

文章编号:1000-4653(2025)04-0070-08

# 基于 EEG 的虚拟火灾场景下的船员恐惧情绪识别

孙铭泽, 任鸿翔, 孙健, 王德龙

(大连海事大学 航海学院, 辽宁 大连 116026)

**摘要:** 船舶火灾事故对船舶安全构成重大威胁,人为因素是事故发生的主要因素。准确识别船员在船舶火灾场景下的恐惧情绪变化,对提升船员的火灾处置能力有重要意义。采用虚拟现实技术模拟海上火灾场景收集多个受试者的脑电信号。对脑电信号进行预处理以及离散小波变换将原始信号分解为不同频段的子信号,提取每个子频段的3种特征建立特征集,包括平均绝对值、标准差和均方根。构建多个情绪识别领域适用的机器学习模型,采用精确率、准确率和  $F_1$  等评估指标对模型进行评估。试验结果表明:支持向量机分类模型效果最好,准确率达到87.97%,在船员的恐惧情绪三分类问题中效果显著。将虚拟现实技术与脑电信号情绪识别技术相结合,可有效地诱发和识别船员在火灾场景下的恐惧情绪。该方法有助于在船员消防培训中,评估和提升船员的应急能力。

**关键词:** 船员评估;脑电图;虚拟现实;船舶消防;小波变换;支持向量机

中图分类号:U69

文献标志码:A

DOI:10.3969/j.issn.1000-4653.2025.04.008

## Emotion recognition of crew fear in virtual fire scenarios based on EEG

SUN Mingze, REN Hongxiang, SUN Jian, WANG Delong

(Navigation College, Dalian Maritime University, Dalian 116026, China)

**Abstract:** Maritime fire incidents pose a significant threat to the safety of ships, with human factors being the primary cause of these accidents. Accurately identifying the emotional changes of crew members in maritime fire scenarios is of great significance for enhancing their firefighting capabilities. Virtual reality technology is employed to simulate maritime fire scenes and collect Electroencephalogram (EEG) signals from multiple subjects. The EEG signals are preprocessed and decomposed into sub-signals of different frequency bands using discrete wavelet transform. Three features, including mean absolute value, standard deviation, and root mean square, are extracted from each sub-frequency band to establish a feature set. Multiple machine learning models suitable for emotion recognition are constructed, and the models are evaluated using metrics such as precision, accuracy, and  $F_1$  score. Experimental results show that the support vector machine classification model performs the best, with an accuracy of 87.97%, which significantly improves the three-class classification problem of crew members' fear emotions in maritime environments. Combining virtual reality technology with EEG emotion recognition techniques can effectively induce and identify crew members' fear emotions in fire scenarios. This method is beneficial for assessing and improving the emergency response capabilities of crew members in firefighting training.

**Key words:** crew assessment; EEG; virtual reality; maritime firefighting; wavelet transform; support vector machine

船舶火灾事故对航行安全构成严重威胁,不仅可能造成巨额的经济损失,更在极端情况下危及船员生命安全<sup>[1]</sup>。大量研究表明,人为因素仍是水上

交通事故的首要诱因,其中约75%的船舶火灾事件源于人为过失或操作不当<sup>[2]</sup>。为最大程度减少此类事故带来的损害,加强船员的消防应急培训至关

收稿日期:2024-06-18

基金项目:国家自然科学基金(52071312);交通运输行业重点科技项目(2022-ZD3-035);辽宁省应用基础研究计划(2023JH2/101300144);广西重点研发计划(AB22080106);大连市科技创新基金项目(2022JJ12GX035)资助

第一作者:孙铭泽(1999—),男,硕士生,研究方向为船舶仿真建模。E-mail:18004087635@163.com

通信作者:任鸿翔(1974—),男,教授,研究方向为计算机影像学。E-mail:dmu\_rhx@163.com

引用格式:孙铭泽,任鸿翔,孙健,等.基于 EEG 的虚拟火灾场景下的船员恐惧情绪识别[J].中国航海,2025,48(4):70-77.

SUN M Z, REN H X, SUN J, et al. Emotion recognition of crew fear in virtual fire scenarios based on EEG[J]. Navigation of China, 2025, 48(4):70-77. (in Chinese)

重要。在开展消防培训的过程中,为检验培训效果,需评估船员在面对火情时能否有效调控情绪反应。传统的主观评估方式通常采用问卷调查等方法来衡量船员的恐惧程度,但其结果易受个体主观偏差影响,可靠性较低。相较之下,基于脑电、肌电、眼动和心率等生理信号的客观评估方法,能更准确地反映船员在火灾应急情境下的情绪状态,从而弥补主观评价的不足。

脑电图 (Electroencephalogram, EEG) 技术如今已被广泛应用于情绪识别和分析的研究领域。其信号采集自大脑,能更加直观清晰地反映情绪,在情绪识别方面有着独特的优势。周丰丰等<sup>[3]</sup> 针对脑电信号分别提取时域、频域和空间域特征,采用三段式特征选择策略进行特征筛选,建立较为准确的情绪识别分类模型,并探讨与情绪密切相关的脑电通道与频带。MOKATREN 等<sup>[4]</sup> 提取脑电信号中的小波能量和小波熵,利用电极的空间位置信息构建脑电数据模型,采用卷积神经网络 (Convolutional Neural Networks, CNN) 进行情绪分类。DU 等<sup>[5]</sup> 提出一种基于残差网络的多尺度可变形卷积交互注意网络 (MDCNAResnet), 通过结合差分熵特征、可变形卷积和多尺度特征金字塔网络,有效提升 EEG 情绪识别的性能,试验结果表明,该方法在 DEAP (Distributed Evolutionary Algorithms Python) 数据集上的 Valence 和 Arousal 维度的情绪识别准确率分别达到 98.63% 和 98.89%。利用脑电信号对驾驶人员进行情绪识别已广泛应用于路面驾驶和航空领域<sup>[6-7]</sup>, 通过监测与分析驾驶员的情绪状态可有效地减少事故的发生<sup>[8]</sup>。在航海领域,由于海上环境信号干扰大,船上人员组织结构复杂,EEG 信号采集困难等因素,相关研究相对较少。FAN 等<sup>[9]</sup> 利用驾驶模拟器模拟船员工作状态,采集 EEG 信号,利用支持向量机 (Support Vector Machine, SVM) 进行情绪识别,准确率达到 77.55%, 研究发现消极情绪比积极情绪更容易导致突发状况下的操作失误。刘清等<sup>[10]</sup> 采集船舶驾驶员在不同工作负荷下的脑电信号,提取其 Alpha 和 Beta 频段的功率密度之比作为特征输入 SVM 进行二分类,得到 92% 的准确率。LIU 等<sup>[11]</sup> 设计了一套基于 EEG 的船员培训评估系统,评估船员在海上执行任务时的心理状态,对船员的考核评估结果给出建议。

在以往的船员消防训练中,常通过人工布置火灾情境来开展教学,这种方式不仅耗费大量人力物力,还存在潜在的安全风险。而若仅依赖火灾图片或视频进行教学,又难以有效激发受训者在真实火

灾环境下的情绪反应与心理应激状态。近年来,虚拟现实 (Virtual Reality, VR) 技术得到了快速发展。该技术具有高度可控、安全性强和可重复使用等优势,并且能根据特定需求灵活构建训练或试验场景,因而被广泛应用于多种情景模拟中,用以实现情绪诱发与心理反应研究。LI 等<sup>[12]</sup> 提出了一种结合脑电图、虚拟现实和实验室环境控制 (Laboratory Environment Control, LEC) 的方法,探讨温度和空间开放度对灾后人群生理恢复的综合影响。通过模拟不同温度和空间开放度的试验,发现低温封闭空间对心理恢复有积极作用,而高温环境有助于稳定心理状态。BASBASSE 等<sup>[13]</sup> 采用 VR 技术进行恐惧诱导试验,通过分析被试人员 EEG 信号,论证 VR 技术可更加有效地进行情绪诱发。李晓军等<sup>[14]</sup> 在 VR 模拟环境中,采用不同色温的灯光对路面照明进行驾驶模拟试验,发现色温对驾驶员注意力影响显著。将 VR 技术和脑电技术相结合应用于交通领域,正逐渐成为一种新型发展趋势。

综上所述,本文利用 VR 技术构建逼真的火灾情境,并同步采集船员的脑电信号数据。在此基础上,提取脑电信号的关键特征,结合适宜的分类算法,对船员在火灾应急场景中的情绪状态进行精准识别,从而为优化船员消防训练方案提供科学依据与针对性建议。

## 1 脑电信号数据采集试验设计

### 1.1 受试人员

试验招募 15 名年龄为 20 ~ 26 岁的人员进行试验,均为男性,且主修专业为航海技术,系统地学习过船员相关职业技能,其中 6 人具有 1 a 以上的船员工作经验。20 ~ 26 岁处于身体和心理发育的成熟期,具备良好的认知和情绪调节能力。受试人员均身体健康,且在试验前未体验过本试验所搭建的 VR 场景。在试验的前一天,所有人员都充分休息,且未服用过可能影响神经系统的药物。

### 1.2 VR 场景搭建

该试验基于虚拟现实技术构建一个沉浸式的船舶舱室环境。

1) 利用 3ds MAX 建模软件以巴拿马型散货船“长山海”为原型,建立包含船舱结构、消防设备和虚拟人物在内的三维模型见图 1。

2) 在 Unity 引擎中为舱室场景添加火焰、烟雾等粒子特效,以模拟火灾环境,并实现船舶消防设备与虚拟人物之间的交互功能。正常舱室模型见图 2,失火舱室模型见图 3。



图1 散货船“长山海”模型

Fig. 1 Model of bulk carrier“Changshanhai”




图2 正常舱室模型

Fig. 2 Normal compartment model




图3 失火舱室模型

Fig. 3 Compartment model in fire

3) 场景中还叠加了警报声、燃烧声等听觉元素,从视觉和听觉2个维度增强试验对象的沉浸感与情境真实度。

### 1.3 试验设备

试验采用 EMOTIV 公司的 EMOTIV EPOC X 脑电仪进行脑电信号采集,采样频率为 128 Hz,试验流程见图 5。其采用目前发展迅速的干电极技术,通过 14 个通道覆盖头皮,电极分布符合国际 10 ~ 20 标准导联分布,使用时无需涂抹导电介质,并且其所获得的信号通过蓝牙进行传输,更加的便捷舒适,可满足受试人员在试验中进行移动的需求。试

验中按照脑电仪的使用说明,将电极按照位置要求紧贴头皮放置,保证信号的稳定。VR 设备采用头戴式显示设备 HTC Vive,是一款市场反馈良好、使用体验舒适的可移动式 VR 设备。



图4 脑电仪:EPOC X

Fig. 4 Electroencephalogram device: EPOC X

### 1.4 试验流程

受试者到达试验现场后,由试验人员向其详细说明试验流程及注意事项,并协助佩戴与调试 VR 设备和脑电采集装置。在确认画面显示清晰、脑电信号稳定后,试验正式开始。

1) 受试者首先进入无火灾的船舶舱室虚拟环境中进行短暂的熟悉阶段,以减轻初次进入 VR 场景所产生的情绪波动。

2) 熟悉结束后,试验人员启动火灾情境,受试者需在限定时间内依次完成以下任务:触发火灾警报、穿戴消防防护服和移动至灭火器位置并取用灭火器,最后返回起火点实施灭火操作。

3) 若在规定时间内未完成操作,则视为任务失败。对于在试验过程中出现明显恐惧反应的受试者,可允许其在安全范围内的最近位置进行观察,以保障试验安全与受试者身心状态稳定。

试验结束后,受试者需填写主观不舒适度量表 (Subjective Units of Distress, SUDS),以评估其在试验过程中的心理不适程度。该量表采用 0 ~ 10 分的评分方式,其中,0 代表完全平静,10 表示极度恐惧。根据受试者的评分结果,本文将情绪状态划分为平静 (0 ~ 3 分)、轻度恐惧 (4 ~ 7 分) 和重度恐惧 (8 ~ 10 分) 等 3 类。上述分类结果同时作为后续机器学习模型训练与情绪识别的标注依据。试验流程见图 5。

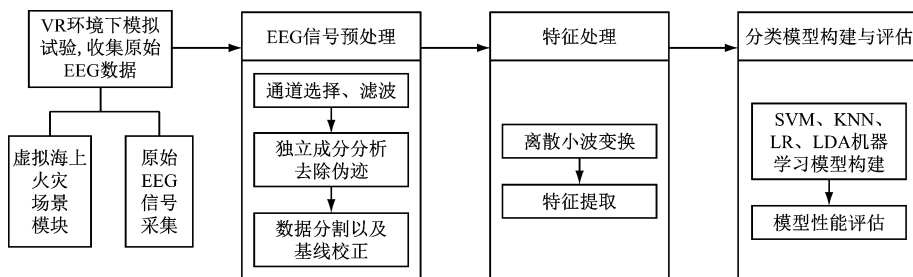


图5 试验流程

Fig. 5 Experimental workflow diagram

## 2 数据预处理与特征提取

### 2.1 脑电数据预处理

由于脑电信号是一种一维时间序列信号,其具有信噪比低,信号质量不稳定等特性,导致原始信号存在噪声过大,伪迹干扰等影响,降低试验结果准确率。因此,需对原始脑电信号进行预处理,具体步骤如下:

1) 通道选择:研究表明,额叶区域附近的对称电极在恐惧情绪识别中表现出较高的敏感性和区分度<sup>[15]</sup>。因此,本试验选取位于额叶区域的 F3 和 F4 这 2 个通道作为分析对象。

2) 滤波处理:采用带通滤波器将信号频率范围限定在 1 ~ 60 Hz,以消除低频直流漂移;同时,运用陷波滤波器去除 50 Hz 的电源干扰成分,确保信号的纯净度。

3) 伪迹去除:利用独立成分分析 (Independent Component Analysis, ICA) 方法分离并去除眼电、肌电等伪迹信号,并结合绝对阈值法剔除存在明显异常的信号片段。

4) 数据分割与基线校正:在采样率为 128 Hz 的条件下,以 2 s 为时间窗口对数据进行分段,从而扩充样本量;同时进行基线校正,以减小信号漂移对分析结果的影响。

经过预处理后的脑电信号见图 6,所有的预处理步骤均通过 MATLAB 中的 EEGLAB 工具箱进行。




图 6 预处理后的脑电信号

Fig. 6 Preprocessed EEG signals

### 2.2 特征提取

#### 2.2.1 离散小波变换

脑电信号属于典型的一维时间序列数据,由于其具有显著的非平稳特性,仅依靠时域或频域分析难以全面反映其特征信息。离散小波变换 (Discrete Wavelet Transform,  $D_{WT}$ ) 能将信号分解为不同尺度的小波分量,从而在高分辨率层面同时捕捉时间与频率特征。该方法能有效表征信号的瞬态变化特性,因此,在处理非平稳信号时具有更高的适用性与分析精度。离散小波变换将信号分解为近似系数 (Approximation Coefficients)  $A[n]$  和细节系数 (Detail Coefficients)  $D[n]$ 。 $A[n]$  包含脑电信号的低频信息, $D[n]$  包含了脑电信号的高频信息。然后

将近似系数通过滤波器进一步分解为下一级的近似系数和细节系数。高通滤波器用于下采样提取信号的细节,低通滤波器用于提取信号的近似。信号  $x(t)$  的  $D_{WT}$  为

$$D_{WT}(j, k) = \int_{-\infty}^{+\infty} \frac{x(t)}{\sqrt{|2^j|}} \varphi\left(\frac{t - 2^j k}{2^j}\right) dt \quad (1)$$

式(1)中: $\varphi(\cdot)$  为小波基函数; $k$  为滤波次数; $j$  为尺度系数。

该试验所使用的脑电信号采样率为 128 Hz,根据奈奎斯特采样定理,最大有效采样率为脑电信号采样频率的 1/2,即 64 Hz。本文的  $D_{WT}$  采用 Daubechies 小波对脑电信号进行小波变换,4 层离散小波分解见图 7。Daubechies 小波是定义离散小波变换的正交小波,一般简写成 db $N$ ,其中  $N$  是小波阶数,随着阶次的增加消失矩阶数增加,采用 db4 小波进行分解。在一级分解中,脑电信号(0 ~ 64 Hz)被分解为细节分量  $D_1$ (32 ~ 64 Hz) 和近似分量  $A_1$ (0 ~ 32 Hz),以此类推,经过四阶分解,脑电信号被分解为  $D_1$ (32 ~ 64 Hz)、 $D_2$ (16 ~ 32 Hz)、 $D_3$ (8 ~ 16 Hz)、 $D_4$ (4 ~ 8 Hz) 和  $A_4$ (0 ~ 4 Hz) 这 5 个子频带,这 5 个子频段分别对应于生理上的 Gamma、Beta、Alpha、Theta 和 Delta 等 5 个子频段,见表 1。这 5 个子频段共同作用于主观不适度

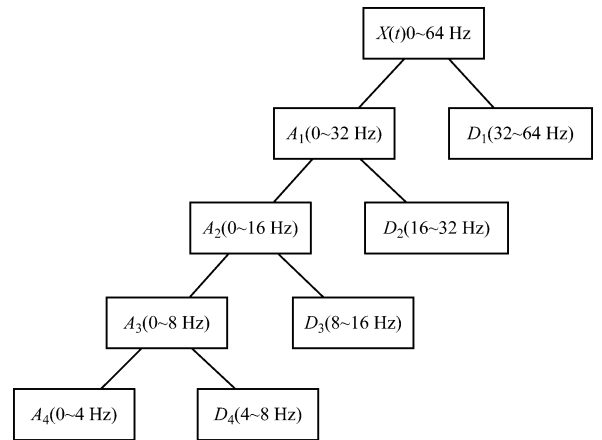


图 7 4 层离散小波分解

Fig. 7 4-level wavelet decomposition of EEG signals

表 1 5 种脑电波频段

Tab. 1 Five EEG wave frequency bands

信号频率/Hz	对应波形	情绪状态
0 ~ 4	Delta ( $\delta$ 波)	深度睡眠,深层次的放松状态
4 ~ 8	Theta ( $\theta$ 波)	精神受挫,情绪处于压抑状态
8 ~ 16	Alpha ( $\alpha$ 波)	放松,平静状态
16 ~ 32	Beta ( $\beta$ 波)	紧张,压力较大的状态
32 ~ 64	Gamma ( $\gamma$ 波)	激动,亢奋的状态

量表所划分的3种情绪,可全方位地显示受试人员的情绪状态。例如在研究中发现Beta波的变化通常与恐惧、焦虑等情绪的增加有关<sup>[16]</sup>,Gamma频段在情绪识别中起着重要作用<sup>[17]</sup>。通过对5个子频段的特征进行提取可以多维度,更全面地对受试人的情绪进行分析。

### 2.2.2 特征选取

在将原始信号分解为5个子频段之后,提取几种主要的特征对脑电信号进行特征降维。研究表明<sup>[18]</sup>,用 $M$ 表示提取平均绝对值,表示脑电信号在一段时间内的平均振幅,可捕捉信号的整体强度; $S$ 表示标准差,用于度量信号的离散程度; $R$ 表示均方根,是脑电信号能量的度量。这3种统计特征可有效地对脑电信号进行情绪识别,是脑电信号能量的度量。因此,本文对5个子频段的3种特征进行提取。具体计算见式(2)~式(4)。

$$M = \frac{1}{n} \sum_{i=1}^n |x_i| \quad (2)$$

$$S = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n-1}} \quad (3)$$

$$R = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n}} \quad (4)$$

式(2)~式(4)中: $n$ 为脑电数据总量; $x_i$ 为第 $i$ 个脑电数据; $\mu$ 为脑电数据均值。

通过上述方法提取脑电数据5个子频段中共计15个特征,因为不同特征之间存在着尺度差异,为避免影响分类模型的性能,对上述15个特征进行无量纲化处理,消除特征之间的尺度差异。

## 3 特征分类

### 3.1 SVM模型

支持向量机(Support Vector Machine, SVM)是一种监督式机器学习方法,在处理高维度的非线性分类问题时有着广泛地应用。

在传统的线性可分问题中,SVM寻找一个超平面将两类数据分开,这个超平面可用函数 $f(x) = \mathbf{w}^T \mathbf{x} + b$ 表示。而对于非线性问题,SVM则是先在低维空间中完成运算,然后通过核函数 $k(x_i, y_i)$ 将样本从低维空间映射到高维空间。核函数可直接在特征空间中进行内积计算,从而避免了高维空间中的复杂运算。

本文使用高斯核函数,将15个特征映射到高维空间中寻找最优平面进行分类。定义核 $k$ 为

$$k(x_1, x_2) = \exp\left(-\frac{\|x_1 - x_2\|^2}{2\sigma^2}\right) \quad (5)$$

式(5)中: $\sigma$ 控制高斯核函数的作用范围, $\sigma$ 越大,高斯核函数的影响越大, $\sigma$ 越小,则会导致过拟合。将 $x$ 映射到特征空间得到特征向量 $\Phi(x)$ ,此时的最优分类函数为

$$f(x) = \text{sign}\left(\sum_{i=1}^n a_i y_i k(x_1, x_2) + b\right) \quad (6)$$

式(6)中: $a_i$ 为拉格朗日乘子; $b$ 为偏置量。

传统的支持向量机算法主要用于二分类任务,而本试验需将恐惧情绪划分为3种类型,因此,本文引入错误纠正输出编码(Error Correcting Output Codes, ECOC)方法来实现多分类处理。该方法是一种常见的多对多分类策略,通过引入编码与解码机制提升分类精度与鲁棒性。

具体而言,ECOC先对所有类别进行编码,将多个类别划分为若干组,每次将部分类别设为正类、其余设为反类,从而构建出多个二元分类器。编码完成后形成一个矩阵,其中行对应类别,列对应分类器。随后进入解码阶段,利用这些分类器对样本进行预测,并将输出的编码结果与各类别的标准编码进行比对,选择距离最近的编码所对应的类别作为最终识别结果。各输出编码不仅代表预测类别的置信度,还具备一定的纠错能力。通过适当增加编码长度,可有效地提升模型的容错性和分类性能,但同时也会带来计算复杂度的上升。

在本次试验中,SVM分类器的训练采用网格搜索法对惩罚系数和核函数参数进行优化。为提高模型的泛化性能,试验引入5折交叉验证策略,将15组试验样本按照4:1的比例划分为训练集与测试集。每次选取不同的数据子集作为测试集,重复验证5次,并以5次验证结果的平均值作为模型的最终性能指标,以降低个体差异带来的影响并提升模型的稳定性。

### 3.2 模型评估

在建立机器学习的分类模型后,需对模型的性能进行评估以选取最优的分类模型。分类结果采用混淆矩阵进行表征,并计算模型的准确率( $A$ )、精确率( $P$ )、召回率( $R$ )和 $F_1$ 值作为模型的评估参数。

混淆矩阵是用于评估模型分类性能的工具,本文将恐惧情绪划分为3个等级,因此采用三分类混淆矩阵表征分类结果。混淆矩阵共有真正(True Positive,  $T_P$ ),真负(True Negative,  $T_N$ ),假正(False Positive,  $F_P$ ),假负(False Negative,  $F_N$ )。对本文的

三类问题,样本的真实类型与模拟预测类型均为 3 类,对于 0 类来说,0 类脑电信号被视为正类 (Positive),非 0 类被视为负类(Negative)。

准确率是对于混淆矩阵整体计算的,指模型预测正确的结果占总观测值的占比,计算公式为

$$A = \frac{T_P + T_N}{T_P + T_N + F_N + F_P} \quad (7)$$

精确率是对于单类别计算的,指模型预测的本类结果中,预测正确的占比,以 0 类为例,有

$$P = \frac{T_P}{T_P + F_P} \quad (8)$$

召回率指在真实类别为本类的结果中,模型预测正确的占比,以 0 类为例,有

$$R = \frac{T_P}{T_P + F_N} \quad (9)$$

$F_1$  是综合考虑了精确度和召回率的调和值,综合评估模型性能的指标,当精确率和召回率的权重相同时,有

$$F_1 = 2 \frac{P \times R}{P + R} \quad (10)$$

通过上述评价指标,可评估分类模型的整体性能以及对于每一类的分类性能。本文选取其他几种在脑电信号情绪识别中常用的机器学习分类算法进行对比,包括 K 最近邻 (K Nearest Neighbors, KNN)<sup>[19]</sup>、逻辑回归 (Logistic Regression, LR)<sup>[20]</sup> 和线性判别分析 (Linear Discriminant Analysis, LDA)<sup>[21]</sup> 等 3 种分类算法。

## 4 试验结果分析

本文试验数据处理与算法实现平台为 13th Gen Intel(R) Core(TM) i5-13500HX CPU @ 2.50 GHz, 16 GB 运行内存,使用 MatlabR2023a 和 Python 进行数据处理与分析。

### 4.1 SUDS 量表结果

SUDS 量表结果见表 2。参加试验的 15 名被试人员在试验过程中均无不适现象,试验数据良好。被试人员在试验后填写的 SUDS 量表显示标签为平静的为 5 人,显示标签为轻度恐惧的为 4 人,显示标签为重度恐惧的为 6 人。样本标签均衡,SUDS 量表结果在统计学方面存在显著性差异( $p < 0.05$ )。

### 4.2 分类结果比较

本试验对比了 4 种分类算法,各模型的准确率见图 8。由图 8 可知:在 4 种分类算法中,SVM 的分类效果是最好的,达到 87.97%,并且较其他分类算法有显著的提升。其他分类算法也都有着较为良好

表 2 SUDS 量表结果

Tab.2 SUDS Scale results

情绪类别	人数/人
平静	5
轻度恐惧	4
重度恐惧	6

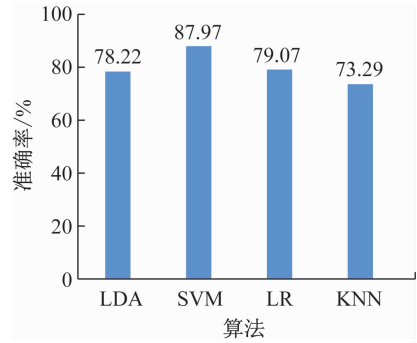


图 8 各分类算法准确率

Fig.8 Accuracy of various classification algorithms

的准确率,表明本试验所选取的特征与恐惧情绪有着强关联性,可较为有效地应用于船员恐惧情绪识别。

各分类算法中每一类的情绪类别、精确率、召回率和  $F_1$  Score 这 3 种模型评估参数,见表 3。分析表 3 数据可知,SVM 每一类的精确率、召回率和  $F_1$  均显著高于其他分类器,表示该模型在 3 种情绪类别中均可成功地覆盖绝大多数正类样本并且可有效地

表 3 分类模型评估参数

Tab.3 Evaluation parameters of classification models

分类算法	情绪类别/	精确率/	召回率/	$F_1$ Score/
	%	%	%	%
LDA	平静	71.83	79.52	75.48
	轻度恐惧	77.47	45.19	57.09
	重度恐惧	82.30	88.89	85.47
SVM	平静	86.47	84.87	85.66
	轻度恐惧	82.67	73.40	77.76
	重度恐惧	90.37	94.89	92.57
LR	平静	73.40	78.41	75.83
	轻度恐惧	76.15	53.21	62.64
	重度恐惧	83.18	88.44	85.73
KNN	平静	67.57	69.47	68.51
	轻度恐惧	54.76	54.50	54.63
	重度恐惧	82.49	81.36	81.92

避免误报,同时,在精确率和召回率上实现了良好的平衡,对于恐惧情绪的识别有着出色的性能。综上,SVM为最优分类器,对3种情绪类别赋予相同的权重,分类器总体精确率为85.52%,召回率为84.39%, $F_1$ 为84.92%。

SVM的分类算法混淆矩阵见图9,图9中:a、b、c分别表示平静、轻度恐惧和重度恐惧。SVM对于平静状态的召回率为84.9%,对于恐惧状态的召回率为94.9%,对于轻度恐惧状态的召回率为73.4%。由表3可知:在其他分类算法中也均有上述现象,可发现轻度恐惧情绪较平静与重度恐惧情绪更难识别,并且重度恐惧情绪具有最好的识别效果。




图9 SVM分类算法混淆矩阵

Fig.9 Confusion matrix for SVM classification algorithm

## 5 结束语

本文针对船员面对火灾时的情绪识别问题提出一种方法,旨在提高船员恐惧情绪识别的准确率。将VR技术与脑电情绪识别技术相结合,实现更好的情绪诱发,并将其引入到船员消防培训体系中;采用小波分解方法更好地对原始脑电信号进行分解并提取了各个频段有效的特征;比较多种分类器,并最终采用SVM分类器对提取的特征进行分类,得到87.97%的准确率并且模型各评估参数均表现良好。进行消防培训后,若船员的情绪识别为轻度恐惧,代表船员在面对火灾时的应急能力还有待加强,应该对船员进行补充培训;若船员的情绪识别为重度恐惧,代表船员在面对火灾时应对能力不足,应对船员重新进行培训。

本文的研究工作尚存在一些局限性:

1) 试验对于脑电信号在通用场景下的去噪过程较为简单,后续将进一步探究如何更好地在复杂场景下提升脑电信号的信噪比。

2) 单一的生理信号可能难以全面的体现情绪,后续的研究中可结合心电、肌电等生理信号进行分

析,以提高情绪识别的可靠性。

3) 虽然虚拟现实技术提供一个安全、可控和可重复的环境,但其与真实火灾场景之间仍存在一定的差异性,后续的研究可考虑通过多感官融合技术,进一步增强虚拟现实场景的真实感。

## 参 考 文 献

- [1] 陶阳. 船舶典型环境下火灾特征演化规律实验研究[D]. 武汉:中国地质大学, 2020.  
TAO Y. Experimental investigation on the fire characteristics evolution under typical ship environmental conditions [D]. Wuhan: China University of Geosciences, 2020. (in Chinese)
- [2] REN J, JENKINSON I, WANG J, et al. A methodology to model causal relationships on offshore safety assessment focusing on human and organizational factors [J]. Journal of Safety Research, 2008, 39(1): 87-100.
- [3] 周丰丰, 朱海洋. 基于三段式特征选择策略的脑电情感识别算法SEE [J]. 吉林大学学报(工学版), 2022, 52(8): 1834-1841.  
ZHOU F F, ZHU H Y. SEE: sense EEG-based emotion algorithm via three-step feature selection strategy [J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(8): 1834-1841. (in Chinese)
- [4] MOKATREN L S, ANSARI R, CETIN A E, et al. EEG classification by factoring in sensor spatial configuration [J]. IEEE Access, 2021, 9: 19053-19065.
- [5] DU X, MENG Y, QIU S, et al. EEG emotion recognition by fusion of multi-scale features [J]. Brain Sciences, 2023, 13(9): 1293.
- [6] 戚春华, 刘昱忻, 李航天, 等. 基于驾驶员警觉度的交通标志适宜信息量研究 [J]. 科学技术与工程, 2021, 21(34): 14829-14835.  
QI C H, LIU Y X, LI H T, et al. Appropriate information volume of traffic sign based on driver alertness [J]. Science Technology and Engineering, 2021, 21(34): 14829-14835. (in Chinese)
- [7] 崔志翔, 陈大伟, 吴东苏, 等. 飞行员异常事件处理能力的脑电评估方法 [J]. 科学技术与工程, 2022, 22(30): 13562-13568.  
CUI Z X, CHEN D W, WU D S, et al. EEG-based evaluation method for pilot's abnormal event handling competency [J]. Science Technology and Engineering, 2022, 22(30): 13562-13568. (in Chinese)
- [8] HEALEY J A, PICARD R W. Detecting stress during real-world driving tasks using physiological sensors [J]. IEEE Transactions on intelligent transportation systems, 2005, 6(2): 156-166.

- [9] FAN S, ZHANG J, BLANCO-DAVIS E, et al. Effects of seafarers' emotion on human performance using bridge simulation [J]. *Ocean Engineering*, 2018, 170: 111-119.
- [10] 刘清, 万志远, 杨柳, 等. 基于 EEG 的船舶驾驶员工作负荷识别研究 [J]. *武汉理工大学学报(交通科学与工程版)*, 2022, 46(5): 759-763.  
LIU Q, WAN Z Y, YANG L, et al. Identification of workload for seafarers based on EEG [J]. *Journal of Wuhan University of Technology (Transportation Science & Engineering Edition)*, 2022, 46(5): 759-763. (in Chinese)
- [11] LIU Y, LAN Z, SOURINA O, et al. EEG-based cadets training and performance assessment system in maritime virtual simulator[C]//2018 International Conference on Cyberworlds (CW). New York:IEEE, 2018: 214-220.
- [12] LI J, JIN Y, ZHAO R, et al. Using the EEG + VR + LEC evaluation method to explore the combined influence of temperature and spatial openness on the physiological recovery of post-disaster populations [J]. *Building and Environment*, 2023, 243: 1-15.
- [13] BASBASSE Y E, PACKHEISER J, PETERBURS J, et al. Walk the plank! using mobile electroencephalography to investigate emotional lateralization of immersive fear in virtual reality [J]. *Royal Society Open Science*, 2023, 10(5): 1-20.
- [14] 李晓军, 凌加鑫, 沈奕, 等. 基于虚拟现实技术的隧道内光源色温对司驾安全的影响 [J]. *同济大学学报(自然科学版)*, 2021, 49(2): 204-210.  
LI X J, LING J X, SHEN Y, et al. Effect of color temperature of light source in tunnel on driving safety based on virtual reality technology [J]. *Journal of Tongji University (Natural Science)*, 2021, 49(2): 204-210. (in Chinese)
- [15] MASOOD N, FAROOQ H. Investigating EEG patterns for dual-stimuli induced human fear emotional state [J]. *Sensors*, 2019, 19(3): 522-535.
- [16] DE CARVALHO M R, VELASQUES B B, FREIRE R C, et al. Frontal cortex absolute beta power measurement in panic disorder with agoraphobia patients [J]. *Journal of Affective Disorders*, 2015, 184: 176-181.
- [17] LI M, LU B L. Emotion classification based on gamma-band EEG[C]//2009 Annual International Conference of the IEEE Engineering in medicine and biology society. New York:IEEE, 2009: 1223-1226.
- [18] KHAIRUDDIN I M, SIDEK S N, MAJEED A P, et al. The classification of movement intention through machine learning models: the identification of significant time-domain EMG features [J]. *PeerJ Computer Science*, 2021, 7(1): 1-15.
- [19] 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(S1): 509-519.
- [20] ZHENG W L, SANTANA R, LU B L. Comparison of classification methods for EEG-based emotion recognition [C]//World Congress on Medical Physics and Biomedical Engineering, Canada. ;Springer International Publishing, 2015: 1184-1187.
- [21] TREDER M S, PORBADNIGK A K, AVARVAND F S, et al. The LDA beamformer: optimal estimation of ERP source time series using linear discriminant analysis [J]. *Neuroimage*, 2016, 129: 279-291.