

基于自监督图网络的脑电情绪识别方法研究

张嘉翔, 潘敏, 张瑞

引用本文

张嘉翔, 潘敏, 张瑞. 基于自监督图网络的脑电情绪识别方法研究[J]. 计算机科学, 2025, 52(5): 122-127.

ZHANG Jiexiang, PAN Min, ZHANG Rui. [Study on EEG Emotion Recognition Method Based on Self-supervised Graph Network](#) [J]. Computer Science, 2025, 52(5): 122-127.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于超图卷积和多角度拓扑细化的骨骼行为识别方法](#)

Hypergraph Convolutional Network with Multi-perspective Topology Refinement for Skeleton-based Action Recognition

计算机科学, 2025, 52(5): 220-226. <https://doi.org/10.11896/jsjcx.240600125>

[基于时空图注意力卷积神经网络的车辆轨迹预测](#)

Vehicle Trajectory Prediction Based on Spatial-Temporal Graph Attention Convolutional Network

计算机科学, 2024, 51(12): 157-165. <https://doi.org/10.11896/jsjcx.231100145>

[基于全局时空图卷积神经网络的城市交通流量预测](#)

Urban Traffic Flow Prediction Based on Global Spatiotemporal Graph Convolutional Neural Network

计算机科学, 2024, 51(11A): 240200045-9. <https://doi.org/10.11896/jsjcx.240200045>

[基于图卷积网络的糖尿病视网膜病变分级模型](#)

Grading Model for Diabetic Retinopathy Based on Graph Convolutional Network

计算机科学, 2024, 51(11A): 231000042-5. <https://doi.org/10.11896/jsjcx.231000042>

[基于多模态数据与融合深度网络的自动睡眠分期方法](#)

Automatic Sleep Staging Based on Multimodal Data and Fusion Deep Network

计算机科学, 2024, 51(11A): 231100160-6. <https://doi.org/10.11896/jsjcx.231100160>

基于自监督图网络的脑电情绪识别方法研究

张嘉翔 潘敏 张瑞

西北大学医学大数据研究中心 西安 710127

(zhangjiaxiang@stumail.nwu.edu.cn)

摘要 脑电情绪识别是指通过分析人类脑电信号来识别相应情绪状态的技术,其在医疗健康、人机交互等领域有着广泛的应用。目前,脑电情绪识别往往借助机器学习或深度学习方法对标签脑电数据进行充分训练从而能够辨别不同情绪状态。然而,以往方法严重依赖于大量标签数据,而数据标注耗时耗力,并且脑电信号的个体差异性导致传统方法表现不佳。同时,研究表明,脑电信号的空间结构信息能够反映不同情绪状态下蕴含的脑区相互作用,有助于提高情绪的辨识度。为此,提出了一种基于自监督图网络的脑电情绪识别方法。首先,使用减数分裂方法预处理脑电信号;其次,利用图卷积网络提取脑电信号的空间结构信息,并设计自监督辅助任务对图卷积网络进行训练;最后,在公开数据集 SEED 和 SEED-IV 上验证所提方法的可行性和有效性,其情绪识别准确率为 95.16% 和 80.23%,优于现有方法。

关键词: 脑电信号;情绪识别;减数分裂;自监督学习;图卷积网络

中图分类号 TP391

Study on EEG Emotion Recognition Method Based on Self-supervised Graph Network

ZHANG Jiexiang, PAN Min and ZHANG Rui

Medical Big Data Research Center, Northwest University, Xi'an 710127, China

Abstract EEG emotion recognition refers to the technology of identifying human emotional states by analyzing electroencephalogram (EEG) signals, which has wide application prospects in some fields such as medical health, and human-computer interaction. Currently, EEG-based emotion recognition frequently relies on machine learning or deep learning techniques to thoroughly train labeled EEG data and differentiate various emotional states. However, such methods require a lot of data annotation, which is time-consuming and labor-intensive. Meanwhile, research shows that the spatial structure information of EEG signals can reflect the interaction of brain areas related to different emotional states, which can help identify emotional characteristics. To this end, this paper proposes an EEG emotion recognition method based on self-supervised graph network. First, the meiosis method is used to preprocess the EEG signal. Then, a graph convolutional network is used to extract spatial structure information from EEG signals, and the network is trained through self-supervised tasks. Finally, the feasibility and effectiveness of the proposed method have been validated through numerical experiments using the public datasets SEED and SEED-IV. Numerical results show that the accuracy of emotion recognition is 95.16% and 80.23%, which is superior to current methods.

Keywords EEG, Emotion recognition, Meiosis, Self-supervised learning, Graph convolutional network

1 引言

情绪是基于思维、感觉和行为综合表现出的生理和心理状态,影响着人的认知、感知、理性决策等日常活动^[1]。情绪识别是指根据生理、行为特征对人类的情绪状态,包括快乐、悲伤、愤怒等,进行辨别^[2]。近年来,随着计算机技术和人工智能的快速发展,借助计算机辅助系统对人类情绪状态进行

自动识别已成为医疗健康、交通安全和人机交互等多个领域中重要且具有挑战性的研究内容^[3]。发展准确、高效的情绪自动识别方法,对于守护人类的生命健康和提升生活品质具有重要的现实意义和价值。

目前,情绪识别主要依据身体行为表现和生理信号等信息^[4]。其中,身体行为表现包括面部表情、语音特征和肢体动作等,此类识别方式容易受主观因素干扰,易伪装,从而影响

到稿日期:2024-02-06 返修日期:2024-06-12

基金项目:国家自然科学基金(12071369, 62006189);陕西省自然科学基金(2021JQ-430, 2023-JC-QN-0028);中国博士后科学基金(2022M722580)

This work was supported by the National Natural Science Foundation of China(12071369, 62006189), Natural Science Foundation of Shanxi Province, China(2021JQ-430, 2023-JC-QN-0028) and China Postdoctoral Science Foundation(2022M722580).

通信作者:张瑞(rzhang@nwu.edu.cn)

识别效果。与之相比,生理信号能够更加客观、真实地反映情绪变化。普遍采用的生理信号有脑电、眼电以及心电信号等^[5]。其中,脑电信号(Electro-encephalogram, EEG)是大脑神经元电活动的头皮表面记录^[6]。研究表明,脑电信号与人的心理状态和认知行为密切相关,其变化能够直观反映人的情绪活动^[7]。

借助脑电信号进行情绪识别是当前的研究热点之一。常用方法是通过机器学习或深度学习模型对标签脑电数据进行情绪识别任务^[8],此类监督学习方法依赖于大量的标签脑电数据,但数据标注耗时耗力,且个体差异的存在会导致出现噪声标签,使得模型的准确性与泛化性降低。针对上述问题,学者开始探索利用无监督学习方法来进行情绪识别。传统的无监督学习方法有模糊聚类、自组织映射和自编码机等^[9],其优势是可以挖掘无标注数据的内在特征,但缺乏一定的可解释性。相比之下,自监督学习(Self-Supervised Learning)作为一种特殊的无监督学习方法,能够利用无标注数据的内在结构或属性来构造监督信息,具有一定的可解释性。

相关研究表明,脑电信号的空间结构信息,即不同电极通道之间的空间位置和连接关系,能够反映脑区之间的相关性、同步性等,可作为情绪识别的重要参考^[10]。为了充分利用空间结构信息,可借助图卷积神经网络(Graph Convolutional Neural Network, GCN)处理图结构脑电数据,捕获不同脑电通道之间的关联关系,从而提高情绪特征的辨识度^[11]。

为了解决传统脑电情绪识别方法中存在的标签依赖问题和个体差异问题,本文提出一种新的基于自监督图网络的脑电情绪识别方法。针对个体差异问题,通过使用减数分裂方法对脑电信号进行数据增强,减少受试者之间的个体差异;针对标签依赖问题,本文利用自监督学习的思想,在模型训练的过程中,设计两个自监督辅助任务(包括空间辅助任务和对比辅助任务)对图卷积网络进行训练,以减少对数据标签的依赖。最后在公开的脑电情绪数据集 SEED 上验证所提方法的可行性与有效性。

2 相关工作

基于脑电信号进行情绪识别的一般过程包括特征提取和情绪分类。主要方法分为两大类,基于监督学习和无监督学习的方法。传统的基于监督学习的方法通常提取脑电信号的时域特征、频域特征以及非线性特征等,如分形维度^[12]、功率谱密度^[13]、微分熵(Differential Entropy, DE)^[14]等,然后使用支持向量机^[15]、K-最近邻^[16]等机器学习模型进行情绪分类。此外,还有使用深度学习模型的监督学习方法,如卷积神经网络^[17]、深度信念网络^[18]等。然而,监督学习方法严重依赖于标签信息,且难以克服个体差异带来的噪声标签问题。近年来,无监督学习方法以其高效、灵活、可扩展的优势在计算机视觉和语言识别等领域取得了显著的效果^[19]。因此,许多研究人员开始探索无监督学习,特别是自监督学习方法在脑电情绪识别中的应用。例如,Shen等^[20]提出了一种自监督对比学习框架 CLISA,通过比较两个受试者在观看相同视频剪辑时的脑电信号的相似度,来学习跨个体的情绪特征。类似地, Mohsenvand等^[21]提出了一种基于对比学习的脑电信号特征

提取方法 SeqCLR,通过重新组合脑电信号的通道来训练特征提取器,从而学习更具辨识度的情绪特征。但是,已有研究忽视了脑电情绪识别的标签依赖问题和个体差异问题。

基于此,本文着重于缓解标签数据的依赖性以及个体差异性,设计了一种基于自监督图网络的情绪识别模型,以进行脑电情绪分类研究。

3 基于自监督图网络的脑电情绪识别方法

本文提出了一种基于自监督图网络的脑电情绪识别方法。首先,使用减数分裂(Meiosis)方法对脑电信号进行增强处理;其次,将脑电信号转换为图结构数据,并通过图卷积网络提取图结构数据的特征;然后,利用自监督学习的思想,设计空间(Space)辅助任务和对比(Contrast)辅助任务来训练所构建的图卷积网络;最后,将所构建的自监督图网络模型(MSC-GCN)用于脑电情绪分类任务。

3.1 减数分裂方法

减数分裂方法是一种受遗传学启发的数据处理方法,其通过模拟细胞分裂过程中染色体的配对、重组、分裂等步骤对信号数据进行相似的处理,以达到数据增强和减少个体差异的效果。本文采用该方法预处理脑电信号,具体步骤如下:

如图 1 所示,首先,将 $2p$ 名受试者的原始脑电信号分为两组,采用两两配对的方式将所有受试者配为 p 对 $\{S_1, S_{p+1}\}, \{S_2, S_{p+2}\}, \dots, \{S_p, S_{2p}\}$ 后,将每对受试者的脑电信号进行部分脑电片段交叉重组;采用 $1s$ 的非重叠窗将脑电数据划分为 q 段,记为 $S_j = \{s_j^1, \dots, s_j^q\} (1 \leq j \leq 2p)$,代表第 j 个受试者的脑电信号,之后按给定分裂位置 $c (1 \leq c \leq q)$,交换每组两个脑电信号的前 c 段脑电数据;最后,分裂为两个个体差异较小的脑电信号,即 $\hat{S}_j = \{s_j^1, \dots, s_j^c, s_{j+p}^{c+1}, \dots, s_j^q\}$ 和 $\hat{S}_{j+p} = \{s_j^1, \dots, s_j^c, s_j^{c+1}, \dots, s_{j+p}^q\}$ 。

接着,计算每段脑电信号 $s_j^k (1 \leq k \leq q)$ 所有电极通道的微分熵特征,从而得到第 j 个受试者的第 k 个样本数据 $X_j^k \in \mathbb{R}^{n \times d}$,其中 n 是电极个数, d 是频带数,即对 d 个频带计算相应的微分熵。则第 j 个受试者的样本数据为 $\{X_j^1, \dots, X_j^q\}$,将所有受试者的样本数据整合后记为 $\{X_i\}_{i=1}^N, N = 2pq$ 。

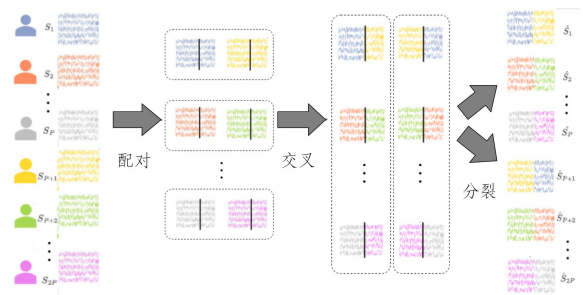


图 1 减数分裂方法流程

Fig. 1 Process of meiosis method

3.2 图网络构建

首先,采用图数据转换的方法,将经过减数分裂处理后的脑电样本数据 $\{X_i\}_{i=1}^N$ 转换为图结构数据,并将其作为图网络的输入。具体步骤如下:

将脑电信号采集设备上的多导联电极作为图的节点,将

电极之间的物理连接作为图的边(如图 2 所示):每个样本数据 $\mathbf{X}_i \in \mathbb{R}^{n \times d}$ 可看作图数据的特征矩阵,即特征矩阵拆解为 n 个 d 维向量作为图数据的节点向量;然后,根据电极之间的欧氏距离得到初始连接矩阵 $\mathbf{A} \in \mathbb{R}^{n \times n}$,用于描述节点之间的连接状态以及连接强度。依据图论相关理论可以获得图数据的拉普拉斯矩阵 \mathbf{L} ,以便图卷积核的计算。

然后,使用切比雪夫卷积作为卷积核构建图卷积网络,并将该图卷积网络作为 MSC-GCN 模型的特征提取器,表示为 $F(\cdot)$ 。将所构建的图结构数据输入到图卷积网络中提取特征,得到的特征表示为:

$$F(\mathbf{X}_i) = \sigma\left(\sum_{k=0}^{K-1} \theta_k T_k(\tilde{\mathbf{L}})\mathbf{X}_i\right) \quad (1)$$

其中, $\sigma(\cdot)$ 是激活函数, \mathbf{X}_i 是输入脑电数据样本, θ_k 是网络训练中的学习参数, $T_k(\cdot)$ 是 k 阶切比雪夫多项式。 $\mathbf{L} = 2\tilde{\mathbf{L}}/\lambda_{\max} - \mathbf{I}$, 其中 λ_{\max} 是拉普拉斯矩阵 \mathbf{L} 的最大特征值。

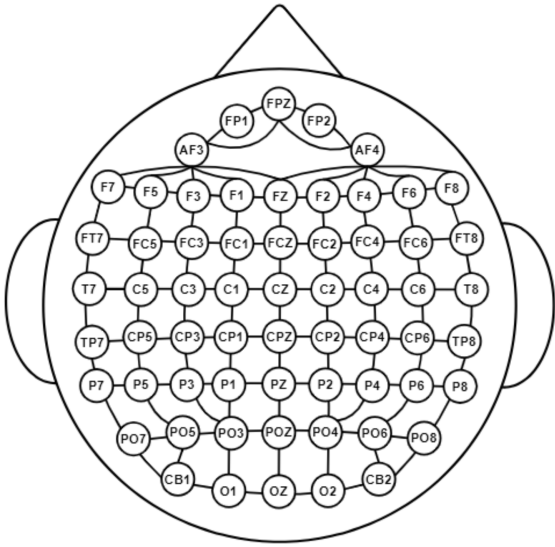


图 2 电极分布示意图

Fig. 2 Diagram of electrode distribution

3.3 自监督辅助任务

3.3.1 空间辅助任务

本文设计了一个用于改变脑区的空间排布的空间辅助任务,来辅助图卷积网络学习脑电信号的空间信息。主要步骤如下:

根据国际 10-20 系统划分的大脑区域位置,可将电极划分到 10 个不同的脑区。以单个脑电样本 $\mathbf{X}_i \in \mathbb{R}^{n \times d}$ 为例,基于所划分的脑区,可将其表示为 $\mathbf{X}_i = (x_{i1}, \dots, x_{i10})^T$, 其中 $x_{ij} \in \mathbb{R}^{n_j \times d}$, $\sum_{j=1}^{10} n_j = n, n_j > 0$ 。若将脑区的排布顺序打乱,则有 $10!$ 种排列顺序,表示为:

$$\begin{cases} \hat{\mathbf{X}}_i^1 = (x_{i1}, x_{i2}, \dots, x_{i9}, x_{i10}) \\ \hat{\mathbf{X}}_i^2 = (x_{i1}, x_{i2}, \dots, x_{i10}, x_{i9}) \\ \vdots \\ \hat{\mathbf{X}}_i^{10!} = (x_{i10}, x_{i9}, \dots, x_{i2}, x_{i1}) \end{cases} \quad (2)$$

其中, $\hat{\mathbf{X}}_i^m (1 \leq m \leq 10!)$ 表示第 m 种排列顺序构成的样本。将不同排列顺序的序数作为 $\hat{\mathbf{X}}_i^m$ 的伪标签,记为 \hat{y}_i^m 。

然而,使用 $10! = 3628800$ 个排列构成的标签进行分类任务难以实现。为减少伪标签的类别,本文通过定义一种变换 $R_k(\cdot)$, 在式(2)的全排列中选择汉明距离最大的 k 个排列,使得每个输入数据 \mathbf{X}_i 经过 $R_k(\cdot)$ 变换后得到的脑区排布顺序属于这 k 个排列之一,得到与之唯一对应的伪标签。上述过程表示为:

$$(\hat{\mathbf{X}}_i^t, \hat{y}_i^t) = R_k(\mathbf{X}_i) \quad (3)$$

其中, $\hat{\mathbf{X}}_i^t, t \in \{1, 2, \dots, k\}$ 是生成的样本数据, $\hat{y}_i^t \in \mathbb{Z}_{128}$ 是生成样本的伪标签。对于所有训练样本 $\{\mathbf{X}_i\}_{i=1}^N$, 通过变换 $R_k(\cdot)$ 后再经过特征提取层和空间任务分类器得到预测结果 y_i 。

$$y_i = H_s(\hat{\mathbf{X}}_i^t) \quad (4)$$

最后,通过伪标签 \hat{y}_i^t 与预测结果 y_i 计算交叉熵损失,得到空间辅助任务的损失 L_s , 计算式如下:

$$L_s = -\sum_{i=1}^N \hat{y}_i^t \log(y_i) \quad (5)$$

其中, $F(\cdot)$ 是共享特征提取层, $H_s(\cdot)$ 是空间辅助任务的分类器, N 是训练样本的数量。

3.3.2 对比辅助任务

为了进一步减少受试者之间的个体差异,本文设计了对比辅助任务以进一步训练所构建的图卷积网络。首先,根据减数分裂过程中的分组情况,将 p 组受试者的所有样本按组表示为 $\{\mathbf{X}_{u1}^k, \mathbf{X}_{u2}^k\}, 1 \leq u \leq p, 1 \leq k \leq q$, 其中 \mathbf{X}_{u1}^k 代表第 u 组第 1 个受试者的第 k 个样本数据。然后,构建正负样本对,来自同组的两名受试者的脑电样本构成正样本对,不同组的受试者样本构成负样本对。将样本输入特征提取层,再通过对比任务的投影器 $H_p(\cdot)$ 映射到特征空间得到特征向量,即 $z_{uv}^k = H_p(F(\mathbf{X}_{uv}^k)), v=1, 2$ 。用余弦相似度 $s(z_{u1}^k, z_{u2}^k)$ 作为两个样本间的相似度度量,其取值范围是 $0 \sim 1$, 计算式如下:

$$s(z_{u1}^k, z_{u2}^k) = \frac{z_{u1}^k \cdot z_{u2}^k}{\|z_{u1}^k\| \|z_{u2}^k\|} \quad (6)$$

接下来,利用对比损失函数(Contrastive Loss)计算一组样本 $\{\mathbf{X}_{u1}^k, \mathbf{X}_{u2}^k\}$ 的对比损失。利用该对比损失训练模型的核心思想是:使所定义的正样本之间相似度增高,并使正负样本之间的相似度降低。采用对比学习中常用的 infoNCE loss 作为损失函数,计算正、负样本间的对比损失 h_+ 和 h_- , 最后得到该组的对比损失 l^u , 计算过程如下:

$$h_+ = \sum_{k=1}^q \exp(s(z_{u1}^k, z_{u2}^k)/\tau) \quad (7)$$

$$h_- = \sum_{k=1}^q \sum_{w=1}^q \sum_{v, t=1}^2 \exp(s(z_{uv}^k, z_{ut}^k)/\tau), u \neq w \quad (8)$$

$$l^u = -\log \frac{h_+}{h_+ + h_-} \quad (9)$$

其中, τ 是温度系数,用于调整损失对困难样本的关注度。对比辅助任务的总体损失是所有组样本的对比损失的算术平均值,如式(10)所示:

$$L_p = 1/p \sum_{u=1}^p l^u \quad (10)$$

3.4 基于 MSC-GCN 模型的脑电情绪识别方法

在上文的基础上,将所构建的 MSC-GCN 模型应用于情绪识别任务,分自监督训练和情绪分类两个阶段进行。整体流程如图 3 所示。

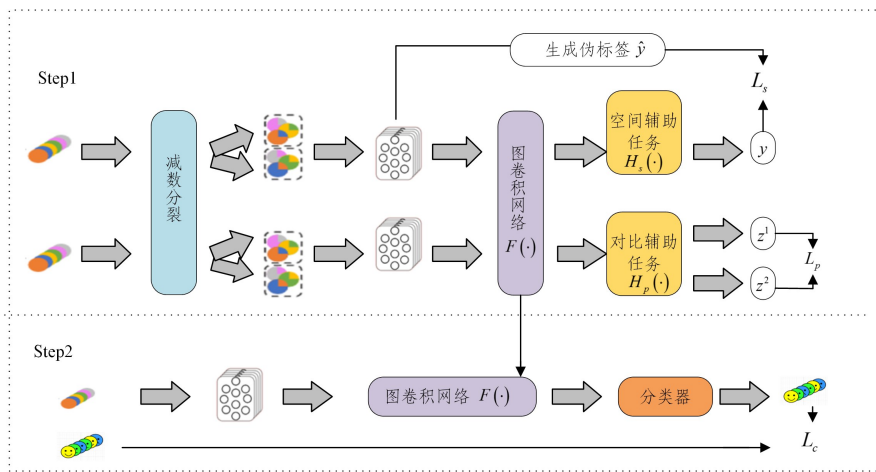


图3 基于 MSC-GCN 模型的脑电情绪识别方法

Fig. 3 EEG emotion recognition based on MSC-GCN model

在自监督训练阶段,使用减数分裂方法对不带真实标签的脑电数据进行处理;然后,将预处理后的脑电信号转换为图数据,再输入以图卷积网络构建的特征提取器,得到特征表示;最后利用空间辅助任务和对比辅助任务对特征提取器进行预训练。

在情绪分类阶段,使用带有真实标签的样本数据,将脑电信号转换为图结构数据,然后由预训练过的特征提取器从图结构数据中提取特征,再经过一个全连接层作为分类器,输出情绪类别的预测结果。最后使用交叉熵损失函数,以真实标签为参考,计算分类损失 L_c 。

在 MSC-GCN 的整体训练过程中,通过对不同阶段的任务产生的损失进行反向传播,来对模型参数进行调优。总的损失函数为:

$$L = \frac{1}{\sigma_{L_s}} L_s + \frac{1}{\sigma_{L_p}} L_p + \frac{1}{\sigma_{L_c}} L_c + \log(\sigma_{L_s}, \sigma_{L_p}, \sigma_{L_c}) \quad (11)$$

其中, L_s, L_p, L_c 分别为空间辅助任务、对比辅助任务以及分类器产生的损失, $\sigma_s, \sigma_p, \sigma_c$ 为对应任务的观测噪声标量。

4 数值实验

4.1 数据集

为了验证所提方法的有效性,本文采用上海交通大学发布的公开情绪数据集 SEED(SJTU Emotion EEG Dataset)与 SEED-IV 进行数值对比实验。

SEED 数据集共包含 7 名男性和 8 名女性的情绪脑电数据。实验使用 ESI NeuroScan System 进行脑电信号记录,采样频率为 1000 Hz,选用 62 个电极,电极放置位置采用国际 10-20 系统(如图 2 所示)。数据集包括积极(Positive)、中性(Neutral)以及消极(Negative)3 种情绪类别。SEED-IV 数据集同样包含 15 名受试者(7 名男性和 8 名女性)的脑电数据,记录设备与 SEED 中使用的设备相同,共包含平静、悲伤、恐惧和高兴 4 种情绪。

在 SEED 数据集采集过程中,每位受试者在 3 个不同的时间段进行实验,实验的间隔周期为 3~7 天。每次实验共分为 15 次小实验,每次小实验受试者需要观看 4 种情绪类型的电影片段之一(大约 4 min),每种情绪类别包含 5 个电影

片段。在 SEED-IV 数据集的采集过程中,每次实验则划分为 24 次小实验,每次小实验受试者需要观看 4 种情绪类型的电影片段之一(大约 2min),每种情绪类别包含 6 个电影片段。通过这些带有特定感情色彩片段的画面刺激受试者以产生相应的情绪状态。

4.2 预处理

为了去除噪声干扰,本文需要对脑电数据进行预处理。首先,对原始信号 S 进行降采样处理。其次,为去除眼电伪迹和肌电伪迹造成的噪声干扰,采用 1~75 Hz 的带通滤波器对降采样后的脑电数据进行滤波处理,从而获得处理后的信号 S' 。随后,采用 1 s 的非重叠窗将脑电信号 S' 分段处理。为了刻画脑电信号的不规则度和复杂度,本文将每段信号在 62 个通道上提取 5 个关键频带上的微分熵特征作为样本数据。

4.3 实验结果与分析

本文在公开的脑电情绪数据集 SEED 和 SEED-IV 上进行了数值实验,使用准确率(ACC)和标准差(STD)作为评价指标,来评估脑电情绪识别的性能。

实验均采用 Python 3.9 作为运行环境,采用 PyTorch 1.13.1 作为深度网络搭建框架。对于 SEED 数据集,按照 3:2 的比例划分为训练集和测试集,其中训练集中包含所有受试者前 9 次实验的样本数据,测试集中包含后 6 次实验的样本数据。对于 SEED-IV 数据集,按照 2:1 的比例划分训练集和测试集,取前 16 次实验的受试者样本数据作为训练集,后 8 次实验的受试者样本数据作为测试集。在训练阶段,选用 Adam 作为优化器,设置学习率为 0.01,权重衰减率为 8×10^{-5} ,最大迭代次数为 100,批量大小为 256。

4.3.1 消融实验

为了探究 MSC-GCN 模型的有效性,本文在 SEED 数据集上进行了消融实验,包括有标签和无标签两种模式。以 GCN 模型作为基准,依次引入减数分裂方法 M、空间辅助任务 S、对比辅助任务 C,用于验证所设计方法的必要性,结果如表 1 所列。根据表中的数据可知,MSC-GCN 模型在有标签模式下的情绪识别准确率为 95.16%;为了减少个体差异,使用减数分裂方法处理脑电信号,模型 M-GCN 相比于基准

模型平均准确率提高了 3.9%。在此基础上,为提取脑电信号的空间特征,引入空间辅助任务对模型进行训练,模型 MS-GCN 的平均准确率进一步提高了近 3.7%。仅将对辅助任务加入模型中时,模型 MC-GCN 的平均准确率提高了 0.83%。最后,将空间任务与对比任务均加入模型中进行训练,模型 MSC-GCN 的准确率最高达到 95.16%,这说明所提方法能够有效提升模型的性能。在无标签模式下, MSC-GCN 模型的情绪识别准确率为 67.14%,相较于初始 GCN 模型提升了 6.69%,说明所提方法能够缓解对标签数据的依赖性。

表 1 消融实验
Table 1 Ablation experiment (%)

模型	有标签		无标签	
	平均准确率	标准差	平均准确率	标准差
GCN	86.02	9.36	59.45	17.65
M-GCN	89.92	8.62	63.82	15.96
MS-GCN	93.66	5.87	65.80	11.95
MC-GCN	90.75	6.06	64.76	11.89
MSC-GCN	95.16	5.38	67.14	11.71

4.3.2 结果对比

为了验证所提方法的优势和创新性,将本文方法与现有方法进行了比较,结果如表 2 所列。根据表中数据可以看出,本文方法在 SEED 和 SEE-IV 数据集上都取得了最高的准确率。与基线模型 SVM 相比, DANN, BiDANN, BiHDM 等深度学习模型凭借其强大的特征表征能力,在情绪识别任务中有着更明显的优势。与 RGNN 相比,本文模型在两个数据集上的识别准确率分别提升了 0.92% 和 3.75%;与 SGMC 相比,本文模型在两个数据集上的识别准确率分别提升了 1.02% 和 4.54%。这说明本文方法能够结合自监督学习和图卷积网络的优势来提取脑电信号关于情绪表达的有效信息,从而提高脑电情绪识别的准确率和泛化能力。

表 2 与已有方法对比

Table 2 Comparison of the proposed method with existing methods (%)

方法	SEED(三分类)		SEED-IV(四分类)	
	平均准确率	标准差	平均准确率	标准差
SVM(2016)	83.99	9.72	56.61	20.05
DANN(2018)	91.36	8.30	64.15	18.81
BiHDM(2018)	93.12	7.04	74.35	14.09
RGNN(2020)	94.24	5.95	76.48	11.82
SGMC(2022)	94.14	5.53	75.69	11.59
MSC-GCN	95.16	5.38	80.23	11.54

4.3.3 参数分析

本文对模型中图卷积网络的切比雪夫卷积阶数 k 和对比任务中的温度系数 τ 两个超参数进行实验分析,以探究参数设置的合理性。

切比雪夫(Chebyshev)卷积核是一种基于切比雪夫多项式近似的频谱图卷积方法,可以有效地降低卷积核的参数数量和计算复杂度,本文通过数值实验来分析不同 Chebyshev 卷积核大小 k 在 SEED 数据集上的效果。在参数分析实验中,分别设置 $k=1,2,\dots,10$,结果如图 4(a)所示。当 $k=2$ 时,模型取得了最好的性能。当 k 大于 2 时,模型的

性能呈相对明显的下降趋势。

温度系数 τ 是对比学习中的一个重要参数,用于调节对比损失函数对正样本和负样本相似度的敏感度。本文在参数分析实验中,探究了不同的温度系数($\tau=0.01,0.1,0.2,\dots,0.5$)对于模型性能的影响,结果如图 4(b)所示。可以看到,当 $\tau=0.1$ 时,模型取得了最好的性能。当 τ 逐渐增大时,模型的性能表现逐渐变差。




图 4 参数分析

Fig. 4 Parameter analysis

结束语 本文提出了一种基于自监督图网络的脑电情绪识别方法。使用减数分裂方法处理脑电信号,从而减少受试者之间的个体差异;利用图卷积网络挖掘脑电信号的空间结构信息,并通过设计自监督辅助任务训练图卷积网络,用以进行情绪识别;最后,在公开的脑电情绪数据集 SEED 和 SEED-IV 上验证所提方法的有效性,得到的情绪识别准确率为 95.16% 和 80.23%,均优于已有方法。综上,本文方法可以有效区分脑电信号的情绪类别,能够用于情绪识别任务。

除了脑电信号的空间结构信息,还可以通过脑电信号的时频域信息来挖掘与情绪相关的特征。因此在后续研究中,可以考虑设计新的自监督任务,将时频域信息以合适的方法辅助训练模型,用于进一步提高脑电情绪识别模型的性能。

参考文献

- [1] DOLAN R J. Emotion, cognition, and behavior [J]. Science, 2002, 298(5596): 1191-1194.
- [2] ROY Y, BANVILLE H, ALBUQUERQUE I, et al. Deep learning-based electroencephalography analysis: a systematic review [J]. Journal of Neural Engineering, 2019, 16(5): 051001.
- [3] LIU Y, SOURINA O, NGUYEN M. Real-time EEG-based emotion recognition and its applications [J]. Transactions on Computational Science XII: Special Issue on Cyberworlds, 2011, 6670: 256-277.
- [4] EKMAN P E, DAVIDSON R J. The nature of emotion: Fundamental questions [M]. Oxford University Press, 1994: 62-65.
- [5] AZCARATE A, HAGELOH F, VAN DE SANDEK, et al. Automatic facial emotion recognition [EB/OL]. <https://www.semanticscholar.org/paper/Automatic-facial-emotion-recognition-Azcarate-Sande/15c11294ea3fe1c48d1b9cff0b06d74143ea264a>.
- [6] SCHULLER B, RIGOLL G, LANG M. Speech emotion recognition combining acoustic features and linguistic information in a hybrid support vector machine-belief network architecture [C] // 2004 IEEE International Conference on Acoustics, Speech, and Signal Processing. IEEE, 2004, 1: 1-577.
- [7] 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.
- [8] LI Y, CHEN J, LI F, et al. GMSS: Graph-based multi-task self-supervised learning for EEG emotion recognition[J]. *IEEE Transactions on Affective Computing*, 2022, 14(3):2512-2525.
- [9] WU F, SOUZA A, ZHANG T, et al. Simplifying graph convolutional networks[C] // *International Conference on Machine Learning*. PMLR, 2019:6861-6871.
- [10] ZHONG P, WANG D, MIAO C. EEG-based emotion recognition using regularized graph neural networks[J]. *IEEE Transactions on Affective Computing*, 2020, 13(3):1290-1301.
- [11] 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)*. IEEE, 2013:81-84.
- [12] NIE D, WANG X W, SHI L C, et al. EEG-based emotion recognition during watching movies[C] // *2011 5th International IEEE/EMBS Conference on Neural Engineering*. IEEE, 2011:667-670.
- [13] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(1):4-24.
- [14] ZHAO L M, YAN X, LU B L. Plug-and-play domain adaptation for cross-subject EEG-based emotion recognition[C] // *Proceedings of the AAAI Conference on Artificial Intelligence*. 2021:863-870.
- [15] KAN H, YU J, HUANG J, et al. Self-supervised group meiosis contrastive learning for EEG-based emotion recognition[J]. *Applied Intelligence*, 2023, 53(22):27207-27225.
- [16] HE K, FAN H, WU Y, et al. Momentum contrast for unsupervised visual representation learning[C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020:9729-9738.
- [17] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations[C] // *International Conference on Machine Learning*. PMLR, 2020:1597-1607.
- [18] LI Y, WANG L, ZHENG W, et al. A novel bi-hemispheric discrepancy model for EEG emotion recognition[J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2020, 13(2):354-367.
- [19] KHOSLA P, TETERWAK P, WANG C, et al. Supervised contrastive learning[J]. *Advances in Neural Information Processing Systems*, 2020, 33:18661-18673.
- [20] SHEN X, LIU X, HU X, et al. Contrastive learning of subject-invariant EEG representations for cross-subject emotion recognition[J]. *IEEE Transactions on Affective Computing*, 2022, 14(3):2496-2511.
- [21] MOHSENVAND M N, IZADI M R, MAES P. Contrastive representation learning for electroencephalogram classification[C] // *Machine Learning for Health*. PMLR, 2020:238-253.



ZHANG Jiaxiang, born in 1998, post-graduate. His main research interests include medical big data analytics and deep learning.



ZHANG Rui, born in 1971, Ph.D, professor, Ph. D supervisor. Her main research interests include medical big data analytics, machine learning and neural computational modeling.

(责任编辑:何杨)