

基于多维特征矩阵和改进稠密连接网络的情感分类

李红利¹, 刘浩雨¹, 张荣华², 成怡¹

(1. 天津工业大学 控制科学与工程学院, 天津 300387; 2. 天津工业大学 人工智能学院, 天津 300387)

摘要: 情感脑电信号是一种低信噪比的非平稳时间序列, 传统的特征提取与分类方法难以提取不同情感状态时的有效特征并进行分类. 针对以上情况, 提出一种自动融合脑电信号不同频段和时频域特征的深度学习模型. 首先, 对预处理后的数据进行分频段处理, 提取各频段的微分熵特征. 然后, 在网络中接入的挤压激励模块, 对不同频段特征的微分熵特征赋权值, 来获取输入数据的有价值信息, 再利用改进的稠密连接网络进行特征融合并分类识别, 保证了网络层之间最大程度的信息传输. 最后, 利用SEED情感脑电信号三分类数据集对算法进行了验证, 分类正确率可达96.03%, 高于现有的基线学习算法, 所提算法可进一步增强网络特征提取能力, 具有较快的收敛速度, 对提升分类器的性能研究具有重要意义.

关键词: 情感分类; 稠密连接; 多维特征矩阵; 深度学习; 挤压激励

中图分类号: TP 29

文献标志码: A

文章编号: 1005-3026(2024)07-0928-08

Emotional Classification Based on Multidimensional Feature Matrix and Improved Dense Connection Network

LI Hong-li¹, LIU Hao-yu¹, ZHANG Rong-hua², CHENG Yi¹

(1. School of Control Science and Engineering, Tiangong University, Tianjin 300387, China; 2. School of Artificial Intelligence, Tiangong University, Tianjin 300387, China. Corresponding author: LI Hong-li, E-mail: lihongli@163.com)

Abstract: Emotional EEG (electroencephalogram) signal is a non-stationary time series with low signal-to-noise ratio. Traditional feature extraction and classification methods are difficult to extract and classify the effective features of different emotional states. In regard to the above situation, a deep learning model that automatically fuses different frequency bands and time-frequency characteristics of EEG signals is proposed. Firstly, the preprocessed data is processed in frequency bands, and the differential entropy features of each frequency band are extracted. Then, the squeeze excitation module connected in the network assigns weight to the differential entropy features of different frequency bands to obtain the valuable information of the input data, and then uses the improved dense connection network for feature fusion and classification recognition to ensure the maximum information transmission between the network layers. Finally, the algorithm is verified by using the SEED emotional EEG of three classification dataset, and the classification accuracy is 96.03%, which is higher than the existing baseline learning algorithm. The proposed algorithm further enhances network feature extraction capabilities and demonstrates faster convergence, which is of great significance for improving the performance of the classifier.

Key words: emotional classification; dense connection; multidimensional feature matrix; deep learning; squeeze excitation

情感在人与人的交流中发挥着重要作用, 是人类对客观事物和个人需求相比较之后产生的

态度和体验. 情感与大脑内部和外部活动相关^[1-2]. 情感识别技术在工作负荷检测、情感障碍

疾病的辅助诊断与治疗的量化评价等方面具有广阔的应用前景^[3]。以往的情感识别大多基于面部特征、肢体语言等,然而,面部特征和肢体语言等信号存在隐蔽性,会使结果出现较大的不确定性。与心电、眼动信号等其他生理信号不同,脑电(electroencephalogram, EEG)信号体现了中枢神经系统的动态变化以及大脑中神经元的活动,因不受主观控制所以更具真实性,能够弥补其他信号的缺陷,能更好地对应人的生理活动,因此基于EEG信号的研究是当今情感分类的热门方法^[4]。但是EEG信号不平稳、微弱且容易受噪声干扰,利用其对情感进行解码时具有内在的难度,因此研究有效的特征提取和分类算法十分重要。

早期的EEG信号分类工作通过机器学习完成,信号的特征提取也是根据经验进行。近年来基于人工提取特征和机器学习相结合的情感分类有一定的效果,但传统的方法需要大量的人工参与来提取EEG信号的特征,耗费了大量的时间和精力。随着人工智能技术的发展,深度学习能够挖掘数据更深的特征,通过组合底层特征形成抽象的高层特征,很多研究者将其运用到情感脑电分类上,获得比人工提取特征和机器学习更优异的性能。其中,卷积神经网络(convolutional neural network, CNN)在信号识别与分类领域可以提高所用分类模型的性能和鲁棒性^[5]。Fdez等^[6]引入了一种新的基于受试的特征归一化方法用于训练深度神经网络,以完成根据EEG信号判断情感分类的任务,在SEED数据集上分类正确率可达91.6%。Joshi等^[7]提出了基于线性差分熵公式LF-DfE(linear formula of differential entropy)特征提取器和双向长短期记忆网络BiLSTM(bidirectional long short-term memory)分类器的EEG信号情感检测方法,在SEED数据集上分类正确率达到90.22%。周如双等^[8]提出一种基于深浅特征融合的残差网络情感分类模型,分类正确率达到91.18%。Liu等^[9]利用多模态深度学习方法,证明了深度自动编码器在SEED数据集上分类正确率达到91.01%。Zhang等^[10]提出一种空间-时间递归神经网络,采用多方向递归神经网络RNN(recurrent neural network)层捕捉长距离全文线索,然后使用双向时间RNN层来辨别信号序列的特征,解决了时空依赖性无法被长距离捕捉和建模问题,分类正确率可达89.50%。Song等^[11]研究了EEG信号更广泛的特征类型,包括18种线性和非线性脑电图特征,并采用支持向量机(SVM)来验证分类性能,正确率可达83.33%,并

发现 β 节律中移动性的Hjorth参数,实现了最佳的平均识别精度。为了证明微分熵(differential entropy, DE)作为提取的特征优越性,Duan等^[12]同时对比了DE及其组合差分不对称(differential asymmetry, DASM)、有理不对称(rational asymmetry, RASM)和传统能谱(energy spectrum, ES)等特征,微分熵特征的平均分类正确率最高,这一结果表明,微分熵比传统特征能量谱更适合于情感分类。苗敏敏等^[13]通过稀疏回归算法对多重局部的微分熵特征进行优化,优化后的微分熵特征更加显著,并进一步验证了微分熵的优越性。

深度学习在对原始数据提取特征和分类方面较机器学习和传统浅层模型有更优异的性能。但现有的深度算法都只针对特征细分后加权融合,并没有考虑不同频段和时频域融合特征对结果的影响。EEG信号的不同频段与不同的情感状态相关联,所以分类结果受信号的不同频段特征影响。此外,单一时域和频域的信号使得深度模型无法建立情感脑电解码的有效特征模型,造成时频特征分类效果较差。为了解决上述问题,提出了一种改进的深度网络模型应用于EEG信号的分类。首先将原始EEG信号裁剪并分频段提取微分熵特征构成三维矩阵,按时间序列排列,融合了时频域特征,然后利用改进的稠密连接网络进行特征融合分析,并在网络中加入挤压激励块,为EEG信号的不同频段分别分配权重,使用全局信息来选择性地强调有价值特征,抑制无价值的特征,充分利用了不同频段之间特征的互补信息来提高分类正确率,提高了网络分类识别性能。

1 脑电数据处理

1.1 数据集

本研究在国际公开数据集SEED^[14]上进行验证测试。实验中利用ESI NeuroScan 62电极脑电采集系统采集EEG信号,采样频率为1 000 Hz,62个电极通道按10~20系统定位。数据集SEED包括15名受试,每名受试的数据采集分3次进行,每次进行15个电影片段的实验评估,15个电影片段包括积极、消极、中性3种类型各5个,标签分别对应(1, -1, 0),15名受试共675组脑电数据。每次实验片段分成4个部分,首先是每段影片播放前会有5 s的提示,然后是电影播放4 min,接着是受试进行对应的自我评估45 s,最后休息15 s。

1.2 数据预处理

将采集的原始 EEG 信号频率由 1 000 Hz 降采样到 200 Hz 后,用 0 ~ 75 Hz 的带通滤波器滤除噪声和去除伪影,并提取与每个电影片段对应的 EEG 片段,得到预处理后的数据集.为了增加数据训练样本,对每段信号进行裁剪,对约为 4 min 的 EEG 信号以每 0.5 s 截取片段且不重叠,并给每个段分配原始实验的标签,对于每个片段用 Butterworth 滤波器将其分解为 $\theta, \alpha, \beta, \gamma$ 4 个频段,然后从每个频段提取 DE 特征.为了保留电极

位置的空间结构信息,将多通道 DE 向量转换为二维矩阵,62 个电极通道转换二维矩阵如图 1 所示,其中 0 表示通道的信号未被使用,将不同频段的二维矩阵构成三维矩阵.因此,每一段脑电数据可以表示为一个三维结构 $X_n \in \mathbf{R}^{h \times w \times d}$,其中 h 和 w 是二维矩阵的高度和宽度,分别为 8 和 9,频段数 d 为 4,预处理的流程图如图 2 所示,最后得到情感分类的单位样本输入数据维数为 (8, 9, 4).

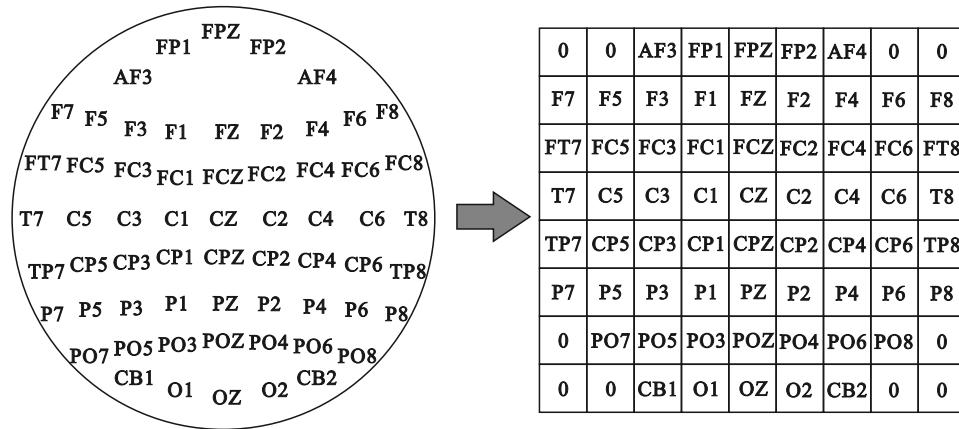


图 1 62 电极通道转换二维特征矩阵

Fig. 1 Two-dimensional characteristic matrix of 62 electrode channels conversion

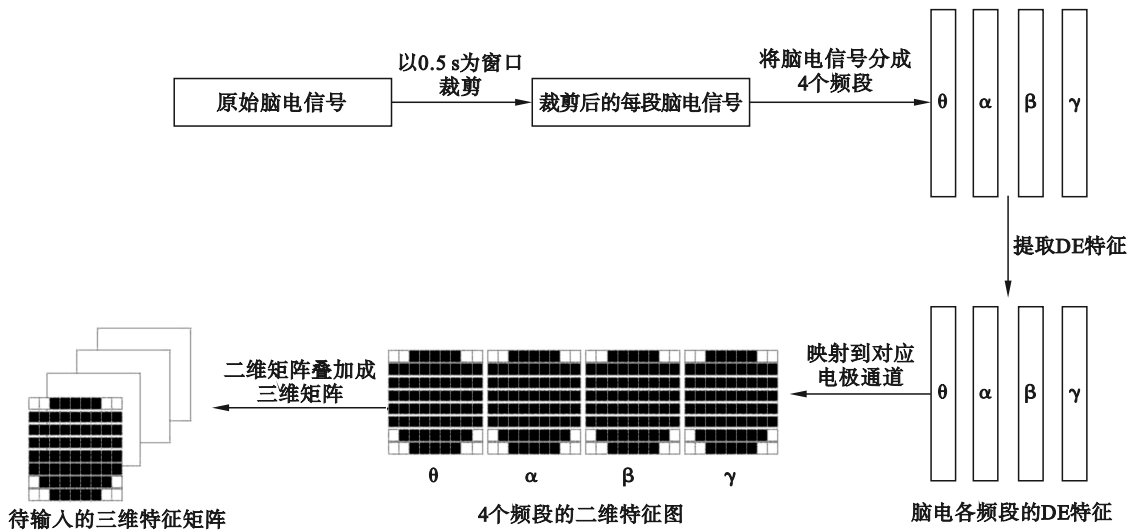


图 2 EEG 信号预处理流程图

Fig. 2 Flow chart of EEG signal preprocessing

2 研究方法

2.1 微分熵特征

微分熵在香农熵的思想上进行延伸,能够测量连续随机信号的复杂性.微分熵是固定长度的

EEG 在某个频段内的对数能量谱.设有 EEG 信号 x_t ,其微分熵表达式如式(1)所示.

$$H(x) = - \int f(x) \ln [f(x)] dx. \quad (1)$$

式中, $f(x)$ 是 EEG 信号的概率密度函数,如果变量服从高斯分布 $N(\mu, \sigma^2)$,则微分熵可通过式(2)计算,其中 σ 为 EEG 信号序列的标准差.

$$H(x) = - \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \ln \left[\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \right] dx = \frac{1}{2} \ln(2\pi\sigma^2). \quad (2)$$

虽然原始的 EEG 不服从一定的固定分布,但经过带通滤波后,EEG 信号在连续子频段中服从高斯分布^[15],由式(2)知,只需要确定 x_i 的标准差 σ 就能得到微分熵,正态分布 $N(\mu, \sigma^2)$ 的方差如式(3)所示.

$$\hat{\sigma}^2 = \frac{1}{N} \sum_{i=1}^N x_i^2. \quad (3)$$

离散信号的频谱能量为 $P = \int_{-\infty}^{+\infty} f^2(t) dt$,由式(3)可知,EEG 信号 x_i 的方差就是它的平均能量值 P ,对于某一个频段的微分熵特征如式(4)所示.

$$H_i(x) = \frac{1}{2} \ln(2\pi\sigma_i^2) = \frac{1}{2} \ln P_i + \frac{1}{2} \ln \left(\frac{2\pi e}{N} \right). \quad (4)$$

采用微分熵特征可以减小某一个频段的能量值过大而造成的影响,减小误差、提高特征精确度^[16].

2.2 挤压激励模块

EEG 信号的不同频段对特征敏感度不同,不同频段有效地聚合了信号的特征信息^[17].为了使模型在学习过程中更有效地关注不同频段间的有效特征信息,本研究在模型中引入了挤压激励模块(squeeze and excitation, SE). SE 模块是一个侧重于频段关系特征的计算单元, Hu 等^[18]的研究证明,SE 模块可以有效地提高神经网络的表现,其结构如图 3 所示.其中 $U = [u_1, u_2, u_3, u_4]$, $C = 4$, u_1, u_2, u_3, u_4 分别代表了由 4 个频段的微分熵特征构成的二维矩阵.挤压操作将每个三维特征矩阵的全局信息放入通道描述符 $z \in \mathbf{R}^C$ 中,通道依赖描述 $z \in \mathbf{R}^4$ 由 U 在每个二维矩阵维度上的全局平均池化生成.因此挤压操作后的输出如式(5)所示.

$$z_c = F_{sq}(u_c) = \frac{1}{h \times w} \sum_{i=1}^8 \sum_{j=1}^9 u_c(i, j). \quad (5)$$




图 3 挤压激励块

Fig. 3 Extrusion excitation block

通过计算,输出 U 由 $h \times w \times d$ 转变为 $1 \times 1 \times d$,将 4 个频段的特征构成的三维特征矩阵进行挤压运算,三维特征矩阵都在 8×9 的维度上进行特征压缩成 4 个实数,表示了特征在 4 个频段上的全局分布.

接下来的激励操作通过两个全连接层和两个激活层实现,通过上一步收集的信息来获得各频段间的完全依赖.目的是关注所有频段,学习不同频段特征的非线性交互,并非单一热激活.通过参数 W 来为每个频段生成权重,其中参数 W 表征着各频段之间的相关性.激励运算用式(6)表示.

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2(\delta(W_1 z))). \quad (6)$$

式中: σ 是 Sigmoid 激活函数; δ 是 ReLU 激活函数; W_1, W_2 代表两个全连接层.激励操作的输出权重是不同频段的重要程度,挤压激励操作后通过重新加权得到最终结果,其将激励操作的输出权重逐频段加权到挤压操作之前的特征上,完成对原始特征的重新加权.将激励运算后的元素与 4 个频段构成的二维特征矩阵相乘得到,如式(7)所示.

$$\tilde{U} = F_{scale}(u_c \cdot s_c) = u_c \cdot s_c. \quad (7)$$

式中 $\tilde{U} = [\tilde{u}_1, \tilde{u}_2, \tilde{u}_3, \tilde{u}_4]$, 挤压激励操作完成了对 EEG 信号各频段特征的分配权重.反向传播时,通过激活函数完成对权重参数的更新,对各频段作用大的特征进行强化,弱化作用小的特征^[19].

2.3 稠密连接块

残差网络块的结构如图 4 所示,通过建立部分之间短路连接来训练出更深的网络,实现更高的准确度,同时有利于梯度的反向传播.然而当网络变深时,输出到输入的路径就会变得更长,梯度反向传播回输入的时候可能会消失. Chen 等^[20]从多路径图像识别领域提出了稠密连接算法,本研究将该算法改进后应用于脑电数据的分类.稠密连接的思路与残差网络相似,该算法中前面所有层与后面层密集连接,稠密连接网络是通过特征在通道上的连接来实现特征重用,在保证网络中各层之间最大程度信息传输的前提下将所有层连接起来,在具有稠密块的网络中,前面所有层的特征都到后一层拼接融合,下层的输入就是上一层融合特征,这样前后层的信息总相关,有利于信息的传递与重新利用.稠密网络与

残差网络区别在于输出是连接而不是简单相加,这很大程度缓解了当网络的层数变深时梯度经过很长的路径反向传播回输入时造成梯度消失的问题.原始的稠密连接中,BN层连接在卷积层后面,本研究为了增强网络泛化能力而将BN层从网络中去掉,BN层过多会造成数据特征和测试集归一化^[21].改进的结构如图5所示,既可以提升网络的泛化能力,又节省了大量计算时间.




图4 传统残差网络块

Fig. 4 Traditional residual network block




图5 改进的稠密连接块

Fig. 5 Improved dense connection

2.4 网络模型

本研究提出的网络模型整体结构如图6所示.由于提取的原始EEG信号时频域多维特征矩阵数据量庞大且需要层层细分,则需要更深的网络来提升网络性能,但网络过深会使结构变得复杂,网络参数变多,不利于网络的收敛,网络梯度会造成弥散,网络性能大大下降.本研究设计的网络模型极大地提高了网络性能.首先数据在经SE模块处理后为每个频段分配一个权重,将通道间的时频特征相结合,然后经过卷积核大小为3×3的卷积操作、BN、ReLU处理后,运用三层改进的稠密连接模块和两层过渡层,过渡层中的卷积核大小为1×1且池化操作为平均池化.接下来再进行一次SE操作,将时频特征相融合进一步增加网络特征提取能力.处理后的数据经全局池化后,最后将高层抽象特征输入全连接层进行输出分类.经实验测试,三层稠密连接模块和两层过渡层相结合的网络结构性能优异,过于复杂的模型容易造成过拟合,过于简单的模型无法有效地融合特征.各层网络单位样本输入参数尺寸如表1所示.本研究提出的模型结合了SE模块和稠密连接网络的运算特点,全局信息更有效地被学习与利用,可获得优异的解码分类性能.

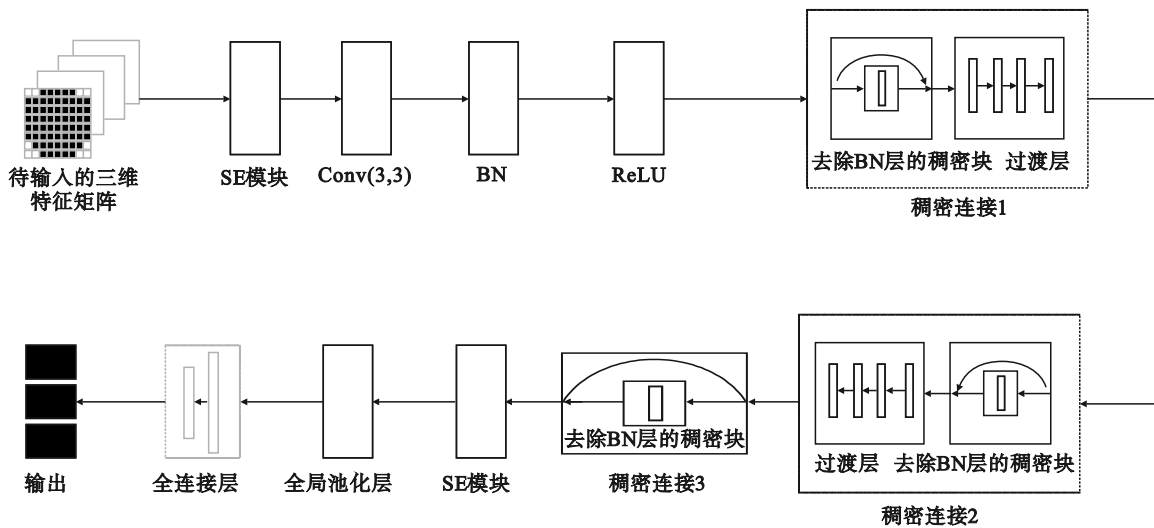


图6 网络整体结构

Fig. 6 Network overall structure

3 实验结果与分析

本研究的网络模型通过Python上的TensorFlow平台进行搭建,利用其各种张量构造网络结构.网络采用自适应随机优化算法进行损失函数

的优化与更新,训练中采用小批样本梯度下降策略.训练单次输入128的批量,使用初始学习率为0.001的Adam优化器来最小化交叉熵的损失函数^[22].采用5折交叉验证技术对实验预处理后的数据进行验证,每折迭代150次,实验中每个受试的80%数据用于训练,20%用于测试.

表 1 各层网络输入参数尺寸

Table 1 Input parameter size of each layer of network

名称	单位样本输入尺寸	单位样本输出尺寸
输入	(8,9,4)	(8,9,4)
SE 模块	(8,9,4)	(8,9,4)
卷积层(3×3)	(8,9,4)	(8,9,64)
稠密连接层 1	(8,9,64)	(8,9,96)
过渡层 1	(8,9,96)	(4,4,48)
稠密连接层 2	(4,4,48)	(4,4,80)
过渡层 2	(4,4,80)	(2,2,40)
稠密连接层 3	(2,2,40)	(2,2,72)
SE 模块	(2,2,72)	(2,2,72)
全局池化层	(2,2,72)	72
全连接层	128	3

3.1 不同模型分类结果比较

通过与其他网络模型方法对比来分析本研究提出的网络模型性能,不同网络模型在 SEED 上的分类正确率如表 2 所示.

表 2 不同模型的正确率

Table 2 Classification accuracy of different models %

模型	正确率
BiLSTM ^[7]	90.22
DCRN ^[8]	91.18
DAEN ^[9]	91.01
STRNN ^[10]	89.50
SVM, LOSO ^[11]	83.33
MCNN ^[23]	91.31
GELM ^[24]	91.07
DGCNN ^[25]	90.40
本文模型	96.03

表 2 中,BiLSTM^[7]模型捕获 EEG 信号的长期依赖性,并从不同的大脑区域学习空间信息来进行分类;DCRN^[8]模型通过设计多层不同卷积核

的卷积层有效地提取和融合脑电的时空特征,实现有效的情感识别;DEAN^[9]模型采用了双峰深度自动编码器(BDAE)提取特征构建模型,并降低获取真实世界应用的生理信号的成本;STRNN^[10]模型采用多方向递归神经网络(RNN)层捕捉上下文线索,信号序列的相关特征被双向时间 RNN 层进一步表征;SVM 结合 LOSO^[11]方法的验证策略来评估分类性能,使用自动特征选择方法,系统地探索不同 EEG 特征识别受试者情绪信息的能力;MCNN^[23]模型用于多通道非线性 EEG 信号的情绪识别,设计了一个多层网络,有效地分析了多变量非线性时间的 EEG 信号;GELM^[24]方法是一种机器学习方法,主要研究了随着时间推移的稳定脑电图模式,并采用判别图正则化极限学习机对微分熵特征进行分类;DGCNN^[25]模型是一种基于动态图卷积神经网络的多通道脑电情感识别方法,所提方法的基本思想是使用图形的方式对多通道 EEG 特征进行建模,由邻接矩阵表示不同脑电图信道之间的内在关系,从而有利于更具鉴别性的特征提取.

然而,因为个别受试数据特征可能会出现过度拟合的情况,并且不同网络模型对数据集中不同的受试数据敏感性不同,从而造成本文所提模型会出现某一受试的正确率低于其他模型.但是本文所提模型的平均准确率更高,具有更优异的性能.

3.2 训练过程比较

本研究将受试单独训练并画出了 15 名受试的平均训练过程图,如图 7 所示,通过分析本研究改进模型、无稠密连接的卷积模型和无 SE 模块的模型的训练过程来比较性能.




图 7 三种模型的训练过程

Fig. 7 Training process of three models

(a)—本文模型; (b)—无稠密连接的卷积模型; (c)—无 SE 模块的模型.

由图 7 可见,本文模型较其他两种实验模型,能够稳定收敛且时间更短.网络中应用稠密连接

模块,实现了前层的特征都与前面所有层的特征融合,融合后的特征作为下层的输入,促进了信

息的传递和利用,这样每一层的特征信息都互相关联,加快了网络的训练速度;网络中加入SE模块可以对不同频段的微分熵特征进行加权,因此具有更好的学习能力.不同特征间会存在冗余信息,直接进行特征融合会造成传统网络出现过拟合,SE模块的挤压和激励操作通过对不同频段的特征重新校准来提升网络的表示能力,从而表现出比传统网络更优异.

3.3 通道位置关系性能分析

在实际中,应用更少的电极实现更高正确率的情感分类也具有重要的研究意义,因此本部分利用本研究提出的改进模型验证电极通道数目

的影响,在8×9矩阵上提取不同数目脑电通道的4个频段微分熵进行研究.脑区中影响情感的区域主要是颞叶、前额和前半脑区^[26],所以图8显示了本研究选取的3种数目(9,15,33)的通道,表3显示了15名受试在4种通道上的分类正确率,9通道、15通道和33通道的平均正确率分别为82.10%,89.78%,95.18%,可以看出分类正确率随着电极通道数目的增加而上升,说明电极通道的数目和空间位置的排列对分类正确率造成影响.从表3可以看出,33通道数的分类正确率仅略低于62通道数,说明这33个电极中的信息特别重要,可为高效率研究提供参考.



图8 3种不同通道的电极分布

Fig. 8 Electrode distribution of three different number channels

表3 各受试在不同数目电极通道上的分类正确率
Table 3 Classification accuracy of each subject on different number of electrode channels %

受试	9通道	15通道	33通道	62通道
1	74.48	87.75	92.32	93.48
2	76.09	92.14	94.75	97.33
3	84.89	90.03	93.24	96.45
4	86.07	97.79	99.86	99.85
5	76.67	86.54	94.57	95.41
6	88.64	90.77	98.53	99.44
7	80.24	86.23	93.32	92.46
8	86.45	91.64	96.54	97.33
9	84.85	89.31	97.35	96.59
10	86.75	91.25	97.37	97.34
11	83.43	89.42	93.36	95.56
12	81.56	88.64	92.41	95.71
13	83.16	89.72	96.32	95.27
14	82.48	89.93	97.78	96.44
15	75.69	85.56	90.03	91.86
平均	82.10	89.78	95.18	96.03

4 结 语

本文在原始稠密连接网络模型的基础上提出了一种改进的稠密连接网络,并在网络中加入SE模块为不同频段的特征分别分配权重.本研究提出的情感脑电特征融合与分类的方法具有以下优势:①将原始EEG信号数据进行裁剪并分成4个频段,将时频特征相结合,利用电极间的位置关系将特征映射在二维矩阵上,使特征按空间位置关系排布;②在模型中加入SE模块来增强特征提取能力,挤压和激励操作强化了重要频段特征并弱化了作用较小的频段特征;③利用改进的稠密连接网络对提取的特征进行融合分析,使每一层之间的特征信息都有所关联,增强了信息的传递与重新利用,从而使得全局信息更易被学习.

本研究遇到的问题是卷积结构的变动与网络结构参数的优化对结果造成何种影响,在日后的工作中会进一步进行研究.同时将设计自采数据集及跨被试实验来验证模型的性能.

参考文献:

- [1] 郑伟龙,石振锋,吕宝粮.用异质迁移学习构建跨被试脑电情感模型[J].计算机学报,2020,43(2):177-189.
(Zheng Wei-long, Shi Zhen-feng, Lyu Bao-liang. Building cross-subject EEG-based affective models using heterogeneous transfer learning [J]. *Chinese Journal of Computers*, 2020, 43(2): 177-189.)
- [2] 权学良,曾志刚,蒋建华,等.基于生理信号的情感计算研究综述[J].自动化学报,2021,47(8):1769-1784.
(Quan Xue-liang, Zeng Zhi-gang, Jiang Jian-hua, et al. Physiological signals based affective computing: a systematic review[J]. *Acta Automatica Sinica*, 2021, 47(8): 1769-1784.)
- [3] Sani O G, Yang Y X, Lee M B, et al. Mood variations decoded from multi-site intracranial human brain activity [J]. *Nature Biotechnology*, 2018, 36(10): 954-961.
- [4] Zheng W L, Liu W, Lu Y F, et al. EmotionMeter: a multimodal framework for recognizing human emotions [J]. *IEEE Transactions on Cybernetics*, 2019, 49(3): 1110-1122.
- [5] 褚亚奇,朱波,赵新刚,等.基于时空特征学习卷积神经网络的运动想象脑电解码方法[J].生物医学工程学杂志,2021,38(1):1-9.
(Chu Ya-qi, Zhu Bo, Zhao Xin-gang, et al. Convolutional neural network based on temporal-spatial feature learning for motor imagery electroencephalogram signal decoding [J]. *Journal of Biomedical Engineering*, 2021, 38(1): 1-9.)
- [6] Fdez J, Guttenberg N, Witkowski O, et al. Cross-subject EEG-based emotion recognition through neural networks with stratified normalization [J]. *Frontiers in Neuroscience*, 2021, 15: 626277.
- [7] Joshi V M, Ghongade R B. EEG based emotion detection using fourth order spectral moment and deep learning [J]. *Biomedical Signal Processing and Control*, 2021, 68: 102755.1-102755.12.
- [8] 周如双,赵慧琳,林玮玥,等.基于深浅特征融合的深度卷积残差网络的脑电情绪识别模型[J].中国生物医学工程学报,2021,40(6):641-652.
(Zhou Ru-shuang, Zhao Hui-lin, Lin Wei-yue, et al. Feature fusion based deep residual networks using deep and shallow learning for EEG-based emotion recognition [J]. *Chinese Journal of Biomedical Engineering*, 2021, 40(6): 641-652.)
- [9] Liu W, Zheng W L, Lu B L. Emotion recognition using multimodal deep learning [C]//International Conference on Neural Information Processing. Cham: Springer, 2016: 521-529.
- [10] Zhang T, Zheng W, Cui Z, et al. Spatial-temporal recurrent neural network for emotion recognition [J]. *IEEE Transactions on Cybernetics*, 2017: 839-847.
- [11] Song D W, Zhang Y Z, Hu B, et al. Exploring EEG features in cross-subject emotion recognition [J]. *Frontiers in Neuroscience*, 2018, 12: 162.
- [12] 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 (NER). San Diego, 2013: 1-4.
- [13] 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.
(Miao Min-min, Xu Bao-guo, Hu Wen-jun, et al. Emotion EEG recognition based on the adaptive optimized spatial-frequency differential entropy [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(3): 221-230.)
- [14] 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.
- [15] Shi L C, Jiao Y Y, Lu B L. Differential entropy feature for EEG-based vigilance estimation [C]//International Conference of the IEEE Engineering in Medicine & Biology Society. San Diego, 2013: 6627-6630.
- [16] 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.
(Dai Zi-yu, Ma Yu-liang, Gao Yun-yuan, et al. A multi-scale convolutional kernel CNN for EEG emotion recognition [J]. *Journal of Transduction Technology* 2021, 34(4): 496-503.)
- [17] 李红利,尹飞超,张荣华,等.基于通道注意力和稀疏时频分解的运动想象分类[J].生物医学工程学杂志,2022,39(3):488-497.
(Li Hong-li, Yin Fei-chao, Zhang Rong-hua, et al. Motor imagery electroencephalogram classification based on sparse spatiotemporal decomposition and channel attention [J]. *Journal of Biomedical Engineering*, 2022, 39(3): 488-497.)
- [18] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City, 2018: 7132-7141.
- [19] 晁浩,曹益鸣,刘永利.基于三维特征矩阵和冲压激励网络的多通道脑电情感识别[J].控制与决策,2023,38(12):3427-3435.
(Chao Hao, Cao Yi-ming, Liu Yong-li. Emotion recognition from multi-channel EEG data through three-dimensional feature matrix and squeeze-and-excitation networks [J]. *Control and Decision*, 2023, 38(12): 3427-3435.)
- [20] Chen B L, Zhao T S, Liu J H, et al. Multipath feature recalibration DenseNet for image classification [J]. *International Journal of Machine Learning and Cybernetics*, 2021, 12(3): 651-660.
- [21] 柴国强,王大为,芦宾,等.基于注意机制的轻量化稠密连接网络单幅图像去雨[J].北京航空航天大学学报,2022,48(11):2186-2192.
(Chai Guo-qiang, Wang Da-wei, Lu Bin, et al. Lightweight dense network based on attention mechanism for single-image deraining [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2022, 48(11): 2186-2192.)
- [22] Kingma D P, Ba J. Adam: a method for stochastic optimization [C]//The 3rd International Conference on Learning Representations. San Diego, 2015: 1412.6980.
- [23] Dang W D, Lyu D M, Li R M, et al. Multilayer network-based CNN model for emotion recognition [J]. *International Journal of Bifurcation and Chaos in Applied Sciences and Engineering*, 2022, 32(1): 2250011.
- [24] Zheng W L, Zhu J Y, Lu B L. Identifying stable patterns over time for emotion recognition from EEG [J]. *IEEE Transactions on Affective Computing*, 2019, 10(3): 417-429.
- [25] 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.
- [26] Zheng W L, Guo H T, Lu B L. Revealing critical channels and frequency bands for emotion recognition from EEG with deep belief network [C]//7th International IEEE/EMBS Conference on Neural Engineering (NER). Montpellier, 2015: 154-157.