



计算机科学

COMPUTER SCIENCE

基于多重有向加权图与卷积神经网络的脑电情感识别

罗瑞奇, 严金林, 胡新荣, 丁磊

引用本文

罗瑞奇, 严金林, 胡新荣, 丁磊. 基于多重有向加权图与卷积神经网络的脑电情感识别[J]. 计算机科学, 2023, 50(6A): 220600128-8.

LUO Ruiqi, YAN Jinlin, HU Xinrong, DING Lei. EEG Emotion Recognition Based on Multiple Directed Weighted Graph and Convolutional Neural Network [J]. Computer Science, 2023, 50(6A): 220600128-8.

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)

[基于图像数据耦合识别的输电线路安全风险评估方法](#)

Image Recognition Method of Transmission Line Safety Risk Assessment Based on Multidimensional Data Coupling

计算机科学, 2023, 50(6A): 220500032-6. <https://doi.org/10.11896/jsjcx.220500032>

[基于改进CNN-BP的多波束声纳高程数据预测研究](#)

Study on Multibeam Sonar Elevation Data Prediction Based on Improved CNN-BP

计算机科学, 2023, 50(6A): 220100161-4. <https://doi.org/10.11896/jsjcx.220100161>

[基于多模态特征融合的时间序列异常检测](#)

Anomaly Detection of Time-series Based on Multi-modal Feature Fusion

计算机科学, 2023, 50(6A): 220700094-7. <https://doi.org/10.11896/jsjcx.220700094>

[注意力特征融合的孪生网络目标跟踪方法](#)

Attentional Feature Fusion Approach for Siamese Network Based Object Tracking

计算机科学, 2023, 50(6A): 220300237-9. <https://doi.org/10.11896/jsjcx.220300237>

[基于改进的ResNeXt网络结构的遥感图像分类](#)

Remote Sensing Image Classification Based on Improved ResNeXt Network Structure

计算机科学, 2023, 50(6A): 220100158-6. <https://doi.org/10.11896/jsjcx.220100158>

基于多重有向加权图与卷积神经网络的脑电情感识别

罗瑞奇 严金林 胡新荣 丁磊

武汉纺织大学计算机与人工智能学院 武汉 430200

(rqluo@wtu.edu.cn)

摘要 脑电信号应用于情感识别的研究近年来受到广泛的关注,将时间序列映射为可见图表示,通过可见图边和节点的度量能够有效进行脑电情感识别。传统可见图算法忽略了多通道脑电信号间的相关性,难以保留时间序列上复杂的特征信息。因此提出一种多重有向加权可见图提取脑电信号特征的方法,并将脑电信号特征用于情感识别。首先将脑电信号转换成有向加权网络图,强化信号的特征表示,使用加权聚类系数表征复杂网络结构,以多重复杂网络建立脑电连接矩阵,最后采用卷积神经网络进行特征学习,通过学习后获得情感识别结果。多重有向加权可见图构建的复杂网络模型在公开数据集验证的准确率达到了93.85%,优于现有的简单可见图方法;多重加权可见图与单变量可见图相比,情感识别准确率提高了9.4%。实验结果表明,该方法在跨被试者数据上同样适用,具有很好的鲁棒性。

关键词:情感识别;脑电信号;多重可见图;卷积神经网络;聚类系数

中图法分类号 TP391

EEG Emotion Recognition Based on Multiple Directed Weighted Graph and Convolutional Neural Network

LUO Ruiqi, YAN Jinlin, HU Xinrong and DING Lei

School of Computer Science and Artificial Intelligence, Wuhan Textile University, Wuhan 430200, China

Abstract In recent years, research on EEG signals applied to emotion recognition has received extensive attention, and mapping time series into visibility graph representation can effectively perform EEG emotion recognition through the metric of edges and nodes of the visibility graph. Traditional visibility graph algorithms ignore the correlation between multi-channel EEG signals, and it is difficult to retain the complex feature information on the time series. Therefore, this paper proposes a method to extract EEG signal features from multiple directed weighted visibility graphs and use EEG signal features for emotion recognition. Firstly, the EEG signal is converted into a directed weighted network graph to enhance the feature representation of the signal, the complex network structure is characterized using weighted clustering coefficients, the EEG connection matrix is established with multiple complex networks, and finally the convolutional neural network is used for feature learning, and the emotion recognition results are obtained through learning. The complex network model constructed by multiple directed weighted visibility maps achieves 93.85% accuracy in public dataset validation, which is better than the existing traditional visibility graph methods, and the multiple weighted visibility graph improves the emotion recognition accuracy by 9.4% compared with univariate visibility graph. Experimental results show that the method is also applicable to cross subject data and has good robustness.

Keywords Emotion recognition, EEG signal, Multiple visible graph, Convolutional neural network, Clustering coefficient

喜怒哀乐等情绪是人类个体与生俱来的本能,但是对于机器来说似乎是一个难以打开的黑盒子。当前的脑电信号智能应用重视情感开发,开发和实施新的情感自动识别算法至关重要,创建更加人性化的智能应用方式,减少人与机器之间冰冷的交流内容。科学家对神经科学和认知科学的研究结果证明,情绪的产生机理与大脑皮层的活动密切相关,脑电图(Electroencephalogram, EEG)代表大脑皮层神经元突触连接产生的电活动^[1]。在传统研究中,人们提出将脑电以线性

系统的指标来求得特征。其中包括基于频率特征的算法,如广泛使用的功率谱密度与大脑半球在不同频带的不对称性。然而,线性度量只能在 EEG 信号中提供有限的信息,因为神经活动过程远不是线性的,因此也不符合叠加原理,即使在细胞水平上,也表现出高度异质性和非平稳行为^[2]。非线性技术在这几年被证明其效果优于传统线性方法^[3]。

复杂网络可以准确描述非线性的时间序列,使得需要大量人工标记或者操作的信号数据通过数学模型获取特征

基金项目:湖北省高等学校优秀中青年科技创新团队计划项目(T201807);湖北省教育厅科学研究计划重点项目(D20191708)

This work was supported by the Outstanding Young and Middle-aged Scientific and Technological Innovation Team Project of Colleges and Universities in Hubei Province(T201807) and Key Projects of Scientific Research Plan of Hubei Provincial Department of Education(D20191708).

通信作者:胡新荣(hxr@wtu.edu.cn)

内容。许多复杂的信息系统,如电力、信号、社交、交通等,都可以用数学方法建模成复杂网络进行分析。复杂网络从特定的角度将数据以可理解的形式表现出来,在各种研究领域十分常见。复杂网络常用的研究方法包括概率论、统计学、遗传算法、图论、矩阵等。脑电等生理信号是典型的非线性时间序列,传统的研究方法从信号的时域、频域、空间域等方面入手。Small 等^[4]研究混沌信号中的动力学特征,在低维和充满噪声的混沌时间序列当中发现了复杂网络的不同特征表现;Xiang 等^[5]在递归相空间网络的多尺度特征上发现不同的拓扑空间中其复杂网络的节点重要性不同,其结构也会有所变化;Sporns 等^[6]研究人类生理信号关联程度,发现多种不同的网络拓扑统计特征能够很好地表征信号的动力学特性;Gao 等^[25]在随后的研究当中利用可见图的方式对脑电、心电等多种生理信号进行复杂网络特征分析,获得了优异的分类结果;Liu 等^[26]使用转移网络分析了多种状态下的脑电信号特征,针对单一信号的癫痫检测给出了准确的识别结果。这些研究内容证明了复杂网络在脑电信号上有效应用的可行性。基于此,本文研究一种高效的可见图复杂网络用于脑电情感识别。

本文提出的方法如下:

(1)构建多重有向加权可见图(Multiple Directed Weighted Visibility Graph, MDWVG)的脑电信号复杂网络,显著分离信号的特征表示,强化多通道脑电信号之间的关联特征信息;

(2)使用加权聚类系数(Weighted Clustering Coefficient, WCC)描述复杂网络特征,利用特征相关性融合多重网络,建立脑电连接矩阵(EEG Connection Matrix, ECM),在保留特征信息的情况下增加了泛化能力;

(3)使用 SEED 公开数据集进行验证评估,所提方法在跨被试者数据上提升了准确率,具有普遍适用性。

1 相关工作

1.1 经典脑电特征提取

在脑电信号的研究方面,学者们从经典的信号处理方面出发提取脑电图的特征信息,证实脑电的信号特征跟情绪有着明显的关联。分形维数(Fractal Dimension, FD)特征、微分不对称特征、理性不对称特征和功率谱密度特征等信号特征被应用于脑电波的表征上^[7]。Harmon 等^[8]证明了左右额叶区域的脑电信号(即脑电不对称)分别与积极情绪和消极情绪相关,在情绪研究中得到了广泛的关注。Sananda 等^[9]使用多分形去趋势波动分析方法从脑电图信号的每个通道中提取整个频带的特征,获得了最高 85.83% 的识别准确率。Zheng 等^[10]使用微分熵(Differential Entropy, DE)特征研究了 DEAP^[11]和 SEED(SJTU Emotion EEG Database)^[12]两个公开数据集,用以识别 3 种情绪(快乐、悲伤、正常),对比 DE 和改进的 FD 两种方法获得的准确率为 80.27% 和 72.09%。经典脑电特征提取方式是直接对信号进行手动特征分析之后进行分类,获得识别结果,特征形式不直观,难以强化特征表示。新的研究方式是将信号转换成网络或者图的特征强化表示形式,进一步获取特征内容用于识别任务。

1.2 复杂网络脑电特征提取

复杂网络是使用拓扑结构来描述真实世界复杂系统的非线性方法,时间序列的复杂网络分析在众多研究领域都有应用。Lacasa 等^[15]提出了一种高效的由信号构建图的方法——可见图(Visibility Graph, VG)。使用可见图构造的网络保留了原始数据在结构上的属性特征,如周期、振幅、分形等转化为随机、连结、规则的网络,逐步应用于脑电信号分析上并取得了进步。之后的研究中更多的 VG 算法出现, Luque 等^[16]提出了可以表征脑电信号的混沌特性的可见性图——水平可见性图(Horizontal Visibility Graph, HVG),将一组信号转换成唯一的可见图,但在长序列上忽略了信号组之间的特征联系,并且在抗噪效果上有缺陷。Wang 等^[17]使用有限穿透可见性图(Limited Penetration Visibility Graph, LPVG)分析阿尔茨海默病,将复杂网络中的度量熵与脑电波形联系起来,未能应用在情感识别任务上。Zhu 等^[18]提出了加权水平可见图(Weighted Horizontal Visibility, WVG),引入了边缘权值,通过信号的可见范围对边进行赋权。加权可见图保留了更多的信号特征,但是其研究只应用在单一脑电信号上。普通可见图在单变量时间序列分析中成功应用,却不能很好地保留序列在时间方向的变化,且无法获取信号在多重通道上的相互关联。改进的可见图需考虑更多的信息。

基于上述事实,本文将单变量可见图的思想推广到构造多层可见图,并在加权的时候指定可见图的方向,创建出 MDWVG。方法将脑电信号根据情绪分类转换成不同的网络拓扑图,采用 WCC 描述拓扑网络的特征,根据特征相关性构建出不同电极间的脑电连接矩阵。在跨被试者数据上, WCC 的局部聚集规律在多被试之间表现出显著的一致性,具有很好的泛化能力。最后将多重特征序列传输到卷积神经网络(Convolutional Neural Network, CNN)模型中,对 3 种情感类别进行分类训练。

2 方法

2.1 研究框架和内容安排

本文提出的 EEG 情绪识别方法框图如图 1 所示。原有的脑电信号样本集合数据量大,直接使用不利于训练和测试,性能要求高,因此使用滑动窗口将其切分为多个小样本块,每个块的长度和大小一致,在 3.2 节实验设置上具体说明;切分后的信号数据以每个通道的方式建立复杂网络,每个通道数据 $X_i = \{x_1, x_2, \dots, x_n\}$, 序列长度为 n , 形成一层复杂网络,构造出多重复杂网络 $MCN = \{X_1, X_2, X_3, \dots, X_m\}$, 层数 m 与通道数一致,在 2.2 节详细介绍这部分内容。使用加权聚类系数描述复杂网络的特征信息,计算网络中的每个节点的加权聚类系数 x_{ij} , 每层网络计算出聚类系数向量,对所有向量两两计算余弦相似,结果存放在 ECM 当中,在 2.3 节详细介绍这部分内容;最后将 ECM 放入 CNN 中训练,获得 3 种情绪识别结果。第 4 节将从特征表示、分类器分析、对比实验和消融实验上对本文方法的结果进行讨论。

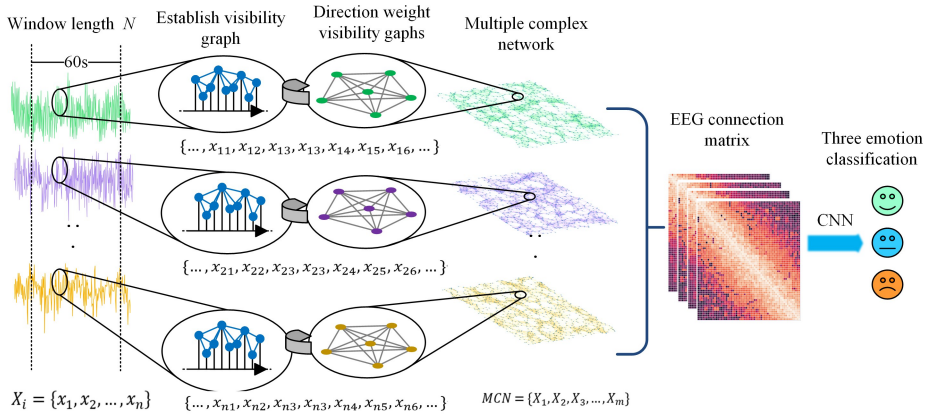


图1 复杂网络脑电信号情感识别方法框架

Fig. 1 Emotional recognition method framework of complex network EEG signals

2.2 可见图算法创建复杂网络

原始的脑电信号在经过下采样和平滑等预处理操作之后,使用可见图算法转换成复杂网络的形式。可见图重点关注信号中样本聚集的特征信息,将样本块中的每个样本点当成网络节点,可见图不同的算法影响信号映射到网络上的特征保留内容,信号中的时域、频域以及多层信号的空间域等能够与网络中的结构、度、相关性等对应,用于强化表征信息,使得数据易于提取和理解。

2.2.1 可见图

VG算法是将时间序列映射成网络的一种方法,其算法核心在于如何确定网络中的节点以及节点之间的连接方式。以单变量时间序列为例,带有 N 个数据样本的脑电信号表示为 $X = \{x_1, x_2, \dots, x_N\}$,将每个时间采样点视为一个节点,如果任意两个节点 x_i 和 x_j 之间存在节点 x_t ,要在 VG 中建立连线,需要满足以下条件:

$$\frac{x_i - x_t}{t - i} > \frac{x_i - x_j}{j - i}, i < t < j \quad (1)$$

其中, i, t, j 表示的是不同的时刻。

将脑电信号以相同的时间间隔标记成不同的序列点,每个点以垂直线的形式显示出来,垂直线对应的高度和位置与时间序列中样本点出现的值是一样的。如图 2(a) 所示,如果任意两条垂直线能够以直线的方式相互可见,不受中间垂直线的影响,就可以对这两个节点进行连接。如图 2(b) 所示,所有序列点以可见图方式连线之后,形成一个区域内的网络连线图,网络中的节点对应脑电信号的样本点,序列中的时间信息以节点的顺序表示,信号的数值大小被隐藏,节点之间的边代表信号中的样本点关联信息,最后所有样本数据形成复杂网络。

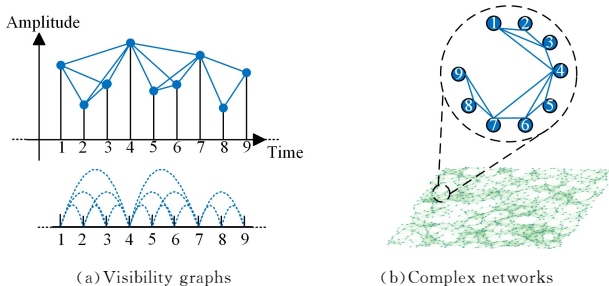


图2 可见图算法构造脑电信号映射的复杂网络

Fig. 2 Constructing complex network of EEG mapping by visibility graph algorithm

2.2.2 多重有向加权可见图

为利用时间序列中更多的特征信息,将单变量时间序列映射的复杂网络扩展到多层时间序列的复杂网络,以有向加权的方式对时间序列中的特征联系进行描述。加权可见图在建立节点和边的时候以垂直线互相可见的角度计算权重,用加权矩阵 $R = (r_{ij}) N \times N$ 表示。如果节点 x_i 和 x_j 可见, x_i 节点顶端和 x_j 节点顶端的连线记作 i_{ab} , x_i 节点顶端和 x_j 节点底端的连线记作 i_{ac} ,那么 x_i 和 x_j 之间连接边的 θ 就是 i_{ab} 与 i_{ac} 的夹角,如图 3(a) 所示。

可见图方向根据节点的可视方向确定,以 x_i 的顶端作为出发点是可见图正向描述,那么以 x_j 顶端作为出发点为可见图反向描述。即:如果节点 x_i 和 x_j 是可见的, x_j 节点顶端和 x_i 节点顶端的连线记作 j_{ab} , x_j 节点顶端和 x_i 的底端连线记作 j_{ac} ,那么 x_i 和 x_j 之间连接边的 α 就是 j_{ab} 与 j_{ac} 的夹角,如图 3(b) 所示。权重大小以角度的余弦值归一化进行计算,公式如下:

$$\omega_{ij} = \frac{\cos \theta + 1}{2} = \frac{\cos \left(\tan^{-1} \frac{x_j - x_i}{j - i} + \tan^{-1} \frac{x_i}{j - i} \right) + 1}{2}, j > i \quad (2)$$

$$\omega_{ji} = \frac{\cos \alpha + 1}{2} = \frac{\cos \left(\tan^{-1} \frac{x_i - x_j}{j - i} + \tan^{-1} \frac{x_j}{j - i} \right) + 1}{2}, j > i \quad (3)$$

其中, i, j 表示序列中的时刻, x_i 和 x_j 是序列中样本点的振幅大小, ω_{ij} 是节点 x_i 到 x_j 的权重大小, ω_{ji} 是节点 x_j 到 x_i 的权重大小。计算中对负值内容进行归一化处理,由于可视图角度范围在 $[0^\circ, 180^\circ]$ 之间,归一化后使得数值在 $[0, 1]$ 区间内。





图3 有向加权可见图算法

Fig. 3 Directed weighted visibility graph algorithm

每个被试者的数据含有多个样本分块,一个样本分块中含有多个样本,将每个样本所含的 N 个信号通道,使用有向加权可见图算法转换成多重有向加权可见图,即将时间序列转换成复杂网络形式。

2.3 聚类系数与脑电信号连接矩阵

聚合系数(Clustering Coefficient, CC)有全局聚类系数和局部聚类系数,全局聚类系数关注网络的整体特征,局部聚类系数关注节点之间的连接度。局部聚类系数可以描述复杂网络中存在的局部特征,能够反映两个节点之间连接的重叠程度^[19]。当前节点 x 有 D_x 个相邻节点,与 x 连接的节点通过其他 x 的邻居节点连接回 x 节点形成一个三角形。如图 4(a)中描述的示例,复杂网络中节点周围有实际连接线 $\{1, 2, 3, 4, 5, 6, 7\}$ (实线), $\{\omega_1, \omega_2, \omega_3, \omega_4, \omega_5, \omega_6, \omega_7\}$ 对应权重,其中 $\{1, 2, 3\}$ 和 $\{1, 3, 5\}$ 分别构成三角形(橙色实线),虚线是



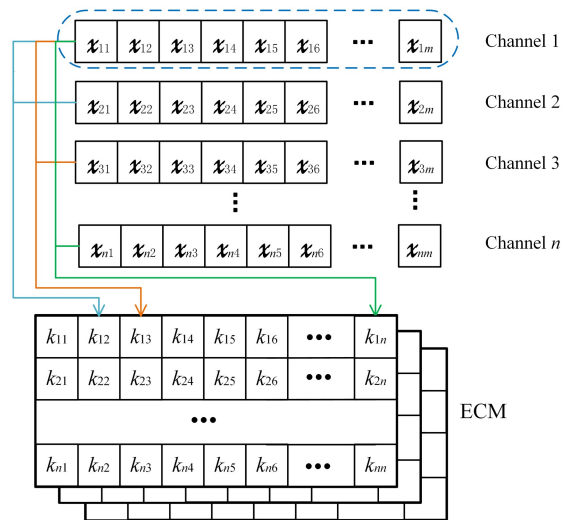
(a) Calculate clustering coefficient

周围可能存在的所有连接线。可以计算其中所有三角形的数量,与 x 有实际连接的是 x 的邻居节点,邻居节点与 x 存在构成三角形的可能,称为三点组。在一个样本中, x 周围产生的三角形连接有 T_x 个, x 相邻节点所有的三点组有 $D_x(D_x - 1)/2$ 个,聚类系数就是节点 x 实际存在的三角形数除以邻居节点的三点组数目,其公式为:

$$CC_x = \frac{2}{D_x(D_x - 1)} T_x \quad (4)$$

其中, T_x 表示当前节点 x 与其他节点实际形成三角形连接的个数, D_x 表示 x 周围节点最多产生的三角形个数。

Vector correlation



(b) Establish ECM

图 4 加权聚类系数和 ECM 的计算方式

Fig. 4 Calculation method of weighted clustering coefficient and ECM

聚类系数用以描述节点的网络连接程度,而在加权网络中不能很好地反映权重在拓扑结构中形成三角形的侧重要作用,一些节点比其他节点具有更大权重,在网络中具有的特征价值没有被考虑到。在加权网络中使用加权聚类系数,不仅要考虑节点 x 周围产生的三角形个数,还要考虑到 x 周围的权重大小。加权聚类系数计算公式:

$$CCW_x = \frac{2}{D_x(D_x - 1)} \sum_{y,z} (\bar{\omega}_{xy} \bar{\omega}_{yz} \bar{\omega}_{zx})^{\frac{1}{3}} \quad (5)$$

在 x 形成的三角形中, y, z 是三角形的另外两个顶点,三角形边的权重分别是 ω_{xy}, ω_{yz} 和 ω_{zx} ,在计算的时候使用归一化的权重数值 $\bar{\omega}_{xy}, \bar{\omega}_{yz}$ 和 $\bar{\omega}_{zx}$,归一化的方式是 $\bar{\omega} = \omega / \omega_{\max}$, ω_{\max} 表示网络中所有权重的最大值。CCW 相比 CC 在计算的时候考虑到相邻所有边权重的影响,三角形中不再是每条边具有一样的数值大小,对加权网络的拓扑结构聚集作用更为明显。

EEG 信号样本转换成复杂网络之后,聚类系数对网络拓扑结构进行描述,计算的结果代表每一个样本点在脑电信号中的表征大小。复杂网络是以节点和边的形式构造的,最终要进行下一步卷积神经网络的识别,用聚类系数将复杂网络结构转换成向量形式,向量中每一个元素表示复杂网络中的每一个节点的 WCC,如图 4(a)所示。对所有脑电通道的数据

进行转换,获得所有通道的信号样本特征向量,计算每一个向量与所有向量的余弦相似度 $Similarity(A, B)$ 并作归一化处理,得到所有脑电信号相关性矩阵,矩阵中的信息代表多重复杂网络中的连接关系,即 ECM。如图 4(b)所示,向量 $M_i^+ = \{x_{i1}, x_{i2}, x_{i3}, \dots, x_{im}\}$ 表示单个通道内所有样本点的正向网络的 CCW 向量,ECM 的每个元素 $k_{ij} = Similarity(M_i^+, M_j^+)$,同样由反向网络的 WCC 向量组成 M_i^- , $k_{ji} = Similarity(M_i^-, M_j^-)$ 。一个 ECM 对应一个样本块的多层复杂网络,ECM 的每行和每列都对应一个脑电通道,由于方向的加入, k_{ij} 与 k_{ji} 的值不相同,ECM 并非对角对称矩阵。

3 实验

3.1 数据集

研究中采用的是公开的脑电情感识别数据集 SEED¹⁾,该数据集由电影片段激活 3 种情绪状态:积极、中性、消极,在情绪识别研究中使用广泛。实验过程中有 15 个中文电影片段,每个电影片段时长约为 4 min,均分 3 种情绪的电影片段数量,即每种情绪状态对应 5 个电影片段,以非聚集的顺序混合排列。脑电信号来自于多个跨被试者,一共 15 名中国被试者,被试者学识、喜好、年龄和性别不相同。每名被试者依次观看 15 个电影片段,重复 3 次观看,即每人一共观看 45 次的

¹⁾ <https://bcmi.sjtu.edu.cn/~seed/index.html>

电影片段。采集脑电过程中,记录被试者评估调查表,用于信号的标签判定依据之一。在研究中采用经过预处理后的脑电波信号来识别3种情绪,信号与电影片段一样切分为15个序列。采用的已经预处理的脑电信号:信号采样率降至200 Hz,使用0~75 Hz的带通滤波器降噪,提取降噪后的信号的微分熵特征,使用线性动态系统进行平滑处理。

3.2 实验设置

本文将SEED数据集预处理的单个样本数据去除掉部分冗余内容且对齐所有样本维度,提取40~210 s的信号部分为一个样本块,设置大小为60 s的滑动窗口,步长30 s,即一个样本块分成5个小样本。样本分割在考虑计算性能的同时保留信号中特征内容不受影响,切分长度经过预处理实验对比得到最佳的数值。每个小样本时间序列构造复杂网络,所有数据归一化处理后放入卷积神经网络中进行训练,验证数据自动以此方式预处理。

实验构建的卷积神经网络包括8个卷积层和4个池化层,使用Relu作为激活函数,交叉熵计算损失函数,最后用softmax进行三分类输出。网络模型参数基于图像分类网络改进,参数值选自于多次训练中最优的设置。此外,设置初始为0.01的动态学习率的Adam优化器对模型进行优化,动态学习率随着迭代次数增长而减小,降低过拟合风险。使用单张显卡V100的计算机进行训练,迭代次数200代,批处理大小设置为128,同时设置dropout防止过拟合。

4 结果讨论

4.1 特征表示

实验中MDWVG在特征表示局部的规律表现出一致性,WCC提取复杂网络的特征,建立ECM的每行或每列表示一个通道的聚类系数,如图5显示的是3种不同情绪状态下形成的脑电连接矩阵,3个图例由显著标记的脑电序列通过第2节方法生成。ECM一共融合了62个通道的脑电信号,矩阵的每个元素值表示通道之间的相关性,2.3节描述了矩阵元素的计算方式。图中显示了1~62个通道归一化后的余弦相关度,从暗到亮显示的色块对应从0到1的数值增长。从图中看到不同情绪状态下的脑电信号在ECM中体现出了不一样的分布特性,可以直观看出脑电信号中由情绪引发的差异,局部聚集规律在多被试之间表现出显著的一致性。从一维时间序列到复杂网络再到ECM,整个过程中情绪相关的特征信息得以保留并强化。由于复杂网络在构造时增加了方向性,形成的ECM并不是对角矩阵,增加了矩阵之间的特征信息。ECM在所有通道上都能表现出与情绪相关的差异,这些差异可以通过卷积神经网络分类器进行自动区分,无须人工关注哪些具体通道对情绪的影响更大。




图5 脑电连接矩阵不同的分布特性

Fig. 5 Different distribution characteristics of EEG connection matrix

4.2 分类器分析

为了测试MDWVG在多种分类器下的性能,实验中对比了4中常见的分类器:卷积神经网络、支持向量机(Support Vector Machines,SVM)、优化拟合的最近邻节点算法(Optimize Fitting k-nearest Neighbor,OF-KNN)以及决策树(Decision Tree,DT)。在经过统一的数据预处理后,在相同的数据量、硬件环境和超参数设置下测试其分类性能。为统一比较多个分类器的训练过程,训练代数设置为200次,结果以准确率为评价指标。在验证策略上,采用“留一法”(Leave One Site Out Validation,LOSO)的交叉验证方式,以验证在跨被试者数据上的适用性。实验结果如表1所列。

表1 使用4种不同的分类器验证MDWVG在脑电情感识别上的效果

Table 1 Use four different classifiers to verify the effect of MDWVG on EEG emotion recognition

分类器	验证策略	评价指标	训练(%) / STD	验证(%) / STD
SVM	LOSO	ACC	85.46/6.12	77.65/9.36
OF-KNN	LOSO	ACC	91.16/3.15	86.01/5.15
DT	LOSO	ACC	89.46/5.05	87.65/3.21
CNN	LOSO	ACC	95.31/1.32	93.85/2.06

训练过程如图6所示,OF-KNN在第99次迭代中达到最高准确率91.16%,其达到最佳准确率的代数最短,但随后出现了过拟合的现象,在200代时准确率降至85.75%;SVM分类器在训练过程中的波动一直持续到后期训练中,最后准确率稳定在85.46%;DT分类器准确率提升过程较为平稳,最佳准确率89.46%出现在第138次迭代中,随后出现波动情况,但准确率稳定在最佳状态,没有因为过拟合出现持续下降。CNN在前100代的学习中准确率曲线波动变化较大,之后一直保持稳定的缓慢增长,在第186次迭代时达到最佳准确率95.31%。CNN的稳定性同样体现在跨被试者的验证数据上,保持了93.85%的准确率。综合4种分类器,CNN的识别效果最佳,SVM的识别效果最差,本文提出的MDWVG算法结合CNN可以获得最佳的脑电情感识别结果。




图6 SVM、OF-KNN、DT、CNN在训练过程中准确率变化曲线

Fig. 6 Accuracy change curve of SVM,OF-KNN,DT and CNN during training

4.3 对比实验

为了说明文中方法在脑电情感识别上的效果,对比了近年来的多个研究^[20-27],对比结果如表2所列。Li等探索了9种线性和9种非线性的EEG信号特征,这18种特征表示与表2中其他特征表示方法不重合,使用滑动窗口方式提取时频域特征和动力系统特征,在自动特征选择上使用支持向量机进行情感分类,获得了83.33%的识别效果。Lu等人关注EEG时间序列上的动态熵,同样应用滑动窗口的方式进行脑电信号预处理,动态熵主要捕获时间序列中与情感相关的

动态特征,使用支持向量机进行分类,得到 85.11% 的识别准确率;Yucel 等人通过加窗、预调整和归一化之后,基于 CNN 改进的 InceptionResnetV2 模型学习隐藏的信号特征信息,得到 86.56% 的识别效果;Yao 等人将脑电时间序列转换成复杂网络,使用节点度熵(Node Degree Entropy, NDE)和聚类系数熵(Clustering Coefficient Entropy, CCE)描述复杂网络特征,但是不能有效应用脑电信号在时间上的方向关联,也忽略了多通道信号间的特征联系,得到 87.26% 的识别准确率;Xiang 等人比较了自动编码器、受限玻尔兹曼机器和变分自动编码器 3 种方式对脑电信号的解码能力,自动编码方式

无需手动特征提取,在变分自动编码器和 LSTM 的组合下获得了 84.29% 的最佳识别率;Fu 等人将显著性检验/顺序反向选择和支持向量机相结合的方法 ST-SBSSVM,提取了 10 种线性和非线性 EEG 特征组合成高维特征,得到 89.50% 的识别准确率;Tong 等将信号源的时空信息的特征学习整合到统一的时空依赖模型 STRNN 中,表征序列的时间依赖性特征,得到 89.50% 的识别准确率;Song 等通过样本节点之间的邻接矩阵构造出有向连接图,使用改进的 CNN 模型动态图卷积网络(Dynamic Graph Convolution Network, DGCNN)进行学习,得到 90.40% 的识别准确率。

表 2 各方法脑电情感识别效果的对比

Table 2 Comparison of EEG emotion recognition effects

	方法	特征表示	数据类型	通道数	分类器	准确率/%
Li 等 ^[20]	ApEn 等	时频域和动态系统特征	EEG	62	SVM	83.33
Lu 等 ^[21]	DySampEns	熵	EEG	62	SVM	85.11
Yucel 等 ^[22]	InceptionResnetV2	—	EEG	62	CNN	86.56
Yao 等 ^[23]	CCE&NDE	复杂网络	EEG	62	SVM	87.26
Xiang 等 ^[24]	Auto-encoder	—	EEG	32	LSTM	84.29
Fu 等 ^[25]	ST-SBSSVM	高维特征	EEG	62	SVM	89.00
Tong 等 ^[26]	STRNN	—	EEG、视频	62	RNN	89.50
Song 等 ^[27]	DGCNN	有向图	EEG	62	CNN	90.40
Our	MWDVG	复杂网络	EEG	62	CNN	93.85

目前,脑电情感识别的关注点主要有两个方面,一个是对时序信号的特征工程处理,从时域、频域以及空间域上提取与情感相关的特征信息,优化后的特征工程^[20-21, 23, 25, 27]在多个方面表征特征信息,获得了优秀的结果;另一个方面是在特征提取的基础上优化分类器模型,随着深度学习的发展,有些工作^[22, 24]无需设置手动特征表示,直接在深度神经网络中提取特征,端到端的学习带来的提升超过了传统的信号处理效果。此外,综合脑电情感识别的两个关注点,改进的特征表示方式结合深度神经网络^[27]应用于脑电情感识别任务。本研究将脑电序列通过可见图算法转换成复杂网络就是基于特征工程的一种优化算法,构建的卷积神经网络模型能更好地适配复杂网络中的特征内容,最终提升情感分类效果。

4.4 消融实验

本节在 MDWVG 上进行单独功能的消除测试。消融对比的目的是验证两个内容的有效性:复杂网络特性和脑电连接矩阵。在去除权重、方向和多层复杂网络特性之后,仅以单层可见图(Single Visibility Graph, SVG)进行对比,并且逐步添加部分网络特性,对比每个特性是否对最后的结果有促进作用。添加权重之后形成单层加权可见图(Single Weighted Visibility Graph, SWVG),添加方向性之后形成单层有向可见图(Single Directed Visibility Graph, SDVG),以及融合的单层有向加权可见图(Single Directed Weighted Visibility Graph, SDWVG)。单层可见图并没有使用聚类系数融合多重可见图特征,直接将可见图放入分类器进行识别,而不构建脑电连接矩阵。作为对比,在多重复杂网络上以同样的方式设置特性内容,构造多重可见图(Multiple Visibility Graph, MVG)、多重加权可见图(Multiple Weighted Visibility Graph, MWVG)、多重有向可见图(Multiple Directed Visibility Graph, MDVG)以及 MDWVG。

这里使用 4 个评价指标:准确率(Accuracy, Acc)、精确度(Precision, Pre)、敏感度(Sensitivity, Sen)、特异性(Specificity, Spe)。

(1)准确率是多数分类任务使用的评价方法,计算的是分类识别正确的样本数量占总样本数量的百分比。准确率在样本分布不均匀的时候不能体现出分类效果。

$$Acc = \frac{TP + TN}{total} * 100\% \quad (6)$$

(2)精确度表示的是正样本预测正确的数量在预测的正样本中所占的比例。该比例越高,表示分类越准确。

$$Pre = \frac{TP}{TP + FP} * 100\% \quad (7)$$

(3)敏感度是关注所有正样本,计算预测正确的正样本在所有正样本中的比例。该比例越高,表明分类效果越全面。敏感度有另一个名称:召回率(recall)。

$$Sen = \frac{TP}{TP + FN} * 100\% \quad (8)$$

(4)特异性是关注所有负样本,计算预测正确的负样本数量在所有负样本中的比例。该比例与敏感度一样,表现分类效果的全面与否。

$$Spe = \frac{TN}{TN + FP} * 100\% \quad (9)$$

上述公式中的 TP 表示把正样本预测为正样本的数量, TN 表示把负样本预测为负样本的数量, FP 表示把负样本预测为正样本的数量, FN 表示把正样本预测为负样本的数量, total 表示所有样本的数量。评价实验数据如表 3 所列。

表 3 可见图功能消融效果的比较

Table 3 Comparison of effects of functional ablation of visibility graph (单位:%)


	Acc		Pre		Sen		Spe	
	Mean	STD	Mean	STD	Mean	STD	Mean	STD
SVG	65.12	5.89	59.45	11.25	60.85	6.25	74.21	6.48
SWVG	82.58	9.25	73.16	2.08	80.72	14.21	82.44	13.85
SDVG	80.64	3.32	82.51	10.68	80.24	16.24	81.59	8.14
SDWVG	84.45	6.49	70.48	0.95	89.83	1.44	90.21	2.41
MVG	74.91	7.47	78.21	1.26	76.45	6.11	79.15	9.81
MWVG	85.52	16.49	84.24	6.59	82.35	2.46	83.45	10.45
MDVG	84.16	6.48	86.14	2.11	81.78	9.56	85.49	8.08
MDWVG	93.85	2.76	92.57	9.18	90.25	2.46	91.39	6.59

消融实验对比结果如图 7 所示。综合消融实验的结果,可以分析出在网络特性和多重网络中的以下几个特点。


(1)增加权重之后准确率提升了 20.46%,在增加了方向性之后准确率提升了 18.52%,在增加了权重和方向性之后准确率增加了 22.33%。网络中的权重强化时间序列特征识别度,方向性扩充了时间序列转换成复杂网络的特征内容,在单层和多层网络当中依旧保持稳定,复杂网络的特性与脑电情感的关联密切。

(2)脑电情感识别任务中,网络权重在时间序列上的影响大于方向特性,在单层上权重效果高于方向效果 1.94%,在多层上权重效果高于方向效果 1.36%。利用时间序列构建可见图时的角度性质设置权重大小,从节点到网络上增加的信息内容比仅网络结构上增加的内容丰富,融合两种信息能够提高特征提取的识别度和稳定性。

(3)对比多重和单层可见图,应用聚类系数表示多重复杂网络的节点特征,使用脑电连接矩阵保留并突出类别差异,转换中保持有效信息的传输,多重有向加权可见图的分类效果比单层有向加权可见图在准确度上提升了 9.4%,在多个指标上都有提升。多通道时间序列的联合特征提取,对比单独通道的特征提取识别能力更强,最终体现在分类效果上。



(a)以权重和方向作为消融目标



(b)以单层和多层作为消融目标

图 7 消融实验对比

Fig. 7 Ablation experiment comparison

结束语 本文研究一种新的时间序列映射到复杂网络的算法——多重有向加权可见图,在公开的跨被试者数据集 SEED 上的实验表明,相比于其他脑电情感识别方法,文中方法有着明显的改善效果。构建脑电连接矩阵能保留多重复杂网络特征信息,使得多重复杂网络的性能优于单层复杂网络。多重复杂网络使用聚类系数进行特征描述,有效保留了时间序列的特征信息,多电极脑电信号在多重网络中的关联性保留在脑电连接矩阵当中,从 ECM 的热图能看出显著关联。通过比对 4 种分类器的实验研究得出,CNN 在跨被试者不同的脑电数据上面依旧保持着很好的准确率,具有较强的鲁棒性,MDWVG 结合 CNN 获得了最佳结果。

目前可见图方法在脑电情感识别任务上的研究较少,本文方法提供了一种新的思路。但复杂网络构建的脑电连接

矩阵在情感信息上的特征保留没有被全部挖掘,后期的研究中将以构建脑电连接矩阵的识别网络为主,着重探索三分类以上的任务。

参考文献

- [1] 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]. IEEE Transactions on Affective Computing,2019,13(2):568-578.
- [2] CAO Y,CAI L,WANG J,et al.Characterization of complexity in the electroencephalograph activity of Alzheimer's disease based on fuzzy entropy[J]. Chaos: An Interdisciplinary Journal of Nonlinear Science,2015,25(8):083116.
- [3] RODRIGUEZ-BERMEDEZ G,GARCIA-LAENCINA P J. Analysis of EEG signals using nonlinear dynamics and chaos: a review[J]. Applied Mathematics & Information Sciences,2015, 9(5):2309.
- [4] SMALL M,ZHANG J,XU X. Transforming time series into complex networks[C]// International Conference on Complex Sciences. Berlin:Springer,2009:2078-2089.
- [5] XIANG R,ZHANG J,XU X K,et al. Multiscale characterization of recurrence-based phase space networks constructed from time series[J]. Chaos: An Interdisciplinary Journal of Nonlinear Science,2012,22(1):013107.
- [6] SPORNS O. The human connectome: a complex network[J]. Annals of the New York Academy of Sciences,2011,1224(1): 109-125.
- [7] ZANGENEH S M,MAGHOOLIK,SETAREHDAN S K,et al. Emotion classification through nonlinear EEG analysis using machine learning methods[J]. Int. Clin. Neurosci. J,2018, 5: 135-149.
- [8] HARMON-JONES E,GABLE P A,PETERSON C K. The role of asymmetric frontal cortical activity in emotion-related phenomena: A review and update[J]. Biological Psychology,2010, 84(3):451-462.
- [9] PAUL S,MAZUMDER A,GHOSH P,et al. EEG based emotion recognition system using MFDFA as feature extractor [C]//2015 International Conference on Robotics, Automation, Control and Embedded Systems(RACE). IEEE,2015:1-5.
- [10] ZHENG W L,ZHU J Y,LU B L. Identifying stable patterns over time for emotion recognition from EEG[J]. IEEE Transactions on Affective Computing,2017,10(3):417-429.
- [11] 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.
- [12] 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.
- [13] ALGUMAEI M,HETTIARACHCHI I T,VEERABHADRAPPA R,et al. Wavelet Packet Energy Features for EEG-Based Emotion Recognition[C]// 2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC). IEEE, 2021: 1935-1940.
- [14] JOSHI V M,GHONGADE R B. EEG based emotion detection

- using fourth order spectral moment and deep learning[J]. *Biomedical Signal Processing and Control*, 2021, 68:102755.
- [15] LACASA L, LUQUE B, BALLESTEROS F, et al. From time series to complex networks: The visibility graph[J]. *Proceedings of the National Academy of Sciences*, 2008, 105(13):4972-4975.
- [16] LUQUE B, LACASA L, BALLESTEROS F, et al. Horizontal visibility graphs: Exact results for random time series[J]. *Physical Review E*, 2009, 80(4):046103.
- [17] WANG J, YANG C, WANG R, et al. Functional brain networks in Alzheimer's disease: EEG analysis based on limited penetrable visibility graph and phase space method[J]. *Physica A: Statistical Mechanics and its Applications*, 2016, 460:174-187.
- [18] ZHU G, LI Y, WEN P P. Epileptic seizure detection in EEGs signals using a fast weighted horizontal visibility algorithm[J]. *Computer Methods and Programs in Biomedicine*, 2014, 115(2):64-75.
- [19] SAMANTA K, CHATTERJEE S, BOSE R. Cross-subject motor imagery tasks EEG signal classification employing multiplex weighted visibility graph and deep feature extraction[J]. *IEEE Sensors Letters*, 2019, 4(1):1-4.
- [20] LI X, SONG D, ZHANG P, et al. Exploring EEG features in cross-subject emotion recognition[J]. *Frontiers in neuroscience*, 2018, 12:162.
- [21] LU Y, WANG M, WU W, et al. Dynamic entropy-based pattern learning to identify emotions from EEG signals across individuals[J]. *Measurement*, 2020, 150:107003.
- [22] CIMTAY Y, EKMEKCIOGLU E. Investigating the use of pre-trained convolutional neural network on cross-subject and cross-dataset EEG emotion recognition [J]. *Sensors*, 2020, 20(7):2034.
- [23] YAO L, WANG M, LU Y, et al. EEG-Based Emotion Recognition by Exploiting Fused Network Entropy Measures of Complex Networks across Subjects[J]. *Entropy*, 2021, 23(8):984.
- [24] LI X, ZHAO Z, SONG D, et al. Latent factor decoding of multi-channel EEG for emotion recognition through autoencoder-like neural networks[J]. *Frontiers in Neuroscience*, 2020, 14:87.
- [25] YANG F, ZHAO X, JIANG W, et al. Multi-method fusion of cross-subject emotion recognition based on high-dimensional EEG features [J]. *Frontiers in Computational Neuroscience*, 2019, 13:53.
- [26] ZHANG T, ZHENG W, CUI Z, et al. Spatial-temporal recurrent neural network for emotion recognition[J]. *IEEE Transactions on Cybernetics*, 2018, 49(3):839-847.
- [27] 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.



LUO Ruiqi, born in 1989, Ph. D. is a member of China Computer Federation. His main research interests include pattern recognition, image recognition and machine learning.



HU Xinrong, born in 1973, Ph.D, professor, is a member of China Computer Federation. Her main research interests include image and processing and image computing.