



计算机科学

COMPUTER SCIENCE

基于时空自适应图卷积神经网络的脑电信号情绪识别

高越, 傅湘玲, 欧阳天雄, 陈松龄, 闫晨巍

引用本文

高越, 傅湘玲, 欧阳天雄, 陈松龄, 闫晨巍. 基于时空自适应图卷积神经网络的脑电信号情绪识别[J]. 计算机科学, 2022, 49(4): 30-36.

GAO Yue, FU Xiang-ling, OUYANG Tian-xiong, CHEN Song-ling, YAN Chen-wei. EEG Emotion Recognition Based on Spatiotemporal Self-Adaptive Graph Convolutional Neural Network[J]. Computer Science, 2022, 49(4): 30-36.

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)

大数据驱动的社会经济地位分析研究综述

Big Data-driven Based Socioeconomic Status Analysis:A Survey

计算机科学, 2022, 49(4): 80-87. <https://doi.org/10.11896/jsjcx.211100014>

图神经网络在 Text-to-SQL 解析中的技术研究

Technical Research of Graph Neural Network for Text-to-SQL Parsing

计算机科学, 2022, 49(4): 110-115. <https://doi.org/10.11896/jsjcx.210200173>

结合绘画先验的线稿上色方法

Sketch Colorization Method with Drawing Prior

计算机科学, 2022, 49(4): 195-202. <https://doi.org/10.11896/jsjcx.210300140>

一种基于深度学习的供热策略优化方法

Heating Strategy Optimization Method Based on Deep Learning

计算机科学, 2022, 49(4): 263-268. <https://doi.org/10.11896/jsjcx.210300155>

GSO:基于图神经网络的深度学习计算图子图替换优化框架

GSO:A GNN-based Deep Learning Computation Graph Substitutions Optimization Framework

计算机科学, 2022, 49(3): 86-91. <https://doi.org/10.11896/jsjcx.210700199>

基于时空自适应图卷积神经网络的脑电信号情绪识别

高越 傅湘玲 欧阳天雄 陈松龄 闫晨巍

北京邮电大学计算机学院(国家示范性软件学院) 北京 100876

北京邮电大学可信分布式与服务教育部重点实验室 北京 100876

(yuegao@bupt.edu.cn)

摘要 随着人机交互在计算机辅助领域的快速发展,脑电信号已成为情绪识别的主要手段。与此同时,图网络因其对拓扑结构数据的优秀表征能力,逐渐受到研究者的广泛关注。为进一步提升图网络对多通道脑电信号的表征性能,文中结合脑电信号的稀疏性、不频繁性等多种特性,提出了一种基于时空自适应图卷积神经网络的脑电情绪识别方法(Self-Adaptive Brain Graph Convolutional Network with Spatiotemporal Attention, SABGCN-ST)。该方法通过引入时空注意力机制解决了情绪的稀疏性问题,并根据自适应学习的脑网络拓扑邻接矩阵,挖掘不同位置的电极通道之间的功能连接关系。最终模型基于图卷积操作进行图结构的特征学习,实现对脑电信号的情绪预测。在 DEAP 和 SEED 两个脑电信号公开数据集上开展了大量实验,实验结果证明,SABGCN-ST 相比基线模型在准确率上具有显著的优势,平均情绪识别准确率达到 84.91%。

关键词: 脑电信号;情绪识别;图卷积神经网络;时空注意力机制;自适应邻接矩阵;深度学习

中图分类号 TP183

EEG Emotion Recognition Based on Spatiotemporal Self-Adaptive Graph Convolutional Neural Network

GAO Yue, FU Xiang-ling, OUYANG Tian-xiong, CHEN Song-ling and YAN Chen-wei

School of Computer Science (National Pilot Software Engineering School), Beijing University of Posts and Telecommunications, Beijing 100876, China

Key Laboratory of Trustworthy Distributed Computing and Service (BUPT), Ministry of Education, Beijing 100876, China

Abstract With the rapid development of human-computer interaction in computer aided field, EEG has become the main means of emotion recognition. Meanwhile, graph network has attracted wide attention due to its excellent ability to represent topological data. To further improve the representation performance of graph network on multi-channel EEG signals, in this paper, considering the sparsity and infrequency of EEG signals, a self-adaptive brain graph convolutional network with spatiotemporal attention (SABGCN-ST) is proposed. The method solves the sparsity of emotion via the spatiotemporal attention mechanism and explores the functional connections between different electrode channels via the self-adaptive brain network topological adjacent matrix. Finally, the feature learning of graph structure is operated via graph convolution, and the emotion is predicted. Extensive experiments conduct on two benchmark datasets DEAP and SEED prove that SABGCN-ST has a significant advantage in accuracy compared with baseline models, and the average accuracy of SABGCN-ST reaches 84.91%.

Keywords Electroencephalogram, Emotion recognition, Graph convolutional neural network, Spatio-temporal attention mechanism, Self-adaptive adjacent matrix, Deep learning

1 引言

情绪识别在人机交互^[1]中起着重要的作用,它可以使机器感知人类的情绪状态。情绪识别方法大体上可以分为两类:一种基于非生理信号,如面部表情图像^[2-6]、身体姿势^[7]以及语音信号^[8];另一种基于生理信号,如脑电图^[9]、肌电图^[10]

和心电图^[11]。其中,脑电信号(Electroencephalogram, EEG)被定义为不同大脑皮层位置记录到的电信号,反映了相应大脑区域神经元产生的放电情况。与生理信号相比,其更能反应大脑的活动状态,与情绪的相关性更强。因此脑电信号成为了识别情绪的主要手段。

然而,受限于人脑本身的复杂性和相关学科理论研究

到稿日期:2021-09-24 返修日期:2021-12-28

基金项目:北京市自然科学基金(M22012, L192026);国家自然科学基金(82071171)

This work was supported by the Beijing Natural Science Foundation(M22012, L192026) and National Natural Science Foundation of China(82071171).

通信作者:傅湘玲(fuxiangling@bupt.edu.cn)

尚未完备,目前基于脑电信号的情绪识别还存在一定的挑战。首先,大脑是一个复杂的系统,需要依靠大脑各个区域的协同作用才能完成基本的活动,情绪的产生也不例外。其次,情绪具有稀疏性、不频繁性和脑电信号是分布在不同脑区的连续时间信号波,而情绪信息可能只在某些时间片段或者大脑区域分布显著。此外,在不同的情绪状态下,大脑各功能区间的信号连接、传输方式也有所差异。建模脑区之间的信息交互以及关注情绪显著的片段和脑区是提取高效情绪特征并提高情绪识别准确率的关键所在。同时,针对脑电信号设计鲁棒的情绪识别模型对推动人机交互系统情绪智能化有切实的现实意义。

针对上述脑电信号存在的稀疏性、不频繁性和功能连接差异等诸多特性问题,本文设计了一种基于时空自适应图卷积神经网络(SABGCN-ST)的模型,用于脑电信号的情绪分类。该模型通过引入时空注意力机制来解决情绪稀疏性的问题,并根据自适应学习的脑网络拓扑连接矩阵,挖掘不同位置的电极通道之间的功能连接关系。依据学习到的脑网络拓扑结构,通过图卷积操作进行基于图结构的特征传播,最终基于图特征进行情绪识别。本文对所设计的时空自适应图卷积神经网络进行了详细的分析比较,并对各种不同的网络参数进行了多次实验。结果表明,所设计的模型相比传统的分类模型在情绪识别的准确率上具有明显的优势。

2 相关工作

现有的脑电情绪识别方法绝大多数都是有监督的范式。早期的情绪识别模型主要以浅层的机器学习模型为主,如支持向量机^[12](Support Vector Machine, SVM), K最近邻算法(K Nearest Neighbor, KNN)^[13]等模型。机器学习模型往往依赖于手工设计好的特征才能发挥较好的效果,自己本身的学习能力较弱,因此在日益兴起的既能学习特征又能完成分类深度学习技术面前,传统的浅层模型逐渐被弃用。Zheng等^[14]构建了一种多层深度置信网络(Deep Belief Network, DBN),从多通道特征中提取高维抽象特征以实现对情绪的识别。Li等^[15]考虑到左右半脑在结构和功能上的差异以及训练集和测试集之间的特征分布差异,设计了双半球域对抗神经网络(Bi-hemispheres Domain Adversarial Neural Network, BiDANN)模型,以减少源域和目标域在左右半脑可能存在的域差异。同时, Li等^[16]进一步研究了更加细粒度的脑区交互,提出了R2G-STNN模型,通过BiLSTM建模脑区的空间信息交互过程并引入区域注意力机制,来加强那些和情绪具有高相关性的区域特征。

近年来,基于图的深度学习方法在深度学习社区中得到了广泛应用。其对拓扑结构的良好表征为基于多通道 EEG 信号的情感分类带来了新的潜力。Song等^[17]进一步以电极

并学习更多的鉴别性特征,从而提高情绪识别能力。然而,他们的研究忽略了情绪的稀疏性,即被试在情绪激发过程中可能只有某些片段或某些脑区存在显著的情绪信息。此外, DGCNN 模型的脑图邻接矩阵建模方法忽略了不同情绪刺激下各脑区功能连接模式的差异。

3 模型及方法

3.1 脑电信号预处理及特征提取

获取的原始 EEG 信号需要经过一系列预处理,以削弱信号收集过程中实验环境、采集设备和被试本身生理活动等所引发的干扰信息或者噪声。本文对数据集中的脑电信号进行了一系列的预处理操作,包括:去除脑电信号中的直流分量,对实验数据进行样本划分,对坏样本进行修复,对修复信号进行带通滤波等。

经过初步的脑电信号预处理后,原始信号中的高频噪声、低频漂移等干扰信号很大程度上都被去除掉,得到了较为干净的脑电样本,即可用于特征提取。当前对脑电信号的特征提取主要有 4 类,分别是时域特征、频域特征、时频特征以及空域特征。其中,频域特征是当前最主流的用于情绪识别的 EEG 特征,可分解为 $\delta(1-4\text{ Hz})$, $\theta(4-8\text{ Hz})$, $\alpha(8-14\text{ Hz})$, $\beta(14-31\text{ Hz})$ 和 $\gamma(31-50\text{ Hz})$ 5 个频段,其对应的功率谱密度平均值可作为该频段的特征。本文选择频域特征中的微分熵(Differential Entropy, DE)特征的 5 个频段的拼接特征作为 EEG 信号的输入特征,用于后续的情绪分类。

3.2 时空自适应图卷积网络模型

SABGCN-ST 将多通道的 EEG 信号建模成以电极通道为节点、节点间连接权重为边的图结构数据,并基于时空注意力机制和自适应邻接矩阵优化了 EEG 信号的稀疏性和不频繁性问题,实现对多通道的 EEG 信号的图卷积表征。

如图 1 所示, SABGCN-ST 模型由 5 部分组成,包括:输入层、时空注意力层、脑网络拓扑结构学习层、图卷积层和情绪分类层。下文将详细描述各层的功能和推导过程。

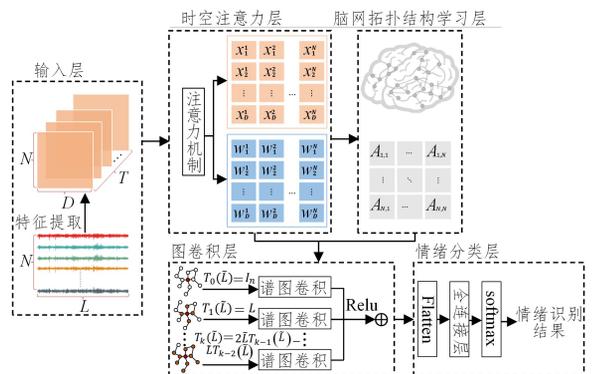


图 1 SABGCN-ST 模型结构图

Fig. 1 Framework of SABGCN-ST

同时,为便于表述,我们首先对文中出现的一些参数符号作出解释,具体参数及其对应的描述如表 1 所列。

表1 文中使用的符号及其含义

Table 1 Descriptions of notations used in this section

参数	描述
N	EEG 信号通道数
L	EEG 信号长度
T	EEG 上下文长度
D	EEG 特征向量维度
X	多通道 EEG 信号特征矩阵
A	多通道 EEG 信号邻接矩阵
W	空间注意力权重矩阵
$T(x)$	切比雪夫多项式
K	切比雪夫多项式阶数

3.2.1 输入层

输入层将 EEG 信号序列划分成样本并进行特征抽取,在 SABGCN-ST 中,样本的特征为 DE 特征。给定连续的样本集合 $X = (x_1, x_2, \dots, x_m) \in \mathcal{R}^{m \times N \times D}$, $x_i \in \mathcal{R}^{N \times D}$ 。由于在情绪诱发阶段,情绪活动可能只在某些片段显著出现。直观地说,不同的片段所包含的情绪信息不同,如果能够关注到这些显著片段,就能有效提升样本的分类能力。因此,为了使模型能够自适应地学习这种片段重要性,我们将模型的输入样本与其上下文相结合。EEG 样本的上下文指以当前待分类样本 x_i 为窗口中心、左右邻近 d 个时间步的样本集合 $x_{i-d}, \dots, x_{i-1}, x_{i+1}, \dots, x_{i+d}$ 。在处理每一个待识别的样本时,将其上下文信息也编码起来作为输入,以确保在保留足够的训练样本规模的同时尽可能地丰富样本的情绪信息。综上所述, SABGCN-ST 模型中的输入层为三维的张量 $\mathbf{X}_i = (x_{i-d}, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_{i+d}) \in \mathcal{R}^{T \times N \times D}$, $T = 2d + 1$ 。 T 作为模型的一个超参数,对模型的影响将在后续实验部分进行讨论。

3.2.2 时空注意力机制层

直觉上,被试在接收外界刺激时大脑并不会全程都产生显著的情绪活动,这意味着只有若干片段存在与情绪相关的信息。此外,在不同情绪状态下,大脑不同区域的激活水平也不相同,导致区域对情绪识别的贡献也不同。目前对于重要通道的识别方法主要有利用通道之间的互信息大小,利用分类器对不同通道的特征进行评估等。这说明考虑不同脑区通道对于识别情绪是非常有必要的。基于上述两种情况,本文引入注意力机制,从时间和空间两个维度提取 EEG 样本的上下文中与情绪更相关的元素。时空注意力层包含两个注意力模块,分别是时间注意力模块和空间注意力模块。其中时间注意力模块的具体表达式如式(1)和式(2)所示:

$$\mathbf{Attn}^{\text{Time}} = V_t \cdot \sigma((\mathbf{X}^T M_1) M_2 (M_3 X) + b_t) \quad (1)$$

$$\mathbf{Attn}_{m,n}^{\text{Time}} = \text{softmax}(\mathbf{Attn}_{m,n}^{\text{Time}}) \quad (2)$$

其中, $V_t, b_t \in \mathcal{R}^{T \times T}$, $\mathbf{X}^T \in \mathcal{R}^{N \times D \times T}$; $M_1 \in \mathcal{R}^{N \times 1}$, $M_2 \in \mathcal{R}^{D \times N}$, $M_3 \in \mathcal{R}^{D \times 1}$ 为待学习的参数; $\mathbf{Attn}_{m,n}^{\text{Time}} \in \mathcal{R}^{T \times T}$ 表示片段之间的相关性,即第 n 个时间步的片段信息对分类第 m 个时间步的样本的贡献; $\text{softmax}(\cdot)$ 函数将各个元素的得分重新归一化到 $0 \sim 1$ 。随机初始化以上参数并随训练过程更新。

空间注意力模块建模通道间的相关性,用于在后续的图卷积运算中增强更重要的边之间的特征传播。其计算式与

时间注意力模块类似,如式(3)和式(4)所示:

$$\mathbf{Attn}^{\text{Spatial}} = V_s \cdot \sigma((\mathbf{XZ}_1) Z_2 (Z_3 \mathbf{X}^T) + b_s) \quad (3)$$

$$\mathbf{Attn}_{m,n}^{\text{Spatial}} = \text{softmax}(\mathbf{Attn}_{m,n}^{\text{Spatial}}) \quad (4)$$

其中, $V_s, b_s \in \mathcal{R}^{N \times N}$, $\mathbf{X}^T \in \mathcal{R}^{N \times D \times T}$ 。 $M_1 \in \mathcal{R}^{T \times 1}$, $M_2 \in \mathcal{R}^{D \times T}$, $M_3 \in \mathcal{R}^{D \times 1}$ 为待学习的参数, $\mathbf{Attn}_{m,n}^{\text{Spatial}} \in \mathcal{R}^{N \times N}$ 表示通道 m 和通道 n 构成的边的重要性。时空注意力层最终输出时间维度的注意力矩阵 $\mathbf{Attn}^{\text{Time}} \in \mathcal{R}^{T \times T}$ 和空间维度的注意力矩阵 $\mathbf{Attn}^{\text{Spatial}} \in \mathcal{R}^{N \times N}$ 。

3.2.3 脑网络拓扑结构学习层

如何确定脑网络的邻接矩阵 A 是得到图结构表征的关键所在。以往的一些图论方法主要依靠先验知识来确定拓扑结构,如通道空间相邻等信息。但这些预先定义的静态的结构可能并不能很好地反映通道间的拓扑关系。Song 等^[17]提出的 DGCNN 中将邻接矩阵 A 视为一个模型参数,并加上相应的限制使其满足图卷积的条件。通过模型自动地学习和优化,结果证明了模型学习到的脑网络拓扑结构也是一种有效的手段,相比通过先验知识来确定的拓扑结构,通过训练优化的结构具有一定的动态性。但是根据 Song 等^[17]的方法,不同情绪状态下的脑图结构即邻接矩阵的结果是相同的,而 Li 等^[18]的研究指出,人类大脑区域在经历某种情绪时会遵循不同的激活模式,因此我们进一步认为,不同情绪状态下人脑区域的功能连接模式可能存在差异,而这能够通过通道间的信号关系反映出来。即在不同情绪下,大脑的拓扑结构不是一成不变的,而是自适应的。因此我们提出让模型学习自适应的脑网络邻接矩阵。具体的方法是定义一个非负的函数 $g(X_m, X_n)$, 输入任意两个通道的特征,该函数能够量化出通道间的连接强度。这样就能够从通道间的信号关系中计算出两个节点间的连接权重,连接权重会因信号的差异而变化。函数 g 的计算式如式(5)所示:

$$A_{m,n} = \frac{\exp(\text{Relu}(W_t | X_m - X_n |))}{\sum_{i=1}^N \exp(\text{Relu}(W_t | X_m - X_n |))} \quad (5)$$

其中, $W_t \in \mathcal{R}^D$ 为待学习的参数; $|X_m - X_n|$ 计算两个不同通道的特征向量的差异,即信号差异; Relu 作为激活函数能够确保权重 $A_{m,n}$ 非负; $g(X_m, X_n)$ 可以通过多层神经网络实现。通过学习脑网络拓扑结构,该层能够输出脑图的邻接矩阵 A 为接下来的图卷积层提供输入。

3.2.4 图卷积层

各个电极通道在物理空间呈现一种非欧几里得式的空间位置关系。在对相邻节点进行卷积特征提取时,图卷积神经网络是更适合的表征方法。图卷积层首先接收输入层的原始输入 \mathbf{X} 和时空注意力层输出的时间注意力矩阵 $\mathbf{Attn}^{\text{Time}}$, 以计算图上的特征矩阵 \mathbf{X}^0 , 如式(6)所示:

$$\mathbf{X}^0 = \mathbf{X} \mathbf{Attn}_{\text{mid}}^{\text{Time}} \quad (6)$$

其中, $\mathbf{Attn}_{\text{mid}}^{\text{Time}}$ 表示 EEG 的中间片段与其他上下文片段的相关性系数。计算完初始的图特征矩阵 \mathbf{X}^0 后,根据脑网络拓扑结构学习层输出的邻接矩阵 A 和空间注意力矩阵 $\mathbf{Attn}^{\text{Spatial}}$ 进行多层图卷积,传播相邻电极对之间的特征。为了求解切比

雪夫多项式,首先用 softmax 函数将邻接矩阵 \mathbf{A} 的权重缩放成 0-1。接着进行归一化,具体实现如式(7)所示:

$$\mathbf{A} = \mathbf{D}^{-\frac{1}{2}} (\mathbf{I}_N + \mathbf{A}) \mathbf{D}^{-\frac{1}{2}} \quad (7)$$

然后计算图的拉普拉斯矩阵 $\mathbf{L} = \mathbf{D} - \mathbf{A}$, 令 $\hat{\mathbf{L}} = \mathbf{U} \hat{\Lambda} \mathbf{U}^T = \frac{2\mathbf{L}}{\lambda_{\max}} - \mathbf{I}_N$, 由于对 \mathbf{A} 进行了归一化,其拉普拉斯矩阵特征值域为 $[0, 2]$, 可近似认为 $\lambda_{\max} = 2$, 接着通过傅里叶逆变换得到原信号 $x = \mathbf{U} \hat{x}$, 并计算 K 阶的切比雪夫多项式 $T_0(\hat{\mathbf{L}})$, $T_1(\hat{\mathbf{L}}), \dots, T_{k-1}(\hat{\mathbf{L}})$ 如式(8)所示。给定第 l 层图卷积层的输入 \mathbf{X}^{l-1} , 其图卷积输出 \mathbf{X}^l 可由式(9)表示:

$$T_i(x) = 2x T_{i-1}(x) - T_{i-2}(x), i = 2, 3, \dots \quad (8)$$

$$\mathbf{X}^l = \sigma \left(\sum_{k=0}^{K-1} \theta_k T_k(\hat{\mathbf{L}}) \mathbf{X}^{l-1} \text{Attn}^{\text{Spatial}} \right) \quad (9)$$

其中, θ_k 为相应的图卷积层的参数,通过叠加多层图卷积层,模型能够从局部的信息聚合得到更加整体的信息。经过卷积操作之后,各节点的特征随着图结构进行特征传播。由于脑中节点数量只有 32 或者 62,图节点的规模并不大。为了避免不必要的信息丢失,本文不进行图池化操作,而是直接将各个图卷积层的输出求和并摊平,将所有节点的特征整合起来作为图级别的向量表示,记为 \mathbf{h} , 如式(10)所示:

$$\mathbf{h} = \sum_{i=0}^l \mathbf{X}^i \quad (10)$$

3.2.5 情绪分类层

最后情绪分类层经过多层全连接层,总结各个节点的特征并起着最终分类器的作用。通过 softmax 层输出各个情绪识别类别的概率记为 \hat{y} , 输出概率最大的情绪类别作为模型最终的预测结果,其定义如式(11)所示:

$$\hat{y} = \text{softmax}(\sigma(\mathbf{W}_h \mathbf{h} + \mathbf{b}_h)) \quad (11)$$

在训练阶段,模型的损失函数的定义由 3 部分组成:分类结果的交叉熵损失、权重 L2 正则化损失以及邻接矩阵上的 L1 正则化损失。交叉熵损失在机器学习中常用来计算真实概率分布与预测概率分布之间的差异程度。交叉熵的值越小,模型分类效果则越好。权重 L2 正则化损失能够起到稀疏模型权重的目的,通过使大多数参数位于 0 附近一定程度上对模型进行剪枝,来降低模型复杂度并缓解过拟合。而对邻接矩阵进行 L1 正则化约束,主要是为了约束关联性小的节点之间的权重,使之尽可能为 0。损失函数如式(12)所示:

$$\text{Loss} = -\frac{1}{C} \sum_{i=1}^C \sum_{k=0}^{K-1} y_{i,k} \log y_{i,k} + \lambda_1 \sum_{j=0}^J \omega_j^2 + \frac{\lambda_2}{C} \sum_{i=1}^C \sum_{j=1}^N \sum_{k=1}^N |A_{jk}| \quad (12)$$

其中, C 为样本数量, N 为节点数量, λ_1 和 λ_2 分别为正则化参数。通过定义损失函数,模型在每一次迭代中根据相应的学习率步长和梯度来更新模型参数。

4 实验结果及分析

4.1 数据集

本文的实验主要基于两个主流脑电信号公开数据集

DEAP 和 SEED 开展。

4.1.1 DEAP 数据集

DEAP 数据集是一个经典的脑电情绪数据集,其数据库以音乐视频材料诱发刺激的方式采集了 32 名受试者的脑电数据。DEAP 数据集的情绪标签则通过被试自身的主观评价得到。在一次脑电数据采集的实验过程中,被试被要求观看 40 段音乐视频片段,并通过 32 导的干电极脑电帽以 512 Hz 的采样率全程采集 EEG 信号。DEAP 数据集额外记录了被试未受情绪刺激状态下的生理数据作为基线数据,可以供后处理。然后是大约 1 min 的音乐视频情绪刺激阶段。最后是被试的主观评价环节,被试被要求填写观看视频过程中的愉悦度,唤醒度进行 1~9 的打分,分数越高,强度越大。针对该数据集,学者们一般会在愉悦度和强度两个维度进行二分类。比如将愉悦度大于 5 的定为愉快标签,反之为不愉快标签。

4.1.2 SEED 数据集

SEED 数据集是目前脑电情绪分析领域主流的公开数据集之一。它是由上海交通大学 BCMI 实验室在实验室环境下采集的单模态多被试的 3 类脑电情绪数据集。SEED 收集了 15 名被试(平均年龄为 23 岁,其中男性 7 人,女性 8 人)的 EEG 数据。在一次脑电数据采集的实验过程中,被试被要求观看 15 段电影片段,并通过 62 导的干电极脑电帽,以 1000 Hz 的采样率全程采集 EEG 信号。单名被试的一次脑电数据采集实验包含 15 段有情绪标签(5 个积极、5 个中性、5 个消极情绪)的 62 导的 EEG 时间序列数据。

4.2 实验设置

本文选取了 5 个具有代表性的算法进行复现并作为 baseline,包括:随机森林(RF),支持向量机(SVM)^[12]、深度置信网络(DBN)^[14]、循环神经网络(R2G-STNN)^[16] 和动态图卷积神经网络(DGCNN)^[17]。

在性能对比实验中,网络模型中的所有参数均采用 xavier 初始化方法进行随机初始化。网络训练时均采用小批量梯度下降法(Mini-Batch Gradient Descent, MBGD)。参数的更新通过计算每个小批量样本的损失函数进行误差反向传递。优化算法选择 Adam,训练轮数设为 100,学习率设为 0.001,并加入学习率衰减,学习率随着迭代轮数以 0.01 的系数进行线性衰减,帮助模型在训练后期以更小的幅度进行更新。

本文采取单被试实验,即每次实验的训练和测试分类器的数据都来自同一名被试的同一次实验。为了增强可比性,本文遵守基于此数据集的论文所采用的训练集和测试集划分设置。对于 SEED 数据集,每个被试每个 session 的前 9 个刺激片段中的样本作为训练集,后 6 个作为测试集。对于 DEAP 数据集,本文进行以刺激片段为单位的十折交叉验证。所有 baseline 方法和本文模型均采用相同的训练流程和优化器。特征均选择 DE 全频段特征, SABGCN-ST 模型中的超参数上下文长度 T 取 5,切比雪夫多项式阶数 K 取 3。

4.3 结果分析

在 SEED 数据集上的实验结果如表 2 所列,在 DEAP 数据集上的唤醒度和愉悦度的分类结果如表 3、表 4 所列。

表 2 各方法在 SEED 数据集上的情绪识别结果

Table 2 Emotion recognition results of each method on SEED

Subject	RF	SVM	DBN	R2G-STNN	DGCNN	SABGCN-ST
1	0.6642	0.7399	0.7537	0.7908	0.8772	0.8978
2	0.5708	0.5994	0.7441	0.7064	0.8750	0.8904
3	0.6983	0.7413	0.8125	0.8466	0.8955	0.9279
4	0.7279	0.7022	0.7096	0.7086	0.7824	0.8118
5	0.7554	0.6939	0.7745	0.7167	0.7647	0.7448
6	0.7563	0.6959	0.7110	0.9025	0.8941	0.8235
7	0.6189	0.6538	0.7289	0.8409	0.8167	0.8345
8	0.7397	0.7620	0.7652	0.8221	0.8404	0.9596
9	0.7304	0.7499	0.9047	0.7446	0.8830	0.9264
10	0.5902	0.6495	0.5784	0.7100	0.8191	0.7698
11	0.7461	0.7772	0.8801	0.7483	0.8890	0.7402
12	0.8088	0.8451	0.7458	0.8608	0.8525	0.8688
13	0.7865	0.7824	0.8007	0.7892	0.9169	0.8061
14	0.6681	0.7186	0.7360	0.7088	0.6485	0.8588
15	0.8150	0.8202	0.7596	0.9843	0.9772	0.9872
Mean	0.7118	0.7288	0.7603	0.7920	0.8488	0.8565
std	0.0743	0.0658	0.0756	0.0837	0.0767	0.0749

表 3 各方法在 DEAP 数据集上的愉悦度的情绪识别结果

Table 3 Emotion recognition results of valence of each method on DEAP

Subject	RF	SVM	DBN	R2G-STNN	DGCNN	SABGCN-ST
1	0.5980	0.6316	0.7743	0.7920	0.8360	0.8284
2	0.6908	0.5755	0.7956	0.7595	0.8639	0.7543
3	0.6856	0.5717	0.6750	0.7789	0.8105	0.8085
4	0.7350	0.7494	0.8375	0.8306	0.8122	0.9289
5	0.6580	0.6940	0.7745	0.7007	0.8505	0.7188
6	0.5866	0.5746	0.6868	0.8161	0.7282	0.8231
7	0.6189	0.6881	0.7757	0.8135	0.8537	0.8321
8	0.6300	0.6315	0.7652	0.7832	0.8384	0.8567
9	0.6000	0.6225	0.7047	0.7528	0.7837	0.8167
10	0.5902	0.5703	0.5784	0.7410	0.7507	0.8096
Mean	0.6393	0.6309	0.7368	0.7768	0.8128	0.8177
std	0.0487	0.0622	0.0743	0.0395	0.0453	0.0558

表 4 各方法在 DEAP 数据集上的唤醒度的情绪识别结果

Table 4 Emotion recognition results of arousal of each method on DEAP

Subject	RF	SVM	DBN	R2G-STNN	DGCNN	SABGCN-ST
1	0.5670	0.6043	0.8212	0.8451	0.7262	0.8733
2	0.7808	0.8021	0.7956	0.7195	0.8731	0.7395
3	0.6226	0.5470	0.8500	0.6730	0.7495	0.6828
4	0.6350	0.4865	0.8375	0.7631	0.6707	0.8823
5	0.5080	0.5802	0.7045	0.8312	0.7570	0.8322
6	0.7866	0.8235	0.8305	0.9090	0.8748	0.9298
7	0.8125	0.8466	0.7757	0.7547	0.9304	0.7781
8	0.6300	0.6749	0.7645	0.7959	0.7556	0.8619
9	0.7050	0.7719	0.7700	0.8435	0.8346	0.8600
10	0.5902	0.8281	0.6548	0.6956	0.8846	0.7554
Mean	0.6638	0.6965	0.7804	0.7831	0.8057	0.8195
std	0.1029	0.1341	0.0619	0.0752	0.0847	0.0771

在 baseline 方法中,SVM 算法和 RF 算法是传统机器学习方法的代表,DBN 算法是无监督深度学习模型的代表,R2G-STNN 是基于时序性深度学习模型的代表,DGCNN 是基于图神经网络的代表模型。表 3 列出了各方法在每个被试上 3 次 session 识别的平均准确率,最后两行表示所有被试的平均

情绪识别准确率和标准差。其中单被试的最高分类准确率均已加粗显示。整体来看,传统的 SVM 和 RF 算法分类准确率都较低;DBN 和 R2G-STNN 模型由于具备一定的建模通道间关联的能力,在准确率上有大幅的提升;而 DGCNN 将多通道 EEG 信号建模成图数据,相比其他方法能够更好地捕捉两两通道间的特征关联,因而在 baseline 中取得了更好的效果。

在 SEED 数据集中,所提 SABGCN-ST 模型在 15 个被试中的 10 个上均取得了最高的准确率,达到 98.72%。在 DEAP 数据集的愉悦度和唤醒度分类结果中,最高的准确率基本上都是 SABGCN-ST 模型取得的,且相比 baseline 方法有不错的提升,最高准确率能够达到 93.04%。这说明基于图网络建模对多通道的脑电信号的情绪信息具有更好的表征能力。此外,对比 DGCNN 和 SABGCN-ST 的实验结果,后者在 3 个情绪分类实验中的平均情绪识别准确率都高于前者,这表明时空注意力机制和自适应的脑图拓扑结构学习有助于图网络模型更好地提取情绪相关信息。

图 2 给出了 SABGCN-ST 模型在 SEED 3 类情绪数据集上的情绪分类混淆矩阵结果。图中 negative, neutral 和 positive 分别表示负向、中性和正向情绪标签。纵坐标表示样本的真实类别,横坐标表示模型的预测类别。矩阵中每个元素表示模型将各个类别的数据预测成 3 类情绪的概率。从图中可以看出,模型对于积极情绪的分类效果最好,达到了 92.81%的准确率;对中性情绪的分类能力也达到了 91.86%的水平;而对消极情绪的识别能力最差,准确率只有 64.66%,并且消极情绪最容易容易被误识别为中性情绪而中性情绪却不容易被识别为消极情绪。

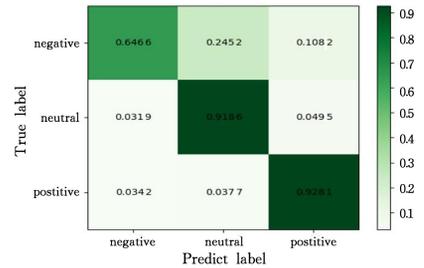


图 2 模型对各类情绪的预测结果混淆矩阵示意图

Fig. 2 Schematic diagram of confusion matrix for different emotion prediction results of SABGCN-ST

4.4 消融实验

以上实验结果说明了所提方法的有效性。接下来本文将在 SEED 数据集上进行实验,分析模型的结构和超参数对情绪识别性能的影响。

4.4.1 自适应邻接矩阵

脑图邻接矩阵是脑图卷积模型中关键的一环。为了说明本文设计的脑图拓扑结构学习层的有效性,本文首先对比了几种不同的邻接矩阵设置对图卷积的影响。

(1)全连接邻接矩阵(Full Connected,FC):邻接矩阵中所有元素均为 1,代表所有通道之间都存在连接,且连接权重相同。

(2)局部连接的邻接矩阵(Local Connected,LC):参考 Li 等^[16]的研究,将整个脑区划分为 16 个区域,只有同一区域的

通道间的连接权重为 1。

(3)随机连接的邻接矩阵(Random Connected,RC):无任何先验知识,邻接矩阵中所有元素均使用 0-1 间的随机数进行初始化。

(4)基于空间距离的邻接矩阵(Distance Based,DB):通道间的连接权重由它们之间的欧几里得距离决定。空间上越近,则连接权重越大。

(5)基于特征向量余弦相似度的邻接矩阵(Cosine Similarity of Feature Vector,CSFV):通道间的连接权重由其特征向量之间的余弦相似度决定,特征向量越相似,则连接权重越大。相似度的计算取训练集所有样本相似度的平均值。

图 3 给出了这 5 种邻接矩阵和本文设计的自适应的邻接矩阵的学习方法的对比结果。随机初始化的邻接矩阵可能会导致图上特征传播的错误路径,因此整体准确率最低。局部连接相比全连接的邻接矩阵准确率略低,但差异不大,可能的原因是,从空间位置来看,关键的连接可能存在局部区域。基于距离衰减的邻接矩阵由于对不同距离的通道存在差异化的权重,准确率稍高一些。基于特征向量相似度的邻接矩阵从信号的角度刻画通道间的功能性连接强度,取得了 5 种 baseline 方法中的最佳效果,这是比较符合直觉的。本文设计的自适应的邻接矩阵学习方法是根据通道间特征向量的差异学习到的,该方法不需要任何先验知识,但效果比其他方法更好、更稳定。这可能是因为它可以根据损失函数自动优化邻接矩阵,能够发现除空间位置和特征维度以外的更多信息。

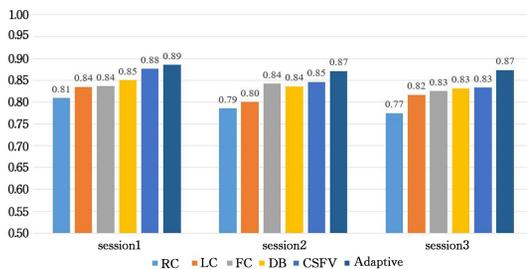


图 3 不同邻接矩阵对图卷积网络的影响

Fig. 3 Effect of different adjacent matrices on graph convolution network

4.4.2 参数设置

此外,我们进一步分析了 SABGCN-ST 模型的超参数的取值对模型最终的情绪识别性能的影响,包括输入层的上下文长度 T 和图卷积层的切比雪夫多项式 K 。随机选取 SEED 中的某一被试进行消融实验。图 4、图 5 给出了各参数不同的取值下 3 个 session 的平均识别率的变化情况。

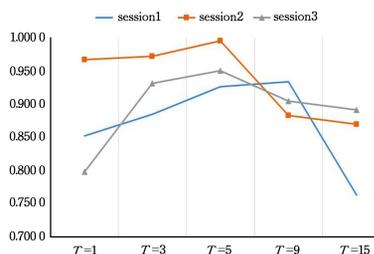


图 4 不同 T 取值对模型识别率的影响

Fig. 4 Effect of different T on model recognition rate

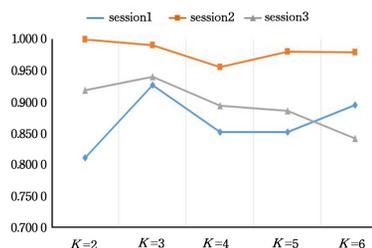


图 5 不同 K 取值对模型识别率的影响

Fig. 5 Effect of different K on model recognition rate

T 的取值会影响样本的上下文长度,在模型中主要通过时空注意力层关注到样本 T 窗口内的情绪信息更加显著的片段。从图 4 可知,随着上下文长度增加,准确率先上升再趋于平稳最后反而下降。一方面,这可能是由于随着 T 的增加,训练集中的样本减少,当 T 为 15 时,以 1 min 的实验时长为例,样本量减少了 23.33%。另一方面,样本数量减少、特征维度增加会使模型的参数增加,进而导致性能受过拟合现象的影响严重。上下文长度为 5 时效果最好。而切比雪夫多项式中 K 的取值主要影响图卷积层的参数。 K 越大,切比雪夫多项式的近似效果越好,同时模型的参数量也就越大,同样也可能带来过拟合问题。图 5 的结果基本反映了这个规律。当 K 取 3 时达到最佳的效果,当 K 再增大时,准确率反而下降。

结束语 本文在对脑电信号情绪识别问题的研究中,将多通道 EEG 数据建模成图结构数据,并引入图卷积表征。针对情绪的稀疏性和不频繁性问题,我们引入了时空注意力机制,从时间和空间两个维度提取 EEG 样本中与情绪更相关的元素。针对脑网络拓扑结构学习的问题,本文设计了自适应法对邻接矩阵进行动态学习,以反映真实情况下不同情绪状态下人脑区域的功能连接模式存在的差异。我们基于此开发适合脑电情感识别的脑图卷积神经网络模型 SABGCN-ST。本文在 SEED 和 DEAP 脑电数据集上进行了单被试实验,并且与当前 EEG 情绪识别的代表性方法进行了大量对比实验。实验证明 SABGCN-ST 能够取得明显优于基线方法的情绪分类结果。同时,本文还对不同脑图邻接矩阵设置对脑图卷积网络的分类性能的影响进行了讨论,以证明自适应邻接矩阵学习方法的有效性,并对模型的超参数的取值影响进行了广泛的实验分析。我们的工作表明,通过对图网络的有效建模,基于多通道的 EEG 情绪识别性能能够得到有效提升。

参考文献

- [1] COWIE R, DOUGLAS C E, TSAPATSOLIS N, et al. Emotion recognition in human-computer interaction[J]. IEEE Signal Processing Magazine, 2001, 18(1): 32-80.
- [2] ANDERSON K, MCOWAN P. A real-time automated system for the recognition of human facial expressions[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2006, 36(1): 96-105.
- [3] HUANG X, ZHAO G, HONG X, et al. Spontaneous facial micro-expression analysis using spatiotemporal completed local quantized patterns[J]. Neurocomputing, 2016, 175: 564-578.

- [4] HUANG X, WANG S, ZHAO G, et al. Facial micro-expression recognition using spatiotemporal local binary pattern with integral projection[C]// IEEE International Conference on Computer Vision Workshop. 2015;1-9.
- [5] HUANG X, WANG S, LIU X, et al. Discriminative spatiotemporal local binary pattern with revisited integral projection for spontaneous facial micro-expression recognition [J]. IEEE Transactions on Affective Computing, 2017, 10(1): 32-47.
- [6] LIU Y, ZHANG J, YAN W, et al. A main directional mean optical flow feature for spontaneous micro-expression recognition [J]. IEEE Transactions on Affective Computing, 2016, 7(4): 299-310.
- [7] YAN J, ZHENG W, XIN M, et al. Integrating facial expression and body gesture in videos for emotion recognition[J]. IEICE Transactions on Information and Systems, 2014, E97-D(3): 610-613.
- [8] ANG J, DHILLON R, KRUPSKI A, et al. Prosody-based automatic detection of annoyance and frustration in human-computer dialog[C]//International Conference on Spoken Language Processing. 2002;2037-2040.
- [9] ZHENG W. Multichannel EEG-based emotion recognition via group sparse canonical correlation analysis[J]. IEEE Transactions on Cognitive and Developmental Systems, 2017, 9(3): 281-290.
- [10] CHENG B, LIU G. Emotion recognition from surface EMG signal using wavelet transform and neural network[C]// 2nd International Conference on Bioinformatics and Biomedical Engineering. 2008;1363-1366.
- [11] AGRAFIOTI F, HATZINAKOS D, ANDERSON A. ECG pattern analysis for emotion detection[J]. IEEE Transactions on Affective Computing, 2012, 3(1): 102-115.
- [12] NOBLE W S. What is a support vector machine? [J]. Nature Biotechnology, 2006, 24(12): 1565-1567.
- [13] MERT A, AKAN A. Emotion recognition from EEG signals by using multivariate empirical mode decomposition [J]. Pattern Analysis and Applications, 2018, 21(1): 81-89.
- [14] ZHENG W L, LU B. 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] LI Y, ZHENG W, ZONG Y, et al. A bi-hemisphere domain adversarial neural network model for EEG emotion recognition [J]. IEEE Transactions on Affective Computing, 2021, 12(2): 494-504.
- [16] LI Y, ZHENG W, WANG L, et al. From regional to global brain: a novel hierarchical spatial-temporal neural network model for EEG emotion recognition[J/OL]. IEEE Transactions on Affective Computing. <https://doi.ieeecomputersociety.org/10.1109/TAFFC.2019.2922912>.
- [17] SONG T, ZHENG W, SONG P, et al. EEG emotion recognition using dynamical graph convolutional neural networks[J]. IEEE Transactions on Affective Computing, 2018, 11(3): 532-541.
- [18] LI P, LIU H, SI Y, et al. EEG based emotion recognition by combining functional connectivity network and local activations [J]. IEEE Transactions on Biomedical Engineering, 2019, 66(10): 2869-2881.



GAO Yue, born in 1998, Ph.D candidate. His main research interests include natural language processing, medical informatics and recommender system.



FU Xiang-ling, born in 1975, Ph.D, associate professor. Her main research interests include medical informatics, deep learning and text mining.

(责任编辑:李亚辉)