

面向情绪识别的脑电特征研究综述

张冠华¹, 余曼婧^{1*}, 陈果¹, 韩义恒¹, 张丹², 赵国朕³, 刘永进^{1*}

1. 清华大学计算机科学与技术系, 北京 100084
2. 清华大学社会科学院心理学系, 北京 100084
3. 中国科学院心理研究所, 北京 100101

* 通信作者. E-mail: yumj14@mails.tsinghua.edu.cn, liuyongjin@tsinghua.edu.cn

收稿日期: 2018-12-24; 接受日期: 2019-03-19; 网络出版日期: 2019-09-06

国家自然科学基金(批准号: U1736220, 61725204)资助项目

摘要 情绪是人对外界事物产生的心理和生理反应。准确地识别情绪在人机交互研究中占据着重要位置, 其成果可应用在医学、教育、心理、军事等方向。由于脑电信号具有客观, 不易伪装等特点, 其在情绪识别领域的应用广受关注。从脑电信号中提取与情绪关联大、区分能力强的特征, 有助于后续的分类器更有效地识别不同情绪状态。本文调研了目前常用于情绪识别研究领域的脑电信号特征, 从时域、频域、时频域和空间域 4 个方面介绍其定义、计算方法, 以及与情绪的联系, 在 SEED, DREAMER 和 CAS-TU 3 个公开的脑电-情绪数据集上, 使用 SLDA 算法评估和比较了各类脑电特征区分不同效价的能力。本文也对目前存在的问题和未来的研究方向进行了讨论和展望, 可以为研究人员系统性地了解面向情绪识别的脑电特征研究现状以及开展后续研究提供思路。

关键词 情绪识别, 脑电信号, 特征提取, 特征选择, 情绪效价

1 引言

情绪是人对客观事物的态度体验及相应的行为反应^[1], 对于人类的行为和心理健康有着重要影响。如何准确识别情绪, 在人机交互研究中占据重要位置, 且有实际应用的意义: 在医学方面, 有助于对有心理疾病或表达障碍的患者进行疏导与诊断; 在教育方面, 根据听者的情绪施以不同的教学手段, 可提高授课效率。在《国家中长期科学和技术发展规划纲要(2006~2020)》中, 脑科学和人机交互均列为国家重大需求的关键技术, 而情绪识别技术将为其研究提供重要的理论依据。

为了识别情绪, 研究人员需要对情绪状态进行量化和建模。目前广泛使用的情绪量化模型主要有离散模型和维度模型两种。在离散模型中, 情绪空间由离散而有限的基本情绪构成, 例如大多数心理学研究者公认的 6 种基本情绪——高兴(happiness)、悲伤(sadness)、惊讶(surprise)、恐惧(fear)、愤

引用格式: 张冠华, 余曼婧, 陈果, 等. 面向情绪识别的脑电特征研究综述. 中国科学: 信息科学, 2019, doi: 10.1360/N112018-00337
 Zhang G H, Yu M J, Chen G, et al. A review of EEG features for emotion recognition (in Chinese). Sci Sin Inform, 2019, doi: 10.1360/N112018-00337

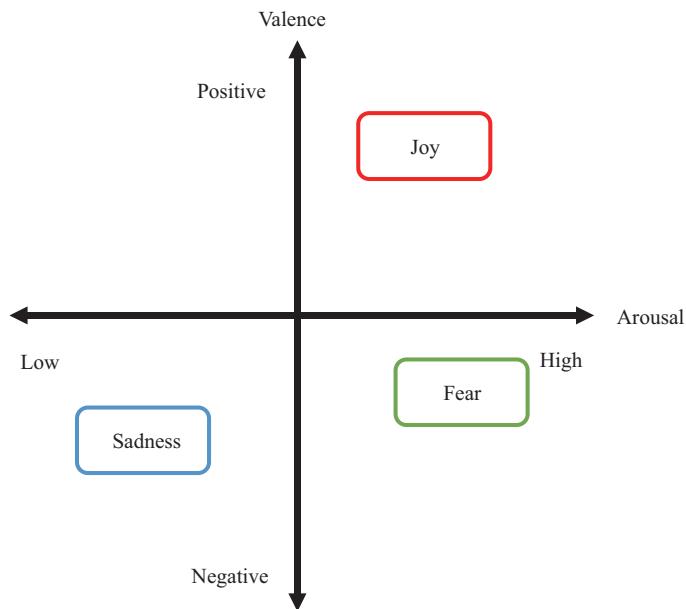


图 1 (网络版彩图) 情绪的效价 – 唤醒度维度模型示意图
Figure 1 (Color online) Valence-arousal dimensional emotion model

怒 (anger) 和厌恶 (disgust), 其他情绪都可以由基本情绪组合而成^[2]. 维度模型则是基于认知评价将情绪空间划分为效价 – 唤醒度 (valence-arousal, VA) 两个维度^[3], 或效价 – 唤醒度 – 优势度 (valence-arousal-dominance, VAD) 3 个维度^[4], 目前对于 VA 模型的研究比 VAD 模型更广泛. 效价表示情绪是积极还是消极的; 唤醒度反映情绪的强烈程度; 优势度指人能否控制这种情绪. 维度模型可将离散情绪映射至坐标空间, 图 1 即为用 VA 模型表示高兴、恐惧和悲伤 3 种离散情绪.

面部表情、语音语调、姿势动作和生理信号都可以作为情绪识别的数据来源, 其中生理信号难以伪装, 包含的信息也更丰富^[5]. 使用生理信号识别情绪通常包括以下 6 步: (1) 情绪诱发, 使用图片、声音或视频等刺激材料诱发被试者产生特定类型的情绪; (2) 信号采集, 通过设备采集被试产生情绪时的各种生理信号; (3) 信号预处理, 通常使用滤波去除噪声和伪迹; (4) 特征提取, 对信号进行变换, 从中计算与目标任务相关的特征; (5) 用机器学习领域的分类算法进行情绪分类; (6) 以图表等形式反馈识别结果. 其中, 特征提取是至关重要的一步, 若能找出与情绪最相关的特征集合, 有利于提高后续分类器的识别准确率.

在脑电 (electroencephalogram, EEG)、心电 (electrocardiogram, ECG)、肌电 (electromyography, EMG) 和皮肤温度 (skin temperature, SKT) 等生理信号中, 使用脑电识别情绪具有操作简单、成本低、效果好的优势, 近年来得到了广泛关注^[6]. 脑电是记录头皮电位变化的信号, 在一定程度上反映大脑皮层的活动. 研究表明不同脑区参与不同的感知和认知活动, 例如额叶 (frontal lobe) 与思维、意识有关, 颞叶 (temporal lobe) 与人脸和场景等复杂刺激信息的处理、嗅觉和听觉有关, 顶叶 (parietal lobe) 与多种感官信息的整合和对物体的操作控制有关, 枕叶 (occipital lobe) 则与视觉有关^[7].

本文围绕面向情绪识别的脑电特征, 从时域、频域、时频域和空间域 4 个方面介绍特征的定义、计算方法, 以及与情绪的联系, 在 SEED, DREAMER 和 CAS-THU 3 个公开的脑电 – 情绪数据集上评估和比较了各类脑电特征区分不同效价的能力, 并对未来的可行研究方向进行展望. 本文的组织如下: 文章分为 5 个部分, 其中第 1 节为引言, 第 2 节介绍目前研究中常用的面向情绪识别的脑电特征,

第3节设计实验,评估并比较各类特征在3个数据集上区分效价的能力,第4节讨论未来的研究方向,第5节对全文进行总结.

2 现有脑电特征的定义与计算方法

在情绪识别领域,EEG传统特征主要分为时域(time domain)特征、频域(frequency domain)特征、时频域(time-frequency domain)特征3类.考虑到脑区的不对称性也可以反映情绪信息,空间域(space domain)特征也因此逐渐用于识别情绪.本节将从时域、频域、时频域、空间域4个角度介绍常用于情绪识别的脑电特征.

2.1 时域特征

大多数脑电设备以时域形式采集EEG信号,故时域特征最直观易得,其主要包括:事件相关电位、信号统计量、能量、功率、高阶过零分析、Hjorth参数特征、不稳定指数和分形维数.

脑电设备根据一定的采样频率对原连续信号进行采样,得到离散序列.我们约定,用 $s(n)$ 表示某个电极上第 n 次采样得到的EEG信号值, $n=1,2,\dots,N$, N 表示总采样数.

2.1.1 事件相关电位

事件相关电位(event related potential,ERP)是指由离散刺激事件引发的脑电电压波动,可反映认知加工的过程^[8].与不间断的脑电电压波动幅度相比,大多数ERP幅度小,因此通常取多段由相同刺激引发的EEG的平均值分析ERP^[9].

ERP的波形随时间变化呈现具有不同持续时间、振幅和极性的波峰,因而通常从3个方面来衡量:潜伏期(latency)、振幅(amplitude)、正负极性(polarity).图2是在0 ms时发生的刺激事件引发的ERP波形示意图.

(1) 潜伏期指大脑皮层从接受刺激到发生反应的延迟时间,通常计算刺激起始到波峰顶点间的时间.潜伏期与神经活动的加工时间有关,加工越久潜伏期越长.

(2) 振幅有基线–波峰和波峰–波峰两种测量方式,反映大脑的兴奋性高低,例如给被试呈现负性刺激材料时,ERP的振幅会增加^[10].

(3) 极性中的正性电压波动(positive)用P表示,负性(negative)用N表示^[11].

ERP的成分一般遵循两种命名体系,一种依据潜伏期,例如P300表示电压向正性波动,且潜伏期为300 ms左右;另一种则依据成分的序列性,例如刺激诱发的第一个显著的负成分为N1,第三个显著的正成分为P3.ERP成分的潜伏期数值往往约为序列位置的100倍,所以第1种命名方式中的P300等价于第2种方式的P3.

在情绪方面,潜伏期较短的ERP成分与效价有关^[12~15],如枕叶的P100在产生消极情绪时的振幅大于积极情绪时的振幅^[16,17].P300和潜伏期在500 ms以上的皮层慢电位(slow cortical potential,SCP)等潜伏期较长的ERP成分与唤醒度有关^[6,18~20].由于P300的测量更可靠,且其振幅和潜伏期特征包含的信息更丰富,故P300为神经科学领域研究最多的ERP成分^[11].Nieuwenhuis等^[21]的研究表明,P300在正性或负性情绪下都比中性状态时更显著.

ERP的瞬时分辨率强,常用于由离散的视、听和触觉刺激诱发情绪的情况,例如图片、短音频和振动等,而不常用于连续的情绪诱发.在实时系统中,情绪的触发点很难确定和控制,所以ERP难以应用在情绪的实时诱发和检测中^[22].

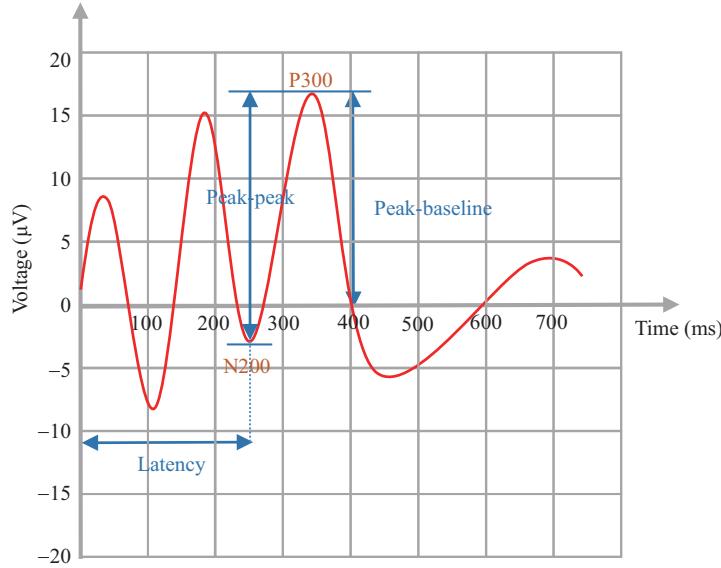


图 2 (网络版彩图) 0 ms 时发生刺激事件产生的 ERP 示意图
Figure 2 (Color online) ERP pattern stimulated by event at 0 ms

2.1.2 信号统计量

电信号通用的时域统计特征也可应用于 EEG 信号, 它们简单易计算, 且可以得到较好的识别效果^[23~25]. 例如, 平均值 μ_s , 标准差 σ_s , 一阶差分绝对值的平均值:

$$\delta_s = \frac{1}{N-1} \sum_{n=1}^{N-1} |s(n+1) - s(n)|, \quad (1)$$

二阶差分绝对值的平均值:

$$\gamma_s = \frac{1}{N-2} \sum_{n=1}^{N-2} |s(n+2) - s(n)|, \quad (2)$$

归一化的一阶差分 (也称为归一化长度密度, 可衡量脑电信号的自相似性^[26]):

$$\bar{\delta}_s = \frac{\delta_s}{\sigma_s}, \quad (3)$$

和归一化的二阶差分:

$$\bar{\gamma}_s = \frac{\gamma_s}{\sigma_s}. \quad (4)$$

2.1.3 能量

大脑皮层的活跃程度影响 EEG 的振幅, 进而反映为能量的波动. 信号的能量在时域上表示为幅度的平方, 即

$$E_s = \sum_{n=1}^N |s(n)|^2. \quad (5)$$

2.1.4 功率

平均功率可用能量除以采样数得到^[27], 在频域上也有能量和功率的计算方法, 将在 2.2 小节进行说明.

$$P_s = \frac{1}{N} \sum_{n=1}^N |s(n)|^2. \quad (6)$$

2.1.5 Hjorth 参数特征

Hjorth 定义了信号在时域上的 Hjorth 参数特征^[28], Activity 衡量信号波幅的偏离程度:

$$\text{Activity} = \frac{1}{N} \sum_{n=1}^N (s(n) - \mu_s)^2, \quad (7)$$

Mobility 衡量坡度的变化:

$$\text{Mobility} = \sqrt{\frac{\text{var}(s'(n))}{\text{var}(s(n))}}, \quad (8)$$

Complexity 衡量一个振幅上有多少个标准的坡 (slope):

$$\text{Complexity} = \frac{\text{Mobility}(s'(n))}{\text{Mobility}(s(n))}, \quad (9)$$

其中, μ_s 表示信号平均值, $s'(n)$ 表示一阶导数, var 表示方差.

2.1.6 高阶过零分析

Petrantonakis 等^[29] 提出高阶过零分析 (higher order crossings, HOC) 的方法, 用信号通过零点的次数来反映信号的振荡程度. 将 EEG 序列 $s(n)$ 转换为均值为 0 的序列 $Z(n)$, $n = 1, 2, \dots, N$, 将该序列通过 M 个高通滤波器, k 表示滤波器的顺序, $k = 1, 2, \dots, M$:

$$L_k\{Z(n)\} = \sum_{j=1}^k \frac{(k-1)!}{(j-1)!(k-j)!} (-1)^{j-1} Z(n-j+1), \quad (10)$$

再根据 $L_k\{Z(n)\}$ 构建二值序列

$$X_n(k) = \begin{cases} 1, & L_k\{Z(n)\} \geq 0, \\ 0, & L_k\{Z(n)\} < 0, \end{cases} \quad k = 1, 2, \dots, M, \quad n = 1, 2, \dots, N, \quad (11)$$

$X_n(k)$ 中符号的变化次数即为 HOC 值:

$$\text{HOC}_k = \sum_{n=2}^N (X_n(k) - X_{n-1}(k))^2. \quad (12)$$

由于 EEG 在不同情绪下的振荡模式和特性不同, 与谱功率相比, HOC 可以更鲁棒地表征信号的振荡特点^[18]; 与统计特征或基于小波变换的特征相比, 使用 HOC 可以更好地区分第 1 节所述的 6 种基本情绪^[29].

2.1.7 不稳定指数

不稳定指数 (non-stationary index, NSI) 衡量局部平均值随时间的变化^[26]. 将信号分成 n 段并计算各段的均值, NSI 定义为这 n 个平均值的标准差. NSI 越大表示局部平均值振荡越大. Hausdorff 等^[30]发现在不同的分割时长上, 得到的 NSI 值是类似的.

2.1.8 分形维数

分形维数 (fractal dimension, FD) 可用来表示时域信号的复杂程度. Sevcik 方法^[31]、分形布朗运动 (fractal Brownian motion)^[32]、计盒法 (box-counting)^[33]、Higuchi 算法^[34]都可用来计算 FD, 而 Higuchi 算法的效果更好^[22], 使用该算法计算 EEG 的分形维数特征 FD_s 的过程如下: 首先将时域信号序列 $s(n)$, $n = 1, 2, \dots, N$ 重写为 $\{s(m), s(m+k), \dots, s(m + \lfloor \frac{N-m}{k} \rfloor \cdot k)\}$, 其中, $m = 1, \dots, k$ 是起始时间, k 是时间间隔. 在每个 m 的取值上, 令

$$H_m(k) = \frac{N-1}{\lfloor \frac{N-m}{k} \rfloor k^2} \sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |s(m+ik) - s(m+(i-1)k)|. \quad (13)$$

用 $\bar{H}(k)$ 表示 $H_m(k)$ 的平均值, 取 FD_s 为

$$FD_s = -\frac{\log \bar{H}(k)}{\log k}. \quad (14)$$

2.2 频域特征

由于时域特征无法展示信号的频率信息, 研究者加入了频域分析^[35]. 首先将原始的时域信号转换至频域获得频谱, 之后将频段分解到与人的心理活动联系密切^[36] 的 5 个子频段 $\delta, \theta, \alpha, \beta, \gamma$, 再从中计算特征.

通常使用傅里叶变换 (Fourier transfer, FT) 进行时 – 频域转换. 将信号投影到固定的正交函数系上, 用一组变换系数 (谱线) 表示时间函数, 各谱线表示某一频率分量的相位、幅度等参数^[37].

由于采集到的 EEG 信号为离散序列 $s(n)$, 实际操作中多使用离散傅里叶变换法 (discrete Fourier transfer, DFT), 用求和代替积分运算, 使计算机能够处理傅里叶变换^[5]. 应用于 EEG 信号可得频谱

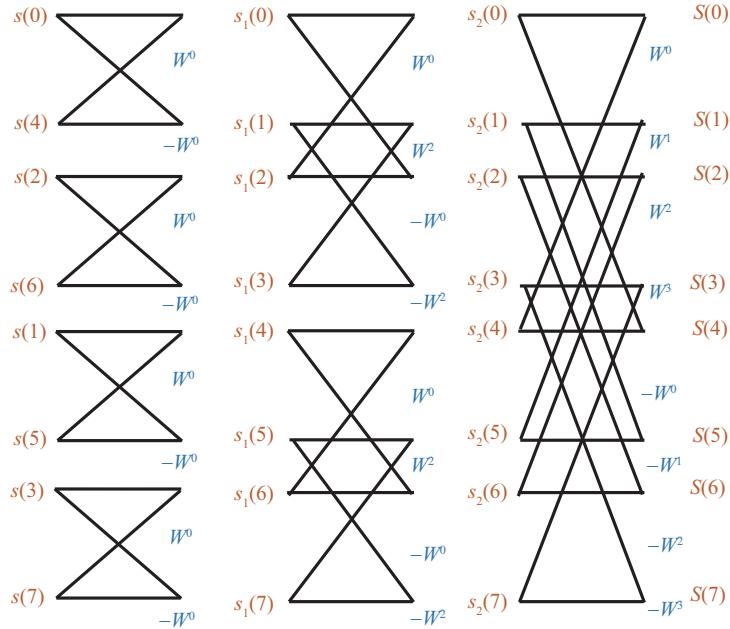
$$S(k) = DFT[s(n)] = \sum_{n=0}^{N-1} s(n) W_N^{nk} = \sum_{n=0}^{N-1} s(n) e^{-j(\frac{2\pi}{N})nk}, \quad (15)$$

其中 k 表示样本点序号, $k = 0, 1, \dots, N-1$. 记 $W_N = e^{-j(\frac{2\pi}{N})}$ 为变换矩阵. 从式中可看出, 每个 $S(k)$ 需要 $N-1$ 次复数加法和 N 次乘法运算, 整个序列的 DFT 运算需要 $N(N-1)$ 次复数加法和 N^2 次复数乘法, 运算复杂度高.

快速傅里叶变换 (fast Fourier transfer, FFT) 也称库利 – 图基 (Cooley-Tukey) 算法, 利用 W_N 的周期性 $W_N^{nk} = W_N^{(nk)\text{mod}N}$ 和对称性 $W_N^{nk+\frac{N}{2}} = -W_N^{nk}$, 将 DFT 运算按照奇偶性逐级分解, 第 1 级将 N 个点分为各 $\frac{N}{2}$ 个采样点的两组, 第 2 级再细分为各 $\frac{N}{4}$ 个采样点的四组, 以此类推, 运算流程如图 3 所示, 自图的左端向右运算, 两条线的汇合点表示数值相加, 线旁标注的 W^k 表示与相应的数值相乘. 例如

$$s_1(0) = s(0) + W^0 s(4), \quad s_1(1) = s(0) - W^0 s(4).$$

从上式可看出, 单元包含一个复数乘和两个复数加操作. 对于 N 个采样点, 共 $\log N$ 层, 每层 $\frac{N}{2}$ 个单元, 因而整个 FFT 算法只需要 $\frac{N}{2} \log N$ 次乘和 $N \log N$ 次加法, 且 N 越大, FFT 的优越性越显著^[37].

图 3 (网络版彩图) $N = 8$ 时的 FFT 计算流程图Figure 3 (Color online) FFT calculation when $N = 8$

由上述步骤处理后得到的频段经过分解, 得到 5 个子频段 δ (1~4 Hz), θ (4~8 Hz), α (8~12 Hz), β (13~30 Hz), γ (31~45 Hz), 在不同实验中, 各频段的边界略有几赫兹的差异. EEG 的不同频段与不同的意识状态有关: δ 波与无意识的状态有关, 常出现于深度无梦的睡眠; θ 波与潜意识有关, 例如有梦境的睡眠或浅度睡眠、困倦, 当诱发积极情绪时, 额中线上的 θ 波功率会增强^[38]; α 波多出现于较为放松的有意识状态, 额叶上 α 波的不对称性可反映情绪的不同效价^[39, 40]; β 波与活跃的意识状态例如注意力集中的活动有关, 在额叶区域较为显著, 可反映情绪的效价^[6, 41, 42]; γ 波则与大脑的过度活跃现象、特定的认知或运动有关^[43~45]. 中性情绪和消极情绪在 β 和 γ 波段有相似的振荡模式, 但其在 α 波段的振荡能量更高^[46].

分解频段后, 再分别提取功率、功率谱密度、事件相关同步化、事件相关去同步化、高阶谱、微分熵等特征.

2.2.1 功率

功率在时域上的计算方法如式 (6) 所示. 而在频域上, 可通过功率谱密度的积分运算得到. 通过将整个频段划分为若干个子频段, 计算各子频段功率的平均值、最值和方差等. 此外, β 波段和 α 波段的平均功率之比可以表征脑部的活跃状态, 可用于情绪识别研究^[22].

2.2.2 功率谱密度

功率谱密度 (power spectral density, PSD) 描述信号的功率随频率的变化情况, 可由直接法或间接法得到.

直接法. 直接法包括周期图法、Welch 法等线性经典谱估计法, 和最大熵法、最大似然法等非线性现代谱估计法. 经典谱估计法更适合长序列, 当信号序列较短时, 谱分辨能力较差; 而非线性方法可保证较高的谱分辨率^[5].

(1) 周期图法 (periodogram). 功率谱密度由 DFT 后幅频特性的平方除以 EEG 序列的长度得到. 由于 DFT 的周期性, 功率谱也有周期性, 故称周期图. 因为不同序列长度会产生不同的周期图, 无法得到稳定的估值, 故取各子区间上周期图的均值作为功率谱估值.

(2) Welch 法. 在周期图的基础上加入平滑操作. 先分成若干子波段, 再用子波段内的信号与窗函数相乘进行平滑, 最后在各子区间上取平均, 以降低周期图的波动程度.

(3) 最大熵法. 取一组自相关函数与已知信号序列相等, 且自相关函数以外的部分随机性最大的序列, 以所取序列的功率谱作为已知序列功率谱的估值. 由于要求随机性最大, 因而熵最大, 称最大熵法.

(4) 最大似然谱估计法. 也称最小方差谱估计法. 让信号通过一个滤波器, 保证所需信号不失真且其他频率信号均方差最小. 若将一个确定信号加一个 Gauss 白噪声作为输入, 则滤波器输出此信号的最大似然估值, 故称为最大似然法. 若信号只是一个确定信号, 例如脑电信号, 则输出为确定信号最小方差的无偏估值, 即为该信号的功率谱估值.

间接法. 由维纳 – 辛钦 (Wiener-Khinchin) 定理可知, 信号的功率谱密度可由时域信号的自相关函数的傅里叶变换得到, 称为间接法.

得到功率谱后, 根据给定的某一波段, 计算该波段内功率谱密度的均值、最值、方差等统计量作为特征.

2.2.3 事件相关 (去) 同步化

在一个刺激事件之后的若干毫秒内, EEG 信号在某一频段上功率的快速升高称为事件相关同步化 (event related synchronization, ERS); 相反, 功率降低称为事件相关去同步化 (event related desynchronization, ERD) [47]. 它们在时域中不明显, 需要在频域上经过带通滤波和平滑后才能观察到. 一般认为 ERS 和 ERD 与大脑神经元放电的同步性有关, 当同步性增加时能量叠加变高, 产生 ERS, 同步性下降时能量降低, 产生 ERD. 第 n 个采样点上得到的特征 ERDS_n 为

$$\text{ERDS}_n = \frac{A_n - R_n}{R_n} \times 100, \quad (16)$$

其中, A_n 表示在第 n 个采样点上的功率, R 表示在该采样点前后一段区间上的平均功率 [48].

效价上, γ 波段上的 ERS 和 ERD 特征可区分正负性情绪 [45]; 产生正性情绪时, 颞叶左侧的 θ 波段上的 ERS 特征会变得显著, 而产生负性情绪时, 右侧 ERS 特征更显著 [41]. 唤醒度上, 非中性情绪与中性情绪相比, θ 波段的 ERS 和 ERD 特征在整个右侧脑区都更加显著 [49].

2.2.4 高阶谱

高阶谱 (higher order spectrum, HOS) 特征通常需要计算双谱 (bispectrum) 和双相干谱 (bicoherence). 双谱是信号三阶矩的傅里叶变换, 可用来量化信号分量之间的二次相位耦合, 即原信号与谐波发生耦合作用, 产生的新频率成分的和频与差频. 与功率谱密度相比, 双谱特征涵盖相位信息, 其计算方法为

$$\text{Bis}(f_1, f_2) = \mathbb{E}[F(f_1) \cdot F(f_2) \cdot F^*(f_1 + f_2)], \quad (17)$$

其中, f_1, f_2 指两个信号各自的频率, $F(f)$ 指傅里叶变换, $\mathbb{E}[x]$ 为期望, $*$ 表示共轭复数. 双相干谱是双谱的归一化形式

$$\text{Bic}(f_1, f_2) = \frac{\text{Bis}(f_1, f_2)}{\sqrt{P(f_1) \cdot P(f_2) \cdot P(f_1 + f_2)}}, \quad (18)$$

其中, $P(f) = \mathbb{E}[F(f)F^*(f)]$ 是功率谱. Bis 与 Bic 各自的模或模的平方都可以作为高阶谱特征 [22].

2.2.5 微分熵

微分熵 (differential entropy, DE) 是香农 (Shannon) 信息熵 $-\sum_x p(x) \log(p(x))$ 在连续变量上的推广形式

$$DE = - \int_a^b p(x) \log(p(x)) dx, \quad (19)$$

其中, $p(x)$ 表示连续信息的概率密度函数, $[a, b]$ 表示信息取值的区间. 对于一段特定长度的近似服从 Gauss 分布 $N(\mu, \sigma_i^2)$ 的 EEG, 其微分熵为^[46, 50]:

$$DE = - \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(x-\mu)^2}{2\sigma_i^2}} \log \left(\frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(x-\mu)^2}{2\sigma_i^2}} \right) dx = \frac{1}{2} \log(2\pi e \sigma_i^2), \quad (20)$$

等于其在特定频段上的能量谱的对数^[51].

Zheng 等^[46] 在识别正性、中性和负性 3 种情绪的实验中, 使用 DE 作为特征获得的识别准确率高于其他特征.

2.3 时频域特征

傅里叶变换的作用范围是整个时域, 缺乏局部化能力, 且无法确认非平稳信号各频域成分对应的时刻, 所以引入了时域与频域结合的时频域. 通常做法是划分出若干时间窗, 各窗内的子信号近似平稳, 将其变换至频域得到一组频域特征, 滑动时间窗可处理不同时段, 从而同时获取信号的时域和频域信息, 提高对不稳定信号的处理能力, 可粗略计算情绪开始和持续的时间^[52]. 通常使用短时傅里叶变换 (short-time Fourier transform, STFT)、小波变换 (wavelet transform, WT) 和小波包变换 (wavelet packet transform, WPT) 或 Hilbert-Huang 方法来进行时频域信号变换.

2.3.1 短时傅里叶变换

STFT 可提高对噪声干扰的鲁棒性^[53]. 使用等长的窗函数 $w(n-t)$ 计算窗内信号的傅里叶变换:

$$X(n, \omega) = \int_{-\infty}^{\infty} w(n-t)f(t)e^{-j\omega t} dt, \quad (21)$$

再求出各窗函数的时间点及频率成分. 常见的窗函数有三角波、方波和 Gauss 函数等, 通常默认使用 Gauss 函数, 此时 STFT 也称 Gabor 转换.

选择合适的窗长度至关重要, 短的时间窗提供的信息量不足, 导致频域分辨率差; 长的时间窗又会导致各窗差异大, 时域分辨率差. 目前情绪识别研究中效果好的时间窗长度多为 1 ~ 2 s^[5, 54, 55].

2.3.2 小波变换

由于 STFT 的时间窗长度对效果有明显影响, 且无法同时在时域和频域获得高分辨率, 故引入小波变换. 主要有两种基本类型: 连续小波变换 (continuous wavelet transform, CWT) 和离散小波变换 (discrete wavelet transform, DWT)^[56].

基本小波, 或称小波母函数 $\phi(t)$ 应平方可积, 且其傅里叶变换满足 $\frac{|\phi(\omega)|^2}{|\omega|} d\omega < \infty$. 平移 τ 可使小波函数在时间轴上移动; α 变大或变小会使其变窄或变宽^[57], 其中, $\alpha, \tau \in R, \alpha > 0$. 由此得到变换后的函数

$$\phi_{\alpha, \tau}(t) = \frac{1}{\sqrt{\alpha}} \phi \left(\frac{t - \tau}{\alpha} \right), \quad (22)$$

称为参数为 α 和 τ 的小波基函数. $\frac{1}{\sqrt{\alpha}}$ 将能量归一化. 当参数可连续取值时, 称为连续小波变换; 当参数只能取离散值时, 称为离散小波变换.

2.3.3 小波包变换

小波变换将信号分成低频和高频两个部分, 只分解低频部分, 导致忽略表征信号细节的高频部分, 使高频分辨率差, 丢失细节信息. 因此引入 WPT, 仍将信号分解为低频和高频部分, 但两部分都会继续分解, 低频上丢失的信息可以在高频中补充. 因此, 小波包变换可以提供更丰富的信号分析, 提高分辨率^[58].

2.3.4 Hilbert-Huang 谱

Hilbert-Huang 是一种非线性的时频域特征提取方法, 与 STFT 相比, 抵抗噪声干扰的能力更强^[22, 59]. 首先用经验模式分解 (empirical mode decomposition, EMD) 得到固有模态函数 (intrinsic mode functions, IMFs) 来表征原 EEG 信号 $X(t)$, 假设共分解出 k 个固有模态函数:

$$X(t) = \sum_{i=1}^k \text{IMF}_i(t) + r(t), \quad (23)$$

其中, $r(t)$ 表示剩余的单调或常数的部分. 再对每个 $\text{IMF}_i(t)$ 计算 Hilbert 变换, 解析信号可用振幅 $A_i(t)$ 和瞬时相位 $\theta_i(t)$ 来表征, 瞬时频率 $f_i(t) = \frac{1}{2\pi} \frac{d\theta_i}{dt}$, 则原信号可表示为

$$X(t) = \sum_{i=1}^k A_i(t) e^{j2\pi \int f_i(t) dt}. \quad (24)$$

通过上述方法将 EEG 按时间段变换至频域后, 再提取如前所述的频域特征, 例如功率、功率谱密度的均值、最值等. 除此之外, 也可根据时间窗提取时频域上的相对能量

$$\text{RE}_{\text{band}} = \frac{\text{Energy}_{\text{band}}}{\text{Energy}_{\text{total}}} \quad (25)$$

和每个时间窗上的熵

$$\text{Entropy} = - \sum_{\text{band}} \text{RE}_{\text{band}} \log \text{RE}_{\text{band}}, \quad (26)$$

其中, $\text{Energy}_{\text{band}}$ 表示某个时间窗内信号在某个频段上的能量, $\text{Energy}_{\text{total}}$ 为该时间窗内所有频段能量之和^[40].

2.4 空间域特征

脑电信号采自若干个对应大脑皮层不同位置的电极, 如前所述, 左右半球产生的 EEG 信号与情绪效价有关: 消极情绪能激活右侧额叶、颞叶和顶叶, 而积极情绪可以激活左侧区域^[60~63]. 因此形成 EEG 的空间域特征, 主要分为空频域特征和电极组合特征.

2.4.1 空频域

先提取各电极上的频域特征, 再用共同空间模式 (common spatial patterns, CSP) 等算法与空间域结合, 计算空频域特征.

共同空间模式. CSP 常用于二分类问题, 根据信号所属的类别标签, 设计特殊的空间滤波器, 使两类信号的功率最大, 继而得到区分度高的特征^[64, 65] 以及各电极信号的权重^[66].

假设 n 段 EEG 信号分为正性和负性效价两类, 每段信号都表示为通道数 \times 采样点个数的矩阵形式, 将两种分类下信号的协方差矩阵分别取平均得到 Σ^+ 和 Σ^- , 并进行特征值分解 $\Sigma^+ + \Sigma^- = UDU^T$, U 是特征向量矩阵, D 是特征值构成的对角矩阵, 则白化值矩阵为 $P = \sqrt{D^{-1}}U^T$, 白化后的信号的协方差矩阵为

$$\begin{aligned} S^+ &= P\Sigma^+P^T = B\Lambda B^T, \\ S^- &= P\Sigma^-P^T = I - S^+ = B(I - \Lambda)B^T. \end{aligned} \quad (27)$$

二者特征向量相同, 且特征值加和为 1. I 表示单位矩阵, B 表示特征向量矩阵, Λ 表示特征值构成的对角矩阵, 那么

$$\begin{aligned} B^TP\Sigma^+P^TB &= B^TS^+B = \Lambda, \\ B^TP\Sigma^-P^TB &= B^TS^-B = I - \Lambda. \end{aligned} \quad (28)$$

因此, 称投影矩阵 $W = B^TP$ 中的每个行向量 w_j 就是一个空间滤波器, 越大的特征值表示 w_j 在两类上可以得到差距越大的方差. 而 W^{-1} 的每一列称为共同空间模式 [66].

Koelstra 等 [65] 在效价 (valence)、唤醒度 (arousal) 和喜爱度 (like/dislike) 3 项上, 分别以原始 PSD 和 CSP 作为特征, 用支持向量机 (support vector machine, SVM) 进行二分类, CSP 得到的分类准确率高于 PSD.

共同空间模式的改进. 由于不同个体的脑电信号在各频段上的显著程度不同, 因此当被试较多且差异较大时, 为保证识别效果, 需要大量手动调整 CSP 的频段. 为了解决这一问题, Novi 等 [67] 提出了子波段共同空间模式 (sub-band common spatial pattern, SBCSP), 用基于傅里叶的 Gabor 滤波器组将信号分成不同频段, 在各波段上提取 CSP 特征, 使用 LDA 算法自动选择显著的频段和相应的 CSP 特征, 最后用分类器对 CSP 特征进行分类. SBCSP 可以实现自动调整且保证识别准确率.

Ang 等 [68] 进一步改进了 SBCSP 算法, 提出了滤波器组共同空间模式 (filter bank common spatial pattern, FBCSP), 其与 SBCSP 的区别在于使用零相位切比雪夫 (Chebyshev) 滤波器组作为滤波器, 克服了 IIR (infinite impulse response) 滤波器造成的非线性相移; 在特征选择和分类中, 可广泛使用现有的特征选择和分类器算法, 具有普适性.

2.4.2 电极组合

计算电极组合特征时, 先对各电极信号计算前述时域、频域或时频域特征作为初步特征值, 再将若干电极组合成对, 进一步计算特征. 电极对的组合方式包括对称和不对称两种, 对称方式又分为前后对称和左右对称. 为了便于论述, 以 32 导 NeuroScan Quik-cap 脑电帽的电极位置为例. 该设备包括 2 个参考电极和 30 个采样电极, 如图 4 所示.

左右位置对称. 以中间的灰色竖线为对称轴, 剩余 24 个电极左右对称, 可得到 12 对电极, 绿色线标识的两列电极互为电极对, 蓝色线标识的两列同理. 用 L 列举出所有电极对中的左侧电极, R 为相应的右侧电极:

$$\begin{aligned} L &= \{\text{FP1}, \text{F3}, \text{FC3}, \text{C3}, \text{CP3}, \text{P3}, \text{O1}, \text{F7}, \text{FT7}, \text{T7}, \text{TP7}, \text{P7}\}, \\ R &= \{\text{FP2}, \text{F4}, \text{FC4}, \text{C4}, \text{CP4}, \text{P4}, \text{O2}, \text{F8}, \text{FT8}, \text{T8}, \text{TP8}, \text{P8}\}. \end{aligned}$$

(1) 不对称差/不对称商. 不对称差 (differential asymmetry, DASM) 和不对称商 (rational asymmetry, RASM) 分别指左右对称电极上特征的差分和比值 [69]

$$\begin{aligned} \text{DASM} &= \text{Feature}(X_L) - \text{Feature}(X_R), \\ \text{RASM} &= \text{Feature}(X_L)/\text{Feature}(X_R), \end{aligned} \quad (29)$$

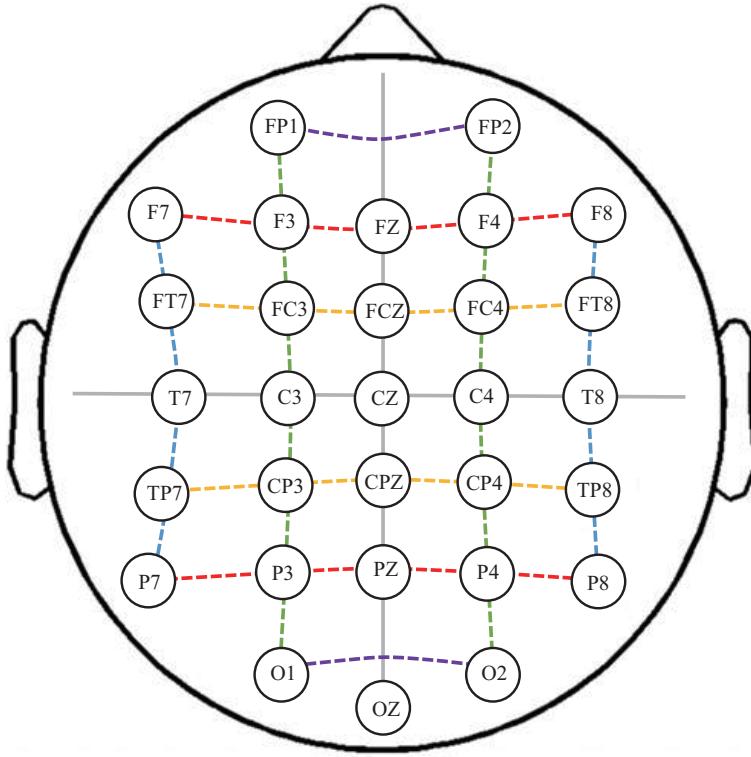


图 4 (网络版彩图) 32 导 NeuroScan Quik-cap 脑电帽的 30 个采样电极位置

Figure 4 (Color online) 30 sampling electrodes of 32-channel NeuroScan Quik-cap

或者更复杂的计算方法, 用左右特征的差除以和, 此处称为不对称系数^[18]:

$$\text{Index} = \frac{\text{Feature}(X_L) - \text{Feature}(X_R)}{\text{Feature}(X_L) + \text{Feature}(X_R)}, \quad (30)$$

其中, X_L 和 X_R 分别表示左侧和右侧电极采集到的 EEG 信号, Feature(X) 表示在信号 X 上提取的初步特征值.

(2) 多维度有向信息. Sakata 等^[70] 提出了多维度有向信息 (multidimensional directed information, MDI), 反映从某个电极流向其他电极的信息量, 通常测量左右电极对之间流动的信息量. MDI 的优势在于可以表示各电极之间信号量的绝对量而非相对量^[71]. 首先将两个电极上长度为 N 的 EEG 信号平均划分为 n 段, 每段以 x_k 和 y_k 界定

$$X = x_{k-p} \cdots x_{k-1} x_k x_{k+1} \cdots x_{k+M} = X^P x_k X^M,$$

$$Y = y_{k-p} \cdots y_{k-1} y_k y_{k+1} \cdots y_{k+M} = Y^P y_k Y^M,$$

那么两序列的互信息为

$$I(X; Y) = \sum_k I(x_k; Y^M | X^P Y^P y_k) + I(y_k; X^M | X^P Y^P x_k) + I(x_k; y_k | X^P Y^P). \quad (31)$$

前后位置对称. 以图 4 中间横向的灰色横线为对称轴, 并舍弃 OZ 电极, 剩余 24 个电极前后对称, 可得到 12 对电极, 紫色线标识的两行电极互为电极对, 红色线、橙色线同理. 用 F 列举出所有电

极对中的前部电极, P 为相应的后部电极:

$$F = \{FP1, FP2, F7, F3, FZ, F4, F8, FT7, FC3, FCZ, FC4, FT8\},$$

$$P = \{O1, O2, P7, P3, PZ, P4, P8, TP7, CP3, CPZ, CP4, TP8\}.$$

DCAU (differential caudality) 可以用来描述前后电极上的不对称性^[46]

$$\text{DCAU} = \frac{\text{Feature}(X_{\text{frontal}})}{\text{Feature}(X_{\text{posterior}})}. \quad (32)$$

3 不同脑电特征对于情绪识别结果的影响

为了测试特征对情绪识别结果的贡献, 本文选择 3 个脑电数据库 SEED, DREAMER 和 CAS-THU, 计算各类特征值, 将稀疏线性判别分析 (sparse linear discriminant analysis, SLDA)^[72] 选择特征的权重作为评价标准.

需要说明的是, 频域与时频域本质都是将时域信号变换至频域, 且二者计算的特征类型 (如 PSD, 微分熵等) 相同; 但时频域按时间段划分信号, 含有更丰富的特征信息, 也更常用于情绪识别领域. 因而本实验对 EEG 加时间窗以提取时频域特征, 不计算整个信号的频域特征.

3.1 数据库介绍

3.1.1 SEED

SEED 数据库^[46,69]由上海交通大学发布, 用时长 4 min 左右的华语电影片段诱发正性、中性和负性效价的 3 种情绪. 使用 62 导的 ESI NeuroScan 系统采集 15 名被试 (7 名男性, 8 名女性, 年龄平均值为 23.27, 标准差为 2.37) 的脑电数据, 采样率为 1000 Hz. 每名被试在不同时间做 3 次实验, 每次观看 15 段电影片段, 即共 45 个试次. 对 EEG 信号的预处理包括: 信号下采样至 200 Hz, 去除眼电和肌电噪声, 并使用 0.3 ~ 50 Hz 的带通滤波器. 计算时频域特征时, 使用长度为 1 s 互不重叠的 hanning 窗进行短时傅里叶变换, 并划分 5 个频段 δ (1~3 Hz), θ (4~7 Hz), α (8~13 Hz), β (14~30 Hz), γ (31~50 Hz).

3.1.2 DREAMER

DREAMER 数据库^[73]由 University of the West of Scotland 发布, 提供被试对影片在效价、唤醒度和控制度上的评分, 并据此得到相应情绪的正负性或唤醒度、控制度的高低. 影片共 18 段, 长度在 65 ~ 393 s 之间^[73,74]. 实验使用 14 导的 Emotiv EPOC 系统, 采集 23 名被试 (14 名男性, 9 名女性, 年龄平均值为 26.6, 标准差为 2.7) 观看电影时的脑电和心电数据, 采样率为 128 Hz. 截取每段信号最后的 60 s, 并用 MATLAB 环境下的 EEGLAB 工具包^[75]做预处理. 用长度为 2 s、相邻窗重叠 1 s 的时间窗进行短时傅里叶变换, 并将信号分为 θ (4~7 Hz), α (8~13 Hz), β (14~30 Hz) 3 个频段.

3.1.3 CAS-THU

CAS-THU 数据库^[76]由中国科学院心理研究所与清华大学共同提出, 使用 16 段华语影片诱发 8 种离散情绪, 包括搞笑、高兴和温馨 3 种正性情绪, 厌恶、恐惧、愤怒和悲伤 4 种负性情绪以及中性状态. 使用 14 导 Emotiv EPOC 系统采集 30 名男性被试 (年龄平均值为 23, 标准差为 1.73) 的脑电数据. 预处理时先通过 1 ~ 45 Hz 的带通滤波器, 再用独立成分分析 (independent component analysis,

ICA) 和 MATLAB 环境下的 EEGLAB 工具包^[75] 除去眼电干扰. 与 DREAMER 相同, 采用长度 2 s 且相邻重叠 1 s 的时间窗做 STFT, 将信号划分为 5 个频段: δ (1~4 Hz), θ (4~8 Hz), α (8~12 Hz), β (13~30 Hz), γ (31~45 Hz)^[76].

综上可知, 3 个数据库都包含情绪的效价信息, 其中 SEED 和 CAS-THU 包含正性、中性和负性 3 类效价, DREAMER 只包含正性和负性两类效价, 所以本实验只衡量各特征在判断效价上的作用.

3.2 特征提取

由于 ERP, ERS 和 ERD 3 项事件相关的特征需要离散材料作为诱发, 而本实验数据库均用视频持续诱发情绪, 更符合实际应用场景. 因此在本文的实验中, 不提取这 3 个特征. 另外, CSP 适用于二分类任务, 因此只对 DREAMER 数据库计算 CSP 特征. 综上, 本文实验在 3 个数据库上共同计算的特征包括:

- (1) 时域. 平均值、标准差、一阶差分、归一化的一阶差分、二阶差分、归一化的二阶差分、Hjorth 特征 (activity, mobility, complexity)、能量、功率、高阶过零分析、不稳定指数、Higuchi 分形维数.
- (2) 时频域. 功率谱密度、高阶谱、微分熵.
- (3) 空间域. DASM、RASM、不对称系数、DCAU、多维度有向信息.

对于每个数据库, 按照其描述添加相应时间窗应用 STFT. 需要注意的是, 在计算高阶谱 HOS 特征时, 我们使用 MATLAB 上的 HOSA 工具包^[77]; 在提取电极组合特征时, 使用广泛用于情绪识别领域的 PSD 特征.

表 1 列出了 3 个数据集上各类特征的维数, 需要强调的是, 每类特征会有多列, 即“一类”特征可能包含“多维”特征值.

3.3 计算特征重要程度

令 $n \times p$ 的矩阵 X 表示提取的 EEG 特征, n 表示样本数, 每一行样本都属于一类效价. 属于第 j 类的样本下标为 C_j , 数量为 n_j ; p 为特征维数, 即表 1 最后一行的“总计”维数, 例如 $p_{SEED} = 2423$. 线性判别分析 (linear discriminant analysis, LDA) 从 Fisher 线性判别法的角度寻找判别向量, 使类间方差相对类内方差最大化, 即

$$\max_{w_l} \{w_l^T \Sigma_b w_l\} \quad (33)$$

满足 $w_l^T \Sigma_w w_l = 1$. 其中 $\Sigma_b = \sum_{j=1}^k n_j \mu_j \mu_j^T$ 是类间协方差矩阵, $\Sigma_w = \frac{1}{n} \sum_{j=1}^k n_j \sum_{i \in C_j} (x_i - \mu_j)(x_i - \mu_j)^T$ 是类内协方差矩阵, $\mu_j = \frac{1}{\#C_j} \sum_{i \in C_j} x_i$ 是第 j 类的均值向量, $\#C_j$ 是第 j 类的样本总数.

但是, 当所选特征的数量大于观测数量时, 特征的类内协方差矩阵会变得单一. 可应用稀疏的 LDA (sparse LDA, SLDA)^[72], 添加 l_1 罚项对判别向量施加稀疏约束, 以解决这个问题.

$$\max_{w_l} \{w_l^T \Sigma_b w_l - \lambda \|w_l\|_1\}, \quad (34)$$

其中, $w_l^T (\Sigma_w + \Omega) w_l = 1$, Ω 是一个正定矩阵. 该问题至多有 $k - 1$ 个非平凡解, 故至多有 $k - 1$ 个判别向量^[72], 其正交方向最优地划分了 k 类样本. 由此, 原有的 p 维特征下降至 $k - 1$ 维, 每个判别向量 w_i 反映对应特征对分类的影响. 令 $W = \sum_{i=1}^{k-1} |w_i|$, 则 W 为特征的权重.

在本实验中, 我们用 MATLAB 上的 SpaSM 工具包^[78] 实现 SLDA 算法, 使用默认参数以保证算法在不同数据库上的统一性. 采用准确率较高的被试留一法划分数据, 即, 若数据集中包括 s 名被试, 将其划分为 s 个子集, 各子集包含一个被试的全部样本^[79]. 每次取其中的 $s - 1$ 个子集的数据送入

表 1 各类特征在 SEED, DREAMER, CAS-THU 3 个数据库上的维数

Table 1 Feature dimensions on SEED, DREAMER and CAS-THU

Domain	Feature	SEED	DREAMER	CAS-THU
Time	Mean	62	14	14
	Standard deviation	62	14	14
	1-order difference	62	14	14
	Normalized 1-order difference	62	14	14
	2-order difference	62	14	14
	Normalized 2-order difference	62	14	14
	Hjorth-activity	62	14	14
	Hjorth-mobility	62	14	14
	Hjorth-complexity	62	14	14
	Energy	62	14	14
Time-frequency	Power	62	14	14
	HOC	310	70	70
	NSI	62	14	14
Space	FD	62	14	14
	PSD	310	42	70
	HOS	248	56	56
Space	DE	310	42	70
	DASM	135	21	35
	RASM	135	21	35
	Index	27	7	7
	DCAU	115	6	10
	MDI	27	7	7
	CSP	—	9	—
	Total	2423	463	542

SLDA 算法, 计算权重 W_i ; 在 s 次上取权重均值并排序, 再计算每一类特征的“重要程度”, “重要程度”定义如下.

定义1 (重要程度) 若某特征共有 p_i 维, 其中有 m_i 维排在所有维度的前 $x\%$, 则该特征的重要程度值为

$$d_x = \frac{m_i}{p_i}. \quad (35)$$

例如, 由表 1 可知, $p_{\text{SEED}} = 2423$, 其中 310 列是功率谱密度 (PSD), 令 $x = 10$, 则关注权重排在前 $2423 \times 10\% \approx 242$ 位的特征, 若 242 列中有 100 列来自 PSD, 则 PSD 特征的重要程度值 $d_{10} = \frac{100}{310} \approx 0.32$. x 值越小, 越可以反映特征的重要程度.

3.4 结果分析和讨论

将各类特征按照 $x = 10, 30, 50$ 分别计算重要程度并排序; 统计在 2 个或全部 3 个数据库上都排在前 10 位的特征. 需要注意的是, CSP 为 DREAMER 数据集独有的特征, 故不参与排名. 最终结果如表 2 所示. 可看出时域特征中的一阶差分、二阶差分、Hjorth 特征, 以及不稳定指数的重要程度最高,

表 2 x 分别取 10, 30, 50 时, 重要程度值在 SEED, DREAMER, CAS-THU 中的 2 个或 3 个库上都排在前 10 位的特征类别

Table 2 Features whose importance values are of top 10 on 2 or 3 datasets of SEED, DREAMER and CAS-THU when $x=10, 30$ or 50

x	Domain	2 datasets	3 datasets
10	Time	Normalized 1-order difference	1-order difference
		Normalized 2-order difference	2-order difference
		Hjorth-activity	Hjorth-complexity
	Space	NSI	Hjorth-mobility
		FD	—
		DASM	—
30	Time	RASM	—
		Normalized 1-order difference	1-order difference
		Normalized 2-order difference	2-order difference
	Space	Hjorth-mobility	Hjorth-complexity
		HOC	NSI
		FD	—
50	Time	DASM	—
		Normalized 1-order difference	—
		Normalized 2-order difference	1-order difference
	Space	Hjorth-complexity	2-order difference
		Hjorth-mobility	NSI
		FD	—
Time-frequency		DE	—

其次是归一化的一阶差分、归一化的二阶差分, 以及分形维数; 频域中的微分熵, 空间域中的 DASM 和 RASM 也有较好的表现. 时域特征对效价的分辨能力强于时频域和空间域.

对于 CSP 特征, 当 x 取 10 时, 其重要程度排在 DREAMER 所有 23 类特征中的第 16 位; 当 x 取 30 时, 排在第 5 位; x 取 50 时排在第 2 位. 说明 CSP 在该数据库上可以较好地表征效价, 但表征能力并不突出.

根据以上结果可知, 时域特征对情绪效价的分辨能力最强, 因而在后续相关研究中, 研究者可考虑加入时域特征来优化情绪识别效果. 此外在所有时域特征中, 统计特征的重要程度高, 原因之一在于, 不同数据库中同效价的影片唤醒度可能有异. 例如诱发正性情绪的两部影片, 其产生正性情绪的强烈程度可能不同, 即此处效价的分类会受到唤醒度的影响.

4 对未来工作的展望

本节将从实际应用和理论研究两个方面, 提出面向情绪识别的脑电特征进一步研究的可行思路.

4.1 实际应用

需要建立包括脑电信号数据和情绪诱发材料的情绪标准化库, 作为后续情绪理论研究的基础. 该库应满足以下要求:

(1) **采用视听刺激的方式诱发情绪.** 相比于单一的视觉或听觉刺激, 视听刺激结合的方式更贴近实际生活, 内容和情节也更丰富, 例如电影片段、音乐视频等, 这种方式下产生的脑电信号具有良好的动态性、不可欺骗性和高生态效度^[80].

(2) **适用于中国社会和文化背景.** 由于文化背景的差异, 现有国外标准库难以直接用于我国被试, 因此建立针对我国人群的标准库具有极大的应用价值.

(3) **涵盖更多的正性情绪类别及样本数.** 近年来有关情绪的最新行为学研究认为, 积极情绪至少可以分为 10 种代表性类型^[81], 包括高兴、感恩、宁静、兴趣、希望、自豪、搞笑、激励、敬畏、爱. 在实践应用或社会需求的角度, 积极情绪比消极情绪更重要. 积极情绪有助于扩大注意、认知及行为的范围, 促进身体、智力与社交能力的健康发展. 但已有情绪库中的正性情绪种类较少, 正负情绪材料和样本数量不平衡, 不利于情绪模型建立和应用, 因此脑电信号数据库应涵盖更多的正性情绪种类及样本数.

(4) **尽量排除刺激材料本身对被试的影响.** 应尽量排除刺激材料本身内容(如画面的明暗、声音的强弱等)产生的影响, 让采集的 EEG 信号直接反映情绪对被试的影响.

4.2 理论研究

(1) **从多学科交叉角度分析脑电特征与情绪识别结果的关系.** 基于 EEG 信号的情绪识别是多学科交叉的研究问题. 而现有的情绪识别研究中, 特征计算方法多来自电信号处理领域, 对特征的讨论主要停留在实验准确率的层面, 鲜有特征与情绪本身联系的探讨. 如果从生理、心理和神经科学的理论层面分析特征与情绪的关系, 将有助于理解情绪产生的机制, 进而设计出与情绪最相关的脑电特征, 优化识别效果.

(2) **多人脑功能影像数据联合分析方法.** 通过联合分析多名被试在特定任务状态下大脑活动之间的关系, 研究被试在完成任务时的认知过程, 可提取绝对强度不大, 但持续时间较长、个体间一致性较好的“微弱”神经响应. 这一方法可能分析出在传统事件相关分析中被低估的神经响应, 有利于提取更深层次的情绪响应特性.

(3) **深度学习方法.** 近年来兴起的深度学习(deep learning)方法采用分层结构, 先将原空间的特征表示转换到新的空间, 再进行后续分类. 与人工构造的特征相比, 利用海量数据学习到的特征更能反映数据的内在本质^[82], 克服特征冗余问题, 提高情绪识别的智能和普适性.

5 总结

情绪识别是人机交互中的重要组成部分, 在医学、教育和军事等方面都具有切实的研究需要和广阔的应用前景, 脑电信号是目前情绪识别领域中识别效果较好的生理指标. 从信号中提取与情绪关联度高、区分度大的特征有助于达到较高的情绪识别准确率.

本文围绕面向情绪识别的脑电特征, 从时域、频域、时频域和空间域 4 个方面介绍了特征的定义、计算方法和与情绪的联系, 在总结已有工作的基础上, 在 SEED, DREAMER 和 CAS-THU 3 个公开的脑电 – 情绪数据集上, 对各类特征的效价区分能力进行评估和比较, 并展望未来可行的研究方向, 为开展进一步研究提供思路.

参考文献

- 1 Huang X T. Introduction to Psychology. Beijing: Peoples Education Press, 1991 [黄希庭. 心理学导论. 北京: 人民教育出版社, 1991]
- 2 van den Broek E L. Ubiquitous emotion-aware computing. *Pers Ubiquit Comput*, 2013, 17: 53–67
- 3 Posner J, Russell J A, Peterson B S. The circumplex model of affect: an integrative approach to affective neuroscience, cognitive development, and psychopathology. *Develop Psychopathol*, 2005, 17: 715–734
- 4 Lang P J. The emotion probe: studies of motivation and attention. *Am Psychol*, 1995, 50: 372–385
- 5 Zhao G Z, Song J J, Ge Y, et al. Advances in emotion recognition based on physiological big data. *J Comput Res Dev*, 2016, 53: 80–92 [赵国朕, 宋金晶, 葛燕, 等. 基于生理大数据的情绪识别研究进展. 计算机研究与发展, 2016, 53: 80–92]
- 6 Alarcao S M, Fonseca M J. Emotions recognition using EEG signals: a survey. *IEEE Trans Affect Comput*, 2017. doi: 10.1109/TAFFC.2017.2714671
- 7 Chanel G, Kierkels J J M, Soleymani M, et al. Short-term emotion assessment in a recall paradigm. *Int J Human–Comput Stud*, 2009, 67: 607–627
- 8 Hruby T, Marsalek P. Event-related potentials—the P3 wave. *Acta Neurobiol Exp*, 2002, 63: 55–63
- 9 Luck S J, Kappenman E S. The Oxford Handbook of Event-Related Potential Components. Oxford: Oxford University Press, 2011
- 10 Lithari C, Frantzidis C A, Papadelis C, et al. Are females more responsive to emotional stimuli? A neurophysiological study across arousal and valence dimensions. *Brain Topogr*, 2010, 23: 27–40
- 11 Yazdani A, Lee J S, Ebrahimi T. Implicit emotional tagging of multimedia using EEG signals and brain computer interface. In: Proceedings of the 1st SIGMM Workshop on Social Media, Beijing, 2009. 81–88
- 12 Codispoti M, Ferrari V, Bradley M M. Repetition and event-related potentials: distinguishing early and late processes in affective picture perception. *J Cogn Neurosci*, 2007, 19: 577–586
- 13 Olofsson J K, Nordin S, Sequeira H, et al. Affective picture processing: an integrative review of ERP findings. *Biol Psychol*, 2008, 77: 247–265
- 14 Olofsson J K, Polich J. Affective visual event-related potentials: arousal, repetition, and time-on-task. *Biol Psychol*, 2007, 75: 101–108
- 15 Gianotti L R R, Faber P L, Schuler M, et al. First valence, then arousal: the temporal dynamics of brain electric activity evoked by emotional stimuli. *Brain Topogr*, 2008, 20: 143–156
- 16 Jiang J F, Zeng Y, Tong L, et al. Single-trial ERP detecting for emotion recognition. In: Proceedings of the 17th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD), Shanghai, 2016. 105–108
- 17 Smith N K, Cacioppo J T, Larsen J T, et al. May I have your attention, please: electrocortical responses to positive and negative stimuli. *Neuropsychologia*, 2003, 41: 171–183
- 18 Kim M K, Kim M, Oh E, et al. A review on the computational methods for emotional state estimation from the human EEG. *Comput Math Method Med*, 2013, 2013: 13
- 19 Bernat E, Bunce S, Shevrin H. Event-related brain potentials differentiate positive and negative mood adjectives during both supraliminal and subliminal visual processing. *Int J Psychophysiol*, 2001, 42: 11–34
- 20 Cuthbert B N, Schupp H T, Bradley M M, et al. Brain potentials in affective picture processing: covariation with autonomic arousal and affective report. *Biol Psychol*, 2000, 52: 95–111
- 21 Nieuwenhuis S, Aston-Jones G, Cohen J D. Decision making, the P3, and the locus coeruleus-norepinephrine system. *Psychol Bull*, 2005, 131: 510–532
- 22 Jenke R, Peer A, Buss M. Feature extraction and selection for emotion recognition from EEG. *IEEE Trans Affect Comput*, 2014, 5: 327–339
- 23 Wang X W, Nie D, Lu B L. EEG-based emotion recognition using frequency domain features and support vector machines. In: Proceedings of International Conference on Neural Information Processing, Berlin, 2011. 734–743
- 24 Bastos-Filho T F, Ferreira A, Atencio A C, et al. Evaluation of feature extraction techniques in emotional state recognition. In: Proceedings of the 4th International Conference on Intelligent Human Computer Interaction (IHCI), Kharagpur, 2012
- 25 Picard R W, Vyzas E, Healey J. Toward machine emotional intelligence: analysis of affective physiological state. *IEEE*

- Trans Pattern Anal Mach Intell, 2001, 23: 1175–1191
- 26 Kroupi E, Yazdani A, Ebrahimi T. EEG correlates of different emotional states elicited during watching music videos. In: Proceedings of Affective Computing and Intelligent Interaction, Berlin, 2011. 457–466
- 27 Fan C X, Cao L N. Communication Principle. Beijing: National Defense Industrial Press, 2001 [樊昌信, 曹丽娜. 通信原理. 北京: 国防工业出版社, 2001]
- 28 Hjorth B. EEG analysis based on time domain properties. Electroenceph Clin Neurophysiol, 1970, 29: 306–310
- 29 Petrantonakis P C, Hadjileontiadis L J. Emotion recognition from EEG using higher order crossings. IEEE Trans Inform Technol Biomed, 2010, 14: 186–197
- 30 Hausdorff J M, Lertratanakul A, Cudkowicz M E, et al. Dynamic markers of altered gait rhythm in amyotrophic lateral sclerosis. J Appl Physiol, 2000, 88: 2045–2053
- 31 Ansari-Asl K, Chanel G, Pun T. A channel selection method for EEG classification in emotion assessment based on synchronization likelihood. In: Proceedings of the 15th European Signal Processing Conference, Poznan, 2007. 1241–1245
- 32 Khosrowabadi R, bin Abdul Rahman A W. Classification of EEG correlates on emotion using features from Gaussian mixtures of EEG spectrogram. In: Proceeding of the 3rd International Conference on Information and Communication Technology for the Moslem World (ICT4M), Jakarta, 2010. 102–107
- 33 Sourina O, Liu Y S. A fractal-based algorithm of emotion recognition from EEG using arousal-valence model. In: Proceedings of the International Conference on Bio-inspired Systems and Signal Processing (BIOSIGNALS-2011), Rome, 2011. 209–214
- 34 Liu Y, Sourina O. Real-time fractal-based valence level recognition from EEG. In: Proceedings of Transactions on Computational Science XVIII, Berlin, 2013. 101–120
- 35 Conneau A C, Essid S. Assessment of new spectral features for eeg-based emotion recognition. In: Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Florence, 2014. 4698–4702
- 36 Nie D, Wang X W, Duan R N, et al. A survey on EEG based emotion recognition. Chinese J Biomed Eng, 2012, 31: 595–606 [聂聃, 王晓輝, 段若男, 等. 基于脑电的情绪识别研究综述. 中国生物医学工程学报, 2012, 31: 595–606]
- 37 Zheng J L, Ying Q H, Yang W L. Signal and System. 2nd ed. Beijing: Higher Education Press, 2000 [郑君里, 应启珩, 杨为理. 信号与系统 (第二版). 北京: 高等教育出版社, 2000]
- 38 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
- 39 Davidson R J. What does the prefrontal cortex “do” in affect: perspectives on frontal EEG asymmetry research. Biol Psychology, 2004, 67: 219–234
- 40 Yuvaraj R, Murugappan M, Ibrahim N M, et al. Optimal set of EEG features for emotional state classification and trajectory visualization in Parkinson’s disease. Int J Psychophysiol, 2014, 94: 482–495
- 41 Aftanas L I, Varlamov A A, Pavlov S V, et al. Affective picture processing: event-related synchronization within individually defined human theta band is modulated by valence dimension. Neurosci Lett, 2001, 303: 115–118
- 42 Yuvaraj R, Murugappan M, Ibrahim N M, et al. Emotion classification in Parkinson’s disease by higher-order spectra and power spectrum features using EEG signals: a comparative study. J Integr Neurosci, 2014, 13: 89–120
- 43 Keil A, Müller M M, Gruber T, et al. Effects of emotional arousal in the cerebral hemispheres: a study of oscillatory brain activity and event-related potentials. Clin Neurophysiol, 2001, 112: 2057–2068
- 44 Bos D O. EEG-based emotion recognition—the influence of visual and auditory stimuli. Emotion, 2007, 57: 1798–1806
- 45 Balconi M, Lucchiari C. Consciousness and arousal effects on emotional face processing as revealed by brain oscillations. A gamma band analysis. Int J Psychophysiol, 2008, 67: 41–46
- 46 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
- 47 Bekkedal M Y V, Rossi III J, Panksepp J. Human brain EEG indices of emotions: delineating responses to affective vocalizations by measuring frontal theta event-related synchronization. Neurosci Biobehav Rev, 2011, 35: 1959–1970
- 48 Graimann B, Pfurtscheller G. Quantification and visualization of event-related changes in oscillatory brain activity in the time-frequency domain. Progress Brain Res, 2006, 159: 79–97
- 49 Balconi M, Lucchiari C. EEG correlates (event-related desynchronization) of emotional face elaboration: a temporal

- analysis. *Neurosci Lett*, 2006, 392: 118–123
- 50 Duan R N, Zhu J Y, Lu B L. Differential entropy feature for EEG-based emotion classification. In: Proceedings of the 6th International IEEE/EMBS Conference on Neural Engineering (NER), San Diego, 2013. 81–84
- 51 Shi L C, Jiao Y Y, Lu B L. Differential entropy feature for EEG-based vigilance estimation. In: Proceedings of the 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Osaka, 2013. 6627–6630
- 52 Behnam H, Sheikhani A, Mohammadi M R, et al. Analyses of EEG background activity in Autism disorders with fast Fourier transform and short time Fourier measure. In: Proceedings of International Conference on Intelligent and Advanced Systems, Kuala Lumpur, 2007. 1240–1244
- 53 Kiymik M K, Güler İ, Dizibüyük A, et al. Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for real-time application. *Comput Biol Med*, 2005, 35: 603–616
- 54 Yoon H J, Chung S Y. EEG-based emotion estimation using Bayesian weighted-log-posterior function and perceptron convergence algorithm. *Comput Biol Med*, 2013, 43: 2230–2237
- 55 Rozgić V, Vitaladevuni S N, Prasad R. Robust EEG emotion classification using segment level decision fusion. In: Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing, Vancouver, 2013. 1286–1290
- 56 Akin M. Comparison of wavelet transform and FFT methods in the analysis of EEG signals. *J Med Syst*, 2002, 26: 241–247
- 57 Adeli H, Zhou Z, Dadmehr N. Analysis of EEG records in an epileptic patient using wavelet transform. *J Neurosci Method*, 2003, 123: 69–87
- 58 Sun Z, Chang C C. Structural damage assessment based on wavelet packet transform. *J Struct Eng*, 2002, 128: 1354–1361
- 59 Hadjidimitriou S K, Hadjileontiadis L J. Toward an EEG-based recognition of music liking using time-frequency analysis. *IEEE Trans Biomed Eng*, 2012, 59: 3498–3510
- 60 Davidson R J, Ekman P, Saron C D, et al. Approach-withdrawal and cerebral asymmetry: emotional expression and brain physiology: I. *J Personality Soc Psychol*, 1990, 58: 330–341
- 61 Huang D, Guan C, Ang K K, et al. Asymmetric spatial pattern for EEG-based emotion detection. In: Proceedings of International Joint Conference on Neural Networks (IJCNN), Brisbane, 2012
- 62 Takahashi K. Remarks on emotion recognition from bio-potential signals. In: Proceedings of IEEE International Conference on Industrial Technology (IEEE ICIT'04), Hammamet, 2004. 1148–1153
- 63 Davidson R, Fox N. Asymmetrical brain activity discriminates between positive and negative affective stimuli in human infants. *Science*, 1982, 218: 1235–1237
- 64 Blankertz B, Tomioka R, Lemm S, et al. Optimizing spatial filters for robust EEG single-trial analysis. *IEEE Signal Process Mag*, 2008, 25: 41–56
- 65 Koelstra S, Yazdani A, Soleymani M, et al. Single trial classification of EEG and peripheral physiological signals for recognition of emotions induced by music videos. In: Proceedings of International Conference on Brain Informatics, Berlin, 2010. 89–100
- 66 Winkler I, Jäger M, Mihajlovic V, et al. Frontal EEG asymmetry based classification of emotional valence using common spatial patterns. *World Acad Sci Eng Technol*, 2010, 45: 373–378
- 67 Novi Q, Guan C, Dat T H, et al. Sub-band common spatial pattern (SBCSP) for brain-computer interface. In: Proceedings of the 3rd International IEEE/EMBS Conference on Neural Engineering, Kohala Coast, 2007. 204–207
- 68 Ang K K, Chin Z Y, Zhang H, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface. In: Proceedings of IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), Hong Kong, 2008. 2390–2397
- 69 Duan R N, Wang X W, Lu B L. EEG-based emotion recognition in listening music by using support vector machine and linear dynamic system. In: Proceedings of International Conference on Neural Information Processing, Berlin, 2012. 468–475
- 70 Sakata O, Shiina T, Saito Y. Multidimensional directed information and its application. *Electron Commun Jpn*, 2002, 85: 45–55
- 71 Petrantonakis P C, Hadjileontiadis L J. A novel emotion elicitation index using frontal brain asymmetry for enhanced

- EEG-based emotion recognition. *IEEE Trans Inform Technol Biomed*, 2011, 15: 737–746
- 72 Clemmensen L, Hastie T, Witten D, et al. Sparse discriminant analysis. *Technometrics*, 2011, 53: 406–413
- 73 Katsigiannis S, Ramzan N. DREAMER: a database for emotion recognition through EEG and ECG signals from wireless low-cost off-the-shelf devices. *IEEE J Biomed Health Inform*, 2018, 22: 98–107
- 74 Song T F, Zheng W M, Song P, et al. EEG emotion recognition using dynamical graph convolutional neural networks. *IEEE Trans Affect Comput*, 2018. doi: 10.1109/TAFFC.2018.2817622
- 75 Delorme A, Makeig S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *J Neurosci Methods*, 2004, 134: 9–21
- 76 Liu Y J, Yu M, Zhao G, et al. Real-time movie-induced discrete emotion recognition from EEG signals. *IEEE Trans Affect Comput*, 2018, 9: 550–562
- 77 Swami A, Mendel C, Nikias C. Higher-order spectral analysis (HOSA) toolbox. Version, 2000, 2: 3
- 78 Sjöstrand K, Clemmensen L H, Larsen R, et al. SpaSM: a matlab toolbox for sparse statistical modeling. *J Stat Soft*, 2018, 84: 37
- 79 Zhou Z H. Machine Learning. Beijing: Tsinghua University Press, 2016 [周志华. 机器学习. 北京: 清华大学出版社, 2016]
- 80 Gross J J, Levenson R W. Emotion elicitation using films. *Cogn Emotion*, 1995, 9: 87–108
- 81 Fredrickson B L. Positive emotions and upward spirals in organizations. *Positive Organ Scholarsh*, 2003, 3: 163–175
- 82 Yu C, Sun K, Zhong M Y, et al. One-dimensional handwriting: inputting letters and words on smart glasses. In: Proceedings of CHI Conference on Human Factors in Computing Systems (CHI'16), San Jose, 2016. 71–82

A review of EEG features for emotion recognition

Guanhua ZHANG¹, Minjing YU^{1*}, Guo CHEN¹, Yiheng HAN¹, Dan ZHANG²,
Guozhen ZHAO³ & Yong-Jin LIU^{1*}

1. Department of Computer Science and Technology, Tsinghua University, Beijing 100084, China;
2. Department of Psychology, School of Social Sciences, Tsinghua University, Beijing 100084, China;
3. Institute of Psychology, Chinese Academy of Sciences, Beijing 100101, China

* Corresponding author. E-mail: yumj14@mails.tsinghua.edu.cn, liuyongjin@tsinghua.edu.cn

Abstract Emotion recognition is an important research topic in human-machine interaction field, which can be applied to medicine, education, psychology, military and other areas. EEG (electroencephalogram) signal is mostly used among various indices of emotion recognition. Higher accuracy of emotion classifiers benefits from extracting the most relevant and discriminant features of emotion states. The paper surveys EEG features that are widely used in current emotion recognition study, introducing EEG features from four viewpoints, i.e., time domain, frequency domain, time-frequency domain and space domain. SLDA algorithm is imported to three public EEG-emotion datasets-SEED, DREAMER and CAS-THU-in order to evaluate feature capabilities distinguishing emotion valence. Existing problems and future investigations are also discussed in this paper.

Keywords emotion recognition, electroencephalograms, feature extraction, feature selection, valence



Guanhua ZHANG was born in 1996. She is currently a master student in Department of Computer Science and Technology, Tsinghua University, Beijing, China. She received her B.Eng. degree from Beijing University of Posts and Telecommunications, Beijing, China, in 2017. Her research interests include cognitive computing and human-computer interaction.



Dan ZHANG was born in 1983. He received a B.E. degree in automation in 2005 and a Ph.D. degree in biomedical engineering in 2011, both from Tsinghua University. He was a postdoctoral fellow in School of Medicine, Tsinghua University from 2011 to 2013. Currently, he is an associate professor at Department of Psychology, Tsinghua University, Beijing, China. His research interests include social neuroscience, engineering psychology, and brain-computer interfaces.



Guozhen ZHAO was born in 1984. He received the B.S. degree in industrial engineering, from Tianjin University, China, in 2007, and the M.S. and Ph.D. degrees in industrial and systems engineering from the State University of New York, Buffalo, in 2009 and 2011, respectively. He is an associate professor in Institute of Psychology, Chinese Academy of Sciences. His current research interest is the mathematical modeling of human cognition and performance, transportation safety, human computer interaction, emotion recognition, and augmented cognition.



Yong-Jin LIU was born in 1977. He received his B.Eng. degree from Tianjin University, China, in 1998, and Ph.D. degree from Hong Kong University of Science and Technology, Hong Kong, China, in 2004. He is now a professor with Department of Computer Science and Technology, the MOE-Key Laboratory of Pervasive Computing, Tsinghua University, China. His research interests include computational geometry, cognitive computing, pattern analysis and computer vision.