

基于 EEG 和 DE-CNN-GRU 的情绪识别^①



赵丹丹, 赵倩, 董宜先, 谭浩然

(曲阜师范大学 工学院, 日照 276826)

通信作者: 赵倩, E-mail: zhaoq0620@126.com

摘要: 近年, 情绪识别研究已经不再局限于面部和语音识别, 基于脑电等生理信号的情绪识别日趋火热。但由于特征信息提取不完整或者分类模型不适应等问题, 使得情绪识别分类效果不佳。基于此, 本文提出一种微分熵 (DE)、卷积神经网络 (CNN) 和门控循环单元 (GRU) 结合的混合模型 (DE-CNN-GRU) 进行基于脑电的情绪识别研究。将预处理后的脑电信号分成 5 个频带, 分别提取它们的 DE 特征作为初步特征, 输入到 CNN-GRU 模型中进行深度特征提取, 并结合 Softmax 进行分类。在 SEED 数据集上进行验证, 该混合模型得到的平均准确率比单独使用 CNN 或 GRU 算法的平均准确率分别高出 5.57% 与 13.82%。

关键词: 脑电信号; 情绪识别; 微分熵 (DE); 卷积神经网络-门控循环单元 (CNN-GRU)

引用格式: 赵丹丹, 赵倩, 董宜先, 谭浩然. 基于 EEG 和 DE-CNN-GRU 的情绪识别. 计算机系统应用, 2023, 32(4): 206–213. <http://www.c-s-a.org.cn/1003-3254/9041.html>

Emotion Recognition Based on EEG and DE-CNN-GRU

ZHAO Dan-Dan, ZHAO Qian, DONG Yi-Xian, TAN Hao-Ran

(College of Engineering, Qufu Normal University, Rizhao 276826, China)

Abstract: In recent years, research on emotion recognition has no longer only focused on facial and voice recognition, and emotion recognition according to electroencephalogram (EEG)-based physiological signals is becoming increasingly popular. However, due to the incomplete extraction of feature information or the maladjustment of classification models, the classification effect of emotion recognition is poor. Therefore, this study proposes a hybrid model combining differential entropy (DE), convolutional neural network (CNN), and gated recurrent unit (GRU), namely, DE-CNN-GRU, to study EEG-based emotion recognition. The pre-processed EEG signals are divided into five frequency bands, and their DE features are extracted as preliminary features, which are then input to the CNN-GRU model for deep feature extraction and further classified by using Softmax. The hybrid model is tested on the SEED dataset. The result shows that the average accuracy obtained by the hybrid model is 5.57% and 13.82% higher than that obtained by using the CNN or GRU algorithm, respectively.

Key words: electroencephalogram (EEG) signal; emotion recognition; differential entropy (DE); convolutional neural network-gated recurrent unit (CNN-GRU)

情绪是生物针对内部及外部事物的刺激而做出的一系列反应, 且情绪的存在对于生物而言至关重要。近些年, 各个行业对情绪识别的需求不断增长, 在医疗方

面, 情绪识别可以辅助心理疾病及精神疾病的研和治疗^[1], 此外, 通过情绪识别可以对病患的情感状态进行适当评估, 为医生制定合适的治疗方案提供极有利

① 基金项目: 山东省科技厅重大创新工程 (2019JZZY011111); 全国大学生创新训练项目 (S202010446028)

收稿时间: 2022-08-29; 修改时间: 2022-09-30; 采用时间: 2022-10-27; csa 在线出版时间: 2022-12-09

CNKI 网络首发时间: 2022-12-15

帮助。同时，情绪识别在 VR 游戏用户体验、实时监测驾驶员情绪状态^[2] 及特定犯人的审问等各个领域均发挥了重大作用。目前，情绪识别主要通过人的面部表情或者肢体动作等非生理信号进行研究，相较而言，基于脑电 (electroencephalogram, EEG)、肌电 (electromyography, EMG) 以及心电 (electrocardiogram, ECG) 等生理信号的情绪识别研究还不够成熟。然而，由于生理信号能够更好地避开伪装等假性情绪，可以更加准确地识别人的真实情感，故基于生理信号的情绪识别正逐渐成为研究的热点^[3]。

其中，基于脑电的情绪识别过程一般包括脑电信号的采集、脑电信号的预处理、特征提取和情绪识别 4 部分。目前，不同型号的脑电信号采集系统之间的最大区别在于电极材料及放置方法不同。电极主要包括湿电极和干电极两大类^[4]，而本文用于模型验证的 SEED 数据集是通过使用湿电极帽的 NeuroScan ESI-128 系统^[5] 采集的。脑电信号预处理先通过滤波器去除信号中工频噪声干扰，再去除眼电、肌电及心电等伪迹干扰，去除伪迹的主要方法有傅里叶变换 (fast Fourier transform, FFT)、小波变换 (wavelet transform, WT) 及独立成分分析 (independent component analysis, ICA) 等^[6]。本文主要通过 ICA 去除眼电伪迹干扰。准确实时的特征提取对于脑电情绪识别结果具有一定的影响，用于情绪识别的脑电特征主要包括时域特征、频域特征、时频域特征及空间域特征，本文提取频域特征作为分类模型的输入信号。

基于脑电信号的情绪识别算法主要包括机器学习算法和深度学习算法。传统的机器学习算法，如支持向量机 (support vector machine, SVM)、K-近邻 (K-nearest neighbor, KNN) 和决策树 (decision tree, DT) 等，理论发展成熟，在情绪识别方面已经取得了一定的研究成果。例如，骆金晨等^[7] 采用希尔伯特黄变换、一对多共空间模式、近似熵、模糊熵和样本熵等多种特征融合算法，通过主成分分析降维，使用粒子群优化 SVM 对国际标准数据集 BCI2005 Data set IIIa 中的 k3b 受试者数据进行分类处理得到 93.30% 的准确率，之后采用此方法对 4 名实验者的脑电数据进行分类，得到 72.96% 的平均识别率。Bhardwaj 等^[8] 采用 SVM 及 Fisher 判别式的线性判别分析 (linear discriminant analysis, LDA) 对 7 种情感对应的脑电信号特征进行判别分析，获得的平均分类准确率分别为 74.13% 和 66.50%。

深度学习算法主要包括卷积神经网络 (convolutional neural network, CNN) 和循环神经网络 (recurrent neural network, RNN) 两类，在脑电信号识别中亦得到了广泛应用，并且相较于机器学习，其识别率普遍更高。如官金安等^[9] 采用 3DCNN 对 IR-BCI 的靶刺激和非靶刺激进行分类，得到了 85.2% 的平均准确率。Qiao 等^[10] 采用 CNN 的方法对 DEAP 数据集进行情绪识别，得到了 87.27% 的平均识别率。Zheng 等^[11] 采用深度信念网络 (deep belief network, DBN) 代替传统的分类器对脑电情感进行分类，识别率达到 86.08%。

然而，若局限于使用单一的神经网络算法进行情绪分类识别，会导致脑电信号的时间空间域信息不完整。为解决这一问题，一些研究人员首先提出 CNN 与长短时期记忆神经网络 (long short term memory, LSTM) 结合，并取得良好的应用效果。蔡冬丽等^[12] 提出一种 3DCNN 结合双向 LSTM 的混合神经网络 (3DCNN-BLSTM)，并在 SEED 数据集上验证，得到 98% 的准确率。为解决 LSTM 的参数较多导致训练时间过长的问题，提出以门控循环单元 (gated recurrent unit, GRU) 代替 LSTM 进行时序特征提取。目前，采用 CNN 与 GRU 结合的混合神经网络主要应用在非生理信号方面的情感识别。如 Swain 等^[13] 采用级联 CNN 和 GRU 结合的混合模型 (CGRU) 对采用语音信号的韵律和频谱特征进行语音情感识别，并在 Odia 语言数据集上面验证，发现使用 CGRU 算法比单独使用 CNN 与 GRU 提高了 5.36% 与 6.52% 的准确率。Cheng 等^[14] 提出采用多通道卷积与双向 GRU 多头注意力胶囊混合模型提取文本序列的多层次特征，在情感分类通用语料库中的 3 个英文数据集和一个中文数据集进行实验，取得比其他基线模型更好的结果。而在生理信号的脑电情绪识别中应用较少，用于基于脑电的情绪分类研究中更少。黄永庆等^[15] 构建了 CNN-GRU 模型对原始脑电信号进行情绪识别，虽然在公开数据集中验证获得 89.20% 的准确率，然而在自采数据集上仅获得 83.76% 的辨识率，结果表明预处理和特征提取过程对分类结果具有一定的影响。

故本文在此基础上进行改进，增加初步特征提取过程，将初步特征提取过程与 CNN 和 GRU 结合，提出一种混合特征提取分类模型 DE-CNN-GRU。首先对原始数据集的微分熵 (differential entropy, DE) 进行初步特征提取，删减部分无用信息，保留有效特征。随后将

其输入到 CNN-GRU 网络模型, 进一步提取时间与空间域特征信息, 以解决特征信息提取不完整问题, 最终结合 Softmax 进行情绪分类。在 SEED 数据集上验证该模型的有效性, 获得分类准确率最高为 98.9%。整体

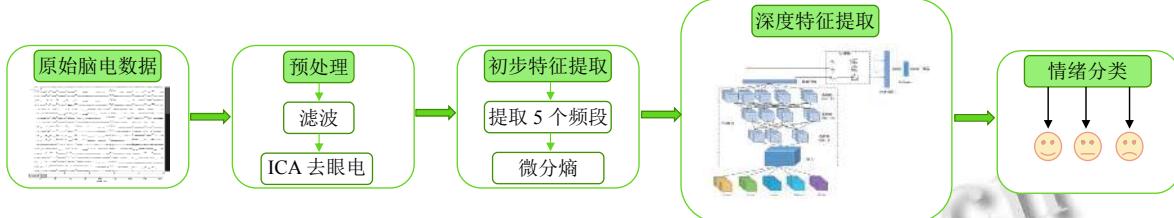


图 1 DE-CNN-GRU 基本框架

1 算法原理

1.1 微分熵

DE 主要是用于描述连续变量的复杂性, 其计算公式如下:

$$DE = - \int_X f(x) \log(f(x)) dx \quad (1)$$

其中, X 表示随机变量, $f(x)$ 是它的概率密度函数。在一个固定频段内, EEG 信号的分布可以近似为高斯分布 $N(\mu, \sigma^2)$ ^[16], 故而 EEG 信号的 DE 可以简化为以下公式:

$$\begin{aligned} DE &= - \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \log\left(\frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{(x-\mu)^2}{2\sigma^2}}\right) dx \\ &= \frac{1}{2} \log(2\pi e \sigma^2) \end{aligned} \quad (2)$$

本文将经过预处理的脑电数据集分为 alpha、beta、delta、gamma 及 theta 这 5 个频段, 再分别提取 DE 特征, 对于某一频带 DE 特征可表示为如下公式^[17]:

$$DE = \frac{1}{2} \log(P_i) + \frac{1}{2} \log\left(\frac{2\pi e}{N}\right) \quad (3)$$

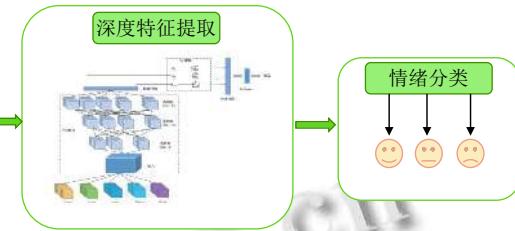
其中, P_i ($i = 1, 2, \dots, N$) 是频谱能量值。

1.2 卷积神经网络

CNN 是由卷积层 (Conv)、池化层 (pooling) 和全连接层 (FC) 构成, 如图 2 所示。卷积处理有两个特性, 即权值共享和局部连接。权值共享是指其通过每个卷积核进行卷积计算, 输出不同的特征, 可见想要获得所需要的特征信息, 必须要选择合适的卷积核。局部连接是指输入中的每个神经元与前一层的局部感受野连接在一起, 对局部进行感知, 综合局部信息作为全局信息。每个卷积层都包含一个激活函数对提取的特征进行非线性变换, 本文选择线性整流函数 (ReLU) 作为卷积层中的激活函数。池化层也称为下采样层, 可以有效减少

实验框架如图 1 所示。

本文主要工作如下: 第 1 节简单介绍相关算法原理; 第 2 节介绍整体的实验过程; 第 3 节对实验结果进行分析与对比; 第 4 节为总结。



神经网络中的参数, 以防止过拟合^[18]。在 CNN 的末端需要连接一个全连接层, 全连接层的每个神经元都与前一层的神经元相连接, 将前层计算得到的多维特征向量映射为一维的向量, 以减少由于特征位置排布对于分类结果的影响, 提高了整个网络的鲁棒性。

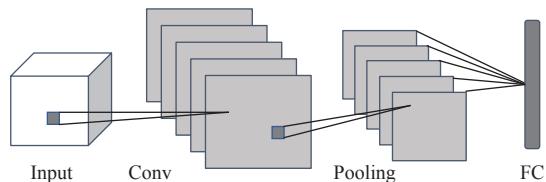


图 2 CNN 的结构图

1.3 门控循环单元

GRU 是由 Cho 等人提出的 LSTM 的一种改进的神经网络^[19], 与 LSTM 一样, 可以解决 RNN 中出现的梯度消失问题。GRU 的原理与 LSTM 非常相似, 且在很多情况下表现出的实际效果相差无几。两者不同之处在于, GRU 只有两个门: 一个是将 LSTM 中的输入门与遗忘门合二为一的更新门, 控制前面记忆信息能够继续保留到当前时刻的数据量; 另一个是重置门, 主要控制要遗忘多少过去的信息。LSTM 需要多个门控控制“遗忘”和“记忆”, 而 GRU 只需要一个门控, 所以 GRU 的参数量比 LSTM 少, 能够很大程度上提高训练效率。图 3 展示了 GRU 的基本内部结构, 其表达式如下所示:

$$z_t = \sigma(W_z \times [h_{t-1}, x_t]) \quad (4)$$

$$r_t = \sigma(W_r \times [h_{t-1}, x_t]) \quad (5)$$

$$\tilde{h}_t = \tanh(W_h \times [r_t \times h_{t-1}, x_t]) \quad (6)$$

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

其中, $\sigma(\cdot)$ 与 $\tanh(\cdot)$ 分别是 Sigmoid 函数与双曲正切函

数, x_t 是指当前节点的输入; h_{t-1} 是上一节点传递下来的隐状态, 包含了之前节点的相关信息; z_t 为控制更新的门控状态; r_t 为控制重置的门控状态; \tilde{h}_t 主要是包含 x_t 的数据信息, 作为输出的一部分; W_z 、 W_r 与 $W_{\tilde{h}}$ 分别为 z_t 、 r_t 与 \tilde{h}_t 的权重.

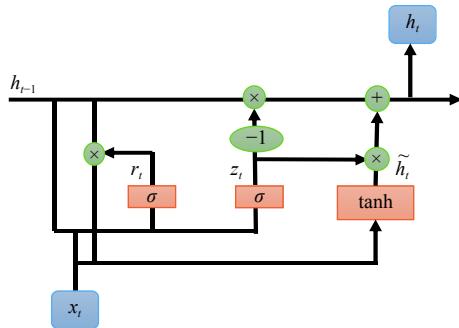


图3 GRU的内部结构图

2 实验过程

2.1 实验平台

本实验全过程均在 Intel(R) Core(TM) i5-12400F 4.4 GHz 处理器、GPU 为 NVIDIA RTX3060 的环境下, 使用 Python 3.7 编程语言以及 TensorFlow 深度学习框架进行的.

2.2 数据集

实验采用上海交通大学的公开数据集 SEED 数据集^[20]作为原始数据集, 进行积极、消极以及中性的三分类情绪识别研究. 受试者一共 15 名(7 名男性, 8 名女性, 平均年龄 23.27), 每位受试者需要进行 3 次实验, 并且每两次实验间隔一周及以上. 每次实验需要观看 15 个电影片段, 故每次实验共有 15 个实验 trials. 这些电影片段是从 6 部电影中截取的, 代表了 3 种不同情绪, 其中每种情绪包括 5 个片段, 每个片段大约 4 min, 且同一种情绪的片段不会连续播放. 表 1 是数据集采集所需要的刺激视频的详细信息. 每个受试者的脑电信号均有 62 个通道, 根据国际 10-20 标准系统的 62 通道的电极分布如图 4 所示. 之后对采集的脑电信号进行下采样处理, 将信号频率从 1000 Hz 降到 200 Hz, 并用 0~75 Hz 的带通滤波器进行滤波处理, 得到预处理后的数据集. 本文将预处理后的数据集进一步通过 ICA 去除眼电信号的干扰, 如图 5 所示. 图 5(a) 是原始脑电信号图, 尖峰突出, 有明显的眨眼伪迹, 图 5(b) 是经过 ICA 去眼电干扰后的信号图, 尖峰消失, 明显比左侧图信号平稳, 有效去除眼电伪迹.

表1 实验中所需影片的详细信息

影片编号	情绪标签	影片名字	时间片段
1	积极	泰囧	0:06:13~0:10:11; 1:05:10~1:08:29
2	积极	唐伯虎点秋香	1:18:57~1:23:23
3	积极	月光宝盒	0:11:32~0:15:33; 0:35:00~0:39:02
			0:00:50~0:04:36; 0:02:59~0:06:40;
4	中性	世界遗产在中国	0:05:36~0:09:36; 0:10:40~0:13:44; 0:10:41~0:14:41
			0:49:58~0:54:00;
5	消极	回到1942	2:01:21~2:05:21; 2:16:37~2:20:37
6	消极	唐山大地震	0:20:10~0:23:35; 1:48:53~1:52:18

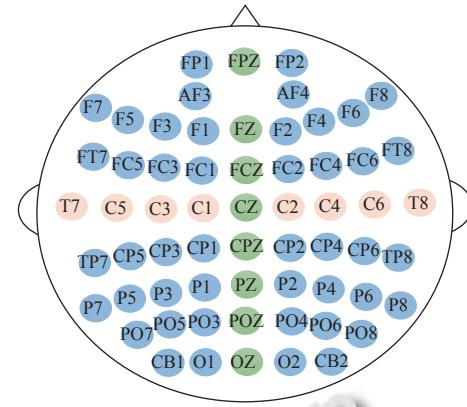


图4 62通道电极分布图

2.3 特征提取

尽管 CNN 与 GRU 均可以直接对原始脑电信号进行特征提取及分类, 但为保证特征信息的完整性, 在将数据输入至 CNN-GRU 模型之前, 提取 DE 特征作为初始特征. 首先将经过滤波以及 ICA 去眼电后的脑电信号分为 delta (0.5~3.5 Hz)、theta (4~7 Hz)、alpha (8~13 Hz)、beta (14~30 Hz) 及 gamma (31~50 Hz) 这 5 个频段信号, 图 6 为第 1 位受试者的 FP1 通道的 5 个频段图. 之后对 5 个频段分别提取 DE 特征^[21], 每个频段每个通道每隔 1 s 取一次. 由于 SEED 数据集中 15 个情绪片段的截取时长不同, 所以每个 trial 的采样点数不同. 其中, 代表中性情绪的第 5 个 trial 的采样点数最小, 为 185. 故本文为统一起见, 以 185 为标准, 将每位受试者的 DE 特征构建为 $62 \times 185 \times 5$ 的三维特征矩阵. 将其输入到 CNN-GRU 结合网络模型中进行深度时间空间域特征提取.

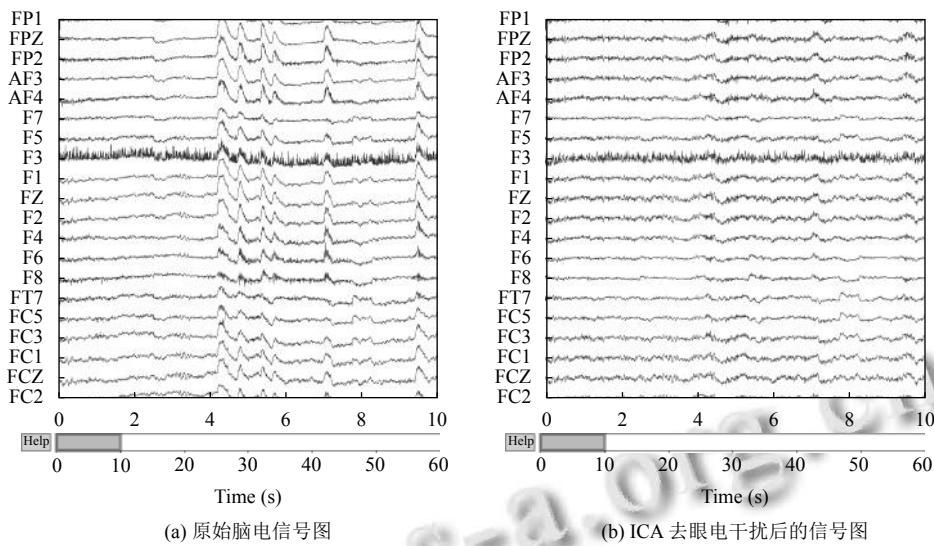


图 5 ICA 去眼电前后脑电信号对比图

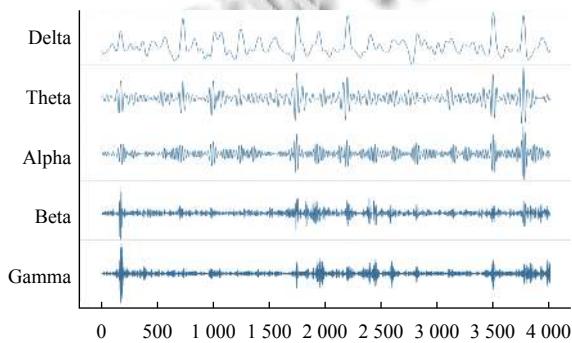


图 6 第 1 位受试者的 FP1 通道的 5 个频段波形图像

2.4 DE-CNN-GRU 混合网络模型

DE-CNN-GRU 混合模型结构框架如图 7 所示。首先将 *DE* 特征输入到 CNN 模块的卷积层中提取脑电信号的空间信息，并在卷积层之后增加一个池化层，减少一定的参数，以便提取更加有用的脑电信息。之后将通过 CNN 模块提取到的空间信息进行维度变换，由三维矩阵转变为适合输入到 GRU 模块的二维矩阵，通过 GRU 模块提取时间域信息。最后通过 Softmax 函数进行情绪识别分类。

整个 DE-CNN-GRU 网络模型包含 3 个卷积层，3 个最大池化层，2 个全连接层及 1 个 GRU 层。3 个卷积层均以 ReLU 作为激活函数，卷积核为 3×3 ，填充方式为“same”，代表填充输入以使输出具有与原始输入相同的长度^[22]。最大池化层的池大小为 2×2 ，步长为 2×2 。GRU 层的激活函数为 tanh，输出维度设置为 128，

GRU 后面的全连接层的输出维度为 128，之后使用 Softmax 函数进行三分类，如表 2 所示。

本文所提模型的参数设置如下：迭代次数为 1000 次，优化器选择 Adam 优化器用于学习，其学习率为 $1E-4$ ，损失函数为交叉熵损失函数，评估标准是准确率。训练集及测试集是按照 7:3 的比例进行划分，输入到 DE-CNN-GRU 中进行训练。

3 实验结果与分析

3.1 实验结果

将 15 名受试者的 *DE* 特征输入 CNN-GRU 混合模型，在混合模型中进行训练。通过该模型进一步提取空间时间信息，输入到 Softmax 函数中进行情绪三分类（积极、中性和消极）。图 8 为经过 1000 次迭代后每位受试者的分类准确率的柱形图。由图 8 可知，第 15 位受试者的分类准确率最高，可达 98.9%，由此可验证该模型在基于脑电的情绪识别研究中的有效性。此外，该实验结果表明，有些受试者的分类准确率较低，而有些受试者的分类准确率很高，究其原因，可能是由于每个人对于刺激的反应强度不同导致数据差异性大小不同，分类效果亦不同。

3.2 混合模型与单一模型的比较

CNN-GRU 模型是 CNN 与 GRU 两个单一模型结合成的混合模型，为证明该混合模型的分类效果优于单一模型，本文设计 DE-CNN、DE-GRU 两个单一模型的实验进行对比分析，为保证单一变量，两个单一模

型只有最后的分类算法与混合模型不同,前面的预处理阶段以及DE特征提取阶段都与之相同。3种不同模型的分类准确率如图9所示,图9结果表明DE-CNN-GRU混合模型对15位受试者的分类准确率普遍高于DE-CNN、DE-GRU两个单一模型。这3种模型的平均分类准确率如表3所示,可知,DE-CNN-GRU混合模型的分类能力优于DE-CNN与DE-GRU单一模型,由此可见,通过更好地提取时间与空间信息特征,DE-CNN-GRU混合模型对于脑电情绪识别具有更优的效果。

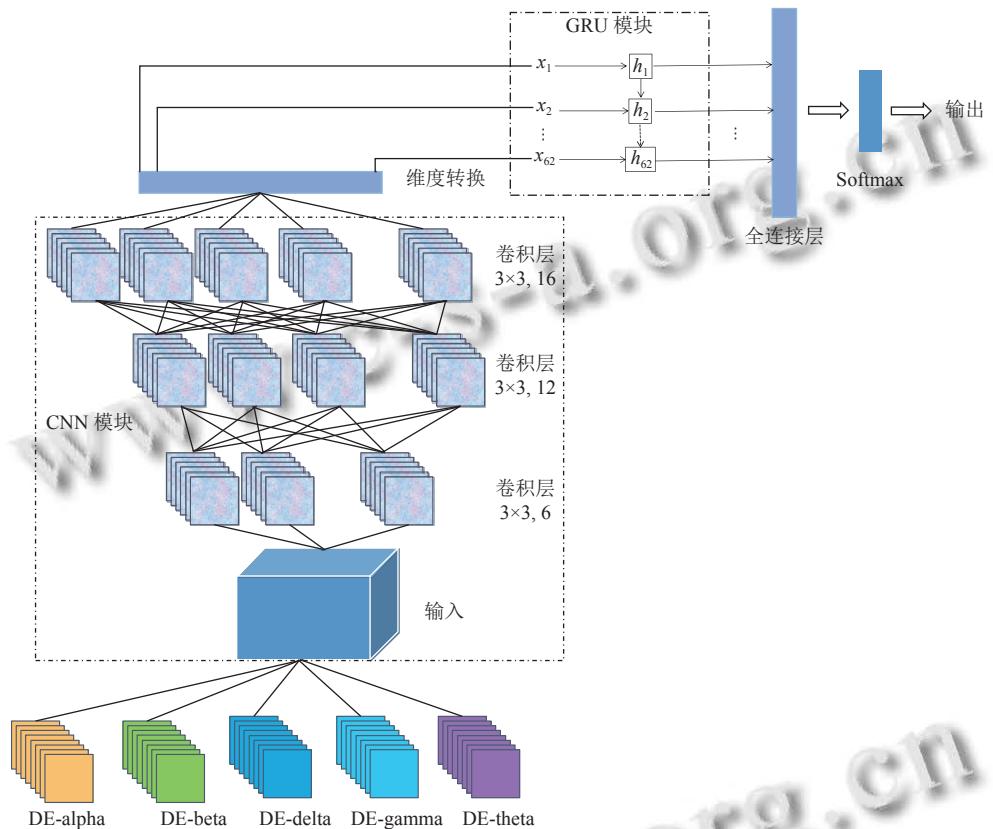


图7 DE-CNN-GRU混合模型结构框架

表2 混合网络结构的具体细节

当前层数	层类型	过滤器数量	卷积核或池化大小	步长	激活函数
1	卷积层	6	3×3	1×1	ReLU
2	最大池化层	—	2×2	2×2	—
3	卷积层	12	3×3	1×1	ReLU
4	最大池化层	—	2×2	2×2	—
5	卷积层	16	3×3	1×1	ReLU
6	最大池化层	—	2×2	2×2	—
7	GRU层	—	—	—	tanh
8	全连接层	—	—	—	ReLU
9	全连接层	—	—	—	Softmax

3.3 与其他算法的比较

为了进一步验证本文DE-CNN-GRU模型的有效性与优越性,将其与已有文献中提到的情绪识别算法结构进行对比分析,结果如表4所示。Badicu等^[23]对

原始脑电数据集使用LSTM进行分类,得到80.00%的识别准确率。Li等^[24]采用CNN和LSTM的混合循环神经网络(CLRNN)对DEAP数据集进行分类,得到的准确率为75.21%。Ren等^[25]采用K-means算法与WT进行特征提取,SVM作为分类器,得到78.20%的准确率。Brown等^[26]将左右电极alpha频段的功率比作为特征,采用KNN算法进行分类处理得到82.00%的准确率。Gonzalez等^[27]采用CNN作为分类器在DEAP数据集上进行分类任务,得到唤醒度为72.42%,效价度为70.26%,表4只列出了该算法得到的唤醒度结果。与之相比,本文的混合模型比单一模型更加完整地提取脑电特征信息,提高了分类准确率。为进一步验证本文所提混合算法DE-CNN-GRU的有效性与优越性,将

其与 Li 等^[28]所提出的和本文思路类似的混合模型 WT-CNN-RNN 进行比较。Li 等利用稀疏 WT 将原始脑电信号变换成二维频谱图输入 CNN-RNN 混合网络，在效价和唤醒度两个维度上的准确率分别为 72.06% 和 74.12%，同样，表 4 只列出唤醒度结果。由表 4 可知，本文所提出的混合模型对基于脑电信号的情绪识别研究得到的平均准确率为 86.50%，明显优于大多数算法模型的分类结果。

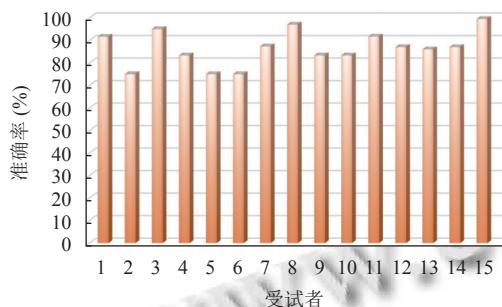


图 8 15 位受试者的三分类准确率

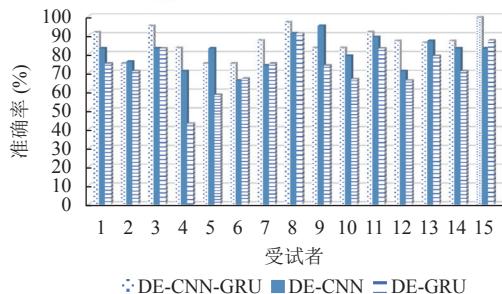


图 9 不同模型的分类准确率对比分析

表 3 3 种模型的平均分类准确率

方法	平均准确率 (%)
DE-CNN	80.93
DE-GRU	72.68
DE-CNN-GRU	86.50

表 4 与其他研究算法的比较

文献	算法	准确率 (%)
[23]	LSTM	80.00
[24]	CLRNN	75.21
[25]	K-means-WT-SVM	78.20
[26]	Alpha 功率比-KNN	82.00
[27]	CNN	72.42
[28]	WT-CNN-RNN	74.12
本文	DE-CNN-GRU	86.50

4 总结

本文以脑电信号为研究对象进行情绪识别研究，

采用 DE-CNN-GRU 混合模型进行特征提取与分类。通过两次特征提取，即初步提取 DE 特征后进一步深度提取时间空间信息，以保证时空域特征信息的完整性，最后通过 Softmax 函数进行分类。在国际公开数据集 SEED 上验证该混合模型的效果，取得了 86.50% 的平均分类准确率。通过与 DE-CNN 或 DE-GRU 两个单一模型进行对比，可证明混合模型的平均准确率优于单一模型，分别高出 5.57% 与 13.82%。同时，与其他算法进行比较，发现本文提出的混合模型对情绪分类的效果是优于大多已有算法的，证明了该混合模型的适应性和有效性。此外，该混合模型的参数及结构仍然具备一定的提升空间，这将在今后的研究工作中进一步讨论。

参考文献

- 王晴. 基于脑电信号的情绪分类 [硕士学位论文]. 北京: 北京邮电大学, 2019.
- 王浩伦, 朱业安, 彭理群, 等. 汽车驾驶人的情绪诱发与识别研究综述. 交通信息与安全, 2018, 36(4): 1–6, 50. [doi: 10.3963/j.issn.1674-4861.2018.04.001]
- Jenke R, Peer A, Buss M. Feature extraction and selection for emotion recognition from EEG. IEEE Transactions on Affective Computing, 2014, 5(3): 327–339. [doi: 10.1109/TAFFC.2014.2339834]
- 赵倩, 谭浩然, 王西岳, 等. 脑电采集电极研究进展. 科学技术与工程, 2021, 21(15): 6097–6104. [doi: 10.3969/j.issn.1671-1815.2021.15.002]
- 滕凯迪, 赵倩, 谭浩然, 等. 基于 SVM-KNN 算法的情绪脑电识别. 计算机系统应用, 2022, 31(2): 298–304. [doi: 10.15888/j.cnki.csia.008332]
- 杜晓燕, 李颖洁, 朱贻盛, 等. 脑电信号伪迹去除的研究进展. 生物医学工程学杂志, 2008, 25(2): 464–467, 471. [doi: 10.3321/j.issn:1001-5515.2008.02.048]
- 骆金晨, 姜月, 胡秀枋, 等. 基于多特征融合的多分类运动想象脑电信号识别研究. 生物信息学, 2020, 18(3): 176–185. [doi: 10.12113/201912006]
- Bhardwaj A, Gupta A, Jain P, et al. Classification of human emotions from EEG signals using SVM and LDA classifiers. Proceedings of the 2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN). Noida: IEEE, 2015. 180–185. [doi: 10.1109/SPIN.2015.7095376]
- 官金安, 汪鹭汐, 赵瑞娟, 等. 基于 3D 卷积神经网络的 IR-BCI 脑电视频解码研究. 中南民族大学学报(自然科学版), 2019, 38(4): 538–546. [doi: 10.12130/znmddzk.20190411]
- Qiao R, Qing CM, Zhang T, et al. A novel deep-learning

- based frame-work for multi-subject emotion recognition. Proceedings of the 2017 4th International Conference on Information, Cybernetics and Computational Social Systems. Dalian: IEEE, 2017. 181–185. [doi: [10.1109/ICCSS.2017.8091408](https://doi.org/10.1109/ICCSS.2017.8091408)]
- 11 Zheng WL, Guo HT, Lu BL. Revealing critical channels and frequency bands for emotion recognition from EEG with deep belief network. Proceedings of the 2015 7th International IEEE/EMBS Conference on Neural Engineering (NER). Montpellier: IEEE, 2015. 154–157. [doi: [10.1109/NER.2015.7146583](https://doi.org/10.1109/NER.2015.7146583)]
- 12 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. 华南师范大学学报(自然科学版), 2021, 53(1): 109–118. [doi: [10.6054/j.scenun.2021017](https://doi.org/10.6054/j.scenun.2021017)]
- 13 Swain M, Maji B, Das U. Convolutional gated recurrent units (CGRU) for emotion recognition in Odia Language. Proceedings of the IEEE EUROCON 2021 19th International Conference on Smart Technologies. Lviv: IEEE, 2021. 269–273. [doi: [10.1109/EUROCON52738.2021.9535608](https://doi.org/10.1109/EUROCON52738.2021.9535608)]
- 14 Cheng Y, Sun H, Chen HM, et al. Sentiment analysis using multi-head attention capsules with multi-channel CNN and bidirectional GRU. IEEE Access, 2021, 9: 60383–60395. [doi: [10.1109/ACCESS.2021.3073988](https://doi.org/10.1109/ACCESS.2021.3073988)]
- 15 黄永庆, 周强. 基于 CNN-GRU 融合网络的情绪脑电信号辨别研究. 传感技术学报, 2021, 34(8): 1109–1116. [doi: [10.3969/j.issn.1004-1699.2021.08.016](https://doi.org/10.3969/j.issn.1004-1699.2021.08.016)]
- 16 陈万, 蔡艳平, 李爱华, 等. 基于脑电微分熵的警觉度估计方法. 计算机应用研究, 2022, 39(8): 2347–2351. [doi: [10.19734/j.issn.1001-3695.2022.01.0021](https://doi.org/10.19734/j.issn.1001-3695.2022.01.0021)]
- 17 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. 传感技术学报, 2021, 34(4): 496–503. [doi: [10.3969/j.issn.1004-1699.2021.04.011](https://doi.org/10.3969/j.issn.1004-1699.2021.04.011)]
- 18 Liu FG, Zhang ZW, Zhou RL. Automatic modulation recognition based on CNN and GRU. Tsinghua Science and Technology, 2022, 27(2): 422–431. [doi: [10.26599/TST.2020.9010057](https://doi.org/10.26599/TST.2020.9010057)]
- 19 Cho K, Van Merriënboer B, Bahdanau D, et al. On the properties of neural machine translation: Encoder-decoder approaches. Proceedings of the 8th Workshop on Syntax, Semantics and Structure in Statistical Translation. Doha: Association for Computational Linguistics, 2014. 103–111. [doi: [10.3115/v1/W14-4012](https://doi.org/10.3115/v1/W14-4012)]
- 20 Zheng WL, Lu BL. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks. IEEE Transactions on Autonomous Mental Development, 2015, 7(3): 162–175. [doi: [10.1109/TAMD.2015.2431497](https://doi.org/10.1109/TAMD.2015.2431497)]
- 21 Duan RN, Zhu JY, Lu BL. Differential entropy feature for EEG-based emotion classification. Proceedings of the 2013 6th International IEEE/EMBS Conference on Neural Engineering. San Diego: IEEE, 2013. 81–84. [doi: [10.1109/NER.2013.6695876](https://doi.org/10.1109/NER.2013.6695876)]
- 22 张学军, 陈都, 孙知信. 基于卷积神经网络的脑电信号情绪分类方法. 电子测量技术, 2022, 45(1): 1–7. [doi: [10.19651/j.cnki.emt.2108357](https://doi.org/10.19651/j.cnki.emt.2108357)]
- 23 Badicu B, Udrea A. Cross-subjects emotions classification from EEG signals using a hierarchical LSTM based classifier. Proceedings of the 2019 E-Health and Bioengineering Conference. Iasi: IEEE, 2019. 1–4. [doi: [10.1109/EHB47216.2019.8969881](https://doi.org/10.1109/EHB47216.2019.8969881)]
- 24 Li YJ, Huang JJ, Zhou HY, et al. Human emotion recognition with electroencephalographic multidimensional features by hybrid deep neural networks. Applied Sciences, 2017, 7(10): 1060. [doi: [10.3390/app7101060](https://doi.org/10.3390/app7101060)]
- 25 Ren FJ, Dong YD, Wang W. Emotion recognition based on physiological signals using brain asymmetry index and echo state network. Neural Computing and Applications, 2019, 31(9): 4491–4501. [doi: [10.1007/s00521-018-3664-1](https://doi.org/10.1007/s00521-018-3664-1)]
- 26 Brown L, Grundlehner B, Penders J. Towards wireless emotional valence detection from EEG. Proceedings of the 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Boston: IEEE, 2011. 2188–2191. [doi: [10.1109/IEMBS.2011.6090412](https://doi.org/10.1109/IEMBS.2011.6090412)]
- 27 Gonzalez HA, Yoo J, Elfadel IM. EEG-based emotion detection using unsupervised transfer learning. Proceedings of the 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Berlin: IEEE, 2019. 694–697. [doi: [10.1109/EMBC.2019.8857248](https://doi.org/10.1109/EMBC.2019.8857248)]
- 28 Li X, Song DW, Zhang P, et al. Deep fusion of multi-channel neurophysiological signal for emotion recognition and monitoring. International Journal of Data Mining and Bioinformatics, 2017, 18(1): 1–27. [doi: [10.1504/IJDMB.2017.086097](https://doi.org/10.1504/IJDMB.2017.086097)]

(校对责编: 牛欣悦)