



基于水平可视图多元联合模体熵的多维 EEG 情感脑电信号识别

杨小冬^{1*}, 马志怡¹, 任彦霖¹, 陈梅辉¹, 何爱军², 王俊³

1. 中国矿业大学计算机科学与技术学院, 徐州 221116

2. 南京大学电子科学与工程学院, 南京 210023

3. 南京邮电大学应用技术学院, 南京 210023

* 通信作者. E-mail: xyang@cumt.edu.cn

收稿日期: 2022-12-16; 修回日期: 2023-03-01; 接受日期: 2023-06-13; 网络出版日期: 2023-12-12

徐州市重点研发计划 (社会发展) (批准号: KC21304) 和国家自然科学基金面上项目 (批准号: 61772532, 61876186, 11774167) 资助

摘要 目前, 许多基于深度学习和神经网络的算法被应用于脑电 (electroencephalogram, EEG) 信号情感识别. 然而, 现有研究大多采用提取单维脑电信号特征的方法. 随着多传感技术的更新, 更具全面性和系统性的多维信号特征提取需求出现. 本文尝试将复杂网络研究应用到多维情感脑电识别中, 提出一种基于水平可视图多元联合模体熵的情感识别算法, 该方法可以有效避免人工选取特征对实验结果的影响, 保持原始序列的非线性动力学特征. 首先利用水平可视图算法将多维情感脑电信号分别转换为多路可视图网络, 提取模体熵特征识别情感脑电研究中的关键频带和关键通道. 在此基础上, 将水平可视图网络两两联合, 提取多元水平联合模体熵向量, 作为输入参数对情感脑电信号进行识别. 由于情感脑电序列长度会对识别效果产生影响, 我们将脑电信号切割成大小不一的窗口, 对比不同窗口大小对分类准确率的影响. 实验结果表明, 当切割窗口大小为 10 s 时, 多元水平联合模体熵对情感脑电信号的识别效果最佳, 对积极脑电/消极脑电、积极脑电/中性脑电、消极脑电/中性脑电的分类准确率分别达到 95.07%, 97.73%, 90.26%, 优于其他二维连接参数. 同时, 三分类的准确率为 93.67%, 本文算法无论在识别复杂度和准确率上, 与已有算法相比均有较大提高.

关键词 EEG, 多路水平可视图, 多元联合模体熵, 情感识别, 多维分析

1 引言

情绪是一种复杂生理状态, 与人的主观感受、性格、周围环境和当下的动机倾向等有关, 可能会导致身体和心理上的变化. 这种变化对一个人的社交技能、认知能力和个体行为有很大影响, 可以反映

引用格式: 杨小冬, 马志怡, 任彦霖, 等. 基于水平可视图多元联合模体熵的多维 EEG 情感脑电信号识别. 中国科学: 信息科学, 2023, 53: 2406–2422, doi: 10.1360/SSI-2022-0454
Yang X D, Ma Z Y, Ren Y S, et al. Multivariate emotional EEG signal recognition based on multivariate joint motif entropy of a horizontal visibility graph (in Chinese). Sci Sin Inform, 2023, 53: 2406–2422, doi: 10.1360/SSI-2022-0454

其爱好、性格甚至健康信息. 因此, 学会判断个体情绪状态是很有必要的. 人类可以通过另一个人的行为、表情、语气等来理解情感, 然而, 这对于机器来说十分困难. 一些生理、心理学研究^[1,2]发现情绪识别和大脑活动之间有很强的相关性, 因此, 学者们进行脑机接口 (brain-computer interface, BCI) 相关研究, 试图让机器足够智能以解码情感. 脑机接口是近年来新兴的研究领域, 主要用来分析脑电信号. 其初衷是为了帮助患有身体和生理障碍的患者. 随着技术进步和群众需求增大, 现在的脑机接口研究已经扩展到各个领域, 包括正常人. 情感识别作为脑机接口领域的新兴应用之一, 可以帮助提高人机交互的可靠性^[3], 也有助于机器和机器人进行动作处理和社会认知^[4]. 因此, 基于脑电图的情绪识别研究对于脑启发机器人来说是十分重要的, 使得机器可以通过 EEG (electroencephalogram) 信号获取人的交互意图和状态. 理论研究中, 准确率是评价模型效果的重要指标之一. 而当应用到实际生活中时, 脑机交互技术的更新可以促使研究人员为临床、娱乐、营销等开发实时情绪检测, 提高机器识别的准确率可以帮助我们更好地解决实际问题. 例如, 当在心理学治疗中或治疗有表情问题的患者时, 机器识别的真实情绪状态有助于为患者提供更加准确和具体的治疗方案. 而提高识别准确率, 能够增加机器识别情绪的可靠性, 减少误判, 从而获取患者对该技术的信任, 减少医患矛盾, 有助于医生对患者病情做出更精准的分析并提供后续措施.

基于情感识别的必要性, 学者们开始将注意力放到有关情绪的研究中, 尤其是基于 EEG 信号的情感识别, 受到了广泛的关注. Zhong 等^[5]提出一种基于 MSE (mean square error) 和深度混合网络 (convolutional neural network-hidden Markov model, CNN-HMM) 的脑电情绪识别方法. 以脑电极的位置构造多波段空间特征矩阵作为参数, 在 DEAP 数据集的唤醒、效价维度的准确率分别达到了 79.77% 和 83.09%. Krishna 等^[6]提出了基于混合分类技术的肢体障碍者情绪识别模型. 该模型是一种非对称分布, 可以帮助提取对称或不对称形式的脑电信号. Bao 等^[7]提出基于深度卷积神经网络的两级深度域对抗网络模型识别脑电信号的情绪传递. Salankar 等^[8]采用经验模态分解对脑电数据进行预处理, 从二阶差分图中提取椭圆区域的面积、均值和中心趋势测度等特征, 并将其输入到 SVM (support vector machine) 和 2 隐层感知机中. Fdez 等^[9]提出改进的分层归一化方法, 将脑电信号分解为 4 个频带, 分别提取差分熵 (differential entropy, DE) 特征用于训练深度神经网络, 在 SEED 数据集二分类的平均准确率达到 91.6%. 在情绪识别中, 关键频带和关键通道的选择是一个重要的课题, 为情感识别的研究带来了极大便利. Zheng 等^[10]提出 DBN (deep belief network) 模型, 提取脑电信号的微分熵作为参数输入到该模型中, 成功对关键频带和关键通道进行了识别, 并且对 3 种不同情感状态进行区分, 总体准确率达到 86.65%. Zhuang 等^[11]提取经验模态分解后序列的一阶差分 and 归一化能量, 发现高频分量对不同情绪状态的检测有显著影响, 该文章还通过计算大脑各个电极之间的 Fisher 距离减少情感识别时的电极数. Tao 等^[12]在深度学习模型中引入注意力机制, 提出作用于卷积循环神经网络的空间注意力机制对脑电信号不同电极的重要性进行挖掘, 在 DEAP 情感脑电数据集的效价维和激励维的识别准确率均分别达到 91.48% 和 91.59%.

随着大数据时代到来, 各行各业数以万计的信息涌现, 时间序列以方便直观、准确性高的优势得到广泛关注. 另一方面, 复杂网络通过描述从微观到宏观不同时间尺度的结构, 为量化时间序列的非线性动力学特征提供可能. 2008 年, Zhang 等^[13]开创性的利用伪周期时间序列构建复杂网络, 发现具有不同动力学特性的时间序列表现出不同的拓扑结构. 随后, Lacasa 等^[14]提出可视图 (visibility graph, VG) 算法, 将时间序列中每个数据点看作复杂网络的一个节点, 节点间连接与否取决于数据点之间是否“可视”, 成功将时间序列映射到复杂网络. 2009 年, Luque 等^[15]在可视图基础上, 提出结构更为简单的水平可视图 (horizontal visibility graph, HVG) 算法. 如今, 可视图及其改进算法被广泛应用于金融^[16,17]、地质学^[18]、生物医学信号处理^[19]、图像处理^[20]等各个领域. 大量研究表明, 可视

图构造的网络能在拓扑结构中继承原始时间序列的动力学特征, 其网络参数能够表征系统的潜在动力学特性. 网络模体 (network motif) 作为可视图网络具有周期性和统计显著性的子图, 表征了网络的微观结构特征, 可用于描述系统复杂性 [21,22]. Iacovacci 等 [23] 提出用具有特征频率的序列可视图模体进行无监督学习, 为时间序列分析提供了新的方法. Choudhary 等 [24] 提出分组水平可视图模体, 将具有相同连边数的模体作为一组, 以组概率计算分组模体熵, 克服了构造大尺寸模体时信息量较少的问题, 并成功应用于心电 (electrocardiogram, ECG) 信号的识别. Ren 等 [25] 提出有向穿越可视图模体, 证明有向穿越可视图模体熵在时间序列识别时的鲁棒性, 并利用该指标挖掘了油水两相流信号中的潜在信息. 然而, 已有研究大多基于单维时间序列信号, 多传感器技术的更新使得多维序列联合分析尤为重要. 2016 年, Lacasa 等 [26] 提出多路可视图, 开创了基于可视图的多元时间序列分析先河. 在此基础上, Carmona-Cabezas 等 [27] 利用联合分布图分析环境变量间的相关性, 证明层间互信息和平均边缘重叠可以描述大气污染物之间的相互作用. Gao 等 [28] 利用多路有限穿越可视图对基于稳态运动视觉诱发电位 (steady-state motion visual evoked potential, SSMVEP) 的脑电信号进行分析, 成功识别个体的正常和疲劳行为.

可视图算法因其有效避免人工参数选择的优势, 被广泛运用于心、脑电信号疾病识别. 然而, 在情感脑电信号识别中, 深度学习和神经网络的方法仍然是主流, 准确率较低. 此外, 传统的单一脑电极分析在全面性和准确性等方面已无法满足学科发展的要求. 因此, 本文在水平可视图算法的基础上, 提出基于水平可视图网络的多元联合模体熵, 即多元水平联合模体熵, 将其成功运用到情感脑电信号识别中. 该参数有两个特征, 多元及以水平可视图建网为基础, 不仅突破了单维信号分析的限制, 同时以一种新的角度, 以更简单直观的方式为情感脑电识别构造新的参数. 在情感脑电公开数据集中, 我们对积极、消极和中性状态时的脑电信号进行识别分类. 本研究利用水平可视图算法将情感脑电信号转化为水平可视图并提取模体, 将两两脑电极信号之间的模体进行融合计算, 构造多元水平联合模体熵. 然后, 将其作为参数输入到 SVM 模型中, 提取情感识别中重要的关键频带和关键通道, 并对积极、消极和中性 3 种情绪状态下的脑电信号进行识别, 其识别效果明显优于传统的单维模体熵. 另外, 已有研究发现, 不同窗口大小对情绪识别结果有很大影响. 对此, 我们对原始脑电信号进行窗口切割, 获取最佳识别窗口. 在最佳识别窗口下, 本文所提出的多元水平联合模体熵相比已有的情感脑电识别方法和连接参数 (如皮尔逊 (Pearson) 系数、互信息等), 在特征选择和电极数量上存在优势, 识别准确率也有较大提高.

2 理论

2.1 可视图和模体熵

可视图算法 (VG) 是被广泛应用的一种时间序列复杂网络转换算法, 其构建的网络能够保留原始时间序列内在信息和特征, 其中, 周期序列被映射为规则网络, 随机序列被映射为随机网络, 分形序列被映射为无标度网络. 可视图算法将时间序列映射到图 (Graph) 上, 利用图论和复杂网络的方法研究时间序列潜在的非线性动力学特性. 给定长度为 N 的时间序列 $\{x(t)\}_{t=1}^N$, VG 是一个有 N 个节点的平面图, 时间序列每个数据点都被映射为其中一个节点, 两个节点通过是否“可视”进行连接. 若两个节点 $x(i)$ 和 $x(j)$ 满足如下可视性准则, 则认为这两个节点是“可视”的 (相邻节点必“可视”)

$$x_k < x_i + \frac{k-i}{j-i}(x_j - x_i), \quad i < k < j, \quad (1)$$

其中, $x(k)$ 是位于 $x(i)$ 和 $x(j)$ 之间的节点.

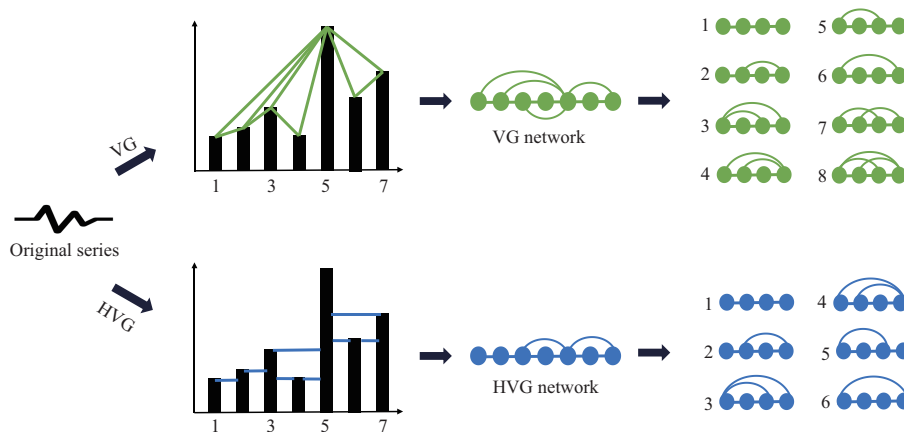


图 1 (网络版彩图) 长度为 7 的时间序列的可视图, 水平可视图连接示意图以及所有可能对应的网络模体 (以 $w = 4$ 为例). 根据可视性准则, 上方由绿色实线连接的直方图代表可视图的连接情况, 下方由蓝色实线连接的直方图代表水平可视图的连接情况, 利用可视图算法分别转换为可视图网络. 右侧分别为 VG, HVG 对应的网络模体. VG 所有可能出现的模体构成共 8 种, HVG 共 6 种, 均在图中进行编号

Figure 1 (Color online) Connection diagram of VG and HVG of time series of length 7 and all possible network motifs (with $w = 4$). According to the visibility criterion, the histogram connected by green solid lines at the top represents visibility connections, and the histogram connected by blue solid lines at the bottom represents horizontal visibility connections. The visibility algorithm is used to convert time series to the visibility network. On the right are network motifs corresponding to VG and HVG. There are 8 possible motifs of VG and 6 of HVG, which are numbered in the figure

水平可视图算法在传统可视图算法的基础上, 通过修改可视性准则, 获得可视图的子图, 大大降低了算法复杂度. 其可视性准则如下:

$$x_k < \inf(x_i, x_j), \quad i < k < j. \quad (2)$$

时间序列的可视性准则如图 1 所示. 其中, 上方由绿色实线连接的直方图表示传统可视图, 下方蓝色部分表示水平可视图. 将可视图的每一个节点映射到复杂网络中, 同时保留对应的连接关系, 就构成了可视图网络 (图 1 第 3 列). 时间序列的可视图建网算法不仅能够解决其他算法中可能存在的无法继承原始序列非线性动力学特征的问题, 而且可以避免网络构造时由于人工提取特征对实验结果造成的影响. 此外, 可视图算法构造过程简单直观, 为时间序列分析提供易于解释的视觉表示. 而在 VG 和 HVG 中, 本文选择水平可视图算法, 不仅由于其低复杂度, 更是由于其在情感识别时的高精确度, 在 4.4 小节中对此作了详细的数值分析.

网络模体可以看作是可视图网络的小型子网络, 定义模体尺寸为 w , 连续 w 个节点所构成的子网络被称为网络模体, 在可视图中以特征频率出现. 每个模体都反映了图的一些拓扑属性, 如数据关系、时间顺序信息等. 当使用网络模体参数时, 若选择的模体尺寸较小, 不能提取时间序列的细节特征, 反之, 若模体尺寸太大, 不仅导致信息分散到更多模体, 使每个单独模体包含的信息太少, 同时, 增加尺寸会引起可视图网络模体数量的显著增加, 给计算带来不便. 图 1 展示了可视图, 水平可视图在尺寸为 4 时对应的网络模体. 由于水平可视图对节点间连接准则的限制, 相对于传统可视图算法, 水平可视图是外平面的, 即边不相交, 因此其所有可能的网络模体构成将少于传统可视图. 图 1 列出了两种可视图算法对应的所有网络模体可能性, 并对他们进行编号 (可视图 1~8 号, 水平可视图 1~6 号).

对于 $\{x(t)\}_{t=1}^N$, 设定模体尺寸为 w , 步长 l 为 1, 则该序列共有 $N - w + 1$ 个模体. 假设其 w -node 水平可视图模体, 即拥有 w 个节点的水平可视图模体共有 S 种构造方式, 那么可以构造一个概率向

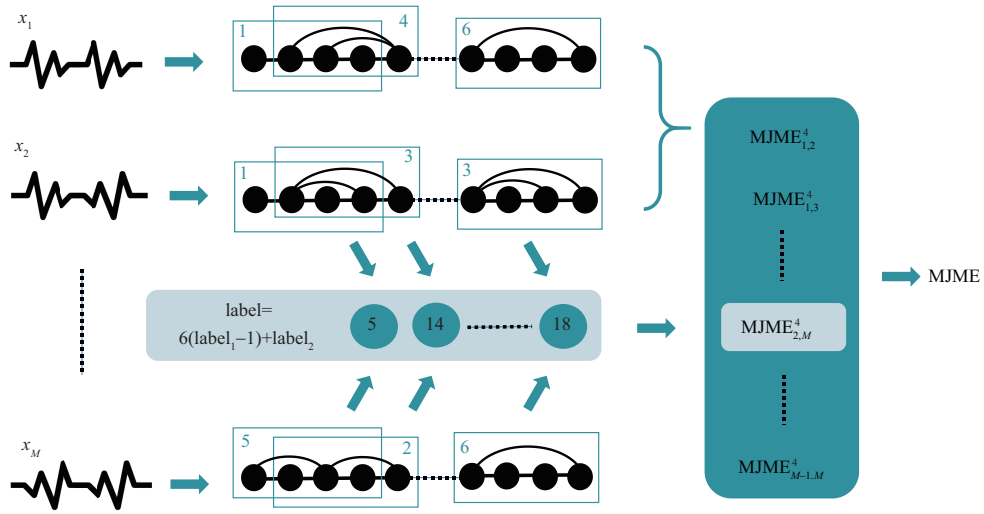


图 2 (网络版彩图) 多元水平联合模体熵构造过程 (以模体尺寸 $w = 4$ 为例). 可视图网络中每个方框表示一个模体, 上方的数字为该单维模体的编号. Label 为相近的上下两层联合模体的编号

Figure 2 (Color online) Construction process of horizontal joint motif entropy (with window size $w = 4$). Each box in the visibility network represents a motif, and the number above is the number of motifs in a single dimension. Label is the number of a similar upper and lower joint motif

量 P^w :

$$P^w : [P_1^w, P_2^w, \dots, P_s^w], \quad (3)$$

其中, P_i^w 表示当模体尺寸为 w 时, 编号为 i 的模体出现的概率 (可视图: $i \in [1, 8]$, 水平可视图: $i \in [1, 6]$). 我们将以上概率向量代入香农 (Shannon) 熵构造水平可视图熵, 即模体熵, 用于量化非线性动力学系统的潜在动力学特征. 表示为

$$\text{HVGE}^w = \sum P_i^w \log P_i^w. \quad (4)$$

2.2 多元水平联合模体熵

传统的模体熵仅适用于单通道信号. 然而, 随着多传感技术的日益更新, 单维非线性时间序列分析早已不能满足研究需求. 因此, 我们提出了基于水平可视图的多元联合模体熵, 即多元水平联合模体熵, 用于多通道的联合分析. 其构造过程如下.

步骤 1. 考虑一个 M 维实值序列 $\{x^{[\alpha]}(t)\}_{t=1}^N$, $x(t) = (x^{[1]}(t), x^{[2]}(t), \dots, x^{[M]}(t))$, 上标 $[\alpha]$ 表示维数, N 代表时间序列长度, 利用水平可视图算法分别将每个一维时间序列映射为水平可视图网络.

步骤 2. 设定模体尺寸为 w , 步长 $l = 1$, 从序列起始点依次向后滑动, 经过的每一个大小为 w 的窗口即为水平可视图网络的一个模体, 其序号 label 为图 1 中对应的水平可视图模体编号.

步骤 3. 根据步骤 1 和 2, 每个时间序列拥有 $N - w + 1$ 个模体. 假设其 w -node 水平可视图有 S 种不同的网络模体构造方式 (当 $w = 4$ 时, $S = 6$), 那么对于一个两层的多维水平可视图, 令网络模体两两联合, 则拥有 $S \times S$ 种不同模体状态. 根据组合为联合模体的两个模体的序号, 我们将这 $S \times S$ 种状态分别编号为 $\text{label}_{\text{MJME}} = S \times (\text{label}_{\text{HVG}_i} - 1) + \text{label}_{\text{HVG}_j} \in [1, S^2]$, 其中, $\text{label}_{\text{HVG}_i}$ 和 $\text{label}_{\text{HVG}_j}$ 分别为第 i 层和第 j 层的水平可视图的 w -node 模体编号.

步骤 4. 计算两个时间序列间 S^2 个联合模体的编号, 并构造不同状态下联合模体的概率向量 P_{MJME}^w

$$P_{\text{MJME}}^w : [P_{\text{MJME}_1}^w, P_{\text{MJME}_2}^w, \dots, P_{\text{MJME}_{S^2}}^w], \quad (5)$$

其中, $P_{\text{MJME}_i}^w$ 表示编号 i 的联合模体在所有联合模体中出现的概率.

根据得到的概率向量, 利用以下公式计算此二维水平可视图的多元水平联合模体熵 (multivariate joint motif entropy, MJME):

$$\text{MJME}^w = \sum P_{\text{MJME}_i}^w \log P_{\text{MJME}_i}^w. \quad (6)$$

然后, 令多维时间序列两两为一组, 依次计算其多元水平联合模体熵, 得到多元水平联合模体熵向量 MJME^w :

$$\text{MJME}^w = [\text{MJME}_{1,2}^w, \text{MJME}_{1,3}^w, \dots, \text{MJME}_{2,3}^w, \dots, \text{MJME}_{M-1,M}^w], \quad (7)$$

其中, $\text{MJME}_{i,j}^w$ 表示第 i 层和第 j 层序列的联合模体熵.

步骤 5. 根据多元水平联合模体熵向量 MJME^w , 计算整个系统的平均多元水平联合模体熵

$$\text{MJME} = \frac{2 \sum \text{MJME}_{i,j}^w}{M(M-1)}. \quad (8)$$

多元水平联合模体熵的构造流程如图 2 所示.

本文实验中选择模体尺寸 $w = 4$. 首先, 目前对于人体生理信号的相关研究中, 大多数研究采用模体尺寸 $w = 4$ 进行分类并取得较高准确率^[29~31], 证明该数据选择在生物电信号分析时的有效性. 其次, 若 $w = 1$, 则无法构成模体; 若 $w = 2$, 那么构造后的多元联合模体熵有且仅有一种模式, 无法对信号不同状态进行区分; 若 w 大于 4, 则多元联合模体熵的数量随着 w 的增大显著增加, 甚至达到上万个, 这不仅增加了计算难度, 也使得每种多元联合模体熵仅包含极少数的信息. 因此, 在接下来的研究中, 令 $w = 4$. 而其与 $w = 3$ 的结果对比也在 4.4 小节做了详细的分析.

2.3 小波包分析

小波包分解 (wavelet package decomposition, WPD) 是对小波变换的优化, 将时、频平面划分的更细致, 解决了小波变换在高频部分分辨率不足的问题. 其中, 小波变换 (wavelet transform, WT) 是一种有效的时频分析工具, 可以研究多分辨率的时间序列. 该方法发展于短时傅里叶变换局部化思想, 能够为原始信号提供随频率改变的“时间 - 频率”窗口, 并对其进行伸缩和平移运算, 从而对信号进行细节操作. 在 WT 中, 原始信号通过一系列低通和高通的滤波器被分解成不同的时间和频率尺度. 因此, 在多次分解过程中, 我们可以得到信号的不同频率子带.

连续小波变换 (continuous wavelet transform, CWT) 的计算公式为

$$\text{CWT}(a, b) = \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{a}} \psi \left(\frac{t-b}{a} \right) dt, \quad (9)$$

其中, a 和 b 分别表示尺度因子和平移因子, ψ 为小波基函数.

在 CWT 基础上, 定义离散小波变换 (discrete wavelet transform, DWT)

$$\text{DWT}(j, k) = \frac{1}{\sqrt{2^j}} \int_{-\infty}^{+\infty} x(t) \psi \left(\frac{t-2^j k}{2^j} \right) dt, \quad (10)$$

表 1 情感识别研究中的 15 个电影片段
Table 1 15 movie clips for emotion recognition

Movies	Emotion	Start time	End time
Thailand	Positive	00:06:13	00:10:11
World Heritage in China	Neutral	00:00:50	00:04:36
Tangshan Earthquake	Negative	00:20:10	00:23:35
Back to 1942	Negative	00:49:58	00:54:00
World Heritage in China	Neutral	00:10:40	00:13:44
Thailand	Positive	1:05:10	1:08:29
Back to 1942	Negative	2:01:21	2:05:21
World Heritage in China	Neutral	2:59	6:40
Flirting Scholar	Positive	1:18:57	1:23:23
Koshihikari Treasure Box	Positive	11:32	15:33
World Heritage in China	Neutral	10:41	14:41
Back to 1942	Negative	2:16:37	2:20:37
World Heritage in China	Neutral	5:36	9:36
Koshihikari Treasure Box	Positive	35:00	39:02
Tangshan Earthquake	Negative	1:48:53	1:52:18

其中, 2^j 和 2^jk 是对尺度因子和平移因子进行离散化后的表示.

本文利用 WPD 对情感脑电信号进行频率提取, 在每一层分解过程中, 信号被重新分解为低频和高频两个部分. 对于原始信号, 其最高频率 f_{\max} 由奈奎斯特 (Nyquist) 抽样定理计算得出, 即

$$f_{\max} = \frac{1}{2}F_s, \quad (11)$$

其中, F_s 为采样频率.

3 实验

3.1 实验设计

采用上海交通大学实验室的 SEED 情感脑电数据集^[10]. SEED 数据集由 15 名受试者的脑电信号组成 (其中 7 名男性和 8 名女性, 平均年龄 23.27 ± 2.37 岁). 通过播放 6 部电影中 15 段 (5 段积极、5 段消极、5 段中性) 不同情绪的片段收集不同情绪脑电信号, 每个电影片段长度约为 4 min, 由实验人员精心挑选裁剪而成, 以确保能够获得受试者的正确情绪. 表 1 列出了详细的 15 个电影片段及其引发的情绪. 在每段电影开始前, 都会有 5 s 的提示, 电影结束后, 会给受试者 45 s 测评时间, 反馈观影体验, 15 s 休息后进入下一个片段. 详细的实验流程如图 3 所示. 实验采用了 62 通道 EEG 电极, 按照国际 10-20 系统记录脑电图信号, 采样频率为 1 kHz. 我们对记录的脑电图信号进行了 200 Hz 的降采样预处理, 然后在 0.5~70 Hz 之间进行带通滤波, 去除干扰噪声和伪影. 由于每个片段的开始和结束阶段, 人的情感将会受到上一个和下一个情绪的影响, 本文实验选取第 50 s 后长度为 50 s 的电影片段, 最大程度避免了该影响.

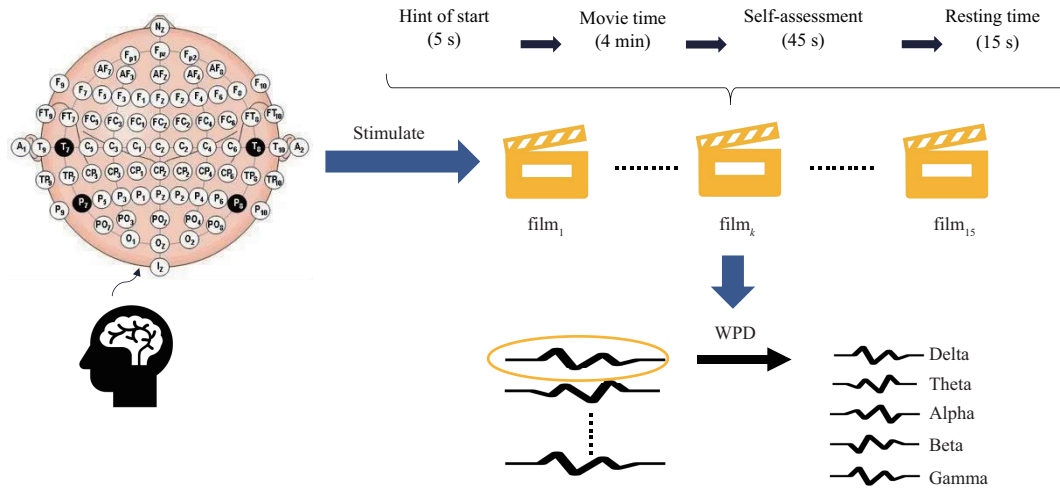


图 3 (网络版彩图) 本文实验流程. 在 62 通道的脑电极下采集信号, 每个受试者将观看 15 个不同情绪的电影片段以刺激大脑 EEG 波段的变化. 每个电影片段大约 4 min, 开始前有 5 s 提示, 结束后将有 45 s 的自我测评及 15 s 的休息时间, 而后开始下一个片段. 对每一条脑电信号, 采用离散小波变换 (DWT) 分解为 5 个频带 (Delta, Theta, Alpha, Beta 和 Gamma 频带)

Figure 3 (Color online) Experimental process. The signals are collected at a 62 channel brain electrode. Each subject watches 15 movie clips of different emotions to stimulate changes in the brain's EEG wavebands. Each movie segment is about 4 min long, with a 5-s cue before the start, a 45-s self-assessment and a 15-s break at the end. Then start the next segment. DWT is used to decompose each EEG signal into five frequency bands (Delta, Theta, Alpha, Beta, and Gamma frequency band).

3.2 脑电信号提取节律

为了研究情感识别的关键频带, 按照 2.3 小节, 应用小波包分解对 SEED 数据集的 EEG 片段进行下采样, 采用 db4 小波基, 将情感脑电划分为 5 个节律. 图 4 给出了详细的分解过程. 在每一层中, 信号被重新分解为低频 (A) 和 高频 (D) 两个部分. 原始信号最高频率为 100 Hz, 分解后的 5 个节律在图中以不同颜色表示, 频率范围分别是: Delta 频带 (0~4.8 Hz)、Theta 频带 (4.8~9.5 Hz)、Alpha 频带 (9.5~15.7 Hz)、Beta 频带 (15.7~37.5 Hz) 和 Gamma 频带 (37.5~100 Hz).

4 结果与讨论

4.1 基于模体熵的关键频带和关键通道识别

近年来, 关键频带和关键通道的识别已经成为情绪识别中重要课题^[12], 为情感脑电相关的研究带来极大便利. 上海交通大学实验室^[10] 在使用差分熵特征进行情感识别时得出结论, 当采用 12 通道脑电极 (分别为 FT7, FT8, T7, T8, C5, C6, TP7, TP8, CP5, CP6, P7 和 P8) 时, 对不同情绪状态脑电信号的分类效果最佳. 因此, 为了获得关键频带, 我们采取与之相同的 12 通道脑电极, 将该 12 维时间序列转换为多路水平可视图网络并分别计算水平模体熵, 然后把结果输入到 SVM 模型中, 对 SVM 模型进行十折交叉验证, 在各个频带下的识别准确率如表 2 所示.

由表 2 可以看出, Beta 和 Gamma 频带, 尤其是 Beta 频带, 相较于 Delta, Theta, Alpha 频带, 在进行情感脑电识别时具有更高的识别准确率. 因此可以判断, Beta 和 Gamma 频带拥有作为情感脑电识别中关键频带的潜力. 以往的神经科学研究表明^[32,33], 人类情感脑电信号在高频段存在特定的模

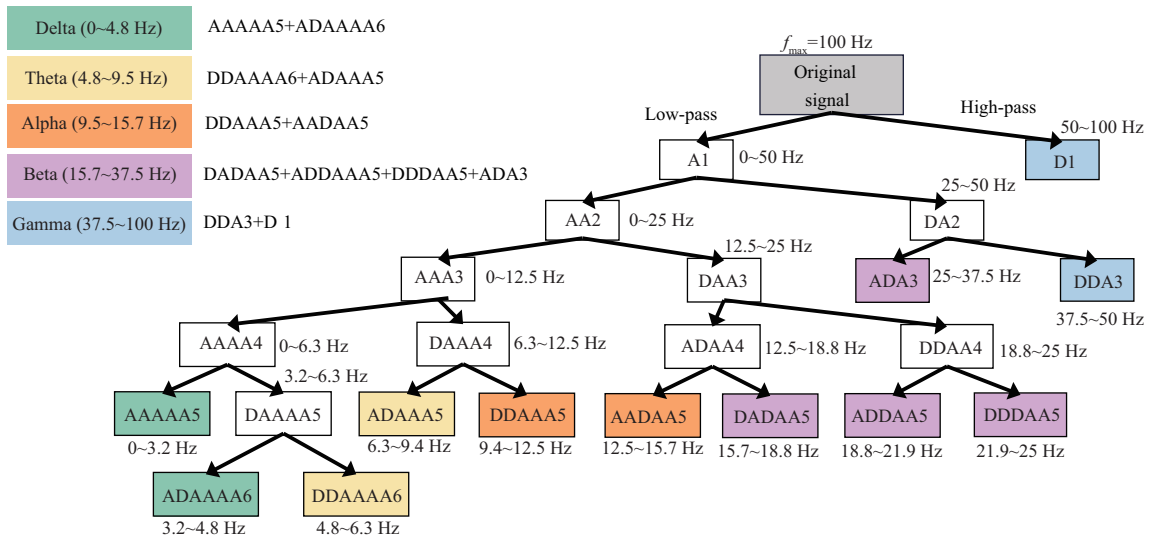


图 4 (网络版彩图) 脑电信号小波包分解流程. 每一层的分解信号被重新分解为近似系数 (A) 和细节系数 (D) 两个部分. 分解后 5 个节律的详细组成及其相应的频率范围分别用不同颜色表示

Figure 4 (Color online) WPD of the EEG. For each level, the signal is repeatedly divided into two parts of the approximation coefficient (A) as well as the detail coefficient (D). Detailed composition of five rhythms and their corresponding frequency ranges after decomposition are represented by different colors

表 2 12 通道下各个频带的识别准确率

Table 2 Identification accuracy of each frequency band under 12 channels

Frequency band	Classification accuracy (%)		
	Positive/negative	Positive/neutral	Negative/neutral
Delta (0~4.8 Hz)	56	50	51.33
Theta (4.8~9.5 Hz)	60	64	55.33
Alpha (9.5~15.7 Hz)	81.33	86.67	56.67
Beta (15.7~37.5 Hz)	85.33	92.67	72
Gamma (37.5~100 Hz)	78.67	85.33	63.33

式, Beta 频带反映了大脑中的情绪和认知处理, EEG 信号的 Gamma 频带适用于情绪分类. 因此, Beta 和 Gamma 频带适合于情感与情绪的分类, 与我们的结论一致. 因此, 在接下来的研究中, 选择准确率明显更高的 Beta 频带作为情感脑电识别的关键频带. 同时, 关键频带的成功识别也证明可视图网络的模体熵特征在情感脑电分类中应用的可能性.

接着, 我们尝试减少脑部电极数来进行 3 种情绪状态的检测 (表 3). 我们同样借鉴上海交通大学实验室的脑部电极选择方案^[10], 分别使用 4 个电极 (FT7, FT8, T7 和 T8)、6 个电极 (FT7, FT8, T7, T8, TP7 和 TP8)、9 个电极 (FP1, FPZ, FP2, FT7, FT8, T7, T8, TP7 和 TP8) 和 12 个电极 (FT7, FT8, T7, T8, C5, C6, TP7, TP8, CP5, CP6, P7 和 P8) 进行关键通道的识别, 实验时仅考虑 Beta 频带的情况. 实验结果表明, 当减少脑部电极数量时, 对积极/消极、积极/中性和消极/中性 3 种情绪识别的准确率均高于全部 62 个脑电极. 这是因为, 减少电极数不仅能够降低计算复杂性, 还可以避免其他未被刺激的无关脑区电极带来的噪声干扰. 当采用 6 个电极时, 对积极/中性脑电和消极/中性脑电的分类准确率分别达到了 94.67% 和 78.67%, 积极/消极两种情绪的脑电信号则在 4 个电极和 9 个电极

表 3 Beta 频带下减少电极时的识别准确率
Table 3 Identification accuracy at reduced electrodes in Beta band

Number of electrodes	Classification accuracy (%)		
	Positive/negative	Positive/neutral	Negative/neutral
4 channel	87.33	89.33	71.33
6 channel	84.67	94.67	78.67
9 channel	87.33	90.67	77.33
12 channel	85.33	92.67	72
62 channel	84	85.33	70.67

时达到最高的识别准确率为 87.33%。

由于关键频带和关键通道的存在,使得情感识别复杂度大大降低,为从事情感识别领域研究的工作人员带来了极大便利。然而,目前对于关键频带和关键通道的研究仍有许多不足,尤其是对于关键通道的识别,需要更加精确的脑区电极选择以实现更全面和准确的研究。在下面的工作中,我们使用 Beta 频带信号以及未经小波分解的原始时间序列进行实验,关键通道选择为表 3 中的 6 个电极 (FT7, FT8, T7, T8, TP7 和 TP8)。

4.2 多元水平联合模体熵的情感识别

根据可视图网络模体熵特征在单维时间序列中的表现,采用 6 通道 EEG 时间序列进行多元水平联合模体熵分析。我们将数据集中 15 个电影片段的连续 3 个 (积极/消极/中性) 视为一组,构造多元水平联合模体熵。根据以往研究经验,当模体尺寸 $w = 4$ 时,能够提取到足够的信息。以其中一个积极情绪片段为例:首先利用水平可视图算法将 6 通道脑电信号转化为多路水平可视图,并对每一层可视图网络提取所有尺寸 $w = 4$,步长 $l = 1$ 时的水平可视图模体,按照图 1 进行编号。然后,对这 6 个通道的水平可视图模体两两联合,构造多元水平联合模体熵向量 (式 (7))。随机从 15 名受试者中抽取一个,计算其 3 种不同情绪脑电信号的多元水平联合模体熵向量,结果如图 5 所示。我们对 6 个脑部电极 (FT7, FT8, T7, T8, TP7 和 TP8) 分别编号为 1~6,编号为 1~5 的通道依次与编号为 2~6 的通道进行联合,即 1&2, 1&3, ..., 2&3, 2&4, ..., 5&6。

由图 5 可以看出,积极、中性和消极这 3 种情绪的多元水平联合模体熵具有显著差异。其中,积极情绪的联合模体熵明显高于其他两种情绪。除了第 1 组的部分多元水平联合模体熵,其余均表现为消极情绪大于中性情绪。可以推测,由积极情绪脑电信号构造的各编号模体分布相对其余两种情绪状态更加均匀,可视图网络的连接复杂性也高于消极情绪和中性情绪。此外,每一组倒数第 2 个多元水平联合模体熵数值,即第 4 通道和第 6 通道的联合模体熵明显低于其余二个通道结果,这两个电极所处脑部区域活动相对平缓,在外界刺激下无明显波动,连接性较低。通过所有二通道联合模体熵的对比分析,可以获得不同情绪脑电信号潜在的非线性动力学特征,得到它的时间序列信息和连接情况。因此,多元水平联合模体熵可以用来对人类情感脑电信号进行识别。

接着,分别计算 15 个受试者在 Beta 频带与未经分解的原始脑电序列下平均多元水平联合模体熵 (式 (8))。仍然采用上述 6 通道序列,并将平均多元水平联合模体熵的计算结果作为参数输入到十折交叉验证 SVM 模型中,获得其在情感脑电识别时的准确率,如表 4 所示。在原始脑电信号下使用联合模体熵进行分类时,积极情绪与消极情绪以及积极情绪与中性情绪的识别准确率分别达到 93.56% 和 98.27%,均高于 Beta 频带,但是对于中性情感脑电和消极情感脑电的分类情况略低于 Beta 频带,




图 5 (网络版彩图) 某个体的积极、中性和消极情绪多元水平联合模体熵 (采用 6 维未经分解的原始脑电序列). 以灰色垂直虚线为划分的每个区域代表一组积极/中性/消极片段, 模体两两联合计算的顺序为: 由编号为 1~5 的模体依次与编号为 2~6 的剩余模体联合

Figure 5 (Color online) MJME of positive, neutral and negative EEG emotional signals of an individual (using 6-dimensional undecomposed original EEG sequences). Each region divided by the gray vertical dashed line represents a set of positive/neutral/negative segments. The order of the pair-to-pair calculation is as follows: motifs numbered 1~5 are joined with the remaining motifs numbered 2~6 in turn

表 4 15 名受试者的平均多元水平联合模体熵
Table 4 Mean joint motif entropy for 15 subjects

Frequency band	Classification accuracy (%)		
	Positive/negative	Positive/neutral	Negative/neutral
Original series	93.56	98.27	71.33
Beta band series	93.16	97.91	86.3

为 85.33%. 然而, 无论是原始序列还是 Beta 频带, 采用多元水平联合模体熵进行情绪识别的效果相较于仅使用一维模体熵有极大提高 (单维模体熵: 积极/消极 87.33%、积极/中性 94.67%、中性/消极 78.67%). 实验结果证明了采用多元水平联合模体熵进行情感脑电识别的有效性.

4.3 窗口大小的选择

为了获得更加精确的结论, 研究人员往往会扩大实验样本或者在使用分类模型时选择更高维度的输入参数. 在情感识别的研究中也不例外, 通常通过对情感脑电信号进行分割的方式增加样本量, 获得更高的输入维度. 在以往的研究中, 分割窗口大小的选择往往是研究人员需要着重考虑的. Nawaz 等^[34]以无重叠的 10 s 窗口进行分割, 使用情绪的三维模型来识别音乐视频触发的情绪. Zhuang 等^[11]选择 5 s 作为窗口大小, 实现了情感识别中关键频带和关键通道的检测. Liu 等^[35]提出了一种有效的多层次特征引导胶囊网络 (MLF-CapsNet), 采用 1 s 的滑动窗口数据作为样本进行多通道 EEG 情绪识别. 这些研究表明, 在对原始信号进行分割时, 窗口大小的选择对实验结果的准确性有较大的影响.

为了研究不同窗口大小对情感识别的影响, 并获取最佳分类窗口, 我们将原始脑电信号依次切割成大小为 1, 2, 5, 10, 25 和 50 s 的无重叠小窗口进行实验. 在每个窗口大小下切割时, 原始脑电信号被分割为不同数量的小片段, 每个小片段的 6 通道脑电信号两两组合, 构造多元水平联合模体熵. 将不同情绪下获得的多元水平联合模体熵作为原始数据, 输入到 SVM 模型进行十折交叉验证自动划分

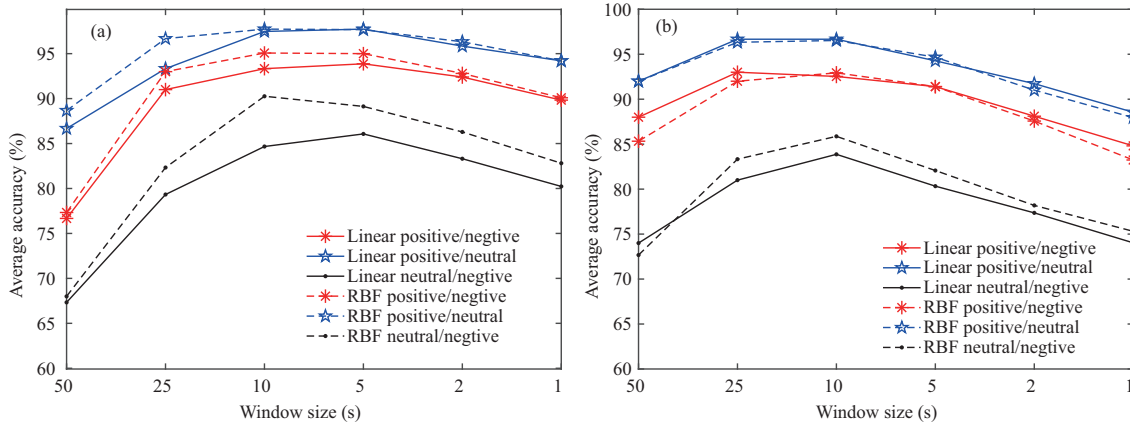


图 6 (网络版彩图) 不同窗口大小下 6 通道平均多元水平联合模体熵对情感识别的分类准确率

Figure 6 (Color online) Classification accuracy of emotion recognition using 6-channel average horizontal joint motif entropy under different window sizes. (a) Raw EEG signal; (b) Beta band signal

训练集与测试集, 获得对不同情绪的分类精度, 并分析窗口大小对情感脑电识别的影响. 不同窗口下的平均分类准确率如图 6 所示.

图 6(a) 和 (b) 分别是在原始脑电信号和 Beta 频带信号的实验结果. 对于该两种信号, 折线图都呈现了中间高、两边低的趋势. 当窗口大小为 50 和 1 s 时, 识别效果不如其他窗口. 经过分析, 当窗口大小选择为较大数值时, 一个完整的时间序列仅被分割为很少的几段, 这就导致样本数不足, 没有足够的特征参数输入到分类器中进行分类, 效果往往不尽如人意. 而当窗口选择过小时, 时间序列被分割成许多小片段, 分配给每个小段的数据点很少, 即序列片段长度过短. 而在构造模体时选择的模体尺寸 $w = 4$, 因此, 每一个小段对应的模体总数非常少, 不同情绪之间的模体难以区分. 构造联合模体熵后, 情况依然如此, 导致最终准确率低于其他较大的窗口选择.

由图 6 可以看出, 窗口大小取 5 和 10 s 时对 3 种情感状态的识别效果最佳. 以往的研究中^[9], 当窗口大小选择为 3~12 s 之间时, 识别效果明显优于其他窗口. 因此, 本实验结果证明了本文方法在情感脑电识别中的有效性. 图 7 中, 我们展示了窗口大小为 10 s 时, 原始脑电信号和 Beta 频带脑电信号不同情绪的识别准确率. 对于原始脑电信号, 积极/消极、积极/中性、消极/中性的识别准确率均达到 90% 以上, 分别为 95.07%, 97.73%, 90.26%; 而对于 Beta 频带脑电信号, 除了消极/中性两种状态的识别准确率为 85.87%, 其余的也都超过 90%, 分别是: 积极/消极 92.93%, 积极/中性 96.53%. 此外, 我们分别选用带有线性核函数 (linear) 和高斯核函数 (radial basis function, RBF) 的 SVM 模型, 根据实验结果, 两种核函数都能有效识别不同的情感状态, 其中 RBF 具有更高的准确率, 这一结果在原始脑电信号中更加突出.

4.4 对比实验

为了验证多元水平联合模体熵在进行情感脑电信号识别时的优势, 我们将表示两序列之间关系的参数: 皮尔逊相关系数^[36]和层间互信息^[26]应用到本文 SEED 数据集的研究中. 这两个参数经常被研究人员用于多维生物电信号的二维连接, 已经在许多领域得到成功应用^[26, 37]. 尤其是皮尔逊相关系数, 目前已趋于成熟. 皮尔逊相关系数可以用来度量两个变量 x 和 y 之间的线性相关性, 层间互信息则主要用于量化多路可视图不同层之间度分布的相关性. 在对不同电极的脑电信号进行联合时, 我们尝试使用这两个参数代替本文提出的多元水平联合模体熵, 计算对应的特征参数向量, 在相同的频




图 7 (网络版彩图) 原始脑电信号和 Beta 频带脑电信号在窗口大小取 10 s 时的平均准确率
 Figure 7 (Color online) Average accuracy of raw EEG and Beta band EEG signals under a window of 10 s

表 5 不同参数识别效果 (10 s)

Table 5 Identification effect of different parameters (10 s)

Comparison parameters	Classification accuracy (%)		
	Positive/negative	Positive/neutral	Negative/neutral
Inter layer mutual information	94.8	96.4	82.13
Pearson correlation	52.67	54.53	52.27
MJME (proposed method)	95.07	97.73	90.26

表 6 不同参数识别效果 (5 s)

Table 6 Identification effect of different parameters (5 s)

Comparison parameters	Classification accuracy (%)		
	Positive/negative	Positive/neutral	Negative/neutral
Inter layer mutual information	92.73	94.73	82.7
Pearson correlation	53.93	57	54.47
MJME (proposed method)	95	97.67	89.13

带和电极选择下, 将结果输入到 SVM 十折交叉验证分类模型中. 表 5 和 6 分别列出了以上 3 种二维连接参数在窗口大小为 10 和 5 s 时的实验结果. 结果显示, 层间互信息在窗口大小为 10 和 5 s 时对积极/消极、积极/中性、消极/中性脑电信号的识别准确率分别为 94.8%, 96.4%, 82.13% 和 92.73%, 94.73%, 82.7%, 均低于本文提出的多元水平联合模体熵, 尤其在对于中性脑电信号和消极脑电信号进行分类时, 与多元水平联合模体熵的准确率差值达到约 7%. 而在以往的研究中, 这两种情绪被证明是相对难以区分的. 同时, 层间互信息计算繁琐, 性能上不如本文参数. 另外, 皮尔逊相关系数对 3 种不同情感脑电信号的识别效果均仅处于 50%~60% 区间, 与我们的识别准确率相差甚远.

此外, 我们分别计算了利用可视图和水平可视图算法在不同模体尺寸下构造水平联合模体熵的实验结果, 如表 7 所示. 在 2.2 小节中已经说明, 过大或过小的模体尺寸均不适用于时间序列的复杂网

表 7 MJME 构造过程不同参数结果对比 (窗口为 10 s)

Table 7 Comparison of parameter influence results during MJME construction process (window size of 10 s)

		Classification accuracy (%)		
		Positive/negative	Positive/neutral	Negative/neutral
HVG	$w = 3$	95.47	96.4	86.4
	$w = 4$	95.07	97.73	90.26
VG	$w = 3$	94.53	95.46	85.6
	$w = 4$	94.8	95.33	84.93

络分析. 这里我们令模体尺寸 w 分别等于 3 和 4. 根据表中的数据可知, 相同模体尺寸下进行情绪识别时, 可视图算法的实验精确度均略逊于水平可视图算法. 而在 HVG 中, 当 $w = 3$ 时, 仅对积极情绪和消极情绪进行二分类的准确率达到 95.47%, 高于模体尺寸取 4 时的结果, 而对积极情绪/消极情绪、消极情绪/中性情绪进行分类时的准确率分别为 96.4% 和 86.4%, 相较 $w = 4$ 的结果更低, 此结果也印证了本文令模体尺寸 $w = 4$ 的可靠性.

最后, 我们在不同窗口下对消极、积极、中性情感脑电信号进行三分类, 并与已有研究结论进行了对比, 如表 8^[10, 38~48]. 经计算, 当窗口大小为 1 s 时, 准确率达到 83.43%, 对比同样采用 SVM (RBF) 的文献 [38], 准确率仅 71.07%. 与文献 [10] 相比, 虽然在窗口大小为 1 s 时, 分类准确率降低约 3%, 但当增加窗口大小为 5 和 10 s 时, 分类准确率分别增加了 5.29% 和 7.02%, 同时, 本文在电极数量上相比文献 [10] 减少一半, 降低了研究人员在进行临床数据采集和数据处理时的工作量. 本文算法在窗口为 10 s 时的分类准确度达到 93.67%, 除了略低于 Tang 等^[39] (93.97%) 和 Li 等^[40] 在使用 DE 特征时的结论 (94.1%), 与其他文献相比, 识别准确率均有提高. 文献 [39, 40] 在对情感脑电信号识别时采用了全部 62 个脑部电极, 并未进行关键电极的检测, 因此会导致冗余信息的产生. 本文提取 6 个关键电极, 达到了较高的准确率, 对情感脑电识别中的关键脑部电极做了精确, 同时关注了其性能优势. 综上, 本文所提出的方法在进行情感脑电识别时, 在实用性和准确率上具有较大的优势.

5 总结

本文将多维脑电信号通过水平可视图算法转换为多路水平可视图网络, 提取并利用模体特征构造基于水平可视图的多元联合模体熵向量, 称为多元水平联合模体熵, 将其作为特征参数输入到 SVM 模型中, 对积极、消极、中性 3 种不同的情感状态进行识别. 我们利用水平可视图单维模体熵向量检测情感识别中重要的关键频带和关键通道, 在上海交通大学对 SEED 情感脑电信号提取的关键通道和关键频带基础上, 证明仅使用其中的 6 个电极 (FT7, FT8, T7, T8, TP7 和 TP8) 就足以达到最佳识别效果, 并验证了 Beta 频带作为关键频带的必要性. 在关键频带和关键通道选择的基础上, 将水平可视图网络两两联合, 进行多元水平联合模体熵分析, 发现在 Beta 频带信号和原始脑电信号中, 多元水平联合模体熵在进行 EEG 情感识别时的准确率相比以往的单维方法有很大提高, 证明本文提出的多元水平联合模体熵在进行情感脑电识别时的有效性. 为了获取更多的基础样本及更高的输入维数, 提高识别精确度, 我们还对原始脑电信号进行窗口切割. 结果表明, 在 10 s 的最佳窗口大小下分割序列, 并采用以上算法对积极/消极脑电、积极/中性脑电, 以及消极/中性脑电情绪的识别准确率分别为 95.07%, 97.73%, 90.26%, 对比常用的二维连接参数如层间互信息和皮尔逊相关系数, 多元水平联合模体熵在识别效果上具有很大优势. 此外, 我们仅使用 6 个电极对情感脑电三分类的准确率达到 93.67%, 在电极数量和识别准确率上, 相比已有研究均有较大提高.

表 8 情感识别研究现状
Table 8 Recent research on emotion recognition

Reference	Dataset	Model	Parameter	Electrodes	Window size (s)	Accuracy (%)
Zheng et al. [10]	SEED	SVM	DBN+DE	12	1	86.65
Tang et al. [39]	SEED	Bimodal-LSTM	DE	62	4	93.97
Gupta et al. [38]	DEAP	Random forest	IP	1	–	72.07
		SVM (polynomial)				83.85
Gupta et al. [38]	SEED	SVM (RBF)	IP	1	–	71.07
		Random forest				93.46
Chen et al. [41]	DEAP	CNN-RNN	2D PSD	32	1	93.64
Kumar et al. [42]	SEED-IV	SVM	Hurst exponential, et al	32	–	79
Xing et al. [43]	DEAP	LSTM	Frequency band power	32	1	81.1
Rahman et al. [44]	SEED	CNN	PSD	62	–	89.06
Zhang et al. [45]	SEED	Softmax	DE	62	5	92.47
Du et al. [46]	SEED	ATDD-LSTM	DE	62	–	91.08
		SVM				83.99
Zhou et al. [47]	SEED	PR-PL	DE	62	–	93.18
			DE			94.1
Li et al. [40]	SEED	FGCN	DASM	62	–	78.67
			DACU			84.1
Gu et al. [48]	SEED	DGGN	DE	32	3	83.84
					1	83.43
Proposed method	SEED	SVM	MJME	6	5	91.94
					10	93.67

我们提出的多元水平联合模体熵为情感脑电识别提供了新思路, 是该领域的一次重要尝试. 该算法便捷、准确且易于扩展, 突破了单维时间序列分析的限制. 通过对比多序列联合模体熵, 在对系统内部潜在非线性动力学特征的分析上更加全面. 然而, 本文重点关注不同情感脑电信号的分类, 对于网络微观结构的具体分析有所欠缺, 而网络模体作为网络周期性和结构性的表征, 常常被用于探索序列的时间顺序特征, 我们期待下一步工作对这方面有更多的探索.

参考文献

- 1 Sammler D, Grigutsch M, Fritz T, et al. Music and emotion: electrophysiological correlates of the processing of pleasant and unpleasant music. *Psychophysiology*, 2007, 44: 293–304
- 2 Knyazev G G, Slobodskoj-Plusnin J Y, Bocharov A V. Gender differences in implicit and explicit processing of emotional facial expressions as revealed by event-related theta synchronization. *Emotion*, 2010, 10: 678–687
- 3 Yin Z, Wang Y X, Liu L, et al. Cross-subject EEG feature selection for emotion recognition using transfer recursive feature elimination. In: *Proceedings of the Front Neuroinformatics, Shenyang*, 2017
- 4 Urgan B A, Plank M, Ishiguro H, et al. EEG theta and mu oscillations during perception of human and robot actions. *Front Neuroinformatics*, 2013, 7: 19
- 5 Zhong Q H, Zhu Y S, Cai D L, et al. Electroencephalogram access for emotion recognition based on a deep hybrid network. *Front Hum Neurosci*, 2020, 14: 589001
- 6 Krishna N M, Sekaran K, Vamsi A V N, et al. An efficient mixture model approach in brain-machine interface systems for extracting the psychological status of mentally impaired persons using EEG Signals. *IEEE Access*, 2019, 7: 77905–77914
- 7 Bao G C, Zhuang N, Tong L, et al. Two-level domain adaptation neural network for EEG-based emotion recognition.

- Front Hum Neurosci, 2020, 14: 605246
- 8 Salankar N, Mishra P, Garg L. Emotion recognition from EEG signals using empirical mode decomposition and second-order difference plot. *BioMed Signal Process Control*, 2021, 65: 102389
 - 9 Fdez J, Guttenberg N, Witkowski O, et al. Cross-subject EEG-based emotion recognition through neural networks with stratified normalization. *Front Neurosci*, 2021, 15: 626277
 - 10 Zheng W L, Lu B L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks. *IEEE Trans Auton Mental Dev*, 2015, 7: 162–175
 - 11 Zhuang N, Zeng Y, Tong L, et al. Emotion recognition from EEG signals using multidimensional information in EMD domain. *Biomed Res Int*, 2017, 2017: 1–9
 - 12 Tao W, Li C, Song R C, et al. EEG-based emotion recognition via channel-wise attention and self attention. *IEEE Trans Affect Comput*, 2020, 14: 382–393
 - 13 Zhang J, Small M. Complex network from pseudoperiodic time series: topology versus dynamics. *Phys Rev Lett*, 2006, 96: 238701
 - 14 Lacasa L, Luque B, Ballesteros F, et al. From time series to complex networks: the visibility graph. *Proc Natl Acad Sci USA*, 2008, 105: 4972–4975
 - 15 Luque B, Lacasa L, Ballesteros F, et al. Horizontal visibility graphs: exact results for random time series. *Phys Rev E*, 2009, 80: 046103
 - 16 Zhu J, Wei D J. Analysis of stock market based on visibility graph and structure entropy. *Phys A-Stat Mech its Appl*, 2021, 576: 126036
 - 17 Mori R, Liu R Y, Chen Y. Measuring the topological time irreversibility of time series with the degree-vector-based visibility graph method. *Front Phys*, 2021, 9: 777958
 - 18 Perez-Oregon J, Lovallo M, Telesca L. Visibility graph analysis of synthetic earthquakes generated by the Olami-Federchristensen spring-block model. *Chaos-An Interdisc J Nonlinear Sci*, 2020, 30: 093111
 - 19 Zheng M, Domanskyi S, Piermarocchi C, et al. Visibility graph based temporal community detection with applications in biological time series. *Sci Rep*, 2021, 11: 5623
 - 20 Pei L F, Li Z H, Liu J. Texture classification based on image (natural and horizontal) visibility graph constructing methods. *Chaos-An Interdisc J Nonlinear Sci*, 2021, 31: 013128
 - 21 Milo R, Shen-Orr S, Itzkovitz S, et al. Network motifs: simple building blocks of complex networks. *Science*, 2002, 298: 824–827
 - 22 Yu X, Shi S X, Xu L Y, et al. Analyzing dynamic association of multivariate time series based on method of directed limited penetrable visibility graph. *Phys A-Stat Mech its Appl*, 2020, 545: 123381
 - 23 Iacovacci J, Lacasa L. Sequential motif profile of natural visibility graphs. *Phys Rev E*, 2016, 94: 052309
 - 24 Choudhary G I, Aziz W, Khan I R, et al. Analysing the dynamics of interbeat interval time series using grouped horizontal visibility graph. *IEEE Access*, 2019, 7: 9926–9934
 - 25 Ren W K, Jin N D. Sequential limited penetrable visibility-graph motifs. *Nonlinear Dyn*, 2020, 99: 2399–2408
 - 26 Lacasa L, Nicosia V, Latora V. Network structure of multivariate time series. *Sci Rep*, 2015, 5: 15508
 - 27 Carmona-Cabezas R, Gómez-Gómez J, Ariza-Villaverde A B, et al. Multiplex visibility graphs as a complementary tool for describing the relation between ground level O₃ and NO₂. *Atmos Pollution Res*, 2020, 11: 205–212
 - 28 Gao Z K, Guo W, Cai Q, et al. Characterization of SSMVEP-based EEG signals using multiplex limited penetrable horizontal visibility graph. *Chaos-An Interdisc J Nonlinear Sci*, 2019, 29: 073119
 - 29 Xie W J, Han R Q, Zhou W X. Tetradic motif profiles of horizontal visibility graphs. *Commun Nonlinear Sci Numer Simul*, 2019, 72: 544–551
 - 30 Cai Q, An J P, Gao Z K. A multiplex visibility graph motif-based convolutional neural network for characterizing sleep stages using EEG signals. *Brain Sci Adv*, 2020, 6: 355–363
 - 31 Iacovacci J, Lacasa L. Sequential visibility-graph motifs. *Phys Rev E*, 2016, 93: 042309
 - 32 Klimesch W, Doppelmayr M, Russegger H, et al. Induced alpha band power changes in the human EEG and attention. *Neurosci Lett*, 1998, 244: 73–76
 - 33 Li M, Lu B L. Emotion classification based on gamma-band EEG. In: *Proceedings of Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Minneapolis, 2009*. 1223–1326
 - 34 Nawaz R, Cheah K H, Nisar H, et al. Comparison of different feature extraction methods for EEG-based emotion recognition. *Biocybernet BioMed Eng*, 2020, 40: 910–926
 - 35 Liu Y, Ding Y F, Li C, et al. Multi-channel EEG-based emotion recognition via a multi-level features guided capsule network. *Comput Biol Med*, 2020, 123: 103927
 - 36 Bonita J D, Ambolode Ii L C C, Rosenberg B M, et al. Time domain measures of inter-channel EEG correlations: a comparison of linear, nonparametric and nonlinear measures. *Cogn Neurodyn*, 2014, 8: 1–15
 - 37 Starovoitov V V, Eldarova E E, Iskakov K T. Comparative analysis of the SSIM index and the Pearson coefficient as a criterion for image similarity. *Eurasian J Math Comp*, 2020, 8: 76–90
 - 38 Gupta V, Chopda M D, Pachori R B. Cross-subject emotion recognition using flexible analytic wavelet transform from EEG signals. *IEEE Sens J*, 2019, 19: 2266–2274
 - 39 Tang H, Liu W, Zheng W L, et al. Multimodal emotion recognition using deep neural networks. In: *Proceedings of International Conference on Neural Information Processing, Guangzhou, 2017*. 811–819
 - 40 Li M H, Qiu M, Kong W Z, et al. Fusion graph representation of EEG for emotion recognition. *Sensors*, 2023, 23:

1404

- 41 Chen J X, Jiang D M, Zhang Y N, et al. Emotion recognition from spatiotemporal EEG representations with hybrid convolutional recurrent neural networks via wearable multi-channel headset. *Comput Commun*, 2020, 154: 58–65
- 42 Thejaswini S, Kumar K, Nataraj J L. Analysis of EEG based emotion detection of DEAP and SEED-IV databases using SVM. *Int J Recent Technol Eng*, 2019, 30: 576–581
- 43 Xing X F, Li Z Q, Xu T Y, et al. SAE+LSTM: a new framework for emotion recognition from multi-channel EEG. *Front Neurorobot*, 2019, 13: 37
- 44 Rahman M A, Anjum A, Milu M M H, et al. Emotion recognition from EEG-based relative power spectral topography using convolutional neural network. *Array*, 2021, 11: 100072
- 45 Zhang Y, Zhang Y D, Wang S. An attention-based hybrid deep learning model for EEG emotion recognition. *Signal Image Video Process*, 2022, 17: 2305–2313
- 46 Du X B, Ma C X, Zhang G H, et al. An efficient LSTM network for emotion recognition from multichannel EEG signals. *IEEE Trans Affective Comput*, 2022, 13: 1528–1540
- 47 Zhou R S, Zhang Z G, Fu H, et al. PR-PL: a novel transfer learning framework with prototypical representation based pairwise learning for EEG-based emotion recognition. 2022. ArXiv:2202.06509
- 48 Gu Y, Zhong X Y, Qu C, et al. A domain generative graph network for EEG-based emotion recognition. *IEEE J Biomed Health Inform*, 2023, 27: 2377–2386

Multivariate emotional EEG signal recognition based on multivariate joint motif entropy of a horizontal visibility graph

Xiaodong YANG^{1*}, Zhiyi MA¹, Yanlin REN¹, Meihui CHEN¹, Aijun HE² & Jun WANG³

1. *School of Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116, China;*

2. *School of Electronic Science and Engineering, Nanjing University, Nanjing 210023, China;*

3. *School of Applied Technology, Nanjing University of Posts and Telecommunications, Nanjing 210023, China*

* Corresponding author. E-mail: xyang@cumt.edu.cn

Abstract At present, many algorithms based on deep learning and neural networks have already been applied to the emotion recognition of EEG signals. However, most existing studies extract features of only single-dimensional EEG signals. With the update of multisensing technology, multidimensional signal feature extraction needs to become more comprehensive and systematic. This paper attempts to apply a complex network to emotion EEG recognition and proposes an emotion recognition algorithm based on the multivariate joint motif entropy of a horizontal visibility graph. This method can effectively avoid the influence of artificial feature selection and maintain the nonlinear dynamic characteristics of an original sequence. The horizontal visibility algorithm is used to convert multidimensional emotion EEG signals into multiplex visibility networks, and the key frequency bands and key channels of emotional research are identified by extracting motif entropy. On this basis, the horizontal visibility network is combined in pairs to extract multivariate joint motif entropy vectors, which are input parameters for identifying emotional EEG signals. Because the length of an emotional EEG sequence can affect the recognition effect, we cut the EEG into different-sized windows and compare the recognition conditions under different window sizes. Experimental results show that when the cutting window size is 10 s, the multivariate joint motif entropy attaches the best recognition effect, and the accuracy rate of classifying positive EEG/negative EEG, positive EEG/neutral EEG, and negative EEG/neutral EEG is 95.07%, 97.73%, and 90.26%, respectively, better than other connection parameters. Moreover, the accuracy rate of these three classifications is 93.67%, an improvement over the existing algorithm.

Keywords EEG, multiplex horizontal visibility graph, multivariate joint motif entropy, emotional recognition, multivariate analysis