

半监督元学习在意识障碍患者情绪识别中的应用

李景聪, 陈希昶, 黄海云

(华南师范大学软件学院, 广东 佛山 528225)

摘要: 情绪识别是脑机接口一个主流的应用方向, 有着巨大的研究潜力。然而, 被试之间存在的生理差异会使脑电信号差异较大, 并且意识障碍(DOC)患者的有标签情绪脑电数据极为稀缺。为此, 提出一个利用少量有标签数据和大量无标签数据来实现跨被试情绪识别任务的模型, 并结合半监督与元学习方法微调模型, 以提升数据利用率。在自采数据集上的实验表明, 所提模型识别正常人、DOC患者情绪的准确率分别为82.93%、59.26%, 证实了该方法在跨被试情绪识别任务和DOC患者诊断中的潜力巨大。

关键词: 情绪识别; 脑机接口; 跨被试; 脑电图; 元学习; 半监督

DOI: 10.11907/rjdk.241215

中图分类号: TP18

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2025)004-0012-06



Application of Semi-supervised Meta-learning on the Emotion Recognition of Patients with Disorder of Consciousness

LI Jingcong, CHEN Xichang, HUANG Haiyun

(School of Software, South China Normal University, Foshan 528225, China)

Abstract: Emotion recognition is a mainstream application direction of brain-computer interface, which has great research potential. However, the physiological differences between participants can lead to large differences in EEG signals, and labeled emotional EEG data in patients with impaired consciousness (DOC) are extremely scarce. Therefore, a model using a small amount of labeled data and a large amount of unlabeled data to realize the cross-participant emotion recognition task was proposed, and the model was fine-tuned by combining semi-supervised and meta-learning methods to improve data utilization. Experiments in the self-collected dataset show that the accuracy of the proposed model in identifying emotions in normal people and DOC patients is 82.93% and 59.26%, respectively, which confirms that the method has great potential in the cross-participant emotion recognition task and the diagnosis of DOC patients.

Key Words: emotion recognition; brain computer interface; cross subject; electroencephalogram; meta-learning; semi-supervised

0 引言

为了更好地识别人类情感, 越来越多情绪识别技术被应用于各个领域^[1]。情绪识别可分为基于非生理信号的情绪识别和基于生理信号的情绪识别。其中, 非生理信号包括面部表情、身体姿势或声音等^[2-4]; 生理信号包括脑电图、肌电图和心电图等^[5-7]。

由于脑损伤或脑溢血可能会导致意识障碍(Disorders

of Consciousness, DOC), 包括昏迷、植物人状态(Vegetative State, VS)、最低意识状态(Minimal Conscious State, MCS)和从MCS苏醒(Emergence from MCS, EMCS)。目前, 临床上对于DOC患者的诊断更多的是基于行为量表, 依赖患者对外部刺激的反应, 但该方法的误诊率较高, 原因为DOC患者通常具有严重的运动障碍, 无法提供足够的反馈, 使得医生无法有效检测DOC患者的情绪状态^[8]。

生理信号相较于非生理信号而言, 可靠性更高, 原因为人类有可能会不自觉地隐藏自己的真实情绪, 或因严重的

收稿日期: 2024-03-08

扫描二维码阅读全文:



基金项目: 国家自然科学基金项目(62306120)

作者简介: 李景聪(1991-), 男, 博士, 华南师范大学软件学院副教授, 研究方向为机器学习、深度学习与混合神经网络等; 陈希昶(2000-), 男, 华南师范大学软件学院硕士研究生, 研究方向为机器学习、深度学习与混合神经网络等; 黄海云(1993-), 男, 博士, 华南师范大学软件学院副研究员, 研究方向为模式识别、脑机接口及其临床应用。本文通讯作者: 黄海云。

运动障碍导致反馈较少。脑电图是生理信号的一种,能实时反映人体神经活动,因此相较于其他方法更适用检测DOC患者的情绪状态。

然而,被试之间存在的生理差异会使脑电信号差异较大,并且意识障碍(DOC)患者的有标签情绪脑电数据极为稀缺。为此,本文提出一个利用少量有标签数据和大量无标签数据来实现跨被试情绪识别任务的模型,并结合半监督与元学习方法微调模型,提升数据利用率。

1 相关工作

Musha等^[9]首先提出基于脑电图的情绪识别研究。近年来,越来越多基于脑电图的情绪识别方法被提出^[10]。目前,情绪识别方法通常包含两个步骤:①处理原始脑电图以提取有效特征;②利用提取的特征对情绪进行分类。

特征提取是从原始数据中提取更多与情绪相关的信息,以提升模型识别准确率。目前,常见的特征包括时域特征和频域特征,脑电图的时域特征可通过取平均值、标准差等方法进行提取;频域特征则可将脑电图分解为多个频段,例如 θ 频段(1~3 Hz)、 α 频段(4~7 Hz)、 β 频段(14~30 Hz)和 γ 频段(31~50 Hz)^[12],划分完成后即可从每个频带中提取特征。

基于脑电图常用的情绪特征包括微分熵(differential entropy, DE)、功率谱密度(Power Spectral Density, PSD)、有理不对称(Rational Asymmetry, RASM)、微分不对称(Differential Asymmetry, DASM)^[11-14]。Li等^[15]认为卷积神经网络(Convolutional Neural Network, CNN)是一种在图像识别领域表现良好的深度神经网络(Deep Neural Network, DNN)。Cheah等^[16]利用残差网络优化VGG网络来分类不同电极的脑电图信号,以识别与情感最相关的电极通道。Yin等^[17]使用长短期记忆(The Long Short-Term Memory, LSTM)方法提取脑电图在更长时间中的时间特征,从而提升模型识别情绪的能力。

然而,时域特征并不能完全反映脑电图的所有情绪信息。为此,Chen等^[18]提出双半球差异模型(Bi-Hemispheric Discrepancy Model, BIHDM),学习大脑中两个半球之间脑电图的不对称差异。随着深度学习发展,研究者发现该模型能自动提取数据更深层次的特征,甚至相较于手动提取的特征更远。Hospedales等^[19]提出元学习算法,甚至可以取代人工设计算法模型。

近年来,越来越多研究人员将元学习与半监督方法应用到脑电图情绪识别领域。其中,元学习可优化多个时期的学习算法,提升模型性能^[20]。具体操作为,首先通过学习深度学习模型学到的经验来优化模型,也就是学习如何学习;其次通过模型无关元学习(Model Agnostic Meta Learning, MAML)减少被试间的生理性差异,提升脑电图跨被试情绪识别的准确性,即学习如何初始化参数,以在

一个在验证集上得到表现良好的分类器^[21,22]。

虽然元学习方法擅长使用少量数据微调模型,但数据的选择具有随机性。Tang等^[23]提出的元迁移学习方法可使用少量数据进行元学习优化,缓解跨被试任务中脑电图数据不足的问题。Van等^[24]提出的半监督学习方法介于有监督学习与无监督学习之间,可使用大量无标签数据和少量有标签数据进行实验。Chapelle等^[25]使用半监督方法与任务相关的无标签数据来提升模型性能。Li等^[26]利用半监督方法评估脑电图样本和特征重要性,显著提升了模型性能。综上,上述方法首先使用有标签数据预训练基本模型,其次通过该模型预测无标签数据,最后对无标签数据进行分类,以增加有标签数据的数量,适用于获取有标签数据较困难的脑电图等场景中。

在实际应用中,由于情绪脑电信号采集需要被试观看诱发情绪的视频,然后利用脑电采集设备采集被试的情绪脑电数据,因此需要昂贵的设备、配合的被试和足够的实验时间^[27]。然而,意识障碍患者通常无法很好地配合实验,因此此类有标签的脑电图很难被收集。为此,本文提出一个利用少量有标签数据与大量无标签数据来实现跨被试情绪识别任务的模型,并结合半监督与元学习方法微调模型,提升数据利用率。简而言之,本文使用少量的有标签数据与大量的无标签数据,便可找到脑电图特征与目标对象相似的源对象。

2 本文方法

由于不同被试的生理差异及缺少标签数据是跨被试脑电情绪识别任务进展困难的原因^[28]。为此,本文提出半监督元学习方法(Semi-Supervised Meta Learning, SSML),首先在源被试的数据中训练模型,其次将模型迁移到目标被试中进行实验,如图1所示。其中,模型无关元学习可提升模型学习效率和分类性能;伪标签旨在通过预测新被试的数据,以筛选出高质量的数据来优化模型性能^[29]。




Fig. 1 Semi-supervised meta-learning method

图1 半监督元学习方法

2.1 模型无关元学习

元学习是指学习如何学习,即通过学习大量任务并从这些任务中提取共同特征,进而快速适应新任务。与模型无关的元学习(Model-Agnostic Meta-Learning, MAML)是

一种在没有先验知识的情况下,在多个任务上进行元学习的算法。该方法相较于其他优化方法而言,在生理信号特征提取方面具有良好的表现,更适合跨被试的情绪识别任务^[30,31]。MAML的优势在于一些内部表征相较于其他表征更容易迁移,例如数据集 $D = \langle S, Q \rangle$ 中 $S = \{(X_s, Y_s)\}$ 是源被试的脑电图数据 X_s 和对应标签 Y_s 的支持集, $Q = \{(X_q)\}$ 是由目标被试的无标签数据 X_q 组成的查询集。

本文针对脑电图情绪识别中的被试迁移学习问题,首先使用支持集学习模型,其次将模型应用于目标主题来预测查询集的标签。模型参数 θ^* 的优化公式为:

$$\theta^* = \operatorname{argmax}_{\theta} \mathbb{E}_{(x,y) \in S} [p_{\theta}(y|x)] \quad (1)$$

式中: p 代表分类器将给定样本 x 分类到 S 中的特定类别 y 的后验概率; θ^* 为单个被试的优化参数; $\mathbb{E}$ 为最大化支持集的期望,用来优化模型。

另外,优化后的模型可应用目标主题来预测查询集的标签。例如, MAML 算法由一个支持集的 N_s 个元被试 $S = \{(X_s, Y_s)\}_{s=1}^{N_s}$ 来学习一个元学习器,通过给定一个参数为 θ 的模型 f_{θ} , 通过梯度下降方法优化模型,如式(2)所示。

$$\theta_i^* \leftarrow \theta - \alpha \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta}) \quad (2)$$

式中: $\mathcal{L}$ 为模型输出的预测值与给定数据 $\mathcal{T}_i$ 的第 i 个源被试的损失; ∇_{θ} 为损失计算的梯度; α 为学习率。

为了将模型更好地迁移到新的被试中,使用训练后的模型 f_{θ} 分类新被试的无标签数据分类,并与源被试进行比较,从源被试 S 的每个分类中选择和新被试最接近的 M 个被试作为子集,以训练出一个元学习器。元学习器参数可根据源被试数据的平均值来优化模型。

$$\theta \leftarrow \theta - \beta \nabla_{\theta} \sum_{\mathcal{T}_j \in S} \mathcal{L}_{\mathcal{T}_j}(f_{\theta_j}) \quad (3)$$

式中: $\mathcal{T}_j$ 代表支持集 S 的第 i 个被试的第 j 个分类; β 为训练元学习器的学习率。

由于大部分元学习方法都需要使用新的被试标记数据来微调当前模型,但少量有标签样本无法保证能准确反映整体的分布,因此需要对元学习训练数据进行选择,使训练数据分布与新被试数据接近。此外,引入半监督方法,利用少量样本与大量无标记样本对模型进行训练^[32]。

2.2 半监督元学习方法

如图1所示, SSML 方法可分为预训练阶段和半监督微调阶段。在预训练阶段,模型训练的损失函数结合了中心损失函数与交叉熵损失函数。预训练模型又可分为基础模型和线性模块两个部分,基础模型负责处理输入的 EEG 数据并提取特征向量,线性模块则对特征向量进行分类预测。中心损失函数的目的是学习每个分类对应的分类特征中心,并对特征向量与对应分类中心之间的距离进行惩罚,因此每个分类中心都使用源被试的数据训练所得。模型训练损失函数的计算公式为:

$$\mathcal{L}_c = \frac{1}{2n} \sum_{i=1}^n \|v_i - c_{y_i}\|_2^2 \quad (4)$$

$$\mathcal{L}_s = - \sum_{i=1}^m y_i \log(p_i) \quad (5)$$

$$L = \mathcal{L}_s + \lambda \mathcal{L}_c \quad (6)$$

式中: v_i 为特征向量; c_{y_i} 为分类中心点; n 为特征向量长度; p_i 为预测值; $\mathcal{L}_c$ 为中心损失; $\mathcal{L}_s$ 为交叉熵损失, λ 为一个常数。

中心损失函数将数据特征约束在固定的抽象空间内,使其更平滑。计算分类中中心点的更新公式为:

$$\frac{\partial \mathcal{L}_c}{\partial x_i} = x_i - c_{y_i} \quad (7)$$

$$\Delta c_j = \frac{\sum_{i=1}^m \delta(y_i = j) \cdot (c_j - x_i)}{1 + \sum_{i=1}^m \delta(y_i = j)} \quad (8)$$

式中: 如果满足条件, $\delta(\text{condition})$ 的结果为 1, 如果不满足则为 0。

在半监督微调阶段,主要通过目标被试的少量有标签数据与大量无标签数据来微调模型。半监督方法中伪标签的计算过程为:

$$v_u = f_{\theta}(x_u) \quad (9)$$

$$o_u = \text{Linear}(v_u) \quad (10)$$

$$y_u = \begin{cases} 1 & \hat{u} = \operatorname{argmax}(o_u) \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

式中: x_u 为无标签数据; v_u 为特征向量; o_u 为线性计算层的数据; y_u 为伪标签。

由于有标签数据是从目标被试中随机选择的,无标签数据是目标被试的高质量数据,因此分类中心点与基础模型 f_{θ} 都会通过这些高质量数据进行微调。同时,本文还使用输出值 o_u 、距离 d_u 来评估预测标签 y_u 的可靠性,选择准确率高 ($o_u > \varepsilon$) 且与相应分类中心距离小 ($d_u < \varsigma$) 的数据点形成新的数据集 Γ_q 。 d_u 和支持集 Γ_q 的计算公式为:

$$d_u = \frac{1}{2n} \|v_u - c_{y_i}\|_2^2 \quad (12)$$

$$\Gamma_q = \{(x_u, y_u)\}, (o_u > \varepsilon, d_u < \varsigma) \quad (13)$$

式中: n 为每个特征向量 v 的长度; c_{y_i} 为对应的分类中心点; ε 、 ς 为设置的筛选值,只有预测满足值 ($o_i > \varepsilon$) 且距离满足 ($d_i < \varsigma$) 的数据才能被放入支持集 Γ_q 中。

最后,通过平均梯度对基础模型进行微调。SSML 相较于其他方法而言,可使用标记和未标记的数据来有效拟合新受试者的数据样本分布,从而提升模型对脑电图情绪的分类性能。

3 实验结果与分析

3.1 数据集

DEAP 是广泛使用的公共数据集,采集设备为 32 脑电通道,采集的数据在效价 (Valence)、唤醒 (Arousal) 等维度

有具有评分^[34]。为了便于实验,本文中将效价、唤醒大于或等于5的评分作为高,小于5的评分作为低,以此对数据进行二分类。在DOC患者数据集中,通过10-20标准导联系统采集了32通道脑电图信号,采样频率为250 Hz,数据集包括23名受试者(10名正常人(N1-N10)和8名DOC患者(P1-P8)^[33]。

在实验过程中,受试者观看了30 s的视频片段,使用设备收集被试相应的情绪脑电图信号,并将情绪分为积极或消极两类。DOC患者的数据集是所有临床患者的信息汇总,如表1所示。其中,TBI为创伤性脑损伤;NTBI为非创伤性脑损伤;VS为植物人状态;MCS为最低意识状态;EMCS为从MCS中苏醒;JFK CRS-R为昏迷恢复量表—修订版。

Table 1 Summary of clinical status of patients
表1 患者临床状况汇总

Patient	Age	Gender	Diagnosis	Etiology	JFK CRS-R Score
P1	28	M	EMCS	TBI	13(2-2-6-1-0-2)
P2	26	M	MCS	TBI	11(2-3-3-1-0-2)
P3	35	F	MCS	TBI	10(2-3-2-1-0-2)
P4	24	M	MCS	TBI	10(1-1-5-1-0-2)
P5	32	M	MCS	NTBI	10(1-3-2-2-0-2)
P6	13	M	MCS	TBI	9(1-1-4-1-0-2)
P7	52	M	UWS	NTBI	7(1-1-2-1-0-2)
P8	35	F	UWS	NTBI	5(1-0-1-1-0-2)

为了提取频率特征,脑电图信号会被分为5个频带,并将信号切成多个10 s的片段。因此,模型的输入数据大小应该为 $C \times B \times T$,C为脑电信号采集中使用的电极数量,B为频带数量,T为时间长度。为了验证模型在跨被试任务中的有效性,使用留一被试排除(leave-one-subject-out, LOSO)方法进行交叉验证。首先选择一名被试作为目标被试,并将其余被试的数据作为训练集;其次,使用测试集中的少量标记数据与大量未标记数据来微调模型;最后对每个被试重复该实验,对结果求平均值以获得模型在相应数据集上的整体准确性。

3.2 模型设置

本文模型由卷积层与分类器组成,如图1所示。其中,卷积层提取数据的深层特征,并生成特征向量;分类器包括全连接层和softmax激活函数,对特征向量进行处理以获得最终的预测值。卷积层又包含频域卷积、时域卷积、空间卷积3个阶段,模型的输入数据格式为 $[C, B, T]$,空间卷积核的大小由脑电采集设备的通道数决定,其他卷积核保持不变,原因为该卷积核需要根据电极数量修改尺寸。表2为DOC数据集的骨干网络结构,(32,1,5,10)代表脑电图电极数为32,卷积通道数为1,频率数为band为5,时间长度为10,即10 s。同时,该结构包含一个频域卷积层,两个时间卷积层和一个空间卷积层,除了空间卷积层外其他卷积层相同,并且每个卷积层还包含批量归一化操作,以提升模型泛化能力。

Table 2 Detail of base model

表2 基本模型细节

Layer	Kernel setting	Output Shape
Input		(32,5,10)
Reshape		(32,1,5,10)
F-Conv	(5,3)*32	(32,32,1,8)
T-Conv1	(1,3)*64	(32,64,1,6)
T-Conv2	(1,3)*128	(32,128,1,4)
S-Conv	(32,1)*256	(256,1,4)
Linear		2

3.3 模型细节

本文为了更好地提取脑电图的时间特征和频域特征。首先使用一个二维卷积分别对时间维度和频段维度进行卷积;其次使用两个时域卷积模块处理数据,以进一步提取深层次的时间特征;最后使用空间卷积层处理数据得到空间层面的特征值。Adam优化器作为模型的优化器和元学习器,学习率分别设置为0.001和0.000 1,以更好地训练模型。同时,在学习不同类别的特征中心点时,随机梯度下降优化器的学习率为0.001,中心损失函数的权重设置为0.15,以使模型适应数据集。此外,概率 ϵ 、距离 s 阈值分别设置为0.9和1,以筛选出合格的支持集。

开始预训练模型时,本文将训练集随机分为两部分:一部分用于训练模型;另一部分用于验证模型。具体的,随机选择每个分类对应的少样本有标签数据,以微调预训练模型,当模型在验证集上的分类准确率达到最大值时停止训练。同时,Adam优化器在10个epoch内对模型进行微调,学习率为0.001,权重衰减为0.001。

4 实验结果与分析

4.1 在DEAP数据集上的结果

表3为SSML与现有方法在DEAP数据集中结果。由此可知,SSML在DEAP数据集上表现优异,效价和唤醒率分别为65.35%和66.64%,在唤醒维度上表现最优,证明了SSML能有效区分不同维度的分类数据,原因可能是模型的半监督元学习方法能筛选出有效的数据,并通过微调模型以获得更好的效果。

Table 3 Results of SSML and existing methods on DEAP dataset

表3 SSML与现有方法在DEAP数据集中结果 (%)

Method	Valence Accuracy	Arousal Accuracy
AD-TCH	64.30	63.30
Bagging-RF	50.35	53.49
Boosting-XGBoost	57.70	53.72
TPT	57.43	54.76
TCA	56.23	51.81
KPCA	54.35	58.15
SSML(Ours)	65.35	66.64

4.2 在DOC患者的结果

由于情绪和意识之间具有很强的联系,本文对DOC患者进行情绪识别可能有助于评估他们的残余意识和受损

的大脑功能,从而帮助医生进行诊断,具体识别结果如表4所示。由此可知,SSML方法识别患者的准确率为59%~62.5%,平均准确率为59.62%,相较于其他方法对大多数患者的分类准确率、平均准确率更高。特别的,P1获得了最佳的情绪识别准确值,明显高于偶然值,原因为P1处于EMCS状态,意味着他相较于其他患者具有更高的意识水平。因此,CRS-R评分高可能是方法在部分患者被试上具有更高准确性,该结果也证明了上述推测,即情绪状态和意识状态相关。此外,在面对整体识别性能较差的患者时,SSML方法的识别结果也优于其他方法,进一步证明了该方法在缓解受试者个体差异方面更有效。

Table 4 Results of SSML and existing methods on DOC dataset

表4 SSML和现有方法在DOC数据集上的结果 (%)

Patients	Clinical diagnosis	DAN	Saliency	ST-SC-GNN	Base Model	SSML (Ours)
P1	EMCS	60.83	60.56	62.22	54.67	62.50
P2	MCS	53.06	52.78	54.44	53.83	57.70
P3	MCS	56.39	56.11	60.28	52.17	59.00
P4	MCS	52.78	53.06	52.78	51.50	59.00
P5	MCS	51.11	51.39	53.06	47.50	60.00
P6	MCS	49.17	49.44	48.89	48.50	57.00
P7	UWS	51.67	51.39	51.39	54.50	59.00
P8	UWS	48.33	48.89	48.33	47.67	59.90
Mean		52.91	52.95	53.92	51.29	59.26

4.3 元学习微调数据量K的选择

在SSML方法中,元学习使用不同样本数据量的结果如图2所示。由此可见,随着样本数据量增加,模型在正常人与DOC患者数据集上的平均准确率逐渐增加,最终趋于稳定,与预期结果一致。具体的,由于初期所选样本数量较少,无法完整反映目标被试的数据分布,因此该参数对模型的微调效果较差;后期随着样本数量增加,针对目标被试数据的微调更为精准,因此识别准确率逐渐增加。




Fig. 2 Results of N-shot SSML with different sample sizes on the DOC patient dataset

图2 不同带样本量的SSML在DOC患者数据集下的实验结果

5 结语

本文提出一种用于跨被试情感识别任务的SSML方法,可有效将源被试数据上预训练的模型,迁移到新的目标被试数据上,并获得良好的识别效果。首先使用源被试

数据预训练模型,其次基于少量源被试的有标签数据与目标被试的无标签数据,通过元学习方法微调模型,提升模型性能。

在正常人与DOC患者数据中的实验表明,本文方法相较于其他方法效果更优,能很好地缓解被试之间的生理差异问题,在跨受试者脑电图情绪识别任务和DOC患者的诊断中潜力巨大。然而,该方法仍然存在一定的局限性,未来可考虑采用性能更高的网络来解码高级认知行为,也可考虑在选择有标签数据时对数据进行二次筛选。

参考文献:

- [1] ZHANG J, YIN Z, CHEN P, et al. Emotion recognition using multi-modal data and machine learning techniques: a tutorial and review[J]. Information Fusion, 2020, 59: 103-126.
- [2] GOLDMAN A I, SRIPADA C S. Simulationist models of face-based emotion recognition[J]. Cognition, 2005, 94(3): 193-213.
- [3] METCALFE D, MCKENZIE K, MCCARTY K, et al. Emotion recognition from body movement and gesture in children with autism spectrum disorder is improved by situational cues[J]. Research in Developmental Disabilities, 2019, 86: 1-10.
- [4] CANNON S A, CHATTERJEE M. Voice emotion recognition by children with mild to moderate hearing loss [J]. Ear and Hearing, 2019, 40(3): 477.
- [5] WANG Z, WANG Y, HU C, et al. Transformers for EEG-based emotion recognition: a hierarchical spatial information learning model [J]. IEEE Sensors Journal, 2022, 22(5): 4359-4368.
- [6] CHEN J, RO T, ZHU Z. Emotion recognition with audio, video, EEG, and EMG: a dataset and baseline approaches [J]. IEEE Access, 2022, 10: 13229-13242.
- [7] HSU Y L, WANG J S, CHIANG W C, et al. Automatic ECG-based emotion recognition in music listening [J]. IEEE Transactions on Affective Computing, 2017, 11(1): 85-99.
- [8] CHILDS N L, MERCER W N, CHILDS H W. Accuracy of diagnosis of persistent vegetative state[J]. Neurology, 1993, 43(8): 1465-1465.
- [9] MUSH A T, TERASAKI Y, HAQUE H A, et al. Feature extraction from EEGs associated with emotions [J]. Artificial Life and Robotics, 1997, 1(1): 15-19.
- [10] HOU F, LIU J, BAI Z, et al. EEG-based emotion recognition for hearing impaired and normal individuals with residual feature pyramids network based on time-frequency-spatial features [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-11.
- [11] DUAN R N, ZHU J Y, LU B L. Differential entropy feature for EEG-based emotion classification [C]// 6th International IEEE/EMBS Conference on Neural Engineering, 2013: 81-84.
- [12] NG W B, SAIDATUL A, CHONG Y F, et al. PSD-based features extraction for EEG signal during typing task [C]// IOP Conference Series: Materials Science and Engineering, 2019: 12032.
- [13] LI Z, TIAN X, SHU L, et al. Emotion recognition from EEG using RASM and LSTM [C]// Internet Multimedia Computing and Service: 9th International Conference, 2018: 310-318.
- [14] SUHAIMI N S, MOUNTSTEPHENS J, TEO J. EEG-based emotion recognition: a state-of-the-art review of current trends and opportunities [EB/OL]. <https://onlinelibrary.wiley.com/doi/epdf/10.1155/2020/8875426>.

- [15] LI Y. Research and application of deep learning in image recognition [C]// 2nd International Conference on Power, Electronics and Computer Applications, 2022: 994–999.
- [16] CHEAH K H, NISAR H, YAP V V, et al. Optimizing residual networks and VGG for classification of EEG signals: identifying ideal channels for emotion recognition [EB/OL]. <https://onlinelibrary.wiley.com/doi/epdf/10.1155/2021/5599615>.
- [17] YIN Y, ZHENG X, HU B, et al. EEG emotion recognition using fusion model of graph convolutional neural networks and LSTM [J]. *Applied Soft Computing*, 2021, 100: 106954.
- [18] CHEN H, JIN M, LI Z, et al. MS-MDA: multisource marginal distribution adaptation for cross-subject and cross-session EEG emotion recognition [J]. *Frontiers in Neuroscience*, 2021, 15: 778488.
- [19] HOSPEDALES T, ANTONIOU A, MICAELLI P, et al. Meta-learning in neural networks: a survey [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 44(9): 5149–5169.
- [20] SCHRIER A M. Learning how to learn: the significance and current status of learning set formation [J]. *Primates*, 1984, 25: 95–102.
- [21] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks [C]// International Conference on Machine Learning, 2017: 1126–1135.
- [22] MIYAMOTO K, TANAKA H, NAKAMURA S. Meta-learning for emotion prediction from EEG while listening to music [C]// 2021 International Conference on Multimodal Interaction, 2021: 324–328.
- [23] TANG H, JIANG G, WANG Q. Deep neural network for emotion recognition based on meta-transfer learning [J]. *IEEE Access*, 2022, 10: 78114–78122.
- [24] VAN ENGELEN J E, HOOS H H. A survey on semi-supervised learning [J]. *Machine Learning*, 2020, 109(2): 373–440.
- [25] CHAPELLE O, CHI M, ZIEN A. A continuation method for semi-supervised SVMs [C]// 23rd International Conference on Machine Learning, 2006: 185–192.
- [26] LI X, SHEN F, PENG Y, et al. Efficient sample and feature importance mining in semi-supervised EEG emotion recognition [J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2022, 69(7): 3349–3353.
- [27] 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.
- [28] PENG Y, KONG W, QIN F, et al. Self-weighted semi-supervised classification for joint EEG-based emotion recognition and affective activation patterns mining [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1–11.
- [29] ARAZO E, ORTEGO D, ALBERT P, et al. Pseudo-labeling and confirmation bias in deep semi-supervised learning [C]// 2020 International Joint Conference on Neural Networks, 2020: 1–8.
- [30] WANG L, CAI Q, YANG Z, et al. On the global optimality of model-agnostic meta-learning [C]// International Conference on Machine Learning, 2020: 9837–9846.
- [31] BANLUESOMBATKUL N, OUPPAPHAN P, LEELAARPORN P, et al. MetaSleepLearner: a pilot study on fast adaptation of bio-signals-based sleep stage classifier to new individual subject using meta-learning [J]. *IEEE Journal of Biomedical and Health Informatics*, 2020, 25(6): 1949–1963.
- [32] YOO C, LEE H W, KANG J W. Transferring structured knowledge in unsupervised domain adaptation of a sleep staging network [J]. *IEEE Journal of Biomedical and Health Informatics*, 2021, 26(3): 1273–1284.
- [33] HUANG H, XIE Q, PAN J, et al. An EEG-based brain computer interface for emotion recognition and its application in patients with disorder of consciousness [J]. *IEEE Transactions on Affective Computing*, 2019, 12(4): 832–842.
- [34] KOELSTRA S, MUHL C, SOLEYMANI M, et al. Deap: a database for emotion analysis; using physiological signals [J]. *IEEE Transactions on Affective Computing*, 2011, 3(1): 18–31.

(责任编辑:刘嘉文)