

DOI:10.19651/j.cnki.emt.2211455

# 基于多层注意力机制的4DC-BGRU脑电情感识别<sup>\*</sup>

张丽彩 李鸿燕 司马飞扬 申雁

(太原理工大学信息与计算机学院 晋中 030600)

**摘要:**为了提高脑电情感识别的准确率,提取更丰富的特征信息,提升网络模型稳定性,提出一种改进的基于多层注意力机制的脑电情感识别模型。在特征提取方面,将原始脑电信号转换成四维空间-频谱-时间结构,提取丰富的脑电信息。在网络模型方面,构建双路卷积神经网络学习空间及频率信息,有效提取多尺度特征,增加网络宽度来学习更丰富的特征信息;在卷积层及池化层后融入批量归一化层,防止过拟合。最后,构建多层注意力机制-双向门控循环单元模块处理时间特征并配合Softmax分类。采用双向门控循环单元学习更全面的上下级特征信息。利用多层注意力机制使四维特征中不同时间切片与整体时间切片之间产生关联。该文在DEAP数据集唤醒度和效价两个维度进行了评估实验,二分类平均准确率分别为96.38%和96.73%,四分类平均准确率为93.78%。实验结果显示,与单路卷积神经网络及其他文献算法相比,该文算法的平均准确率有所提高,表明该算法可以有效提升脑电情感识别性能。

**关键词:**脑电情感识别;双路卷积神经网络;多尺度特征;多层注意力机制;双向门控循环单元

中图分类号:TP391 文献标识码:A 国家标准学科分类代码:510.40

## EEG emotion recognition by 4DC-BGRU based on multi-level attention mechanism

Zhang Licai Li Hongyan Sima Feiyang Shen Yan

(College of Information and Computer, Taiyuan University of Technology, Jinzhong 030600, China)

**Abstract:** In order to improve the accuracy of EEG emotion recognition, extract richer feature information and improve the stability of network model, an improved EEG emotion recognition model based on multi-level attention mechanism is proposed. In the aspect of feature extraction, the original EEG signal was transformed into four-dimensional space spectrum time structure to extract rich EEG information. In the aspect of network model, a two-way convolution neural network was constructed to learn spatial and frequency information. It can effectively extract multi-scale features and increase the network width to learn richer feature information. After the convolution layer and pool layer, the batch normalization layer was integrated to prevent over fitting. Finally, a multi-level attention mechanism-bidirectional gated recurrent unit module was constructed to process the time characteristics and cooperate with Softmax classification. The bidirectional gated recurrent unit was used to learn more comprehensive upper and lower level feature information. The multi-level attention mechanism was used to correlate different time slices with the overall time slices in four-dimensional features. The evaluation experiments were carried out in two dimensions of arousal and potency of DEAP data set. The average accuracy of two classifications were 96.38% and 96.73% respectively, and the average accuracy of four classifications was 93.78%. The experimental results show that the average accuracy of this algorithm is improved compared with single channel convolutional neural network and other literature algorithms, which shows that this algorithm can effectively improve the performance of EEG emotion recognition.

**Keywords:** EEG emotion recognition; two-way convolution neural network; multi-scale features; multi-level attention mechanism; bidirectional gated recurrent unit

## 0 引言

近年来,人机交互(man-machine interface, MCI)影响

着我们生活的方方面面<sup>[1]</sup>。情感自动识别是实现人机交互的关键技术之一。脑电信号(electroencephalogram, EEG)是大量神经元电活动在大脑皮层表面产生的电位总和<sup>[2]</sup>。

收稿日期:2022-09-19

\*基金项目:国家自然科学基金(62201377)、山西省回国留学人员科研项目(2022-072)、山西省自然科学基金(201701D121058)、山西省回国留学科研项目(201701D121058)资助

基于脑电信号的情感识别可以避免情感伪装性,能够比较客观地评价人的情感状态,正逐渐成为人们研究的重点<sup>[3]</sup>。

随着深度学习的发展,传统的脑电情感识别系统已经逐渐被基于神经网络的脑电情感识别模型所取代。Yang等<sup>[4]</sup>设计了一种由4个卷积层和1个全连通层构成的连续卷积神经网络模型(continuous convolutional neural network,CCNN)来处理频率和空间信息。Wang等<sup>[5]</sup>设计了由三维(3D)卷积神经网络(convolutional neural networks,CNN)构建的EmotionNet,用来同时提取空间和时间域的特征。此外,循环神经网络(recurrent neural network,RNN)可以很好地处理脑电序列信息。如Yang等<sup>[2]</sup>构建了一种并行卷积递归神经网络(parallel convolutional recurrent neural network,PCRNN),使用CNN学习空间特征,长短时记忆(long short term memory,LSTM)学习时间特征,识别效果显著提升。3DC-BGRU模型<sup>[9]</sup>使用CNN对三维特征数据进行深层特征提取,对于深层特征的序列信息使用双向门控循环单元(bidirectional gated recurrent unit,BGRU)处理,分类准确率有所提高。虽然,CCNN、EmotionNet和PCRNN等模型的提出,都提升了脑电情感识别的效率,但都存在特征提取不足的问题。4DCRNN模型<sup>[11]</sup>充分考虑了空间、时间、频率3种信息,使用CNN学习空间和频率的信息,LSTM处理时间特征,得到了较好的识别效果。

结合上述分析,本文在4DCRNN模型的基础上改进,

提出了一种基于多层注意力机制<sup>[12]</sup>的4DC-BGRU脑电情感识别模型。在特征提取方面,将原始脑电信号转换成由多个时间切片组合而成的四维(4D)空间-频率-时间特征,解决脑电信息提取不足的问题。在网络模型方面,为了避免过拟合,防止梯度爆炸,提取包含更多信息的多尺度特征信息,本文设计了一种在卷积层及池化层后加入批量归一化(batch normalization,BN)层的双路CNN模型<sup>[13]</sup>,使用该模型对空间和频率信息进行学习。最后,为了学习更全面的上下级特征信息,并且针对各个时间切片之间存在一定的依赖、局部特征与整体特征之间存在关联性的特点,采用多层注意力机制-BGRU模型来处理时间特征。即分别对0.5 s时间特征片段和T/2 s时间特征片段引入BGRU和注意力机制并配合Softmax进行分类,从而有效利用4D特征中不同切片与整体时间切片之间的关系。最后,在DEAP数据集下开展实验研究,实验结果验证了该模型可以有效提升情感分类准确率,增强稳定性。

## 1 基于多层注意力机制的4DC-BGRU脑电情感识别

本文充分考虑脑电信号的空间、频率和时间3种信息,提出一种基于多层注意力机制的4DC-BGRU脑电情感识别模型,如图1所示为模型整体框架。主要包括4D空间-频率-时间特征模块双路CNN模块和多层注意力机制-BGRU模块3个模块。

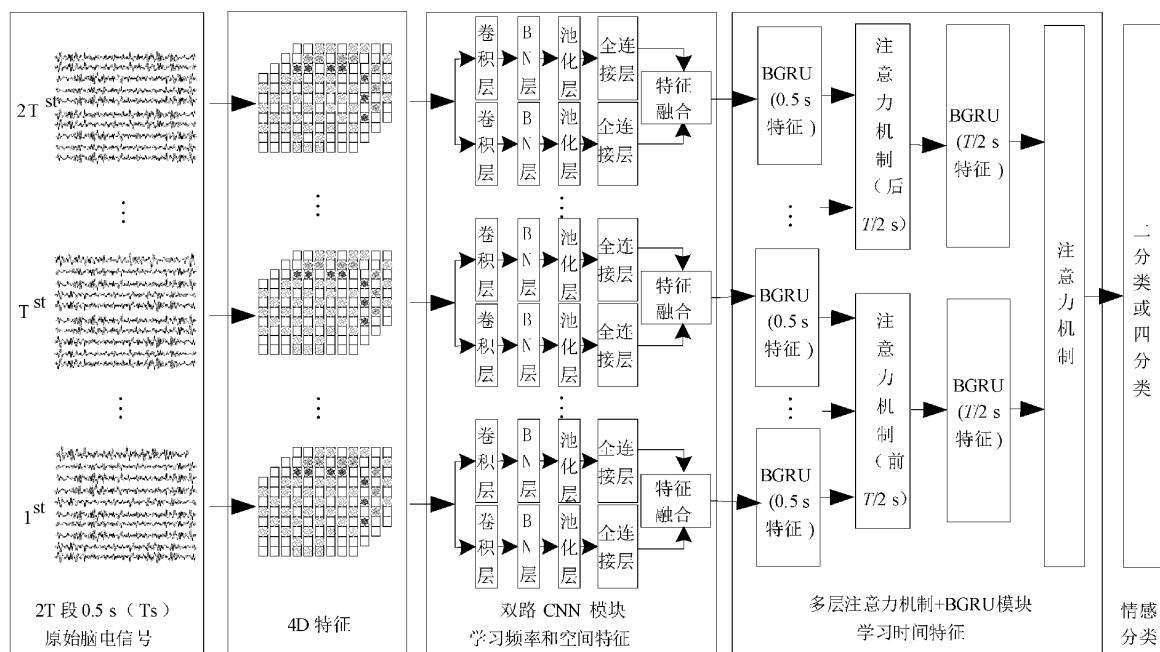


图1 基于多层注意力机制的4DC-BGRU脑电情感识别整体框架

4D空间-频率-时间特征模块:将脑电信号转化成一种包含频率、空间和时间特征的四维数据类型,提取更丰富的脑电信息。

双路CNN模块:从4D输入的每个时间切片中学习多尺度的频率和空间信息。多尺度卷积核分别为 $3 \times 3$ , $5 \times 5$ ,目的是分别提取局部细节信息的小尺度特征和整体

轮廓的大尺度特征,解决单条分支提取特征有限的问题,增加网络宽度学习更丰富的特征,弥补特征提取不足影响模型性能的问题;在学习特征信息时在卷积层及池化层后引入 BN 层,规范数据分布,防止过拟合,降低复杂度。

**多层次注意力机制-BGRU 模块:**BGRU 模块对上一模块提取的时间特征序列进行处理,学习更全面的前向、反向时序信息,更好地解决梯度消失的问题,加快训练速度。多层次注意力

机制使 4D 特征中不同时间切片与整体时间切片之间产生关联,即分别对 0.5 s 时间特征片段和  $T/2$  s 时间特征片段加入 BGRU 和注意力机制并配合 Softmax 进行分类。

### 1.1 4D 空间-频率-时间特征模块

为更好地运用脑电信号,本文使用 4D-CRNN 模型处理脑电信息来形成 4D 空间-频率-时间特征。4D 空间-频率-时间特征生成过程如图 2 所示。

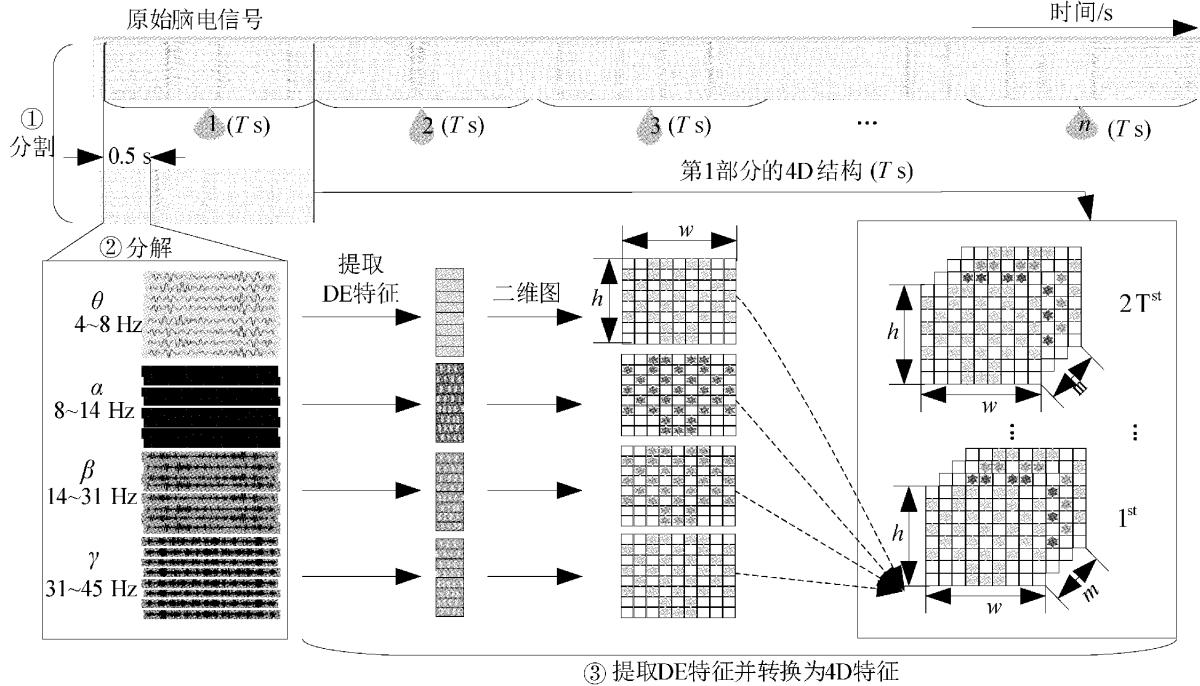


图 2 4D 空间-频率-时间特征图

1) 分割脑电信号:将原始脑电信号分割成不重叠的  $T$  s 片段,对每个片段分配原始脑电信号标签,并将不重叠的  $T$  s 片段又分割成  $2 T$  段  $0.5$  s 片段。

2) 分解  $0.5$  s 片段:使用巴特沃斯滤波器将每个片段分解为 4 个频带: $\theta[4\sim8\text{ Hz}]$ 、 $\alpha[8\sim14\text{ Hz}]$ 、 $\beta[14\sim31\text{ Hz}]$  和  $\gamma[31\sim45\text{ Hz}]$ 。

3) 提取微分熵(differential entropy, DE)特征并转换为

4D 结构:从每个  $0.5$  s 窗口的频带中提取 DE 特征,将提取的 DE 特征组成二维图,二维图映射关系如图 3 所示。然后不同波段的二维图堆叠成一个三维阵列,最后每个  $T$  s 片段都可以表示为 4D 结构  $\mathbf{X}_n \in R^{h \times w \times m \times 2T}$ ,  $n = 1, 2, \dots, N$ 。其中  $N$  是总样本数,  $h$  和  $w$  分别是 2 维图的高度和宽度,  $m$  表示分割的频带数,  $2T$  是指  $T$  s 片段被分割成没有重叠的  $0.5$  s 片段的段数。设置  $h=8, w=9, m=4, T=2$ 。

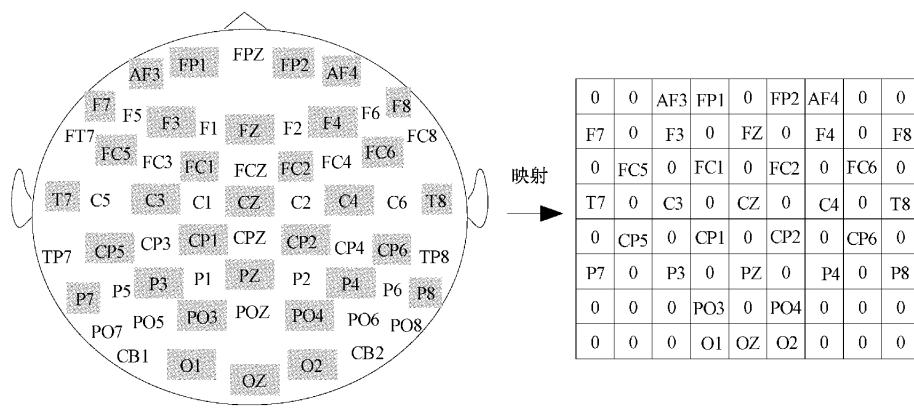


图 3 二维映射关系图

其中,DE 特征可以减小获取 EEG 高频信号时所产生的滤波误差<sup>[14]</sup>,提升模型后续的学习效果。DE 的定义为:

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

式中:  $x$  是随机变量;  $p(x)$  表示连续信息的概率密度函数。

高斯分布  $N(\mu, \delta^2)$  的 DE 特征计算<sup>[15]</sup>如下:

$$\begin{aligned} h(x) &= \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi\delta^2}} \exp \frac{(x-\mu)^2}{2\delta^2} \log \frac{1}{\sqrt{2\pi\delta^2}} \exp \\ &\frac{(x-\mu)^2}{2\delta^2} dx = \frac{1}{2} \log 2\pi e \delta^2 \end{aligned} \quad (2)$$

式中:  $x$  服从高斯分布  $N(\mu, \delta^2)$ ;  $e$  和  $\delta$  分别为欧拉常数和时间序列的标准差。

## 1.2 双路 CNN 模块构建

在学习 4D 空间-频率-时间信息时,网络再深的单路 CNN 模块也会存在特征提取有限的问题,增加网络宽度可以提取到更丰富的特征信息,因此,本文使用双路 CNN

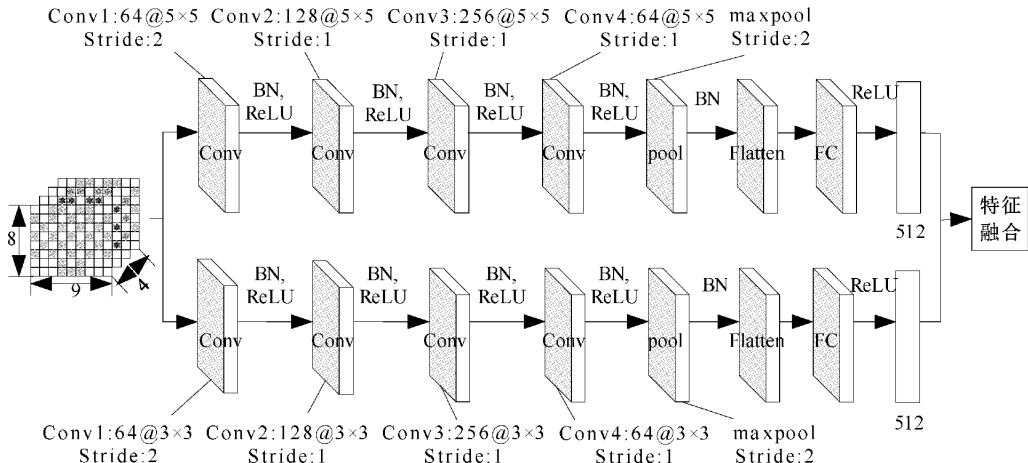


图 4 双路 CNN 模型框架图

## 1.3 多层注意力机制-双向门控循环单元模块

经过双路 CNN 模块后,得到了一种序列形式的脑电信号特征,即  $\mathbf{O}_n = (\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_{2T})$ , 其中  $\mathbf{o}_i = R^{2 \times 512}, i = 1, 2, \dots, 2T$ 。本文通过多层注意力机制-BGRU 来探索内部段之间的时间依赖性。

分别对 0.5 s 的特征片段和  $T/2$  s 的特征片段加入 BGRU 和注意力机制,来研究时间相关性。图 5 所示为多层注意力机制-BGRU 模块 ( $T=2$ ),该算法框架主要包括输入层  $\mathbf{O}_n$ 、多层次 BGRU 特征提取层、多层次注意力机制层和情感分类输出层。其中,输入特征是经过双路 CNN 模型后得到的一系列脑电信号特征。

### 1) 多层 BGRU 特征提层

经过上述 4DCNN 模块得到了一种序列形式的脑电信号特征。LSTM 和门控循环单元(gated recurrent unit, GRU)可以很好地处理序列信息。与 LSTM 相比,GRU 模型高效简单,训练速度更快,解决梯度消失的能力更强。

模块从每个时间切片 ( $\mathbf{L}_i \in R^{h \times w \times m}, i = 1, 2, \dots, 2T$ ) 中提取空间和频率特征。针对数据集较大、收敛速度较慢的问题,本文在双路 CNN 模型的卷积层及最大池化层后面加入 BN 层,规范数据分布,加快网络收敛速度,防止过拟合。

如图 4 所示,双路 CNN 模型的两个分支分别采用不同尺寸的卷积核来提取特征信息,多尺度卷积核分别为  $3 \times 3, 5 \times 5$ ,目的是提取局部细节信息的小尺度特征和整体轮廓的大尺度特征。不同分支的 4 个卷积层的卷积核个数都相同,分别是:64,128,256,64;步长为:2,1,1,1。对于所有卷积层,采用零填充和修正线性单元(rectified linear units, ReLU)激活函数。最大池化层中池化核大小为  $2 \times 2$ ,步长为 2,起到减轻过拟合、增强网络鲁棒性的作用。最后,每个支路的池化层输出被展平并馈送到具有 512 个单元的全连接层(fully connected layer, FC),将两个分支的输出进行特征融合,最终输出的  $\mathbf{O}_n \in R^{2 \times 512 \times 2T}$  是原始脑电片段的频率和空间表示。

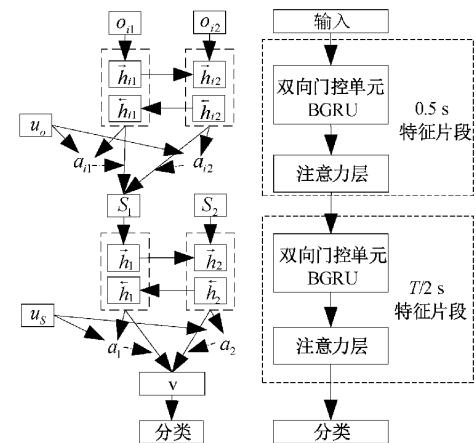


图 5 多层注意力机制-BGRU 模型框架

但是 GRU 不能兼顾上下文信息,因此,本文使用 BGRU 模块对序列信号进行学习。BGRU 的模型结构如图 6 所示。

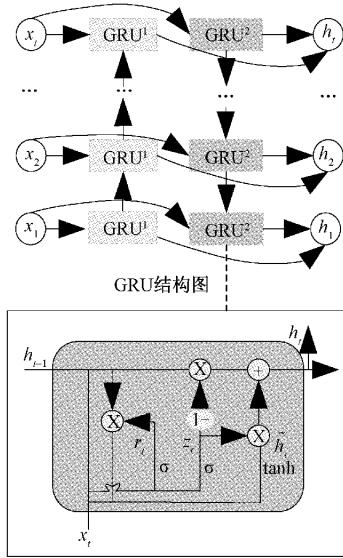


图 6 BGRU 模型

BGRU 的公式为：

$$h_t = [\text{GRU}^1(x_t) \oplus \text{GRU}^2(x_t)] \quad (3)$$

式中：GRU 通过重置门  $r_t$  和更新门  $z_t$  来处理序列信息，其公式如下：

$$r_t = \sigma(W_r x_t + U_r h_{t-1}) \quad (4)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1}) \quad (5)$$

$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t \odot h_{t-1})) \quad (6)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (7)$$

式中： $\tilde{h}_t$  是  $t$  时刻候选激活单元； $h_t$  是  $t$  时刻隐藏单元； $\sigma$  是 sigmoid 激活函数； $W_r, W_z, U_r, U_z, U_h$  是各个神经元的参数； $\odot$  表示 Hadamard 积。

## 2) 多层注意力机制

脑电信息对不同情感抽取的影响可能来源于某个时间段。另外，BGRU 模型虽然解决了关系抽取中的长期依赖问题，但其对脑电信息局部特征和全局特征的利用不充分。因此，本文引入了多层注意力机制，具体实现方法如下。

按照不重叠的 0.5 s 时间片段和  $T/2$  s ( $T=2$ ) 时间片段进行划分，然后分别对这两个时间片段使用注意力机制，增强局部特征与全局特征。通过不断调整计算，分权求和，最后求出最终影响较大的权重特征，提高情感分类的识别效果。

基于 0.5 s 特征时间片段的注意力机制：

$$u_t = \tanh(W_u \cdot h_t + b_u) \quad (8)$$

$$a_t = \frac{\exp(u_t^\top u_o)}{\sum_i \exp(u_i^\top u_o)} \quad (9)$$

$$s = \sum_i a_i u_i \quad (10)$$

式中： $u_t$  表示 BGRU 输出  $h_t$  的隐藏单元； $a_t$  表示通过 Softmax 归一化得到更新后的权重系数； $u_o$  表示初始训练

参数； $s$  表示第  $i$  个  $T/2$  s 时间片段的向量。

基于  $T/2$  s 特征时间片段的注意力机制：

$$u_i = \tanh(W_s \cdot h_i + b_s) \quad (11)$$

$$a_i = \frac{\exp(u_i^\top u_s)}{\sum_t \exp(u_t^\top u_s)} \quad (12)$$

$$v = \sum_i a_i u_i \quad (13)$$

对于  $T/2$  s 特征时间片段，计算方法跟上述类似，最后通过双层注意力机制，输出得到整个  $T$  s 时间段基于 0.5 s 和  $T/2$  s 时间特征片段的情感特征向量  $v \in R^{128}$ 。

## 3) 情感分类输出层

分类器主要由全连接层和 Softmax 分类器组成。将最后的特征向量  $v$  输入到全连接层：

$$N_i = FC(v) \quad (14)$$

最后，将  $N_i$  输入到用于情感识别的 Softmax 分类器：

$$P_i = \text{softmax}(N_i) \quad (15)$$

$$\text{softmax}(x) = \frac{\exp(x)}{\sum \exp(x)} \quad (16)$$

式中： $P_i$  表示脑电图片段  $X_n$  属于某一类情感的概率。

## 2 实验分析

### 2.1 实验数据

DEAP 数据集包含 32 通道脑电信号及 8 通道外围生理信号，本文只采用 32 通道脑电信号作为实验数据，首先以 512 Hz 采样，128 Hz 复采样，然后通过 4~45 Hz 的带通滤波器过滤噪声及去除 EOG 伪像。它记录了 32 名健康参与者的脑电数据，包括被试观看 40 个时长为 1 min 的音乐视频的生理信号及观看视频后对唤醒度、效价、喜好和主导程度的评价。

本文只选择在唤醒度和效价二个维度上进行测试。每个维度的评分阈值为 5，以此将标签类型分为二类。另外，还在二个维度上进行了四分类实验<sup>[16]</sup>。本文采用 2 s ( $T=2$ ) 无重叠的时间窗对 40 个 60 s 脑电图进行分段处理，因此每个被试都获得 1 200 个样本。

### 2.2 实验结果及分析

实验采用的硬件设备是 NVIDIA GeForce GTX 1050 GPU，软件环境为 Python 3.6，神经网络模型由 TensorFlow+Keras 框架搭建。优化器为适应性动量估计算法 (adaptive moment estimation, Adam)，学习率是 0.001。选择交叉损失函数作为分类器的损失函数。batch size 为 128，epoch 为 100。

本文使用 DEAP 数据集中所有被试的数据进行二分类和四分类实验，采用五重交叉验证技术评估模型分类性能。所有被试的平均准确率 (accuracy, ACC) 和标准差 (standard deviation, STD) 表示该方法的最终性能。

$$ACC = \frac{\sum_{j=1}^5 p_{ij}}{5} \quad (17)$$

$$STD = \sqrt{\frac{\sum_{j=1}^5 (p_{ij} - ACC)}{5}} \quad (18)$$

式中:  $p_{ij}$  表示五重交叉验证后脑电片段  $\mathbf{X}_n$  属于某一类情感的概率。

为了更全面地分析多层注意力机制的 4DC-BGRU 模型的分类效果, 使用 DEAP 数据集, 从不同模型实验结果及其他研究方法所得到的结果两个方面进行分析。

### 2.3 模型实验

为得到本文模型, 选择合适的网络参数, 对模型的不同网络结构参数进行对比实验, 找到准确率最高的模型。

1) 首先探究 BN 层对模型性能的影响, 比较评价指标(平均 ACC 和 STD), 找出最合适的组合。模型采用单尺度空间结构, 卷积核参数分别为  $5 \times 5, 5 \times 5, 3 \times 3, 1 \times 1$ , 且步长分别为  $2, 1, 1, 1$ ; 使用 GRU 学习时间特征, 表 1 所示为不同 BN 层的实验结果。

表 1 不同 BN 层实验结果

不同 BN 层	(效价二分类) 平均 ACC ± STD / %
不加 BN 层	94.21 ± 1.22
4 个卷积层后加 BN 层	94.56 ± 1.18
4 个卷积层和池化层后加 BN 层	94.81 ± 1.04

如表 1 所示, 4 个卷积层和池化层后加 BN 层的准确率比较高, 并且标准差比较小, 具有较好的稳定性。

2) 其次探究单路改进 CNN 模块中不同卷积核参数对模型性能的影响。测试时在卷积层和池化层后加 BN 层, 卷积层的步长分别为  $2, 1, 1, 1$ ; 使用 GRU 学习时间特征。选择识别效果最好的一组。表 2 所示为不同卷积核参数的实验结果。

表 2 不同卷积核参数实验结果

各个卷积核参数	(效价二分类) 平均 ACC ± STD / %
$5 \times 5, 5 \times 5, 4 \times 4, 1 \times 1$	94.17 ± 1.61
$3 \times 3, 5 \times 5, 3 \times 3, 1 \times 1$	93.89 ± 1.55
$3 \times 3, 3 \times 3, 3 \times 3, 1 \times 1$	93.66 ± 1.03
$3 \times 3, 5 \times 5, 3 \times 3, 1 \times 1$	93.21 ± 1.41
$5 \times 5, 5 \times 5, 3 \times 3, 1 \times 1$	94.81 ± 1.04

如表 2 所示, 卷积核参数过小, 或者过大, 都会对准确率和标准差有一定程度的影响, 选择平均 ACC 较大, STD 较小的模型, 即: 各个卷积核参数分别是:  $5 \times 5, 5 \times 5, 3 \times 3, 1 \times 1$ 。

3) 其次探究增加网络宽度及改变尺度空间对模型性能的影响。在单路改进 CNN 模块的基础上再增加一路分

支, 更改不同支路的尺度空间, 观察识别效果, 表 3 所示为改变网络宽度和尺度空间对模型性能影响的实验结果。表 3 中改进 CNN-GRU 模型是表 1 和 2 效果最好的一个模型。尺度空间表示不同支路的各个卷积核参数。

表 3 改变网络宽度和尺度空间对模型性能影响实验结果

模型结构	尺度空间	(效价二分类) 平均 ACC ± STD / %
单路改进 CNN-GRU	$5 \times 5, 5 \times 5, 3 \times 3, 1 \times 1$	94.81 ± 1.04
双路 CNN-GRU	$5 \times 5, 5 \times 5, 3 \times 3, 1 \times 1$ $3 \times 3, 3 \times 3, 3 \times 3, 3 \times 3$	95.94 ± 1.15
双路 CNN-GRU	$5 \times 5, 5 \times 5, 5 \times 5, 5 \times 5$ $3 \times 3, 3 \times 3, 3 \times 3, 3 \times 3$	96.10 ± 1.05

如表 3 第 1、2 行所示, 增加网络宽度, 可以有效提升识别效果。由表 3 第 2、3 行可知, 虽然其中一条支路选择单路模型效果最好的一组, 但是并不能充分提取特征, 调整尺度空间大小, 提取多尺度特征, 识别效果有所提升。平均 ACC 比单路模型提升了 1.29%, 标准差较小, 模型比较稳定。

4) 最后探究加入 BGRU 和多层注意力机制对模型识别效果的影响。在表 3 的基础上, 引入多层注意力机制, 将 GRU 改为 BGRU, 得到本文模型。表 4 所示为不同模型的实验结果。

表 4 不同模型实验结果

模型结构	(效价二分类) 平均 ACC ± STD / %
改进 CNN-GRU	94.81 ± 1.04
单路 改进 CNN-GRU + 多层注意力机制	95.06 ± 1.25
双路 改进 CNN-BGRU + 多层注意力机制	95.92 ± 1.08
双路 CNN-GRU	96.10 ± 1.05
双路 CNN-GRU + 多层注意力机制	96.35 ± 1.13
双路 CNN-BGRU + 多层注意力机制	96.73 ± 1.09

如表 4 所示, 多层注意力机制可以更好地探索时间依赖性, 充分利用了脑电信息的局部特征和全局特征; BGRU 能够提取前向、反向时序信息, 解决关系抽取中的长期依赖问题, 能有效提高分类准确率。

### 2.4 不同研究方法对比

为了进一步验证本文方法的有效性, 分别将本文模型与其他相关文献模型在唤醒度和效价维度上进行二分类实

验,对比结果如表 5 所示。由表 5 可知,CCNN 和 PCRNN 两种模型提取 2 种信息,相比其他提取空间、时间和频率

3 种信息的模型,表现不佳,表明信息的利用度对识别效果有影响,3 种信息的结合利用可以更好地识别情感。

表 5 6 种方法在唤醒度和效价维度上二分类的平均准确率

模型	平均 ACC $\pm$ STD/%		信息
	唤醒度	效价	
CCNN <sup>[4]</sup>	89.80 $\pm$ 2.76	90.50 $\pm$ 2.98	频率+空间
PCRNN <sup>[7]</sup>	90.26 $\pm$ 2.88	90.98 $\pm$ 3.09	空间+时间
3DCNN-BLSTM <sup>[17]</sup>	93.56	93.21	空间+时间+频率
4D-CRNN <sup>[11]</sup>	94.22 $\pm$ 2.61	94.58 $\pm$ 3.69	空间+时间+频率
改进 CNN-BGRU+多层注意力机制(单路)	95.61 $\pm$ 1.02	95.92 $\pm$ 1.08	空间+时间+频率
双路 CNN-BGRU+多层注意力机制	96.38 $\pm$ 1.04	96.73 $\pm$ 1.09	空间+时间+频率

PCRNN、3DCNN-BLSTM<sup>[17]</sup>、4D-CRNN 模型表明 CNN 配合 LSTM、GRU 等循环神经网络能够很好地处理脑电序列信息。双路 CNN-BGRU+多层注意力机制模型结合以上模型优点,并引入 BGRU+多层注意力机制,兼顾前向、反向信息,探索时间相关性,使得在唤醒度和效价维度上实现的二分类识别效果有所提升。

进一步将本文模型与其他相关文献模型进行四分类实验,实验结果如表 6 所示。从实验结果可以看出,在情感分类中,CNN 配合 RNN 有良好的分类性能,本文采用双路 CNN-BGRU+多层注意力机制,在四分类实验中,准确率达到 93.78%,并且标准差较小,模型稳定。

表 6 5 种方法在四分类实验的平均准确率

模型	平均 ACC $\pm$ STD/%
3D 分层卷积(单模态) <sup>[18]</sup>	89.15 $\pm$ 0.059 5
3DCNN-BLSTM <sup>[17]</sup>	90.97
4D-CRNN <sup>[11]</sup>	91.35 $\pm$ 1.61
改进 CNN-BGRU+多层 注意力机制(单路)	92.86 $\pm$ 1.08
双路 CNN-BGRU+多层注意力机制	93.78 $\pm$ 1.05

本文模型在 DEAP 数据集上的实验结果如图 7 所示。

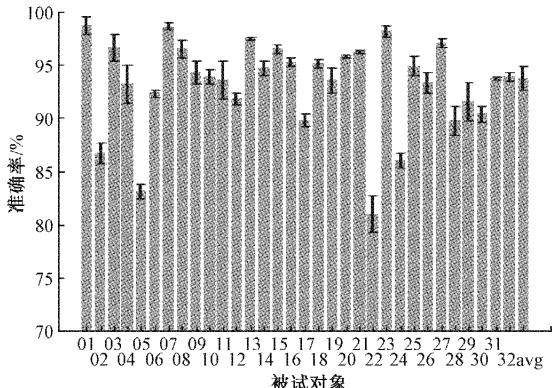


图 7 脑电情感四分类平均准确率

图 7 的横轴为 32 名被试,纵轴为所有被试的脑电情感四分类平均准确率,黑色线条为标准差值。

### 3 结 论

为了解决训练速度慢,过拟合,提取信息不充分以及情感识别率不高等问题,本文提出了一种基于多层注意力机制的 4DC-BGRU 脑电情感识别方法。不重叠的四维空间、频率和时间结构可以充分利用脑电信息;双路卷积神经网络增加网络宽度获取更丰富的信息,提取多尺度空间、频率特征;卷积层及池化层后加入 BN 层用于规范数据分布,防止梯度爆炸,提高学习效率;BGRU 用于学习更全面的前向、反向脑电时序信息,更好地解决梯度消失的问题;多层注意力机制使 4D 特征中不同时间切片与整体时间切片之间产生关联,增强局部特征与全局特征。实验证明,本文模型能有效提高脑电情感识别的准确率。

### 参考文献

- [1] ANDREASSON R, ALENJUNG B, BILLING E, et al. Affective touch in human-robot interaction: Conveying emotion to the nao robot[J]. International Journal of Social Robotics, 2018, 10(3):473-491.
- [2] 郭湛超,覃玉荣,龙安. 基于视觉通路的脑电信号频谱能量分布研究[J]. 电子测量技术, 2016, 39(9):149-152.
- [3] JENKE R, PEER A, BUSS M. Feature extraction and selection for emotion recognition from EEG[J]. IEEE Transactions on Affective Computing, 2017, 5(3):327-339.
- [4] YANG Y, WU Q, FU Y, et al. Continuous convolutional neural network with 3D input for EEG-based emotion recognition[C]. The 25th International Conference on Neural Information Processing, 2018, DOI:10.1007/978-3-030-04239-4\_39.
- [5] WANG Y, HUANG Z, MCCANE B, et al. EmotioNet: A 3-D convolutional neural network for EEG-based

- emotion recognition [C]. 2018 International Joint Conference on Neural Networks(IJCNN), 2018:1-7.
- [6] 李少波,姚勇,桂桂,等.基于 CNN 与多通道声学信号的齿轮故障诊断[J].中国测试,2019,45(10):1-5.
- [7] 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), 2018:1-7.
- [8] 陈思佳,罗志增.基于长短时记忆和卷积神经网络的手势肌电识别研究[J].仪器仪表学报,2021,42(2):162-170.
- [9] 胡章芳,刘鹏飞,蒋勤,等.基于 3DC-BGRU 的脑电情感识别[J].计算机工程与应用,2020,56(20):111-117.
- [10] 张昌凡,刘佳峰,何静,等.基于改进卷积双向门控循环网络的轴承故障诊断[J].电子测量与仪器学报,2021,35(11):61-67.
- [11] SHEN F, DAI G, LIN G, et al. EEG-based emotion recognition using 4D convolutional recurrent neural network[J]. Cognitive Neurodynamics, 2020, 14: 815-828.
- [12] YANG Z, YANG D, DYER C, et al. Hierarchical attention networks for document classification [C]. Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2016:1480-1489.
- [13] 胡城豪,胡昌华,司小胜,等.基于 MSCNN-LSTM 的滚动轴承剩余寿命预测方法[J].中国测试,2020,46(9):103-110.
- [14] 柳长源,李文强,毕晓君.基于脑电信号的情绪特征提取与分类[J].传感技术学报,2019,32(1):86-92.
- [15] ZHENG W L, ZHU J Y, LU B L. Identifying stable patterns over time for emotion recognition from EEG[J]. Affective Computing, IEEE Transactions on, 2017, 10:417-429.
- [16] YIN Z, ZHAO M Y, WANG Y X, et al. Recognition of emotions using multimodal physiological signals and an ensemble deep learning model [J]. Computer Methods and Programs in Biomedicine, 2017, 140: 93-110.
- [17] 蔡冬丽,钟清华,朱永升,等.基于混合神经网络的脑电情感识别[J].华南师范大学学报(自然科学版),2021,53(1):109-118.
- [18] 凌文芬,陈思含,彭勇,等.基于 3D 分层卷积融合的多模态生理信号情绪识别[J].智能科学与技术学报,2021,3(1):76-84.

### 作者简介

张丽彩,硕士研究生,主要研究方向为脑电情感识别。  
E-mail:1746142702@qq.com

李鸿燕(通信作者),博士,教授,主要研究方向为信号与信息处理。  
E-mail:tylhy@163.com

司马飞扬,硕士研究生,主要研究方向为抑郁症情感识别。  
E-mail:1073815026@qq.com

申雁,硕士研究生,主要研究方向为语音识别。  
E-mail:2314547664@qq.com