

DOI:10.19651/j.cnki.emt.2108357

基于卷积神经网络的脑电信号情绪分类方法^{*}

张学军^{1,2} 陈都¹ 孙知信^{3,4}

(1.南京邮电大学电子与光学工程学院 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; 3.南京邮电大学江苏省邮政大数据技术与应用工程研究中心 南京 210003;
4.南京邮电大学国家邮政局邮政行业技术研发中心(物联网技术)南京 210003)

摘要: 情绪作为人脑的高级功能,对人们的心理健康和个性特征有很大的影响。通过对脑电情绪数据集进行情绪分类,能够为今后实时监控正常人或抑郁病人的情绪提供进一步理论及实践依据。因此文章运用公开的脑电情绪数据集所提取的微分熵特征,并使用传统的滑动平均和线性动态系统方法,采用深度学习中的卷积神经网络作为基本前提,设计了一个卷积神经网络的脑电信号情绪分类模型,其包括4个卷积层、4个最大池化层、2个全连接层和1个Softmax层,并采用批归一化使参数搜索问题变容易,抑制模型过拟合。实验结果表明,利用该模型对SEED数据集的3种情绪识别的平均准确率达到了98.73%,精确率、召回率和F1分数分别为99.69%、98.12%和98.86%,ROC曲线下面积达0.998。与最近的类似工作相比,该文提出的卷积神经网络结构对于脑电信号情绪分类具有一定优越性。

关键词: 脑电信号;情绪识别;深度学习;卷积神经网络

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 510.40

Emotion classification method of EEG signal based on convolutional neural network

Zhang Xuejun^{1,2} Chen Du¹ Sun Zhixin^{3,4}

(1. School of Electronic and Optical Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210023, China;
2. Nation-Local Joint Project Engineering Lab of RF Integration & Micropackage, Nanjing University of Posts and Telecommunications, Nanjing 210023, China; 3. Post Big Data Technology and Application Engineering Research Center of Jiangsu Province, Nanjing University of Posts and Telecommunications, Nanjing 210003, China; 4. Post Industry Technology Research and Development Center of the State Posts Bureau (Internet of Things Technology), Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: As an advanced function of the human brain, emotion has a great impact on people's mental health and personality characteristics. The classification of EEG emotion data sets can provide further theoretical and practical basis for real-time monitoring of normal and depressed patients' emotions in the future. The article uses the differential entropy features extracted from the public EEG emotion data set, and uses traditional moving average and linear dynamic system methods. Using the convolutional neural network in deep learning as the basic premise, a convolutional neural network's EEG signal emotion classification model is designed, which includes 4 convolutional layers, 4 maximum pooling layers, 2 fully connected layers, and 1 A Softmax layer, and batch normalization is used to make the parameter search problem easier and suppress the model over-fitting. The experimental results show that the average accuracy of the three emotion recognition of the SEED data set using this model reached 98.73%, the precision, recall and F1 score were 99.69%, 98.12% and 98.86%, respectively, and the area under the ROC curve reached 0.998. Compared with recent similar work, the convolutional neural network structure proposed in this paper has certain advantages for EEG signal emotion classification.

Keywords: electroencephalogram signal; emotion recognition; deep learning; convolutional neural network

0 引言

情绪识别研究是基于面部特征、肢体语言、生理信号等

多种形式的人的情绪识别,是近二十年来的一个活跃的研究主题。面部特征和肢体语言可以做到隐藏伪装,真实性和可靠性略有不足。与它们相比,脑电图(electroencephalogram,

收稿日期:2021-11-16

*基金项目:国家自然科学基金(61972208,61672299)项目资助

EEG)、肌电图(electromyogram, EMG)和眼电图(electro-oculogram, EOG)等生理信号具有难以隐藏的优点。

情绪分类的目的是在给定相关数据记录的情况下,检索人类在特定时间点的情绪状态。先前的认知心理学研究已证实大脑皮层的电活动与人类情绪状态的情绪信息存在内在联系,并有报道称脑电图是情绪引起的直接反应^[1]。然而,脑电图信号的缺点是背景噪声很强且脑电信号较微弱。由于脑电信号是一种随机性很强的非平稳信号,其对情绪的理解具有内在的困难,但基于脑电图的情绪检测仍是一个活跃的研究领域。Duan 等^[2]提出了用微分熵(differential entropy, DE)来表征情绪状态的特征,对常见的正向情绪和负向情绪做二分类,平均分类准确率达到了 84.22%,这一结果表明微分熵比传统特征能量谱更适合于情绪识别。苗敏敏等^[3]提出一种新的自适应优化空频微分熵特征,通过稀疏回归算法对多重局部空间-频域内的微分熵特征进行优化选择。基于 SEED 数据集的积极/消极、积极/中性/中性/消极这 3 个情绪二分类场景平均准确率分别达到 91.8%、93.3% 和 85.1%,结果表明所提出的方法可以有效提高识别准确率,进一步验证了微分熵的优越性。Zhong 等^[4]提出用滑动平均(moving average, MA)技术来平滑短期波动,突出长期趋势或周期,在 Gamma 频段,基于 DEAP 公共情绪数据集的效价和唤醒度识别准确率分别达到 66.23% 和 68.50%。

随着计算能力的提升,深度学习方法得到广泛应用,利用深度学习算法进行基于 EEG 的情绪识别的研究也逐渐兴起。Badicu 等^[5]提出了一种基于长短时记忆(long short-term memory, LSTM)神经网络的分类器,对中性、积极和消极 3 种情绪进行分类,准确率达到 80%。Gonzalez 等^[6]提出了一种半泛型情绪检测框架,其中采用了卷积神经网络(convolutional neural network, CNN)分类方法,使用提出的迁移学习方法的 CNN 分类器的效价平均准确率达到 70.26%,唤醒度的平均准确率达到 72.42%。Liu 等^[7]着重于情绪识别和 SEED 数据集的动态功能分析。实验结果表明,Beta 波段的识别准确率最高,达到 87.03%,显示了动态功能连接在研究情绪相关脑机制方面的潜力。Donmez 等^[8]利用脑电图动力学的频谱图特征用于在 3 种主要情绪(恐惧,高兴和悲伤)之间进行分类,CNN 的平均准确度达到 84.69%。Shchykhivand 等^[9]提出一种将原始脑电图信号直接应用于 CNN 和长短期记忆网络,不涉及特征提取的 CNN-LSTM 网络对脑电信号的情绪进行二分类(积极和消极)和三分类(积极、中性和消极),准确率分别达到 97.42% 和 96.78%。柳长源等^[10]针对脑电信号时空特征结合的特点,以深度学习中的残差神经网络为基础,提出基于多尺度注意力残差网络的脑电情感信号分类模型,实验结果表明,改进后的多尺度注意力残差网络的分类精度达到 85.2%。

本文对积极、中性和消极 3 种主要情绪状态进行了分

类研究。我们利用 SEED 数据集所提取的微分熵特征,并使用其中提供的传统的滑动平均和线性动态系统方法使微分熵特征更加平滑。然后运用 MATLAB 将每一个样本的微分熵特征变换为一维数据。总计 1 350 个样本的微分熵特征即为二维数据,作为 CNN 进行分类任务的输入,在 Tensorflow 框架对输入的特征进行情绪分类。本文提出的 CNN 网络包含 4 个卷积层,4 个最大池化层,2 个全连接层和 1 个 Softmax 层。通过对实验结果的评估,证明了所提出 CNN 模型的有效性。

论文的内容组织如下。在第 2 节中,介绍了在基于 EEG 的情绪分类领域中广泛使用的 SEED 数据集并进行了导入卷积神经网络的预处理。第 3 节详细介绍了所提出的 CNN 结构。第 4 节和第 5 节分别给出了研究结果的分析和结论部分。

1 数据与方法

1.1 数据集描述

本文使用的情绪脑电信号数据集是来自上海交通大学 BCMI 实验室提供的一个公共数据集 SEED^[11]。表 1 是对该数据集的描述。SEED 数据集包括 15 名受试者(男性 7 名,女性 8 名;平均年龄:23.27,标准差:2.37)使用 ESI 神经扫描系统记录的 62 个通道的脑电图数据。这些数据是在参与者观看带有积极、中性和消极 3 种情绪类型的电影时收集的,每部电影大约 4 min,收集了每个受试者 3 个阶段的数据,每个阶段包括 15 个试验/电影,图 1 所示为 SEED 数据集刺激播放的过程。为了与现有研究进行比较,本文在实验过程中所采用的 SEED 数据集中的数据是经过预处理和特征提取后得到的。经过预处理后的数据下采样到 200 Hz,应用了 0~75 Hz 的带通频率滤波器。本文所提取的特征是微分熵^[12],并使用传统的滑动平均和线性动态系统方法,使微分熵特征进一步平滑。

表 1 数据集描述

特征	SEED 数据集描述
受试者数	15
影片数量	15
EEG 通道数	62
采样率/Hz	200
实验信号持续时间/min	约 4
基线信号持续时间/s	5
自我评估/s	45

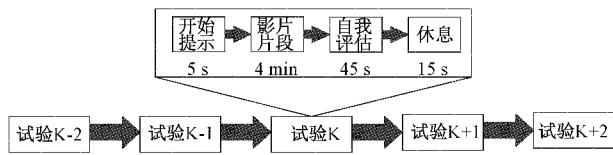


图 1 刺激播放流程

1.2 数据处理

微分熵作为当前常用的情绪脑电信号分类特征,其扩展了香农熵的概念,可以用来度量连续随机变量^[13]的复杂度。

微分熵的原始计算如式(1)所示。

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

将特征提取后的脑电信号在 MATLAB 中做截取处理,以保证每一个样本尺寸一致,方便输入卷积神经网络。将每个样本的三维微分熵特征矩阵转换为一维的时间序列,长度为 57 350。由于 15 个受试者,每个受试者进行 3 次实验,15 部影片,滑动平均和线性动态系统两种处理方法,故共 1 350 个样本。本文将 1 080 个样本作为训练集,270 个样本作为测试集。最后再对所有数据进行了归一化处理以提升模型的收敛速度及精度。

1.3 卷积神经网络

CNN 是传统神经网络更好的替代,非常有效的发展了机器视觉领域的分类方法。CNN 有两个学习阶段:正向传播和反向传播^[14]。CNN 由卷积层、池化层和全连接层 3 层组成^[14-16]。卷积层与全连接层相比,卷积层的主要优势在于参数共享和稀疏连接。参数共享的优势在于能够降低训练参数的数量,使网络更便于优化^[17]。稀疏连接可以在一定程度上抑制过拟合,降低拟合过程中所遇到的风险。

卷积层通过正向传播能使不同的卷积核与输入特征图进行运算,从而输出不同的输出特征图。卷积计算如式(2)所示。

$$\mathbf{Y}_n = \sum_{i=1}^M [(\mathbf{W}_n^i * x_i) + b_n] \quad (2)$$

其中, x_i 表示输入特征图, \mathbf{W}_n^i 是第 i 通道上的第 n 个卷积核, b_n 是偏置, \mathbf{Y}_n 是第 n 个输出特征图, M 是表示总通道数的常量。

池化是缩小高、长方向上的空间的运算。池化层一般有平均池化层和最大池化层两种。平均池化是计算目标区域的平均值,而最大池化是从目标区域中取出最大值。本文采用最大池化层,其具有以下特征:没有要学习的参数、经过池化运算的输入输出数据通道数不发生变化以及对微小的位置变化具有鲁棒性^[18]。

全连接层中每个结点都与前一层的所有结点进行连接,用来将提取到的特征表示映射到样本的标记空间。因为其结点全连接的特性,通常全连接层的参数也是最多的。

2 利用卷积神经网络进行分类

批归一化(Batch normalization^[19], BN)可以使参数搜索问题变得更简单,其作用在于 BN 可以在神经网络中间层也进行归一化处理,使训练速度更快、训练效果更好。BN 除了可以使得学习快速进行,对于初始值的依赖性相

对低,还有轻微的正则化效果,可以抑制过拟合,适用于方差较大的模型。

BN 变换如式(3)~(6)所示。

$$\mathbf{Z}_{norm}^{(i)} = \frac{\mathbf{Z}^{(i)} - \mu}{\sqrt{\sigma^2 + \epsilon}} \quad (3)$$

$$\tilde{\mathbf{Z}}^{(i)} = \gamma \mathbf{Z}_{norm}^{(i)} + \beta \quad (4)$$

其中, $\mathbf{Z}^{(i)}$ 为 BN 层的输入向量, $\tilde{\mathbf{Z}}^{(i)}$ 为第 i 层神经元的输出响应, ϵ 代表一个小数值的常数, γ 和 β 分别是通过学习获得的比例和位移参数。

$$\mu = \frac{1}{m} \sum_i \mathbf{Z}^{(i)} \quad (5)$$

$$\sigma^2 = \frac{1}{m} \sum_i (\mathbf{Z}^{(i)} - \mu)^2 \quad (6)$$

在每一层之后应用一个激活函数。本文使用了 ReLU 和 Softmax 两种激活函数。ReLU 定义如式(7)所示。

$$h(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (7)$$

ReLU 函数用于卷积层,可以将非线性和稀疏性应用到网络结构中。

多分类问题的激活函数常采用 Softmax 激活函数,其是 logistic 回归的一般形式,常与交叉熵损失函数一起使用。因此,在最后的 1 个全连接层使用 Softmax 函数,其定义如式(8)所示。

$$\mathbf{y}_i = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}}, i = 1, 2, \dots, k \quad (8)$$

其中, \mathbf{Z}_i 是输入向量,输出向量 \mathbf{y}_i 介于 0 和 1 之间,所有输出向量的和为 1^[14-16]。

本文提出的情绪识别 CNN 模型体系结构如图 2 所示。其中用于特征分类的 CNN 结构包括 4 个卷积层、4 个最大池化层、2 个全连接层和 1 个 Softmax 层。对于卷积层,使用 ReLU 函数作为激活函数,卷积核为 3,填充为"same",代表填充输入以使输出具有与原始输入相同的长度。对于最大池化层,池的大小为 2×1,步长为 2×1。对于 BN,设置参数 momentum = 0.99, ϵ = 0.001。将以上 1 个卷积层、1 个最大池化层以及 1 个 BN 按顺序构成的结构重复共 4 次,其中第 1 次中的卷积层步长为 2×1,其余 3 次中的卷积层步长为 1×1。结构重复 4 次后,紧接着是两个连续的全连接层,第 1 个全连接层输出空间维度为 3 648,第 2 个全连接层输出空间维度为 128,并在该层后使用 Softmax 函数进行三分类。

表 2 显示了所提出的网络架构的细节。由表 2 可得出,隐藏层从 57 350 (925×62) 继续降维到 128,然后利用非线性 Softmax 函数将选定的特征向量输入到全连接层。

为了选择对所创建 CNN 模型选择合适的参数,批大小(batch size)设置为 16,32,64,128,时期(epoch)设置为 50,60,70,80 进行实验。1 个时期既使用训练集的全部样

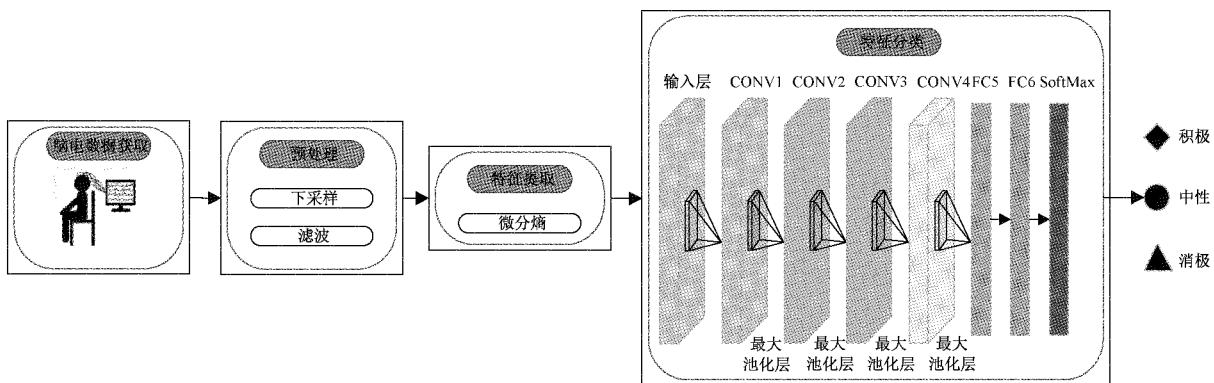


图2 本文所提出的情绪识别CNN模型体系结构

表2 采用的网络大小和步长

当前层	层类型	激活函数	内核或池的大小	步长	过滤器数量	填充
0~1	卷积层	ReLU	3×1	2×1	32	有
1~2	最大池化层	—	2×1	2×1	—	无
2~3	卷积层	ReLU	3×1	1×1	64	有
3~4	最大池化层	—	2×1	2×1	—	无
4~5	卷积层	ReLU	3×1	1×1	64	有
5~6	最大池化层	—	2×1	2×1	—	无
6~7	卷积层	ReLU	3×1	1×1	64	有
7~8	最大池化层	—	2×1	2×1	—	无
8~9	全连接层	ReLU	—	—	—	—
9~10	全连接层	Softmax	—	—	—	—

本训练一次。实验结果如表3,可以得出当为批大小64,时期为70时,准确率最高。

表3 采用不同批大小及时期的准确率 %

时期	批大小			
	16	32	64	128
50	61.63	73.80	79.93	45.79
60	60.05	85.17	93.19	57.06
70	65.59	96.50	98.73	86.08
80	80.31	96.39	95.73	72.60

本文所用CNN模型的参数值如表4所示。优化器选择上使用Adam优化器用于学习权值,配置其学习率 $\alpha=0.001$, $\beta_1=0.9$, $\beta_2=0.999$ 。损失函数选择分类交叉熵,评估标准为准确率,批大小为64,时期为70次。

表4 创建CNN模型的参数值

参数	值
优化器	Adam
学习率	0.001
损失函数	分类交叉熵
指标	准确率
批大小	64
时期	70

3 实验结果与分析

3.1 实验结果

在Python中使用Keras框架库实现了CNN,并在基于谷歌云平台的Tesla T4 GPU上进行了训练。

图3和4分别为三分类(积极、中性和消极)网络的损失函数和准确率。由图3可知,随着时期的增加,情绪三分类的网络损失函数逐渐减小,并从时期达到大约40后达到稳态值。由图4可知,在时期接近50的情况下准确率趋于稳定。此外对本文所提CNN情绪分类模型的其他评价指标如图5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98.73%,总体标准差为0.00706,

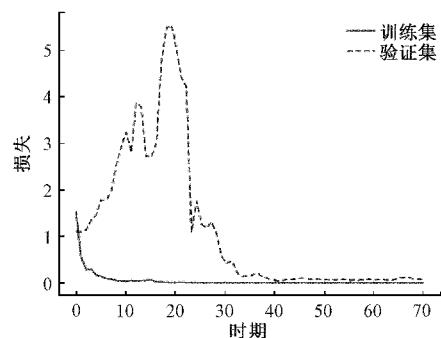


图3 提出的用于情绪分类的网络损失

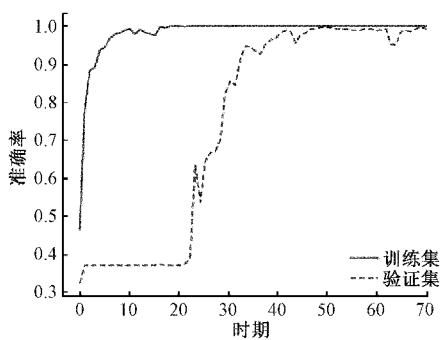


图4 所提出网络用于情绪分类的准确率

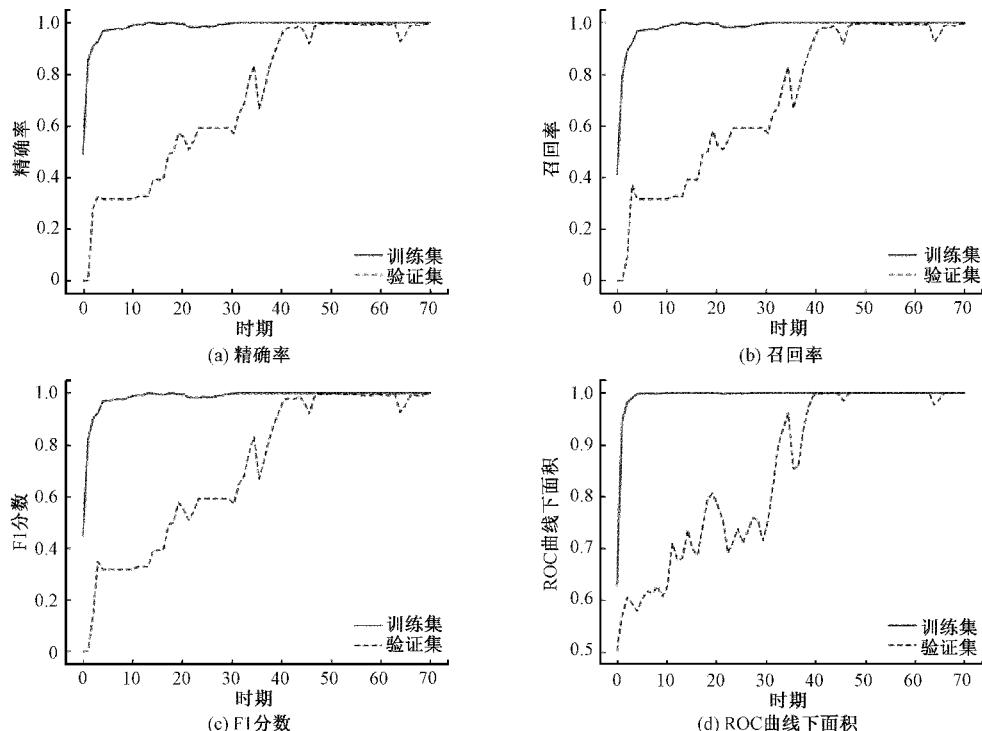


图5 所提分类模型的其他评价指标

表5 不同算法的准确率和ROC曲线下面积

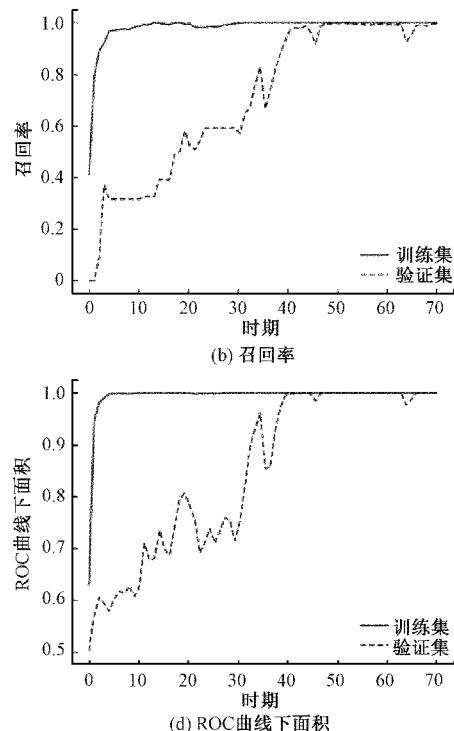
算法	准确率/%	AUC
决策树	67.41	0.79
kNN	78.50	0.82
SVM	67.41	0.78
CNN	98.73	0.998

决策树、kNN 和 SVM 3 种方法是在 MATLAB 2017 调用相应的分类函数分析得出的结果。本文使用决策树算法对同样的 SEED 情绪脑电数据进行分类,其准确率为 67.41%,ROC 曲线下面积为 0.79。kNN 算法是分类问题中较为简单且应用较多的方法,其分类的准确率达到 78.5%,ROC 曲线下面积达到 0.82。SVM 是一种常用的监督学习模型,其核函数的选择对于其性能的表现有至关

精确率、召回率和 F1 分数分别为 99.69%、98.12% 和 98.86%,受试者工作 (receiver operating characteristic, ROC) 曲线下面积(area under curve, AUC) 达 0.998。

3.2 与其他分类算法比较

将本文提出的 CNN 模型应用到 SEED 数据集上,对常见的积极、中性、消极 3 类情绪进行研究分析,并采用了传统的决策树(decision tree)、k 近邻(k-nearest neighbor, kNN)和支持向量机(support vector machine, SVM)识别算法对 3 类情绪进行研究对比分析。通过情绪的平均分类准确率和 ROC 曲线面积对各模型的分类结果进行评估,结果如表 5 所示。



重要的作用,本文采用了 10 倍交叉验证和应用最广的高斯径向基核函数,如式(9)所示。

$$K(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{\delta^2}\right) \quad (9)$$

SVM 的分类准确率为 67.41%,ROC 曲线下面积达到 0.78。

3.3 与其他类似神经网络比较

将本文的研究方法与运用 SEED 数据集的已有研究成果进行对比,结果如表 6 所示。文献[20]提出了具有成对约束损失的双向长短时记忆(bidirectional long short-term memory, BLSTM)网络来分类情绪的 3 种状态,平均准确率为 94.62%,文献[21]提出了一种基于脑电的深度卷积神经网络(deep convolutional neural network, DNN)情绪分类模型来分类情绪的 3 种状态,准确率达到

91.3%，文献[22]提出了一种基于动态图卷积神经网络(dynamic graph convolutional neural network, DGCNN)的多通道脑电情绪识别方法，其中 SEED 数据集受试者相关实验的平均识别准确率达到了 90.4%，文献[23]利用了方差数据处理技术和脉冲神经网络(spiking neural network, SNN)，对 SEED 数据集整体分类精度达到 96.67%，文献[24]提出了一种称为通道融合密集卷积网络(channel-fused dense convolutional network, CDCN)的深度学习框架用于脑电图的情绪识别，其在 SEED 数据集上的平均准确率达到 90.63%。

表 6 与运用 SEED 数据集的已有研究的对比

已有研究	方法	准确率/%
Badicu ^[5] (2019)	LSTM	80.00
Wang ^[20] (2019)	BLSTM	94.62
Asghar ^[21] (2019)	DNN	91.30
Song ^[22] (2020)	DGCNN	90.40
Luo ^[23] (2020)	SNN	96.67
Gao ^[24] (2020)	CDCN	90.63
本文	CNN	98.73

此外将本文方法与平均分类准确度达到 98% 左右的已有研究成果进行对比。文献[25]提出了一种基于卷积神经网络的方法，并结合数据增强方法边界-合成少数过采样技术，通过一维卷积神经网络对情感的效价和唤醒度进行三分类，其平均准确率分别达到 97.47% 和 97.76%。文献[26]提出了一种脑电信号特征提取方法，基于 GAMEEMO 数据集将小波包分解方法与统计特征方法相结合，分类器使用决策树时二分类准确率达到 98.56%。文献[27]提出了一种基于重新排列的脑电特征和深度学习算法的方法，其根据电极传感器的位置将所有通道的特征视为三维特征矩阵，随后采用 CNN 和带线性核的 SVM 处理三维特征矩阵，在 DEAP 数据集进行二分类，其效价和唤醒度的平均准确率分别达到 97.34% 和 96.45%。

本文对 SEED 数据集所提取的微分熵特征，构建了一个 CNN 模型对脑电情绪信号进行三分类识别研究，平均分类准确率达到了 98.73%，较运用 SEED 数据集的已有研究有一定程度提高，验证了本文方法的优越性。与平均分类准确率相近的工作相比，本文在特征提取上使用微分熵特征，相对简单高效，在分类上通过本文所设计的 4 个卷积层、4 个最大池化层、2 个全连接层和 1 个 Softmax 层，并采用批归一化的网络模型结构，同样能达到相近的平均分类准确率，验证了本文方法的可行性。

4 结 论

由于对脑电情绪数据集进行情绪分类，能够为今后实时监控正常人或抑郁病人的情绪提供进一步理论及实践

依据，因此本文提出了一种 CNN 网络的情绪识别方法。在研究过程中使用 SEED 数据集中的脑电数据，对积极、中性和消极 3 种情绪脑电信号进行分类研究分析。提出的 CNN 网络由 4 个卷积层、4 个最大池化层、2 个全连接层和 1 个 Softmax 层组成，并采用批归一化使参数搜索问题变得很容易，抑制模型过拟合。实验结果表明，利用该模型对 SEED 数据集的 3 种情绪的平均准确率达到了 98.73%，精确率、召回率和 F1 分数分别为 99.69%、98.12% 和 98.86%，ROC 曲线下面积达 0.998，与传统决策树、kNN 和 SVM 分类器相比具有较高的情绪识别率，证明了方法的有效性。并与最近基于同一数据集的类似工作以及平均分类准确率相近的工作作了比较，本研究中提出的卷积神经网络结构对于脑电信号情绪分类被证实具有不错的准确性和稳定性。综上表明本文所提的 CNN 模型可以帮助人们有效的通过脑电信号识别情绪。

参 考 文 献

- [1] MIN-KI K, MIYOUNG K, EUNMI O, et al. A review on the computational methods for emotional state estimation from the human EEG [J]. Computational and Mathematical Methods in Medicine, 2013, DOI: 10.1155/2013/573734.
- [2] DUAN R, ZHU J, LU B. Differential entropy feature for EEG-based emotion classification [C]. 2013 6th International IEEE/EMBS Conference on Neural Engineering(NER), 2013: 81-84.
- [3] 苗敏敏,徐宝国,胡文军,等.基于自适应优化空频微分熵的情感脑电识别[J].仪器仪表学报,2021,42(3): 221-230.
- [4] ZHONG X, YIN Z, ZHANG J. Cross-subject emotion recognition from EEG using convolutional neural networks [C]. 2020 39th Chinese Control Conference(CCC), 2020: 7516-7521.
- [5] BADICU B, UDREA A. Cross-subjects emotions classification from EEG signals using a hierarchical LSTM based classifier [C]. 2019 E-Health and Bioengineering Conference(EHB), 2019: 1-4.
- [6] GONZALEZ H A, YOO J, ELFADEL I M. EEG-based emotion detection using unsupervised transfer learning [C]. 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society(EMBC), 2019: 694-697.
- [7] LIU X, LI T, TANG C, et al. Emotion recognition and dynamic functional connectivity analysis based on EEG[J]. IEEE Access, 2019, 7: 143293-143302.
- [8] DONMEZ H, OZKURT N. Emotion classification from EEG signals in convolutional neural networks[J]. 2019 Innovations in Intelligent Systems and Applications

- Conference(ASYU), 2019: 1-6.
- [9] SHEYKHIVAND S, MOUSAVI Z, REZAI T Y, et al. Recognizing emotions evoked by music using CNN-LSTM networks on EEG signals [J]. IEEE Access, 2020, 8: 139332-139345.
- [10] 柳长源,孙雨涵,李文强,等.基于M&Resnet的脑电情绪识别研究[J].仪器仪表学报,2020,41(7):235-242.
- [11] 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.
- [12] 段若男,朱家宜,卢宝良.基于脑电图情绪分类的微分熵特征[C].第六届国际IEEE EMBS 神经工程会议(NER)的报告,2013:81-84.
- [13] GIBBS J W. Elementary principles in statistical mechanics [J]. Elementary Principles in Statistical Mechanics, 2014, ii(1): A55-A59.
- [14] HUNG S L, ADELI H. Parallel backpropagation learning algorithms on CRAY Y-MP8/864 supercomputer[J]. Neurocomputing, 1993, 5 (6): 287-302.
- [15] HINTON G E, SRIVASTAVA N, KRIZHEVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors [J]. Computer Science, 2012, 3(4): 212-223.
- [16] MOUSAVI Z, REZAI T Y, SHEYKHIVAND S, et al. Deep convolutional neural network for classification of sleep stages from single-channel EEG signals[J]. Journal of Neuroscience Methods, 2019, 324: 108312.
- [17] 李勇,林小竹,蒋梦莹.基于跨连接 LeNet-5 网络的面部表情识别[J].自动化学报,2018,44(1):176-182.
- [18] (日)斋藤康毅著.深度学习入门:基于 Python 的理论与实现[M].人民邮电出版社,2018:214-215.
- [19] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. International Conference on Machine Learning, 2015: 448-456.
- [20] WANG Y, QIU S, LI J, et al. EEG-based emotion recognition with similarity learning network[C]. 2019 11st Annual International Conference of the IEEE Engineering in Medicine and Biology Society(EMBC), 2019: 1209-1212.
- [21] ASGHAR A, KHAN F, KHAN M J, et al. EEG-based emotion recognition with combined deep neural networks using decomposed feature clustering model [C]. 2019 13th International Conference on Open Source Systems and Technologies(ICOSST), 2019: 1-6.
- [22] 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.
- [23] LUO Y, FU Q, XIE J, et al. EEG-based emotion classification using spiking neural networks[J]. IEEE Access, 2020, 8: 46007-46016.
- [24] GAO Z, WANG X, YANG Y, et al. A channel-fused dense convolutional network for EEG-based emotion recognition[J]. IEEE Transactions on Cognitive and Developmental Systems, 2020, DOI:10.1109/TCDS.2020.2976112.
- [25] CHEN Y, CHANG R, GUO J. Effects of data augmentation method borderline-SMOTE on emotion recognition of EEG signals based on convolutional neural network[J]. IEEE Access, 2021, 9: 47491-47502.
- [26] ABDULRAHMAN A, BAYKARA M. Feature extraction approach based on statistical methods and wavelet packet decomposition for emotion recognition using EEG signals[C]. 2021 International Conference on INnovations in Intelligent SysTems and Applications(INISTA), 2021: 1-7.
- [27] CHAO H, DONG L. Emotion recognition using three-dimensional feature and convolutional neural network from multichannel EEG signals [J]. IEEE Sensors Journal, 2020, 21(2): 2024-2034.

作者简介

张学军,教授,硕士生导师,主要研究方向为智能信息处理、脑机接口技术、无线射频识别技术等。
E-mail:xjzhang@njupt.edu.cn

陈都,硕士研究生,主要研究方向为智能信息处理、脑机接口技术。
E-mail:cherndo@163.com