

引用格式:韩永明,张明星,耿志强.基于心率变异性特征和PCA-SVR的PAD维度情感预测分析[J].北京化工大学学报(自然科学版),2021,48(5):102-110.

HAN YongMing, ZHANG MingXing, GENG ZhiQiang. Heart rate variability features for emotion dimensional prediction by using a principal component analysis-support vector regression (PCA-SVR) model[J]. Journal of Beijing University of Chemical Technology (Natural Science), 2021,48(5):102-110.

基于心率变异性特征和PCA-SVR的PAD维度情感预测分析

韩永明^{1,2} 张明星^{1,2} 耿志强^{1,2*}

(北京化工大学 1. 信息科学与技术学院;2. 智能过程系统工程教育部工程研究中心, 北京 100029)

摘要:对于PAD(pleasure:愉悦度;arousal:唤醒度;dominance:优势度)维度情感预测和分析中的数值预测问题,结合心率变异性(heart rate variability,HRV)特点,提出了基于主成分分析(principal component analysis,PCA)和支持向量回归(support vector regression,SVR)的PAD维度情感预测模型(PCA-SVR)。通过柔性离子传感器以音乐和视频的诱导方式采集了12名志愿者在放松和焦虑两种情感状态下的心率和心率间期数据,利用PAD量表进行标注,通过均值和方差计算等统计方法、Welch功率谱、Poincaré散点图等分别提取HRV的时域、频域和非线性特征,然后利用PCA模型对HRV特征降维,最后利用降维后的HRV特征作为SVR模型的输入特征进行训练和预测。实验结果表明,结合HRV特征的PCA-SVR模型在PAD的3个维度上均有良好的预测效果,其平均一致性相关系数达到了0.51。同时对比了SVR、极限学习机(extreme learning machine,ELM)和基于PCA的ELM这3种预测方法,结果显示所提方法相对于以上3种方法在一致性相关系数上分别提升了0.14、0.10和0.04,表明该方法能够细致地划分情感,结合可穿戴设备,在情感识别和分析方面有一定补充作用,为在日常生活中针对情感的识别和预测带来了可能。

关键词: PAD维度情感; 心率变异性; 主成分分析; 支持向量回归

中图分类号: TP39 **DOI:** 10.13543/j.bhxbzr.2021.05.013

引言

情感计算是指由情感引发的、和情感有关的或者对情感有影响或起决定作用的计算^[1]。情感计算是人机交互中一个重要的研究方向,常用的情感计算中的输入信号有图像、音频、文本和生理信号^[2],而相对于图像等输入信号,生理信号有着不易掩饰的特点,更能反映出真实的情感状态,因此在临床诊断和治疗上有着不可替代的优势和重要作用^[2]。在基于生理信号的情感计算领域,应用最多的生理信号是脑电图,其次是心电图和心率变异性(heart rate variability,HRV)等数据^[2],其中HRV相对于脑电图在日常生活中更容易获取,又比心电图更直观,能够使得情感的日常检测更加简便。HRV是指连续心率间期的变化情况,能够反映心脏自主神经系统对心血管的调节,可以作为测量和调节情感反应的手段^[3]。

目前,基于生理信号的情感计算模型有两种^[4],一种是离散情感模型,另一种是维度情感模型。离散情感模型将情感分成几类,例如喜悦、愤怒、悲伤等^[5]。离散情感模型目前在情感识别领域中已得到广泛的应用。He等^[6]采集了11名志愿者的脑电图和呼吸信号,利用支持向量机对4种情感进行了识别,针对4种情感的识别准确率分别达到

用^[2]。在基于生理信号的情感计算领域,应用最多的生理信号是脑电图,其次是心电图和心率变异性(heart rate variability,HRV)等数据^[2],其中HRV相对于脑电图在日常生活中更容易获取,又比心电图更直观,能够使得情感的日常检测更加简便。HRV是指连续心率间期的变化情况,能够反映心脏自主神经系统对心血管的调节,可以作为测量和调节情感反应的手段^[3]。

收稿日期:2021-03-15

基金项目:中央高校基本科研业务费(XK1802-4);贵州科技计划项目重大专项(Guizhou Branch [2018]3002)

第一作者:男,1987年生,教授

*通信联系人

E-mail: gengzhiqiang@mail.buct.edu.cn

了 81.82%、63.64%、54.55% 和 30.00%。Guo 等^[7]利用 HRV 信号对积极和消极两种情感状态进行了识别,准确率分别达到了 71.4% 和 56.9%。Cai 等^[8]利用脑电图对抑郁和非抑郁两种情感状态进行识别,准确率达到 86.98%。但情感的变化通常是连续的、渐变的,情感状态也是复杂的,而离散情感模型不足以描述真实的情感状态。维度情感模型是将情感状态映射到连续的空间中,将离散的情感状态看作是不同维度上的连续的组合,能够反映情感的强度,表现出复杂的多类情感的混合状态,弥补了离散情感模型的不足^[9]。PAD (pleasure: 愉悦度; arousal: 唤醒度; dominance: 优势度) 三维情感模型和效价-唤醒二维情感模型^[10]是常用的维度情感模型。近年来,维度情感模型在生理信号情感计算上的应用十分广泛。Song 等^[11]利用脑电信号对维度情感进行了识别,在愉悦度、唤醒度和优势度上的准确率分别达到了 86.23%、84.54% 和 85.02%。Samara 等^[12]利用脑电信号在效价和唤醒两个维度上对情感进行了识别,准确率分别达到 79.83% 和 60.43%。

在连续维度情感的预测上,Keren 等^[13]利用皮肤电活动和心电图对唤醒和效价两个维度进行了预测,其一致性相关系数分别达到了 0.430 和 0.407,平均值小于 0.5。Yu 等^[14]基于图像和心率对愉悦、唤醒和优势这 3 个维度情感进行预测,在 3 个维度上的一致性相关系数分别达到了 0.253 0、0.101 4 和 0.052 1,平均值小于 0.3。这些研究虽然考虑了维度情感的连续性问题,但预测精度仍然不足。随着人工智能的发展,神经网络和支持向量回归 (support vector regression, SVR) 常被用于回归预测中。神经网络训练的数据需求量大,因此对于小样本的生理信号,SVR 更具优势^[15]。因主成分分析 (principal component analysis, PCA) 能够减少输入向量的维数,降低计算的复杂性,本文以 PAD 三维情感模型为基础,从日常生活中易于获取的心率和心率间期中提取 HRV 特征,并利用 PCA 对 HRV 特征降维,最后经 SVR 模型训练预测 PAD 维度的数值。结果表明本文所提方法在 3 个维度上的平均一致性相关系数达到了 0.51,相比于 SVR、极限学习机 (extreme learning machine, ELM)、基于 PCA 和 ELM 的预测方法具有

更好的预测精度,且优于文献[14]、[15]中的方法。此外,本文提出的方法能够量化地反映情感状态,为情感状态提供了更为细致的划分,在心理治疗的跟踪方面具有优势,可简化心理疾病治疗中多次对患者症状进行评级的过程,以数值直观地反映出情感状态的程度,再结合传感器及可穿戴设备,便于情感的日常检测。

1 PAD 三维情感模型

PAD 三维情感模型是由 Mehrabian 和 Russell^[16]于 1974 年提出的维度情感理论,在 PAD 情感理论中,情感被分为 3 个维度,其中 P 表示愉悦度 (pleasure)、A 表示唤醒度 (arousal)、D 表示优势度 (dominance)。愉悦度表示个体情感的积极或消极状态,唤醒度表示个体生理神经的唤醒程度,优势度表示个体对于环境和他人的控制程度。PAD 三维情感模型如图 1 所示。




图 1 PAD 三维情感模型

Fig. 1 PAD three-dimensional model

在 PAD 情感模型中,情感坐标的评定是通过一套基于 PAD 模型设计的量表来完成的。Mehrabian^[17]编制了一个包括 34 个项目的完整量表,考虑到某些情况下需要参与者对情绪状态进行多次评价,于是进一步提出了简化的 PAD 情感量表,其中文版如表 1 所示。李晓明等^[18]对简化的 PAD 情感量表进行了中国化的修订,验证了中文简化版 PAD 量表的有效性。简化 PAD 情感量表共计 12 项,每项为一组词意对立的情感词汇,分值从 -4 到 4,可根据自身实际感受按照量表中所给词汇进行打分,例如第一项中数值如果为 -4 代表愤怒程度最高,

表 1 简化版 PAD 情感量表
Table 1 Abbreviated PAD emotion scale

-4	-3	-2	-1	0	1	2	3	4
愤怒的								感兴趣的
清醒的								困倦的
受控的								主控的
友好的								轻蔑的
平静的								兴奋的
支配的								顺从的
痛苦的								高兴的
关注的								放松的
被引导的								自主的
兴奋的								激怒的
拘谨的								惊讶的
有影响力的								被影响的

如果为 4 代表感兴趣程度最高。PAD 数值可通过 PAD 量表计算得到,具体公式为

$$\begin{cases} Value_P = (V_1 - V_4 + V_7 - V_{10})/4 \\ Value_A = (-V_2 + V_5 - V_8 + V_{11})/4 \\ Value_D = (V_3 - V_6 + V_9 - V_{12})/4 \end{cases} \quad (1)$$

式中, $V_1 \sim V_{12}$ 代表每行记录的数值。通过 PAD 数值标注,将离散的情感状态映射到连续的维度空间中,以维度情感的数值来表示情感状态,体现了情感的连续性^[19]。

2 基于 PCA-SVR 的预测模型

2.1 主成分分析

主成分分析即将一组具有一定相关性的特征集转换成一组互不相关的特征^[20],是一种常用的降维方法。

对于标准化处理样本 S ,其原始元素为 s_{ij} ,标准化后元素为 s_{ij}^* ,计算式为

$$s_{ij}^* = \frac{s_{ij} - \bar{s}_j}{\sqrt{\frac{1}{n-1} \sum_{i=1}^n (s_{ij} - \bar{s}_j)^2}}, i = 1, 2, \cdots, n; j = 1, 2, \cdots, m \quad (2)$$

式中, n 为样本个数, m 为影响因素个数。计算相关系数矩阵 R

$$R = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1m-1} & r_{1m} \\ r_{21} & r_{22} & \cdots & r_{2m-1} & r_{2m} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ r_{n1} & r_{n2} & \cdots & r_{nm-1} & r_{nm} \end{bmatrix} \quad (3)$$

式中, $r_{ij} = \text{Cov} \left(\sqrt{\frac{1}{n-1} \sum_{i=1}^n (s_{ij} - \bar{s}_j)^2}, \sqrt{\frac{1}{n-1} \sum_{i=1}^n (s_{ij} - \bar{s}_j)^2} \right)$,计算 R 的特征值 $\lambda = (\lambda_1, \lambda_2, \cdots, \lambda_m)$ 和特征向量 $a_i = (a_1, a_2, \cdots, a_m)$,并选择前 K 个因素求累计贡献度

$$\theta = \sum_{i=1}^K \lambda_i / \sum_{i=1}^m \lambda_i \quad (4)$$

由前 K 个特征向量组成的降维矩阵 $P = [p_1, p_2, \cdots, p_K]$,降维后的特征矩阵 $S' = SP$ 。

2.2 支持向量回归

支持向量回归是以统计学为基础,将输入向量非线性地变换到高维特征空间中,然后在高维特征空间中进行线性回归,以实现在原空间的非线性回归,达到理想学习的效果^[21]。

假设样本集为 $\{(x_1, y_1), (x_2, y_2), \cdots, (x_n, y_n)\}$,其中 $x_i = (x_{i1}, x_{i2}, \cdots, x_{im})$ 表示特征向量。SVR 主要用于求得样本输入数据 x 对应的预测值 y 。假设 x 与 y 之间的函数关系表达式为

$$y = f(x) = \omega^T \varphi(x) + b \quad (5)$$

式中, $\varphi(x) = (\varphi_1(x), \varphi_2(x), \cdots, \varphi_m(x))^T$ 是 m 维列向量; $\omega = (\omega_1, \omega_2, \cdots, \omega_m)^T$ 是 m 维权向量,表示进行线性回归时的权重; b 为偏置值。输入数据 x 映射到 m 维的特征空间内变成 $\varphi(x)$,使得 $\varphi(x)$ 与 y 的关系为线性关系,输入数据空间内的非线性拟合问题变为高维特征空间内的线性拟合问题。

SVR 采取 ε -不敏感函数作为损失函数。首先,针对具体问题定义一个常量 $\varepsilon > 0$,对于某一样本 (x_i, y_i) ,如果 $|y_i - \omega^T \varphi(x_i) - b| \leq \varepsilon$,则完全没有损失,否则对应的损失为 $|y_i - \omega^T \varphi(x_i) - b| - \varepsilon$ 。即 ε -不敏感函数可整理为

$$e(x_i) = \begin{cases} 0, & |y_i - \omega^T \varphi(x_i) - b| \leq \varepsilon \\ |y_i - \omega^T \varphi(x_i) - b| - \varepsilon, & |y_i - \omega^T \varphi(x_i) - b| > \varepsilon \end{cases} \quad (6)$$

为使损失函数最小,基于结构风险最小化准则,确定 ω 和 b 的约束条件并对目标函数进行优化,构建最优化准则

$$\begin{cases} \min J | J = \frac{1}{2} \omega^T \omega + \frac{1}{2} c \sum_{i=1}^n e_i^2 & i = 1, 2, \dots, n \\ y_i = \omega^T \varphi(x_i) + b + e_i \end{cases} \quad (7)$$

式中, J 为目标函数, e_i 为松弛变量, c 为正则化函数。利用拉格朗日函数将式(7)转化为对偶形式

$$L(\omega, b, e, \alpha) = J - \sum_{i=1}^n \alpha_i \{ \omega^T \varphi(x_i) + b + e_i - y_i \} \quad (8)$$

式中 α_i 为拉格朗日因子。用式(8)求解最优解, 令式(8)对 ω 、 b 、 α_i 和 e_i 的偏导均为 0, 可得

$$\begin{aligned} \omega &= \sum_{i=1}^n \alpha_i \varphi(x_i) \\ \sum_{i=1}^n \alpha_i &= 0 \\ y_i &= \omega^T \varphi(x_i) + b + e_i \\ e_i &= -\alpha_i / c \end{aligned} \quad (9)$$

整理可得

$$y = f(x) = \sum_{i=1}^n \alpha_i K(x, x_i) + b \quad (10)$$

式中, 径向基核函数 $K(x, x_i) = \varphi(x)^T \varphi(x_i)$ 。

2.3 基于 PCA-SVR 的 PAD 预测流程

本文中所提的基于 HRV 特征和 PCA-SVR 的 PAD 预测方法结合可穿戴设备, 从压力脉搏获取的心率和心率间期数据中提取 HRV 时域、频域和非线性特征, 经过 PCA 抽取 HRV 主成分后经 SVR 模型训练预测得到 PAD 数值。具体步骤如下。

1) 经过诱导实验获取相应情感状态的心率和心率间期数据, 并通过 PAD 量表进行标注。

2) 从心率和心率间期数据中提取 HRV 时域、频域和非线性特征, 并通过 PCA 提取 HRV 的主成分特征。

3) 按照 2:1 的比例划分训练集和测试集, 最后经 SVR 训练预测得到 PAD 的 3 个维度的预测值。

3 实验与分析

3.1 实验数据

本文利用安装了柔性离子传感器的穿戴设备^[22], 通过配套的 Matlab 软件接收传感器发送的数据。共采集了 12 名志愿者经视频和音乐诱导后的心率和心率间期数据, 每组数据包含焦虑和放松两

种情感状态, 视频是由电影片段剪辑而成, 诱导焦虑情感, 音乐是一首舒缓的钢琴和管弦民谣, 诱导放松情感。传感器及穿戴设备如图 2 所示。数据采集过程中, 志愿者保持坐立姿势, 在视频和音乐过后, 让志愿者分别填写两次 PAD 量表, 根据量表中各项数值计算 PAD 数值。通过 PAD 数值的标注, 实现从离散的情感状态到连续空间的映射。根据文献[16], 焦虑情感的 PAD 数值范围为 ($Value_p < 0$, $Value_A > 0$, $Value_D < 0$), 放松情感的 PAD 数值范围为 ($Value_p > 0$, $Value_A < 0$, $Value_D > 0$)。根据由 PAD 量表计算得到的 PAD 数值是否在对应的情感范围内来判断数据的有效性。



图2 传感器及穿戴设备

Fig. 2 The sensor and the wearable device

3.2 HRV 特征提取

通过对采集数据进行时域、频域和非线性分析, 共提取了 19 维特征, 如表 2 所示。其中采用均值和方差等统计方法提取了 8 个时域特征, 对应表中编号 1~8; 根据 Welch 功率谱法^[23]提取了 7 个频域特征, 对应表中编号 9~15; 根据 Poincaré 散点图^[24]、熵分析^[25]和分形维数^[26]提取了 4 个非线性特征, 对应表中编号 16~19。

3.3 主成分提取

HRV 特征经 PCA 处理得到主成分贡献率和累计贡献度, 如表 3 所示。

当利用 PCA 对特征进行分析的累计贡献度大于 85% 时, 可认为当前主成分已包含原始数据中的信息, 且累计贡献度越大, 包含的信息越多^[27]。根据主成分贡献度, 本文选择累计贡献度直至达到 99% 的前 12 个主成分 (对应于表 3 中主成分 1~12) 作为 SVR 模型的输入特征。

3.4 性能指标

本文采用均方误差 E_{MS} (MSE)、相关系数 ρ 和一致性相关系数 ρ_c 对模型进行评价, 其公式如下。

$$E_{MS} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (11)$$

$$\rho = \frac{\text{Cov}(y, \hat{y})}{\sigma_y \sigma_{\hat{y}}} \quad (12)$$

表 2 HRV 特征
Table 2 HRV features

编号	HRV 特征
1	平均心跳间期
2	心跳间期标准差
3	平均心率
4	心率标准差
5	心跳间期方根
6	心跳间期大于 50 ms 的个数
7	心跳间期大于 50 ms 的百分比
8	1 min 心跳间期标准差平均值
9	功率谱超低频能量峰值(0 ~0. 04 Hz)
10	功率谱低频能量峰值(0. 04 ~0. 15 Hz)
11	功率谱高频能量峰值(0. 15 ~0. 4 Hz)
12	功率谱超低频能量占比(0 ~0. 04 Hz)
13	功率谱低频能量占比(0. 04 ~0. 15 Hz)
14	功率谱高频能量占比(0. 15 ~0. 4 Hz)
15	低频能量与高频能量比值
16	Poincaré 散点图椭圆拟合半短轴长,表示 HRV 低频成分和超低频成分的变化情况
17	Poincaré 散点图椭圆拟合半长轴长,表示 HRV 的快速变化情况
18	样本熵,衡量时间序列的复杂性
19	标度指数,量化非平稳时间序列的分型

表 3 主成分贡献率及累计贡献度

Table 3 Principal component contribution rate and cumulative contribution

主成分	特征根	贡献率/%	累计贡献度/%
1	7. 30	38. 44	38. 44
2	3. 51	18. 48	56. 92
3	2. 12	11. 13	68. 05
4	1. 89	9. 95	78. 00
5	0. 99	5. 19	83. 18
6	0. 88	4. 65	87. 84
7	0. 72	3. 78	91. 61
8	0. 53	2. 80	94. 41
9	0. 48	2. 50	96. 91
10	0. 26	1. 37	98. 28
11	0. 13	0. 70	98. 98
12	0. 09	0. 48	99. 46
13	0. 06	0. 32	99. 77
14	0. 03	0. 16	99. 93
15	0. 01	0. 05	99. 98
16	0. 00	0. 02	100. 00
17	0. 00	0. 00	100. 00
18	0. 00	0. 00	100. 00
19	0. 00	0. 00	100. 00

表 4 放松情感状态下的回归预测结果

Table 4 Regression prediction results for relaxed emotion

方法	维度	MSE	ρ	ρ_c
ELM	P	0. 92	0. 92	0. 79
	A	2. 12	0. 91	0. 07
	D	0. 18	0. 53	0. 38
	平均	1. 07	0. 79	0. 41
PCA-ELM	P	3. 02	0. 98	0. 16
	A	2. 27	0. 92	0. 18
	D	0. 54	0. 96	0. 75
	平均	1. 94	0. 95	0. 36
SVR	P	0. 65	0. 94	0. 46
	A	0. 17	0. 87	0. 72
	D	0. 15	0. 73	0. 45
	平均	0. 32	0. 85	0. 54
PCA-SVR	P	0. 40	0. 79	0. 24
	A	0. 56	0. 81	0. 18
	D	0. 12	0. 86	0. 28
	平均	0. 36	0. 82	0. 23

$$\rho_c = \frac{2\rho\sigma_y\sigma_{\hat{y}}}{\sigma_y^2 + \sigma_{\hat{y}}^2 + (\bar{y} - \hat{\bar{y}})^2} \tag{13}$$

式中, y 和 \hat{y} 为期望输出和预测输出, n 为测试集样本个数, σ_y 和 $\sigma_{\hat{y}}$ 分别为期望输出和预测输出的标准偏差。MSE 越小,预测结果越准确, ρ 越接近于 1,预测输出与期望输出的拟合度越高, ρ_c 越接近于 1,说明模型的整体表现越好。

3.5 实验结果与分析

对于 2.3 节中划分的训练集和测试集,其中单一情感状态的训练集样本个数为 8 个,测试集样本个数为 4 个,混合情感状态的训练集样本个数为 16 个,测试集样本个数为 8 个。采用本文所提方法在单一情感状态和混合情感状态下分别通过实验进行预测,并与 SVR、ELM^[28]和基于 PCA 的 ELM(PCA-ELM)这 3 种预测方法进行了对比,其中放松情感状态下的预测结果如表 4 所示,焦虑情感状态下的预测结果如表 5 所示,放松和焦虑两类混合情感状态下的预测结果如表 6 所示。

表 5 焦虑情感状态下的回归预测结果
Table 5 Regression prediction results for anxious emotion

方法	维度	MSE	ρ	ρ_c
ELM	P	1.29	0.67	0.34
	A	6.52	0.96	0.75
	D	0.99	0.94	0.77
	平均	2.93	0.86	0.62
PCA-ELM	P	0.93	0.72	0.53
	A	1.48	0.70	0.26
	D	4.12	0.81	0.45
	平均	2.18	0.74	0.41
SVR	P	0.27	0.94	0.39
	A	1.12	0.87	0.20
	D	0.40	0.82	0.65
	平均	0.60	0.88	0.41
PCA-SVR	P	0.18	0.99	0.22
	A	0.22	0.84	0.17
	D	0.11	1.00	0.07
	平均	0.17	0.94	0.15

表 6 混合情感状态下的回归预测结果
Table 6 Regression prediction results for mixed emotion

方法	维度	MSE	ρ	ρ_c
ELM	P	0.88	0.54	0.46
	A	3.08	0.69	0.35
	D	0.70	0.60	0.43
	平均	1.56	0.61	0.41
PCA-ELM	P	2.63	0.32	0.28
	A	6.57	0.47	0.33
	D	0.64	0.79	0.79
	平均	3.28	0.53	0.47
SVR	P	1.52	0.76	0.33
	A	1.54	0.72	0.45
	D	1.17	0.84	0.33
	平均	1.41	0.77	0.37
PCA-SVR	P	0.37	0.80	0.78
	A	1.76	0.87	0.46
	D	0.96	0.66	0.30
	平均	1.03	0.78	0.51

结合表 4、表 5 的预测结果可以看出,在放松情感状态下,P 维度上 PCA-SVR 方法相对于 SVR 方法仅在 MSE 上有所提升,在 D 维度上 ρ 和 MSE 均

有提升,而在 A 维度上 3 个指标均有所降低。在焦虑情感状态下,PCA-SVR 方法相对于 SVR 方法在 P 维度上 ρ 提升较大,而 ρ_c 有所降低,A 维度上 MSE 提升较大,而 ρ 稍有降低,D 维度上 ρ 提升较大, ρ_c 有所降低。在两种单一情感状态下,PCA-SVR 方法相对于 SVR 方法 ρ_c 都有所下降,说明在单一情感状态下,PCA-SVR 模型相对于 SVR 模型的优势并不明显。从表 6 的预测结果可以看到,在混合情感状态下,PCA-SVR 模型在 A 维度上的 MSE 稍差于 SVR 模型;在 D 维度上 ρ 和 ρ_c 稍有下降,MSE 有所提升;在 P 维度上,3 个指标均有所提升。从 3 个维度综合来看,PCA-SVR 相对于 ELM、PCA-ELM 和 SVR 在 ρ_c 上分别提升了 0.10、0.04 和 0.14,且在另外两个指标上也有不同程度的提升,因此在整体上 PCA-SVR 具有更好的预测效果。

在单一情感状态下,从 4 种方法的评价指标可以得到,经过 PCA 处理的模型(PCA-SVR 和 PCA-ELM)相对于原有模型(SVR 和 ELM)提升效果不明显甚至没有提升,原因是在单一情感状态下的训练数据较少,不同方法的预测结果差异较大。放松和焦虑两类混合情感状态下 PCA-SVR 模型在 3 个维度上的标注值和预测值对比如图 3~5 所示。




图 3 P 维度标注值与预测值对比
Fig. 3 Comparison of labeled values and predicted values in the P dimension

从图 3~5 可以看出,在 P 维度和 A 维度上,PCA-SVR 模型能够很好地反映出情感变化情况,而在 D 维度上预测值的变化趋势与标注值相比并不非常吻合。结合表 6 中指标,PCA-SVR 模型能很好地在愉悦度和唤醒度上识别和预测情感,在优势度上的预测效果相对于其他两个维度较差,说明在区分愉悦-非愉悦和唤醒-非唤醒上 PCA-SVR 模型具有更好的效果。




图4 A 维度标注值与预测值对比

Fig. 4 Comparison of labeled values and predicted values in the A dimension




图5 D 维度标注值与预测值对比

Fig. 5 Comparison of labeled values and predicted values in the D dimension

综合以上实验结果,本文所提方法能在一定程度上反映出情感变化的趋势,对于某些消极情感的预警有一定的指示作用。对于需要细致划分的情感,通过 PAD 数值预测可以达到精细划分的目的,在情感识别和分析方面起到了补充作用。

4 结束语

本文提出了基于 HRV 特征和 PCA-SVR 的 PAD 维度情感预测模型。在混合情感状态下的 3 个维度上 MSE 平均仅为 1.03, ρ 平均达到 0.78, ρ_c 平均为 0.51, 对比 SVR、ELM 和 PCA-ELM 这 3 个模型, PCA-SVR 模型在 3 个评价指标上均有提升, 其中在一致性相关系数上分别提升了 0.14、0.10 和 0.04, 同时预测精度优于文献[14] ($\rho_c < 0.5$) 和文献[15] ($\rho_c < 0.3$) 中使用的方法。本文提出的方法能以较高的准确性预测 PAD 维度数值, 可以直观地反映情感的程度, 是对情感识别手段的补充。通过本文所提方法可简化情感相关疾病的

治疗过程中多次评级的过程, 能更直观地表示情感的程度, 且 HRV 信号便于获取, 结合可穿戴设备更适合日常生活中的情感检测。在未来的研究中, 会考虑更多类型的情感, 扩充数据集, 并在预测模型上作出改进。

参考文献:

- [1] PICARD R W. Affective computing [M]. Cambridge, USA: MIT press, 2000.
- [2] 权学良, 曾志刚, 蒋建华, 等. 基于生理信号的情感计算研究综述[J]. 自动化学报, 2021, 47: 1-16.
QUAN X L, ZENG Z G, JIANG J H, et al. Physiological signals based affective computing: a systematic review [J]. Acta Automatica Sinica, 2021, 47: 1-16. (in Chinese)
- [3] ZHU J P, JI L Z, LIU C Y. Heart rate variability monitoring for emotion and disorders of emotion[J]. Physiological Measurement, 2019, 40(6): 064004.
- [4] 李幼军. 生理信号的情感计算研究及其应用[D]. 北京: 北京工业大学, 2018.
LI Y J. The study and application of affective computing based on bio-signals [D]. Beijing: Beijing University of Technology, 2018. (in Chinese)
- [5] EKMAN P, FRIESEN W V. Constants across cultures in the face and emotion[J]. Journal of Personality and Social Psychology, 1971, 17(2): 124-129.
- [6] HE C, YAO Y J, YE X S. An emotion recognition system based on physiological signals obtained by wearable sensors[M]//YANG C, VIRK G, YANG H. Wearable sensors and robots. Lecture notes in electrical engineering. Singapore: Springer, 2017: 15-25.
- [7] GUO H W, HUANG Y S, LIN C H, et al. Heart rate variability signal features for emotion recognition by using principal component analysis and support vectors machine [C]//2016 IEEE 16th International Conference on Bioinformatics and Bioengineering (BIBE). Taichung: IEEE, 2016: 274-277.
- [8] CAI H S, QU Z D, LI Z, et al. Feature-level fusion approaches based on multimodal EEG data for depression recognition[J]. Information Fusion, 2020, 59: 127-138.
- [9] GUNES H, SCHULLER B. Categorical and dimensional affect analysis in continuous input: current trends and future directions[J]. Image and Vision Computing, 2013, 31(2): 120-136.

- [10] RUSSELL J A. A circumplex model of affect[J]. *Journal of Personality and Social Psychology*, 1980, 39(6): 1161–1178.
- [11] SONG T F, ZHENG W M, SONG P, et al. EEG emotion recognition using dynamical graph convolutional neural networks[J]. *IEEE Transactions on Affective Computing*, 2020, 11(3): 532–541.
- [12] SAMARA A, MENEZES M L R, GALWAY L. Feature extraction for emotion recognition and modelling using neurophysiological data [C] // 2016 15th International Conference on Ubiquitous Computing and Communications and 2016 8th International Symposium on Cyberspace and Security (IUCC-CSS). Granada: IEEE, 2016: 138–144.
- [13] KEREN G, KIRSCHSTEIN T, MARCHI E, et al. End-to-end learning for dimensional emotion recognition from physiological signals[C] // 2017 IEEE International Conference on Multimedia and Expo (ICME). Hong Kong: IEEE, 2017: 985–990.
- [14] YU W Y, DING S, YUE Z J, et al. Emotion recognition from facial expressions and contactless heart rate using knowledge graph [C] // 2020 IEEE International Conference on Knowledge Graph (ICKG). Nanjing: IEEE, 2020: 64–69.
- [15] 胡艳香, 孙颖, 张雪英, 等. 基于聚类 PSO-LSSVM 模型的 PAD 维度预测[J]. *计算机应用研究*, 2020, 37(4): 994–998.
HU Y X, SUN Y, ZHANG X Y, et al. Forecast of PAD dimensions using clustering PSO-LSSVM model[J]. *Application Research of Computers*, 2020, 37(4): 994–998. (in Chinese)
- [16] MEHRABIAN A, RUSSELL J A. An approach to environmental psychology [M]. Cambridge, USA: MIT Press, 1974.
- [17] MEHRABIAN A. Framework for a comprehensive description and measurement of emotional states[J]. *Genetic, Social, and General Psychology Monographs*, 1995, 121(3): 339–361.
- [18] 李晓明, 傅小兰, 邓国峰. 中文简化版 PAD 情绪量表在京大学生中的初步试用[J]. *中国心理卫生杂志*, 2008, 22(5): 327–329.
LI X M, FU X L, DENG G F. Preliminary application of the abbreviated PAD emotion scale to Chinese undergraduates [J]. *Chinese Mental Health Journal*, 2008, 22(5): 327–329. (in Chinese)
- [19] NICOLAOU M A, GUNES H, PANTIC M. Continuous prediction of spontaneous affect from multiple cues and modalities in valence-arousal space[J]. *IEEE Transactions on Affective Computing*, 2011, 2(2): 92–105.
- [20] KU W F, STORER R H, GEORGAKIS C. Disturbance detection and isolation by dynamic principal component analysis[J]. *Chemometrics and Intelligent Laboratory Systems*, 1995, 30(1): 179–196.
- [21] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine Learning*, 1995, 20(3): 273–297.
- [22] ZHANG Z C, ZHU Z J, BAZOR B, et al. FeetBeat: a flexible lontronic sensing wearable detects pedal pulses and muscular activities[J]. *IEEE Transactions on Biomedical Engineering*, 2019, 66(11): 3072–3079.
- [23] FUKUNUSHI M, MCDUFF D, TSUMURA N. Improvements in remote video based estimation of heart rate variability using the Welch FFT method [J]. *Artificial Life and Robotics*, 2018, 23(1): 15–22.
- [24] HOSHI R A, PASTRE C M, VANDERLEI L C M, et al. Poincaré plot indexes of heart rate variability: relationships with other nonlinear variables[J]. *Autonomic Neuroscience: Basic and Clinical*, 2013, 177(2): 271–274.
- [25] LI J, YAN J Q, LIU X Z, et al. Using permutation entropy to measure the changes in EEG signals during absence seizures[J]. *Entropy*, 2014, 16(6): 3049–3061.
- [26] MISHRA A K, RAGHAV S. Local fractal dimension based ECG arrhythmia classification[J]. *Biomedical Signal Processing and Control*, 2010, 5(2): 114–123.
- [27] 孙颖, 胡艳香, 张雪英, 等. 面向情感语音识别的情感维度 PAD 预测[J]. *浙江大学学报(工学版)*, 2019, 53(10): 2041–2048.
SUN Y, HU Y X, ZHANG X Y, et al. Prediction of emotional dimensions PAD for emotional speech recognition[J]. *Journal of Zhejiang University (Engineering Science)*, 2019, 53(10): 2041–2048. (in Chinese)
- [28] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. *Neurocomputing*, 2006, 70(1–3): 489–501.

Heart rate variability features for emotion dimensional prediction by using a principal component analysis-support vector regression (PCA-SVR) model

HAN YongMing^{1,2} ZHANG MingXing^{1,2} GENG ZhiQiang^{1,2*}

(1. College of Information Science and Technology; 2. Engineering Research Center of Intelligent PSE, Ministry of Education,
Beijing University of Chemical Technology, Beijing 100029, China)

Abstract: In order to solve the numerical prediction problem in PAD (pleasure, arousal and dominance) dimensional emotion prediction, a PAD dimensional emotion prediction model integrating heart rate variability (HRV) based on principal component analysis (PCA) and support vector regression (SVR) is proposed in this paper. The heart rate and heart interval data of 12 volunteers in two emotion states with relaxation and anxiety induced by music and video were collected by flexible iontronic sensing, and labeled on a PAD emotion scale. The time-domain, frequency-domain and nonlinear features of HRV were then extracted by different statistical methods, namely mean and variance, Welch power spectrum and Poincaré scatter diagram, respectively. Moreover, the PCA model was used to reduce the dimension of HRV features. The HRV features after dimensionality reduction were used as the input features of the SVR model for training and prediction. The experimental results show that the PCA-SVR model combined with HRV features had good prediction effects for the three dimensions of PAD, and its average consistency correlation coefficient (CCC) reached 0.51. The three prediction methods of the SVR, extreme learning machine (ELM) and the ELM based the PCA were compared, and the results showed that the proposed method resulted in improvements in CCC of 0.14, 0.10, and 0.04, respectively. Furthermore, the proposed method can divide emotions in detail, and has a certain complementary role in emotion recognition and analysis. Thus using the method in combination with wearable devices, it is possible to identify and predict emotions in daily life.

Key words: PAD dimensional emotion; heart rate variability; principal component analysis; support vector regression

(责任编辑:吴万玲)