

文章编号: 2096-1618(2023)03-0258-06

基于 XGBoost-RFE-CBR 的心电信号情绪识别研究

杨琳坤, 何培宇, 潘帆, 方安成

(四川大学电子信息学院, 四川 成都 610065)

摘要:情绪是一种复杂的行为现象,是对不同外部刺激的生理反应。为快速、便捷地识别人类的情绪,提出了一种基于极限梯度提升结合可减少相关性偏差和递归特征消除的心电信号情绪识别方法。先对 AMIGOS 数据集进行特征提取、结合 XGBoost-RFE-CBR 特征排序算法进行特征选择,得到 27 个心电信号和心率变异性的时域、频域等特征参数,利用 XGBoost 进行分类,最后在五折交叉验证下,最高准确率达80.5%、平均准确率达77.2%。该方法与多维生理信号特征提取方法相比,在确保准确率的同时降低了计算量,对情绪识别和分类任务有一定的参考价值。

关键词:信号与信息处理;情绪识别;心电信号;极限梯度提升;特征选择;递归特征消除

中图分类号:TP911.7

文献标志码:A

doi:10.16836/j.cnki.jcuit.2023.03.002

0 引言

情绪是人类思想、情感和行为的结合,是对不同外部刺激的生理反应^[1]。近年来,情绪识别引起了广泛关注。为此,提出了许多研究方法以准确识别人类情绪,这些研究方法主要可以分为两大类:第一类基于非生理数据的方法,利用语言和面部表情等^[2-5]数据判断情绪。这类方法的优点是数据很容易收集,不需要任何专门和昂贵的设备。但是非生理信号可以被主观意愿控制^[6],这意味着受试者可以掩盖自己的情绪,并在分类中造成无法检测和消除的不确定性。第二类依据生理数据,如脑电图(electroencephalogram, EEG)^[7-8]、肌电图(electromyogram, EMG)^[9-10]、心电图(electrocardiogram, ECG)^[11-12]、皮肤电反应(galvanic skin response, GSR)^[13-14]等无法人为干预的生理信号作为依据进行情绪判断。这类方法可以更好地与实际情绪状态相关联,但实验的设置较为困难。例如,采集脑电图生理信号需要受试者处于防止外界交流电噪声干扰的屏蔽室,并且对受试者有一定的要求,同时其信号中固有的噪声也会阻碍可靠的情绪识别。两种方法相比之下,第二类方法具有更高的准确性和客观性,并且不限制使用人群。因此,基于生理信号的情绪识别法具有更高的研究价值和实用价值。Kim等^[15]提出了用于识别情绪的基于卷积长短期记忆的深层生理影响网络,在 DEAP 数据集上检测,准确率相较于 DEAP 实验结果提升了15.96%;陈沙利等^[16]融合脉搏波、皮肤电反应、呼吸、皮肤温度等多种信号的特征,通过基于支持向量机的可减少相关性偏差的递归消除特

征排序算法进行情绪分类,平均准确率达到76.9%;Pan L等^[17]提出了一种基于支持向量机、决策树和极端学习机融合的综合模型,在 DEAP 数据集上对4种生理信号进行情绪分类的准确率达到74.64%;CHAO H等^[18]将改进的深度信念网络与神经胶质链和条件随机场集成在一起,提取多通道脑电信号的高阶特征序列,通过 KNN(K-Nearest Neighbor)进行分类,在 AMIGOS 和 DEAP 数据集上得到76.10%和75.46%的平均精确率;Santamaria-Granados等^[19]使用深度卷积神经网络,利用 AMIGOS 数据集的心电信号和皮肤电信号进行情绪分类,在 arousal 和 valence 二维空间分类得到76%和73%的平均准确率。

目前,大量的研究都是使用经过处理后的多维生理信号进行分类,但脑电信号、肌电信号、皮肤电反应信号与心电信号相比采集设备要求更高、数据更易受干扰。根据心电信号得到的心率变异性(heart rate variability, HRV)^[20-21],可以反映出心血管系统在不同情绪下做出的调节,从而体现情绪的变化。所以,本文提出一种基于极限梯度提升结合可减少相关性偏差和递归特征消除的心电信号情绪识别方法。首先,使用公开数据集 AMIGOS^[22]数据集进行实验,采用小波变换和陷波滤波器去除噪声等干扰,提取了心电信号以及心率变异性的时域、频域等35个特征参数;再结合 XGBoost-RFE-CBR(eXtreme gradient boosting-recursive feature elimination-correlation bias reduction)特征排序算法进行特征选择得到27个特征;然后利用 XGBoost 进行分类,最后在五折交叉验证下,对 arousal、valence、dominance 3个情绪标签分别进行二分类,分别获得80.5%、74.8%、76.4%的识别准确率。与采用多维生理信号的方法相比,该方法减少了系统复杂度,与传统分类算法相比有着更高的分类准确率。


1 数据预处理及方法

1.1 数据和预处理


所使用的数据集为 AMIGOS 数据集,它是用于研究个人和团体的情感、人格和情绪的数据集,其中包含 40 名受试者的实验数据,每名受试者独立观看 16 个引起不同情绪的短片并在观看过程中记录心电、皮肤电、脑电数据。选取上述 40 名受试者的独立观看 16 个情感短片的心电数据进行实验。

在 AMIGOS 数据集中,ECG 信号有三导联信号,可以得到采样率为256 Hz的 1280 份 ECG 信号,作为实验样本,其中第 9 个人仅参加了第 4、5、8、14 个情感短片的 ECG 信号采集。为了保证数据的一次完成性,减少外部因素的影响,故舍弃第 9 个实验者的 ECG 信号,最终得到 1248 份实验样本。AMIGOS 数据集以自我情绪评定量表(self-assessment manikin ,SAM)为评价规则,让 40 名受试者在 arousal、valence 和 dominance 3 个维度等若干指标中,使用 1~9 的连续量化分数进行评判,评分从小到大依次表示各项指标由弱到强。以评分作为分类标准,分为 1~5 分和 5~9 分两类,使用 0 和 1 进行标记。

通过观察频谱以及与正常心电信号的对比,在 39 名参与者的 ECG 信号中,存在两个固定干扰,干扰的频率范围分别为 $50\text{ Hz}\pm0.1\text{ Hz}$ 和 $78\text{ Hz}\pm0.1\text{ Hz}$;并且,在测量心电信号的过程中,ECG 信号会因为耦合进肌电干扰而出现测量偏差^[23];此外,原始心电信号会存在一定程度的基线漂移,会影响心电信号的特征^[24]。使用bior2.6小波对原始心电信号进行小波分解、滤波、重构,以去除肌电干扰和基线漂移,再采用 50、78 Hz 的陷波滤波器对 ECG 信号进行滤波处理,从而消除这两项固定存在的干扰。原始心电信号以及处理后的心电信号如图 1 所示。



(a) 原始 ECG 信号



(b) 预处理后的 ECG 信号

图1 原始 ECG 信号与预处理后的 ECG 信号

1.2 特征的提取

ECG 信号的基本波形见图 2,包含以下基本波形:心脏兴奋过程中会相继出现一个 P 波、一个 QRS 波群及一个 T 波,相邻 R 峰的时间间隔通常被称为 RR 间隔。




图2 ECG 信号的基本波形

根据受试者观看视频的时长,实验样本截取时长为50 s的信号进行实验。因为受试者观看情绪短评引起动作干扰导致 R 峰提取存在误差,所以选取使用 Pan & Tompkins 算法提取 R 峰来避免干扰从而获得正确的 R 峰信息,如图 3 所示。




图3 QRS 波检测定位 R 峰位置

准确提取 R 峰后,计算相邻 R 峰的时间间隔(RR 间隔);进一步剔除异常心跳节拍(如心脏异位搏动),获得正常窦性心搏 RR 间隔(简称 NN 间隔),用于衡量心率变异性(HRV)^[20~21]。然后,提取 ECG 信号和 NN 间隔的相关特征作为实验的所需要的特征,具体提取的特征见表 1。

表 1 提取的特征

特征类型	提取特征
时域特征	心率、原始信号最大值、最小值、中值、最大最小差值及其一阶、二阶差分,信号变异系数、相邻 NN 间隔的均值、标准差、相邻 NN 间隔之间的均值、SDSD、RMSSD、pNNx 等
频域特征	TP、LFP、HFP、LF/HF 等
非线性特征	庞卡莱图特征、近似熵、赫斯特指数、柯尔莫哥洛夫熵、去趋势波动分析等

表1中,SDSD是相邻NN间隔之间差异的标准差;RMSSD表示相邻时NN间隔的平方根;pNN_x表示时间间隔大于 x ms的NN间期占有所有NN间期的比重;LFP、HFP、TP分别是HRV相关频域特征分别表示NN间隔对应低频(0.04~0.15 Hz)功率、高频(0.15~0.40 Hz)功率以及总功率(≤ 0.40 Hz)。除时、频域特征之外,非线性方法也常被用于评价HRV动态特性^[21]。如通过庞卡莱图^[25]计算NN间隔的SD1(standard deviation 1)和SD2(standard deviation 2):

$$SD1 = \sqrt{\left(\frac{|\text{NN}_i - \text{NN}_{i+1}|}{\sqrt{2}} \right)^{L-1}}$$

$$SD2 = \sqrt{\left(\frac{|\text{NN}_i + \text{NN}_{i+1}|}{\sqrt{2}} \right)^{L-1}}$$

其中, i 表示第 i 个NN间隔, L 表示NN间隔的总数。为消除不同受试者之间的差异和模型分类,对每个所提取的特征均进行Z-score标准化处理,处理后的特征数据均达到均值为0,标准差为1。

1.3 特征的选择

本文从心电信号及心率变异性中在时域、频率、非线性特征中提取35个特征。特征与特征之间可能会存在相关性,并不是特征越多,模型的分类能力就越好。过多的特征会导致分类模型训练时间增加,也可能使模型训练后出现过拟合的情况,导致分类性能下降。因此,采用XGBoost-RFE-CBR特征选择方法对前面所提取的特征进行筛选。XGBoost-RFE(recursive feature elimination)是一种基于极限梯度提升进行特征排序的^[26]方法,是通过选取特征集合的子集使用XGBoost模型评估效果,然后重复该过程直到得到最优的特征子集,该特征子集中存在的特征就是被选择的特征。首先,使用所有特征训练XGBoost模型,计算每个特征量的重要性并进行排序;其次,提取重要性靠前的特征作为新的特征子集;之后,基于新的特征子集训练XGBoost模型,重新计算每个特征变量的重要性并进行排序;然后,重复上述过程,比较每个特征子集获得的效果;最后,选择并决定最优的特征变量集合。虽然XGBoost-RFE是一种有效的特征选择方法,为了避免相关性较高的特征被一起移除而造成性能损失,所以引入一种可以减少相关性偏差的方法^[27],目的是将某些因相关性较高且被误舍弃的特征重新添加到特征变量集合。每次XGBoost-RFE选取特征子集后,对舍弃的特征中排首位的特征标记为Feature,然后找到所有与被标记特征Feature的相关系数较高的特征。如果这些新找到的特征都已被舍弃,就将标记特征Feature

移回特征子集再进行训练XGBoost模型,基本流程如图4所示。

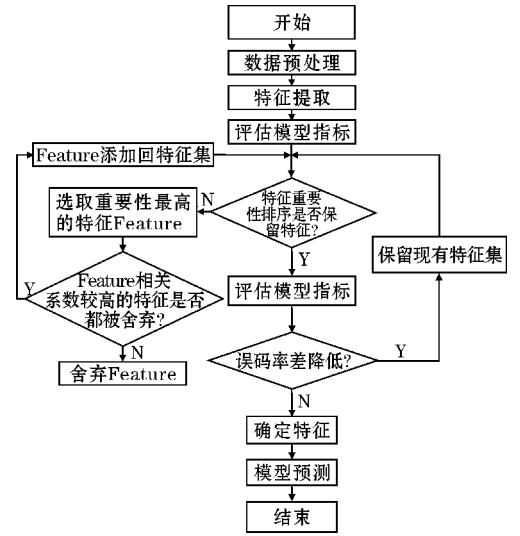


图4 特征选择基本流程

采用XGBoost-RFE-CBR对提取的35个特征进行特征选择。最终,将选出的27个特征作为分类器的输入进行情绪分类。

1.4 模型分类器

在得到心电信号特征后,使用XGBoost^[28]分类器进行特征分类。XGBoost算法是一种梯度提升算法,它是使用模型去训练特征然后计算残差。将前一个模型的输出作为当前模型的输入,最后用模型的共同组合来实现对真实分布的模拟。此处的模型也被称作“树”。XGBoost训练模型过程中的目标函数由梯度提升算法的训练损失和正则项构成:

$$L(\phi) = \sum_{i=1}^n l(y'_i, y_i) + \sum_k \Omega(f_k)$$

其中 ϕ 表示模型的参数和输入, n 为训练的样本数, l 训练损失是计算单个样本的损失值, y'_i 为模型输出的预测值, y_i 为训练样本的真实值。正则项 $\sum_k \Omega(f_k)$ 控制模型的复杂性,有助于避免过拟合, k 表示树的总数。 l 训练损失常用的是均方误差(mean squared error, MSE):

$$l(\hat{y}_i, y_i) = \sum_i (y_i - \hat{y}_i)^2$$

为了计算正则项 $\sum_k \Omega(f_k)$,需要定义每一颗树的复杂度 $\Omega(f_k)$:

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2$$

其中 γ, λ 是模型需要输入的参数用来控制正则项的大小进而控制模型复杂性, T 是树叶的数量, w_j 是每一棵树叶上的权重。为了提高模型的分类准确率,需要尽可能地降低目标函数 $L(\phi)$ 。

由于样本有限,直接训练容易导致过拟合。为了得到稳定可靠的分类模型,本文采用 5 折交叉验证进行训练分类。将样本平均分成 5 份,每次选取其中 4 份作为训练集进行 5 次训练得到 5 个模型,再将剩下的 1 份进行分类预测,分类准确率的结果取平均以得到一个单一的估测值。

2 评估方法及实验结果

2.1 评估方法

本文使用了查全率 (Recall)、精确率 (Precision)、准确率 (Accuracy) 和 F1 值 (H-mean 值) 来更客观真描述实验验证分类器结果的好坏。

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$
$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$
$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}}$$
$$F1 = \frac{2 \times \text{TP}}{2 \times \text{TP} + \text{FP} + \text{FN}}$$

其中,TP (true positives) 是分类后正确的正样本,TN (true negatives) 是分类后正确的负样本,FP (false positives) 是分类后错误的正样本,FN (false negatives) 是分类后错误的负样本。查全率表示预测正确的正样本占实际正样本的比例;精确率表示预测正确正样本数占预测为正的样本的比例;准确率表示所有的预测正确的样本占总的比重;F1 值表示查全率和精确率的调和平均数,该值的特点就是会更多聚焦在较低的值,所以会对每个指标有相同的重视程度。

2.2 实验结果及对比

2.2.1 实验结果

本文的数据集共 1248 条时长 50 s 的 ECG 信号,其中根据前面提出的数据预处理及实验方法进行实验,训练集和测试集的比例为 4 : 1。所研究的分类器的结果在测试集上的情绪分类的结果如表 2 所示。

表 2 情绪分类的结果分析				单位: %
情绪标签	Recall	Precision	Accuracy	F1 值
arousal	80.5	80.8	80.5	80.1
valence	74.8	74.9	74.8	74.4
dominance	76.4	76.6	76.4	76.3

在表 2 中,arousal 的 4 项评估结果均最高,表明所提取的特征对 arousal 有最好的分类效果,对 valence 和 dominance 所提取的特征分类效果较差。这是由于 arousal 所代表的情绪激烈程度的变化会更多地引起生理方面的变化,也可能是用于测试的视频材料能够使人在 arousal 表达上能够有明显体现。

图 5 ~ 7 分别为本文模型预测 3 种标签的混淆矩阵,整体的分类准确率不够高,原因可能是数据样本太少,还有受试者在观看某些视频材料时,情绪波动大、情绪转变快,从而导致模型识别和受试者自述不同,导致模型性能下降,识别率低。




图 5 本文模型预测标签 arousal 的混淆矩阵




图 6 本文模型预测标签 valence 的混淆矩阵




图 7 本文模型预测标签 dominance 的混淆矩阵

2.2.2 结果对比

利用所提出的基于 XGBoost 的心电信号特征信息情绪识别方法对 3 种情绪标签进行了分类,与在机器学习中传统的模型 Naive Bayes^[22]和深度学习神经网络中传统的 CNN 等模型^[19,29]进行对比,结果如表 3 所示。

表 3 情绪分类的对比分析

分类方法	采用信号	特征数量	Average Recall/%	Average Accuracy/%	Average F1/%
Naive Bayes ^[22]	EEG ECG GSR	EEG(105) ECG(77) GSR(31)			56.2
DCNN ^[19]	ECG	200		78.50	72.00
BLSTM+Attention ^[29]	EEG ECG GSR	128		80.14	70.95
本文方法	ECG	27	77.2	77.2	76.9

由表 3 可知,本文方法的 F_1 比 AMIGOS 数据集团队使用的 Naive Bayes 方法的 F_1 提高 20.7%,在仅使用心电信号作为特征的情况下,提升了 F_1 值;与 DCNN 方法相比准确率相近,准确率降低了 1.3%, F_1 值提高了 4.9%;与 BLSTM+Attention 方法相比准确率相近,准确率降低了 2.94%, F_1 值提高了 5.95%。不过,本文所使用的特征数要比其余方法少很多。整体来看,本文方法在这次对比实验中表现要优于 Naive Bayes 模型,与 DCNN 和 BLSTM+Attention 相近。

因此,本文提出的基于 XGBoost 的心电信号特征信息情绪识别方法在情绪识别中,相对传统单一的 Naive Bayes 分类模型在分类准确率上具有优势,相对于传统的深度学习网络模型在达到近似的分类效果上,对特征提取的数量上具有一定的优势,在使用深度学习网络约 10%~20% 的特征数量,达到了相近的分类效果,并且在系统的处理时间上也有提升。

3 结束语

探究了不同情绪下的心电信号与心率变异性的特征变化,通过分析不同情绪状态下的心电信号,对 arousal、valence、dominance 3 种情绪指标进行了二元分类识别。首先,采用小波变换和陷波滤波器降低噪声干扰;其次,提取了心电信号以及 HRV 关于时域、频域和非线性等特征参数;然后,进行了 XGBoost-RFE-CBR 特征选择;最后,利用 XGBoost 算法实现情绪分类,在 arousal、valence、dominance 3 个情绪标签分别进行二分类,分别获得了 80.5%、74.8%、76.4% 的识别准确率。与机器学习的经典算法相比,XGBoost 算法通过使用梯度提升在分类任务上有更高的分类准确率,与深度学习网络相比减少了系统复杂度并且达到了相近的分类准确率。在仅使用心电信号的情况下,获得了与使用脑电信号和多种外周生理信号进行情绪识别时近似的识别效果,对情绪识别和分类任务有一定的参考价值。

参考文献:

[1] Li M,Xu H,Liu X,et al. Emotion recognition from multichannel eeg signals using k-nearest neighbor classification [J]. Technology and Health Care,

2018,26:509-519.
[2] 许芬,闰文彬,张晓平. 姿态情绪识别研究综述[J]. 计算机应用研究,2021,38(12):3521-3526.
[3] 万家华,陈乃金. 基于上下文感知和注意机制的多学习情绪识别方法[J]. 北京师范大学学报(自然科学版),2021,57(5):601-605.
[4] 陈倩,静进. 孤独症谱系障碍面孔情绪识别的研究进展[J]. 教育生物学杂志,2021,9(5):341-346.
[5] 陈媛媛,王建峰. 背景颜色对大学生不同强度面孔情绪识别的影响[J]. 中国健康心理学杂志,2022,30(1):91-96.
[6] Stajc T,Jovanovc J,Jovanovc N,et al. Emotion recognition based on deap database physiological signals [C]. 2021 29th Telecommunications Forum (TEL FOR),2021:1-4.
[7] Liu Z,Wu M,Cao W,et al. A facial expression emotion recognition based human-robot interaction system[J]. IEEE/CAA Journal of Automatica Sinica,2017,4(4):668-676.
[8] Sharma L D,Bhattacharyya A. A computerized approach for automatic human emotion recognition using sliding mode singular spectrum analysis [J]. IEEE Sensors Journal,2021,21(23):26931-26940.
[9] Khateeb M,Anwar S M,Alnowami M. Multi-domain feature fusion for emotion classification using deap dataset[J]. IEEE Access,2021,9:12134-12142.
[10] Romeo L,Cavallo A,Pepa L,et al. Multiple instance learning for emotion recognition using physiological signals [J]. IEEE Transactions on Affective Computing,2022,13(1):389-407.
[11] Hsu Y-L,Wang J-S,Chiang W-C,et al. Automatic ecg-based emotion recognition in music listening [J]. IEEE Transactions on Affective Computing,2020,11(1):85-99.
[12] Sarkar P,Etemad A. Self-supervised learning for ecg-based emotion recognition [C/OL]. ICASSP 2020-2020 IEEE International Conference on Acoustics,Speech and Signal Processing (ICASSP). Barcelona,Spain:IEEE,2020:3217-3221.
[13] Cimtay Y,Ekmekcioglu E,Caglar-Ozhan S. Cross-subject multimodal emotion recognition based on

- hybrid fusion[J]. *IEEE Access*, 2020, 8: 168865–168878.
- [14] Shukla J, Barreda-Angeles M, Oliver J, et al. Feature extraction and selection for emotion recognition from electrodermal activity[J]. *IEEE Transactions on Affective Computing*, 2021, 12(4): 857–869.
- [15] Kim B H, Jo S. Deep physiological affect network for the recognition of human emotions[J]. *IEEE Transactions on Affective Computing*, 2020, 11(2): 230–243.
- [16] 陈沙利, 张柳依, 江锋, 等. 基于多种生理信号的情绪识别研究[J]. *中国医疗器械杂志*, 2020, 44(4): 283–287.
- [17] Pan L, Yin Z, She S, et al. Emotional state recognition from peripheral physiological signals using fused nonlinear features and team-collaboration identification strategy: 5[J]. *Entropy*, 2020, 22(5): 511–534.
- [18] Chao H, Liu Y. Emotion recognition from multi-channel eeg signals by exploiting the deep belief-conditional random field framework[J]. *IEEE Access*, 2020, 8: 33002–33012.
- [19] Santamaria-Granados L, Munoz-Organero M, Ramirez-Gonzalez G, et al. Using deep convolutional neural network for emotion detection on a physiological signals dataset (amigos)[J]. *IEEE Access*, 2019(7): 57–67.
- [20] Shaffer F, Ginsberg J P. An overview of heart rate variability metrics and norms[J]. *Frontiers in Public Health*, 2017(5): 258–275.
- [21] 易慧, 陈瑞娟, 邓光华, 等. 基于心率变异性的情绪识别研究[J]. *生物医学工程研究*, 2020, 39(2): 128–132.
- [22] Miranda-Correa J A, Abadi M K, Sebe N, et al. AMIGOS: a dataset for affect, personality and mood research on individuals and groups[J]. *IEEE Transactions on Affective Computing*, 2021, 12(2): 479–493.
- [23] Dessai A, Virani H. Emotion detection using physiological signals[C]. 2021 International Conference on Electrical, Computer and Energy Technologies (ICECET). 2021: 1–4.
- [24] 杨承金, 聂春燕, 车敏诗, 等. 心电信号去噪效果的评估与分析[J]. *计算机工程与应用*, 2022, 58(1): 300–312.
- [25] Tayel M B, AlSaba E I. Poincaré plot for heart rate variability[J]. *International Journal of Biomedical and Biological Engineering*, 2015, 9(9): 708–711.
- [26] 王昕宇, 杨鹏, 戴健非. 基于RFE-rf-xgboost的坝体位移预测研究[J]. *东北师大学报(自然科学版)*, 2021, 53(2): 60–66.
- [27] Yan K, Zhang D. Feature selection and analysis on correlated gas sensor data with recursive feature elimination[J]. *Sensors and Actuators B: Chemical*, 2015, 212: 353–363.
- [28] Chen T, Guestrin C. XGBoost: a scalable tree boosting system[J/OL]. *ACM*, 2016: 785–794.
- [29] Li C, Bao Z, Li L, et al. Exploring temporal representations by leveraging attention-based bidirectional lstm-rnns for multi-modal emotion recognition[J]. *Information Processing & Management*, 2020, 57(3): 102185–102194.

Emotional Recognition of ECG Signals based on XGBoost-RFE-CBR

YANG Linkun, HE Peiyu, PAN Fan, FANG Ancheng

(College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China)

Abstract: Emotion is a complex behavioral phenomenon that is a physiological response to different external stimuli. To quickly and conveniently recognize human emotions, this paper proposes a method using XGBoost-RFE-CBR to recognize the emotions based on ECG signals. Firstly, the feature of AMIGOS dataset was extracted, and selected according to XGBoost-RFE-CBR feature ranking algorithm, then 27 ECG signals and heart rate variability were obtained in time domain, frequency domain. Other features were classified by XGBoost, and finally, the highest accuracy of 80.5% and the average accuracy of 77.2% were achieved under the five-fold cross-validation. Compared with the multidimensional physiological signal feature extraction method, this research method ensures accuracy while reducing the computational effort, which has certain reference value for emotion recognition and classification tasks.

Keywords: signal and signal processing; emotion recognition; ECG signals; XGBoost; feature selection; RFE.