不确定性总量进行具体量化,可以测量信号的复杂度^[5]。因此,本研究选择PSD和DE作为特征输入到所提模型中。

使用快速傅里叶变换(Fast Fourier Transform, FFT)提取每个样本的PSD特征。FFT将信号从原始域(通常是时间或空间)转换到频域进行表示。转换公式为:

$$X_k = \sum_{n=0}^{N-1} x_i(n) e^{-\frac{j2\pi nk}{N}}, k = 0, 1, \dots, N-1 \quad (1)$$

式中: $x_i(n)$ 表示原始域输入信号, N 为数据长度。

在提取DE特征时,首先使用Butterworth滤波器提取每个样本的4个频段(Theta: 4~8 Hz, Alpha: 8~14 Hz, Beta: 14~31 Hz, Gamma: 31~45 Hz);然后应用以下公式从每个EEG样本的4个频段信号中提取相应特征。DE的计算公式为:

$$DE(X) = -\int_{-\infty}^{\infty} f(X) \log(f(x)) dx \quad (2)$$

式中: X 为服从高斯分布 $N(\mu, \sigma^2)$ 的随机变量,其对应的概率密度函数为 $f(x)$ 。将 $f(x)$ 代入式(2),因此DE可以表示为:

$$DE(X) = -\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \log\left(\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}\right) dx = \frac{1}{2} \log 2\pi e \sigma^2 \quad (3)$$

对于固定长度的信号序列 i ,Shi等^[17]研究表明,DE的公式可以简化为:

$$DE_i(X) = \frac{1}{2} \log 2\pi e \sigma_i^2 \quad (4)$$

式中: σ_i^2 表示信号序列 i 的方差。

EEG在不同人群之间存在显著差异,即对于相同的刺激因素,个体的主观情绪体验也会有所不同。通过计算实验信号与基线信号之间的差异可以减少个体差异对情绪EEG识别结果的影响,更好地区分情绪状态以实现准确识别。首先计算2 s长的基线信号特征 PSD_{Base} 和 DE_{Base} ,然后在实验信号特征中减去基线信号特征。计算公式为:

$$PSD_{Removed} = PSD_{Raw} - PSD_{Base} \quad (5)$$

$$DE_{Removed} = DE_{Raw} - DE_{Base} \quad (6)$$

2.3 3D特征图构建

为保留电极位置的空间结构信息,将从EEG中提取的4个频段的PSD和DE特征向量按照国际10-20体系映射成 9×9 的特征矩阵,其中无电极位置的地方被填充为0。将不同频段的二维特征矩阵堆叠成一个三维特征图,以便各个频带的信息能够相互结合。

3D特征图制作流程如图2所示。每个3D特征图会被作为模型输入,其高度 $h=9$,宽度 $w=9$,深度 $d=8$ 。这种处理方法有助于高效捕捉不同电极之间的时空关系,更好地表征EEG的空间分布特征,并提高模型的预测准确性。




Fig. 2 Flow of 3D feature map production

图2 3D特征图制作流程

3D特征图与样本标签相对应,最终效价构建了32 700个标签,唤醒构建了33 540个标签,具体如表1所示。在将特征提供给分类器之前,使用 z 分数归一化法将数据缩放至零均值和单位方差以对特征进行归一化。

2.4 轻量化CNN

轻量化CNN整体架构如图3所示。首先将形状为 $(8, 9, 9)$ 的3D特征图输入到4个二维卷积块进行特征提取;然后将所提取的深度特征展平输入到全连接层中进行分类。

Table 1 Sample label information

表1 样本标签信息

标签	样本数量	标签	样本数量
HV	17 940	HA	192 90
LV	14 760	LA	14250
总计	32 700	总计	33 540

具体来说,第1个卷积块采用64个滤波器,每个滤波器大小为 5×5 ;接下来的2个卷积块分别采用128个和256个滤

波器, 每个滤波器大小为 4×4 ; 第4个卷积块包含了64个滤波器, 使用 1×1 的滤波器实现降维的作用。在每个卷积块中使用Dropout和Batch Normalization以防止模型过拟合, 激活函数为ReLU。在第4个卷积运算后使用一个大小为 2×2 的最大池化层进行下采样, 以缓解过拟合并增强网络的稳健性; 最后, 分类层使用sigmoid函数输出分类主体的效价水平和唤醒水平。




Fig. 3 Overall structure of the lightweight CNN

图3 轻量化CNN整体架构

3 实验方法与结果分析

3.1 实验环境


本文实验基于Windows10操作系统展开, 使用的深度学习框架为PyTorch 1.12.0, Python版本为3.7.0, CPU为Intel® Core™ i5, GPU为NVIDIA GeForce GTX 1060。

3.2 模型性能评估

为了更有效地利用有限的的数据, 同时确保评估结果尽可能接近模型的真实表现, 采用五折交叉验证法评估模型性能。为避免模型过度拟合, 将初始学习率设置为 $1e-3$, 并根据验证损失自动进行调整; 将衰减率设置为0.5, 并在验证损失连续不下降次数达到10次时提前停止训练。以第一折为例, 本文模型训练与验证损失曲线如图4所示, 准确率曲线如图5所示。


3.3 一维特征与3D特征图结果比较

为证明将频率与空间信息结合起来能够产生更好的效果, 以下进行两组实验, 分别使用一维特征和3D特征图作为模型输入。其中, 一维特征的输入形状为 $(2, 32 \times 4)$,



(a) Loss curve of valence

(a) 效价损失曲线



(b) Loss curve of arousal

(b) 唤醒损失曲线

Fig. 4 Training and validation loss curve of one-fold

图4 第一折的训练集和验证集损失曲线

3D特征图的输入形状为 $(8, 9, 9)$ 。实验结果如表2所示。可以看出, 在效价和唤醒维度上, 使用3D特征图取得了更好的识别结果, 尤其是在唤醒维度方面, 使用3D特征图的识别准确率比使用一维特征时高出了5.68%。

3.4 特征融合结果比较

为证明特征融合对模型识别性能的提升作用, 分别采用PSD、DE以及二者的融合(PSD + DE)作为特征进行模型识别性能比较。实验结果见图6。可以看出, PSD+DE融合特征比仅使用单个特征学习到的信息更多, 更能提高模型对EEG情绪识别的准确率。

3.5 模型参数量比较

为满足真实场景中的应用需求, 模型应使用尽量少的参数实现情绪EEG的准确识别。ResNet和VGG系列模型在图像分类任务上取得了不错的效果, 但它们往往具有较大的模型参数量。为此, 以参数量、总运行时间和作为评价指标, 分别使用ResNet-18、VGG-12模型与所提轻量级CNN模型进行比较实验, 结果如表3所示。为确保比较的公平性, 模型使用相同的超参数设置。可以看出, 与ResNet-18、VGG-12模型相比, 所提出模型具有最少的参




Fig. 5 Training and validation accuracy curve of one-fold

图5 第一折的训练集和验证集准确率曲线

数量,且使用相对较短的总运行时间取得了最佳效价和唤醒分类准确率。

Table 2 Comparison of recognition results between one-dimensional feature maps and 3D feature maps

表2 一维特征和3D特征图识别结果比较 (%)

结果	一维特征		3D特征图	
	效价	唤醒	效价	唤醒
第一折	92.84	90.83	96.76	96.87
第二折	93.00	90.59	97.13	96.75
第三折	93.04	91.01	97.00	96.97
第四折	92.65	91.34	97.31	96.88
第五折	93.15	91.74	97.20	96.44
平均值	92.94	91.10	97.08	96.78




Fig. 6 Comparison of recognition results for different input features

图6 不同输入特征识别结果比较

Table 3 Comparison of the number of parameters, total running time and classification results of different models

表3 不同模型参数量、总运行时间和分类结果比较

模型	参数量/M	总运行时间/s	准确率/%	
			效价	唤醒
ResNet-18	19.6	1 416	92.47	91.88
VGG-12	6.8	391	94.35	94.03
本文模型	1.7	723	97.08	96.78

3.6 与其他方法比较

本文选择同样基于DEAP数据集进行实验的文献[7][9][18][19][20][21][22]模型作为对照,与本文模型进行识别性能比较,结果见表4。可以看出,本文模型平均效价准确率为(97.08±0.32)%,平均唤醒准确率为(96.78±0.34)%,均优于对照模型。这是由于其不仅利用了EEG的频率信息,而且充分利用了EEG的空间分布特征。

Table 4 Comparison of recognition results for different methods on DEAP dataset

表4 不同方法在DEAP数据集上的识别结果比较

方法	特征	分类模型	准确率/%	
			效价	唤醒
文献[18]方法	—	CNN	71.18	70.08
文献[7]方法	3D-PSD	CNN	87.32	85.88
文献[19]方法	DE	CNN-LSTM	87.60	88.58
文献[20]方法	3D-DE	CNN-SAE	89.49	90.76
文献[21]方法	DE	GCNN-LSTM	90.45	90.60
文献[22]方法	3D-DE-FC	GCNN	95.70	95.04
文献[9]方法	4D-DE	3D-CNN	95.87	95.23
本文方法	3D-PSD-DE	CNN	97.08	96.78

4 结语

本文提出一种基于3D特征融合与轻量化CNN模型的情绪EEG识别方法,通过提取EEG的DE特征和PSD特征获取频域信息和空间信息,不仅取得了较高的效价和唤醒准确率,而且模型参数量较小,实时性有一定提高。然而本研究属于被试者依赖型,由于EEG在不同个体间存在较大差异,而本文方法试验样本量不足,普适性有待提高。未来将从迁移学习和域自适应的角度扩大方法的适用范围,以解决跨被试的情绪EEG识别问题。

参考文献:

- [1] MA K, SONG Y Z. How does emotional computing technology promote the development of crime risk assessment tools? [J]. Journal of Psychological Science, 2021(1): 52-59.
马皑,宋业臻.情感计算技术如何推动犯罪风险评估工具的发展?[J].心理科学,2021(1):52-59.
- [2] ZHANG K L, LIU T T, LIU Z, et al. Multimodal human-computer interactive technology for emotion regulation [J]. Journal of Image and Graphics, 2020, 25(11): 2451-2464.
张凯乐,刘婷婷,刘箴,等.面向情绪调节的多模态人机交互技术[J].中国图象图形学报,2020,25(11):2451-2464.
- [3] IETRICH A, KANSO R. A review of EEG, ERP, and neuroimaging studies of creativity and insight [J]. Psychological Bulletin, 2010, 136(5): 822-848.
- [4] AHERN G L, SCHWARTZ G E. Differential lateralization for positive and negative emotion in the human brain: EEG spectral analysis [J]. Neuropsychologia, 1985, 23(6): 745-755.
- [5] DUAN R N, ZHU J Y, LU B L. Differential entropy feature for EEG-based emotion classification [C]//2013 6th International IEEE/EMBS Conference on Neural Engineering, 2013: 81-84.
- [6] ZHENG W L, LIU W, LU Y, et al. EmotionMeter: a multimodal framework for recognizing human emotions [J]. IEEE Transactions on Cybernetics, 2019, 49(3): 1110-1122.
- [7] CHEN J X, MIN C D, LIN W T, et al. Emotion recognition of EEG signal based on 3D matrix features and multi-dimensional convolutional network [J]. Journal of Shaanxi University of Science & Technology, 2022, 40(2): 178-186.
陈景霞,闵重丹,林文涛,等.基于3D矩阵特征与多维卷积网络的脑电信号情感识别[J].陕西科技大学学报,2022,40(2):178-186.
- [8] LI J P, ZHANG Z X, HE H G. Hierarchical convolutional neural networks for EEG-based emotion recognition [J]. Cognitive Computation, 2017, 10(2): 368-380.
- [9] YANG Y L, WU Q F, QIU M, et al. Emotion recognition from multi-channel EEG through parallel convolutional recurrent neural network [C]//2018 International Joint Conference on Neural Networks, 2018: 1-7.
- [10] ZHANG J, ZHANG X Y, CHEN G J, et al. EEG emotion recognition based on the 3D-CNN and spatial-frequency attention mechanism [J]. Journal of Xidian University, 2022(3): 191-198, 205.
张静,张雪英,陈桂军,等.结合3D-CNN和频-空注意力机制的EEG情感识别[J].西安电子科技大学学报,2022(3):191-198,205.
- [11] SONG T, ZHENG W, SONG P, et al. EEG emotion recognition using dynamical graph convolutional neural networks [J]. IEEE Transactions on Affective Computing, 2018, 11(3): 532-541.
- [12] KOELSTRA S, MUHL C, SOLEYMANI M, et al. DEAP: a database for emotion analysis; Using physiological signals [J]. IEEE Transactions on Affective Computing, 2012, 3: 18-31.
- [13] RUSSELL J A. A circumplex model of affect [J]. Journal of Personality and Social Psychology, 1980, 39(6): 1161-1178.
- [14] DAI Z Y, MA Y L, GAO Y Y, et al. A multi-scale convolutional kernel CNN for EEG emotion recognition [J]. Chinese Journal of Sensors and Actuators, 2021, 34(4): 496-503.
戴紫玉,马玉良,高云园,等.基于多尺度卷积核CNN的脑电情绪识别[J].传感技术学报,2021,34(4):496-503.
- [15] LIANG M J, WANG L, WEN X, et al. EEG emotion classification based on multi-feature fusion [J]. Computer Engineering and Applications, 2023, 59(5): 155-159.
梁晶晶,王璐,温昕,等.多特征融合的脑电情绪分类[J].计算机工程与应用,2023,59(5):155-159.
- [16] PARTHANA S, SHOVAN B. Emotion recognition by distinguishing appropriate EEG segments based on random matrix theory [J]. Biomedical Signal Processing and Control, 2021, 70: 102991.
- [17] SHI L C, JIAO Y Y, LU B L. Differential entropy feature for EEG-based vigilance estimation [C]//35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2013: 6627-6630.
- [18] WANG C, HU J Z, LIU K, et al. An emotion recognition method based on EEG channel enhancement [J]. Journal of Northwest University (Natural Science Edition), 2022, 52(4): 560-570.
王晨,胡景钊,刘科,等.基于脑电通道增强的情绪识别方法[J].西北大学学报(自然科学版),2022,52(4):560-570.
- [19] MENG M, HU J H, GAO Y Y, et al. EEG emotion recognition based on normalized mutual information channel selection and hybrid deep neural network [J]. Chinese Journal of Sensors and Actuators, 2021, 34(8): 1089-1095.
孟明,胡家豪,高云园,等.结合互信息通道选择与混合深度神经网络的脑电情感识别方法[J].传感技术学报,2021,34(8):1089-1095.
- [20] AN Y, HU S, DUAN X, et al. Electroencephalogram emotion recognition based on 3D feature fusion and convolutional autoencoder [J]. Frontiers in Computational Neuroscience, 2021, 15: 743426.
- [21] YIN Y Q, ZHENG X W, HU B, et al. EEG emotion recognition using fusion model of graph convolutional neural networks and LSTM [J]. Applied Soft Computing, 2021, 100: 106954.
- [22] LI Z, ZHANG G, WANG L, et al. Emotion recognition using spatial-temporal EEG features through convolutional graph attention network [J]. Journal of Neural Engineering, 2023, 20(1): 016046.

(责任编辑:尹晨茹)