

doi: 10.19562/j.chinasae.qcgc.2025.05.015

# 基于腿部sEMG的驾驶疲劳状态判别方法\*

俞宁<sup>1</sup>, 罗晓茗<sup>1</sup>, 舒梓荣<sup>1</sup>, 李博远<sup>2</sup>, 张颜<sup>3</sup>

(1. 重庆理工大学机械工程学院, 重庆 400054; 2. 高机动防暴车辆技术国家工程研究中心, 北京 100072;  
3. 重庆邮电大学计算机科学与技术学院, 重庆 400065)

**[摘要]** 基于驾驶员腿部的表面肌电信号提出一种非侵入式的驾驶疲劳状态判别方法。首先,通过模拟驾驶疲劳实验采集驾驶员右腿胫骨前肌的肌电信号,并通过主观评价量表进行疲劳状态的标注。其次,采用变分模态分解算法对表面肌电信号进行噪声滤除,并从分解得到的5个IMF分量中提取12个时频域特征值。最后,构建基于鲸鱼算法优化支持向量机的驾驶疲劳状态判别模型。结果表明:该方法对于3种疲劳状态具有较好的判别效果,其准确率可达84%以上。

**关键词:** 驾驶疲劳; 表面肌电信号; 疲劳状态判别

## A Discriminative Method for Driving Fatigue State Based on Leg sEMG

Yu Ning<sup>1</sup>, Luo Xiaoming<sup>1</sup>, Shu Zirong<sup>1</sup>, Li Boyuan<sup>2</sup> & Zhang Yan<sup>3</sup>

1. School of Mechanical Engineering, Chongqing University of Technology, Chongqing 400054;

2. National Engineering Research Center for High Mobility Anti-riot Vehicle Technology, Beijing 100072;

3. School of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065

**[Abstract]** A non-invasive driving fatigue state identification method based on the surface electromyographic signals of the driver's legs is proposed. Firstly, the electromyographic signal of the tibialis anterior muscle of the driver's right leg is collected through a simulated driving fatigue experiment, and the fatigue status is marked through a subjective evaluation scale. Secondly, a variational mode decomposition algorithm is used to filter out noise on the surface electromyographic signal, and 12 time-frequency domain eigenvalues are extracted from the five IMF components obtained by decomposition. Finally, a driving fatigue state discrimination model based on whale algorithm optimized support vector machine is constructed. The results show that this method has a good discrimination effect on three fatigue states, with an accuracy of more than 84%.

**Keywords:** driving fatigue; surface electromyographic signals; fatigue state classification

## 前言

随着汽车保有量的不断上升,交通安全问题日益严重。其中,驾驶疲劳被广泛认为是造成道路交通事故的重要原因之一<sup>[1]</sup>。据相关数据表明,驾驶疲劳导致的交通事故占总交通事故数的8.41%<sup>[2]</sup>。驾驶疲劳会导致驾驶员的反应速度下降、判断能力降低,以及注意力分散和操作失误,从而使其难以

时应对突发情况<sup>[3]</sup>。因此,准确识别驾驶员不同疲劳程度对于采取对应措施至关重要。

国内外众多学者对驾驶疲劳问题进行了深入研究。目前,驾驶疲劳判别方法主要有:(1)基于车辆行驶状态的判别方法<sup>[4-5]</sup>;(2)基于驾驶员行为特征的判别方法<sup>[6-8]</sup>;(3)基于驾驶员生理参数的判别方法<sup>[9-12]</sup>。其中,利用生理信号判别疲劳状态的方法受外部环境和主观因素的影响较小,准确性和客观性较高<sup>[13-14]</sup>,因此受到广泛应用。在生理参数检测方

\* 高机动防暴车辆技术国家工程研究中心开放基金(2023NELEV003)资助。

原稿收到日期为2024年11月20日,修改稿收到日期为2025年01月09日。

通信作者:俞宁,副教授,博士,E-mail:yuning@cqut.edu.cn。

法中,脑电信号和心电信号采集设备对驾驶员的干扰较大,且具有更强的侵入性和较差的抗干扰能力,不利于实际应用。而相比之下,表面肌电信号(sEMG)采集设备对驾驶员的影响较小,且更容易实现,具有很好的实用性。此外,sEMG具有无损伤性、实时性和高灵敏度的特点,使其在疲劳检测中具有独特的优势。相关研究表明,随着疲劳程度的加深,sEMG的频率特征和振幅都会发生显著变化<sup>[15-16]</sup>。因此,许多研究已通过sEMG来判别驾驶员的疲劳状态<sup>[17-19]</sup>。文献[11]中在转向盘上安装肌电传感器采集驾驶员的sEMG,并通过多层特征来识别驾驶员疲劳状态,取得了较高的识别效果。文献[12]中通过驾驶员颈腰部的sEMG来判别疲劳状态,取得较高的识别准确率。

据此,针对长时间驾驶、道路拥堵和道路颠簸等场景下,驾驶员反复踩踏制动和加速踏板,容易出现腿部肌肉疲劳。探究腿部肌肉疲劳与驾驶之间的关系,并建立相应的驾驶疲劳状态判别方法是当前研究的热点之一。本文基于驾驶员腿部sEMG提出一种非侵入式的驾驶疲劳状态判别方法,主要研究内容如下:(1)采用Borg CR10量表的主观评价结果对sEMG进行标注,确定了轻度、中度和重度3种疲劳状态;(2)通过变分模态分解算法(VMD)对sEMG数据进行噪声滤除与信号分解,保证了数据质量;(3)针对重度疲劳类别分类预测准确率较低的问题,采用鲸鱼算法(WOA)优化支持向量机分类器(SVM),提升了驾驶疲劳状态分类模型的整体分类预测准确率。

## 1 模拟驾驶疲劳实验

### 1.1 实验条件

本实验基于51-World汽车驾驶模拟器完成实验平台的搭建。模拟驾驶实验平台和肌电采集设备如图1所示。该平台由驾驶舱、3块投影环幕、6自由度控制支架等组成。采用Physiolab无线生理仪实时采集驾驶员的腿部sEMG数据,采样频率为2 000 Hz。

实验场景为拥堵路段场景,应用51-Simone道路仿真软件,建立了拥堵路段的模拟驾驶场景,选择双向四车道高速路进行模拟驾驶实验研究,车辆密度设计如图2所示。

### 1.2 实验对象

据报告,青年男性往往是驾驶疲劳造成道路安




图1 实验设备

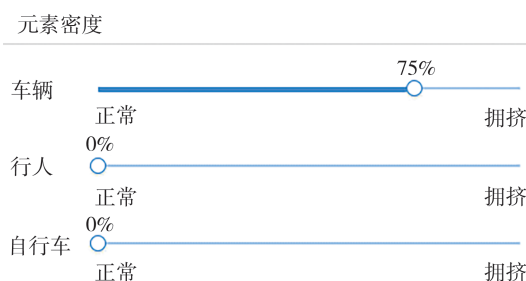


图2 车辆密度仿真

全事故的高危群体<sup>[20]</sup>。因此,本实验选择了10名年龄在22~28岁之间的男性受试者参与模拟驾驶疲劳实验。受试者基本信息如表1所示。这些受试者均持有有效驾驶证,身体状况良好,无肌肉疾病或神经系统疾病等健康问题。

表1 受试者基本信息

类别	均值	标准差
年龄/岁	24.6	1.56
驾龄/年	3.3	1.42
身高/cm	173.7	5.62
体质量/kg	70.8	10.38

在模拟驾驶实验前,首先对胫骨前肌和腓肠肌进行对比实验,以选择待测肌肉。对比结果如图3所示。胫骨前肌相对腓肠肌的频率更高,幅值更大,更容易产生疲劳。因此,本实验选择受试者右腿胫骨前肌作为信号采集部位。胫骨前肌位置及采集方式如图4所示。将两个工作电极片粘贴在经过清洁后的胫骨前肌皮肤表面上,两个工作电极片的中心距离为2 cm,参考电极贴工作电极外侧10 cm范围内。

### 1.3 量表选择

针对驾驶员腿部肌肉疲劳问题,本研究选择常用于评价肌肉疲劳的Borg CR10量表<sup>[21-22]</sup>。量表如表2所示。根据量表对原始11个等级进行重新分




图3 待测肌肉sEMG对比




图4 胫骨前肌位置及采集方式

级。其中0-0.5级为不疲劳,1-2级为轻度疲劳,3-4级为中度疲劳,5-10级为重度疲劳。

表2 Borg CR10主观疲劳感知评估量表

评分	描述	分级
0	没有任何感觉	不疲劳
0.5	极微弱(仅能被察觉)	
1	非常微弱	轻度疲劳
2	轻度	
3	中度	中度疲劳
4	稍重度	
5	重度	重度疲劳
6		
7	很重度	
8		
9	极重度(几乎最大)	
10	最大	

### 1.4 实验过程

实验前须完成设备调试以及为受试者粘贴电极片,受试者进行10 min的预实验以适应模拟驾驶。实验中受试者须进行3 h的模拟驾驶,同时实验员根据Borg量表定期对受试者的疲劳状态进行主观询问,并使用events插件标注疲劳状态。

## 2 sEMG数据预处理

通过模拟驾驶实验,完成了10名受试者的驾驶疲劳数据采集。实验数据包括受试者的腿部胫骨前肌sEMG、自我评价的疲劳状态和疲劳状态标签文件3部分。整个实验过程中,受试者均出现了不同程度的腿部肌肉疲劳现象。由于实验数据存在噪声干扰,须对数据进行降噪预处理。

### 2.1 数据切割

为便于后续时频域特征的提取与驾驶疲劳状态的判别,须对原始sEMG数据与疲劳状态标注数据进行时刻上的匹配,并对原始sEMG数据进行数据切割。sEMG时刻数据与疲劳状态标注时刻数据的计算公式为

$$T_i = \mu t_i \tag{1}$$

式中: $T_i$ 为sEMG的时刻数据; $\mu$ 为采样率; $t_i$ 为疲劳状态标注时刻数据。

图5和图6是实验得到sEMG文本数据与疲劳状态标注文本数据,其中“1”、“2”、“3”分别表示轻

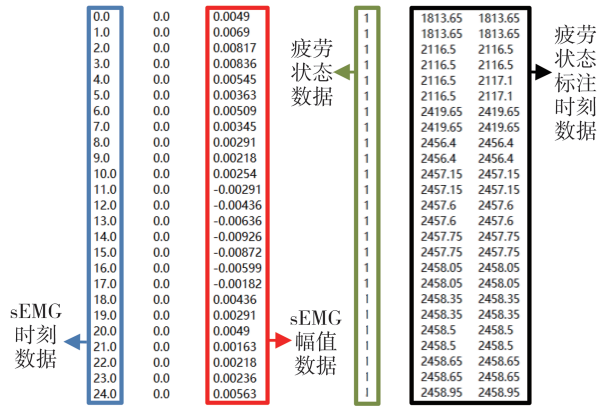


图5 sEMG文本数据 图6 疲劳状态标注文本数据

度、中度与重度3种疲劳状态。根据式(1)进行时刻上的匹配,并得到如表3所示的3类标签的起始节点。

随后按5 s的时间间隔为一个样本,将原始

表3 3类标签起始节点

实验员	轻度疲劳起点	轻度疲劳终点	中度疲劳起点	中度疲劳终点	重度疲劳起点	重度疲劳终点
A	1 813	5 108	5 417	6 862	7 145	7 809
B	1 925	5 122	5 199	7 006	7 104	7 788
C	1 924	5 222	5 520	7 674	7 822	8 145
D	1 807	5 108	5 404	6 804	6 850	7 208
E	1 864	5 409	5 742	7 969	8 168	9 308
F	1 837	5 136	5 438	7 125	7 177	8 104
G	1 785	5 107	5 413	7 144	7 206	7 811
H	1 814	5 145	5 410	6 969	7 110	7 541
I	1 811	5 117	5 406	7 108	7 179	7 803
J	1 810	5 108	5 430	6 881	7 020	7 850

sEMG文本数据切割为如图7所示的文本数据,并为每个数据样本打上3种疲劳状态类别的标签。最终总样本为11 370组,其中轻度疲劳样本6 633组,中度疲劳样本3 427组,重度疲劳样本1 310组。




图7 数据切割后的sEMG文本数据

切割后的sEMG数据的图像如图8所示。

### 2.2 基于VMD算法的噪声滤除

为解决信号中存在的噪声干扰,本研究采用VMD算法对噪声进行滤除。VMD算法可以自适应地将原始sEMG分解为多个IMF分量,在变分框架内构造变分模型,从而获得模型的最优解<sup>[23]</sup>。VMD算法过程如下。

(1) $u_k(t)$ 为分解的 $K$ 个模态,每个模态具有中心频率 $\omega_k$ ,模态 $u_k(t)$ 可以表示为振幅 $A_k(t)$ 和相位 $\varphi_k(t)$ 的函数:

$$u_k(t) = A_k(t) \cos[\varphi_k(t)] \tag{2}$$

(2)VMD算法通过解决以下优化问题来分解信号:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \sum_{k=1}^K \|\partial_t \{ [u_k(t) + j\hat{u}_k(t)] \} e^{-j\omega_k t} \|^2 \\ \text{s. t. } \sum_{k=1}^K u_k(t) = x(t) \end{cases} \tag{3}$$

式中: $x(t)$ 表示sEMG; $j$ 是虚数单位; $\hat{u}_k(t)$ 是由 $u_k(t)$ 的希伯特变换得到的。

(3)引入拉格朗日乘子 $\lambda$ 和惩罚因子 $\alpha$ :

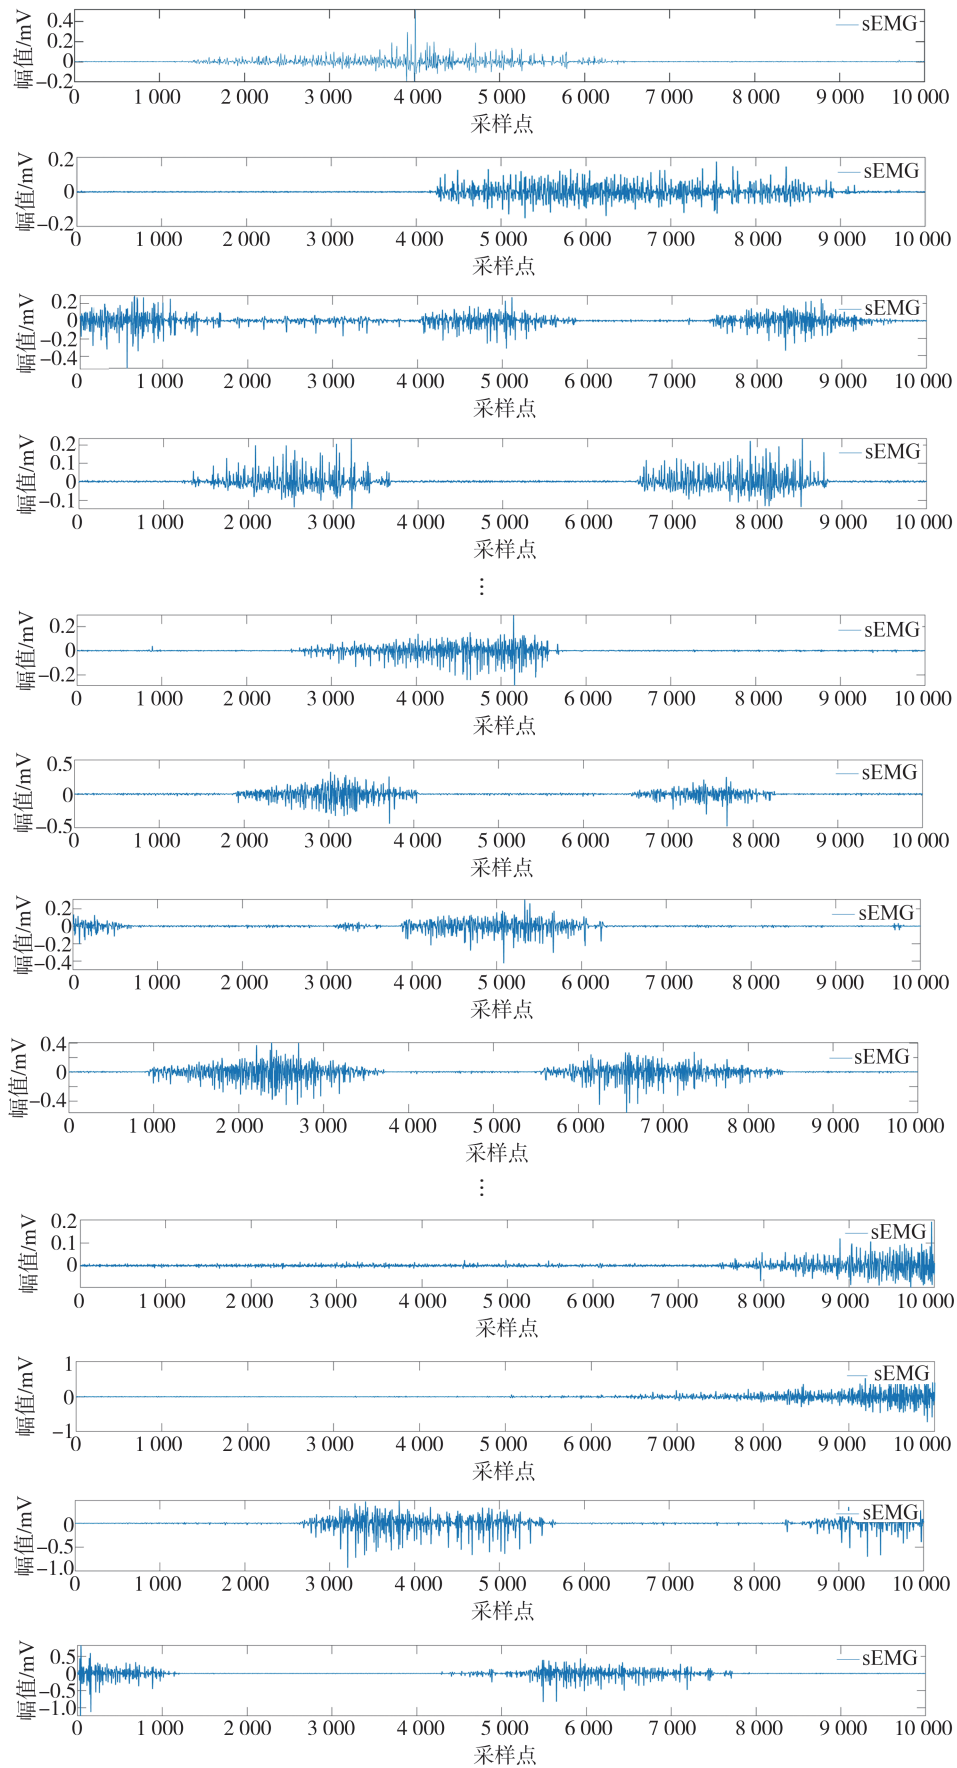


图8 数据切割后的sEMG数据

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left\{ [u_k(t) + j\hat{u}_k(t)] \right\} e^{-j\omega_k t} \right\|_2^2 + \left\| \sum_{k=1}^K u_k(t) - x(t) + \frac{\lambda(t)}{2\alpha} \right\|_2^2 \quad (4)$$

(4)使用交替方向乘法(ADMM)求解上述优化问题,交替更新 $u_k(t)$ 、 $\omega_k$ 、 $\lambda(t)$ 。

(5)对于每个 $K$ ,固定 $\omega_k$ 和 $\lambda(t)$ ,更新 $u_k(t)$ 为

$$u_k^{n+1}(t) = \arg \min_{u_k} \left\{ \partial \sum_{k=1}^K \left\| \partial_t \left\{ [u_k(t) + j\hat{u}_k(t)] \right\} e^{-j\omega_k t} \right\|_2^2 + \left\| \sum_{k=1}^K u_k(t) - x(t) + \frac{\lambda(t)}{2\alpha} \right\|_2^2 \right\} \quad (5)$$

(6)对于每个 $K$ ,固定 $u_k(t)$ 和 $\lambda(t)$ ,更新 $\omega_k$ 为

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega \hat{u}_k^{n+1}(\omega) e^{j\omega t} d\omega}{\int_0^\infty \hat{u}_k^{n+1}(\omega) e^{j\omega t} d\omega} \quad (6)$$

(7)更新拉格朗日乘数 $\lambda(t)$ :

$$\lambda^{n+1}(t) = \lambda^n(t) + 2\alpha \left( x(t) - \sum_{k=1}^K u_k^{n+1}(t) \right) \quad (7)$$

(8)当满足以下条件时停止迭代:

$$\frac{\sum_{k=1}^K \|u_k^{n+1}(t) - u_k^n(t)\|}{\sum_{k=1}^K \|u_k^n(t)\|} < \varepsilon \quad (8)$$

式中 $\varepsilon$ 为正整数,用于控制VMD的收敛速度。

本文将原始sEMG进行变分模态分解,输入初始 $K=2$ ,迭代后确定 $K=5$ 时,sEMG的分解效果最好。分解得到的5个IMF分量幅值均在零刻度线上下对称振荡,符合sEMG的幅值分布特征,有效滤除了信号中存在的噪声。分解后的5个IMF分量如图9所示。




图9 VMD分解图

### 3 时频域特征提取与分析

时域特征是评估信号特征的重要指标,可分为有量纲参数与无量纲参数<sup>[24]</sup>。本研究提取的是有量纲时域特征值,主要有最大值、最小值、均方根值、幅值均值、符号变化数、方差、峰度、偏度、样本熵、绝对

平均值。此外,肌电信号的频域特征也能够有效反映肌肉的收缩和放松状态。因此,本文通过对sEMG进行快速傅里叶变换来提取sEMG的频域特征,提取的频域特征包括中值频率和平均功率频率。

通过计算sEMG的时频域特征值,得到了如图10所示的sEMG数据的时频域特征变化趋势。时域特征中的最大最小值呈上升趋势,表明胫骨前肌运

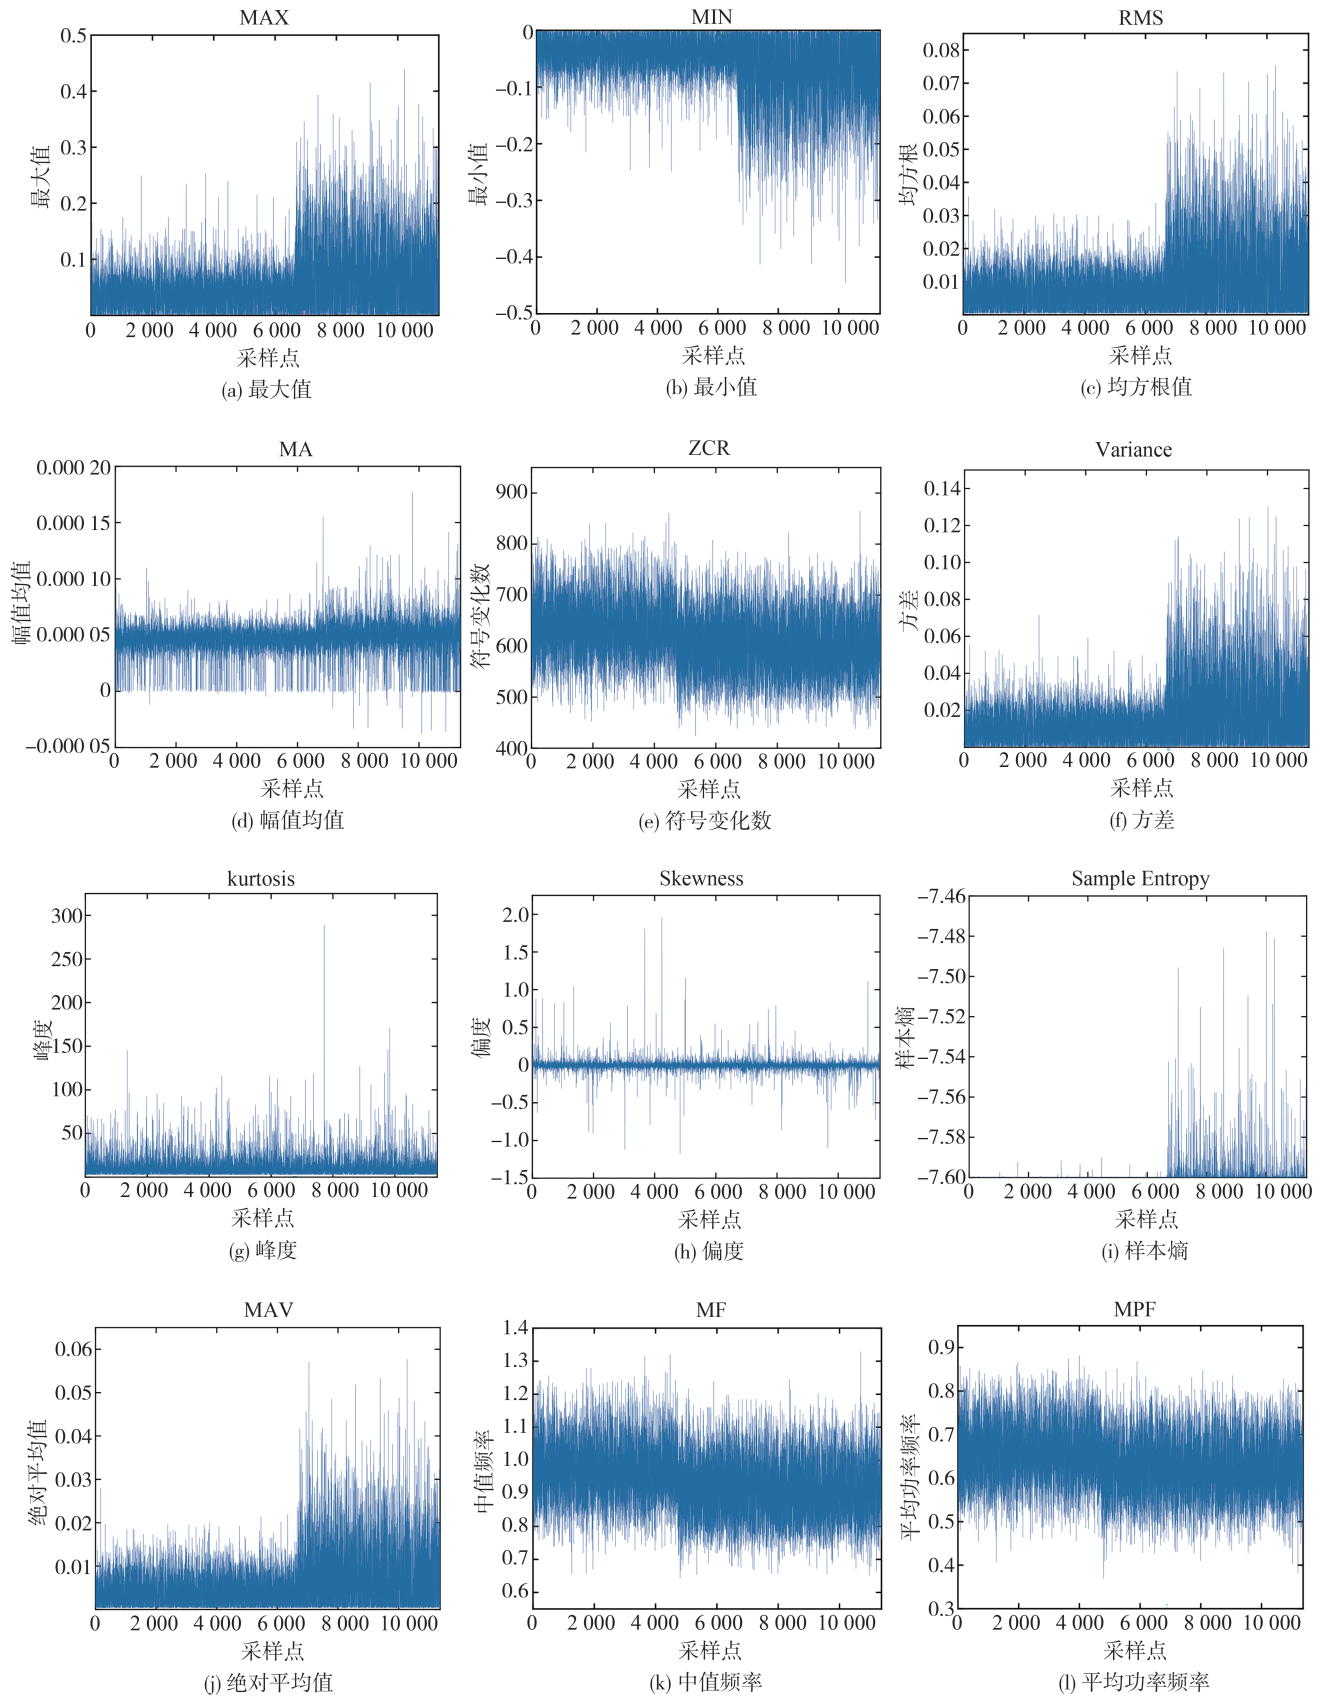


图10 时频域特征值

动单位参与肌纤维放电总量增大,随着驾驶时长的增加,疲劳程度加重。均方根、方差、幅值均值、峰度、样本熵与绝对平均值变化幅度明显增大,表明胫骨前肌的收缩程度增大,疲劳程度加深。符号变化数与偏度随着疲劳的加深整体向下偏移,反映肌肉活动的减少。频域特征中的中值频率和平均功率频率总体分布下降,表明胫骨前肌的电信号中低频成分比例上升,疲劳程度加重。

## 4 驾驶疲劳状态判别模型

### 4.1 SVM方法

SVM是一种基于VC维理论和结构风险最小原理的分类方法,具有较好的泛化能力<sup>[25]</sup>。即使在样本量有限的情况下,也能获得较低的误差。本研究提取的时频域特征值为线性不可分的样本数据,具体研究内容如下。

设训练样本映射后的特征向量为 $\phi(x)$ ,特征空间中的划分超平面可定义为

$$f(x) = w^T \phi(x) + b \tag{9}$$

式中: $w$ 是法向量; $b$ 是位移项。引入惩罚因子 $c$ 与松弛变量 $\varepsilon$ :

$$\min_{w,b} \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n \varepsilon \tag{10}$$

对偶问题为

$$\max_a \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \phi(x_i)^T \phi(x_j) \tag{11}$$

定义核函数:

$$\kappa(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle = \phi(x_i)^T \phi(x_j) \tag{12}$$

将式(12)代入式(21)得:

$$\max_a \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \kappa(x_i, x_j) \tag{13}$$

求解后可以得到最优分类函数:

$$f(x) = w^T \phi(x) + b = \sum_{i=1}^n \alpha_i y_i \kappa(x_i, x_j) + b \tag{14}$$

本研究将疲劳状态分为轻度、中度和重度3个疲劳类别,在利用SVM进行疲劳状态的分类时,属于 $m = 3$ 的线性不可分SVM三分类问题。选取核函数 $\kappa(x_i, x_j)$ 为高斯径向基函数,最优分类函数可表示为

$$f_3(x) = \max_{m \in \{1, 2, 3\}} \left\{ \sum_{i=1}^n \alpha_i y_i \left( -\frac{\|x_i - x_j\|^2}{2\sigma^2} + b_j \right) \right\} \tag{15}$$

### 4.2 SVM分类结果

在本研究中,将样本数据集中的80%作为训练

集,剩余的20%样本数据作为测试集。如图11和图12所示,SVM驾驶疲劳状态分类模型训练集的准确率为86.94%,测试集的准确率为82.89%。该模型正确预测轻度疲劳6482次,错误识别为中度和重度疲劳135次和16次;正确预测中度疲劳2780次,错误识别为轻度和重度疲劳551次和96次;正确预测重度疲劳531次,错误识别为轻度和中度疲劳194次和585次。

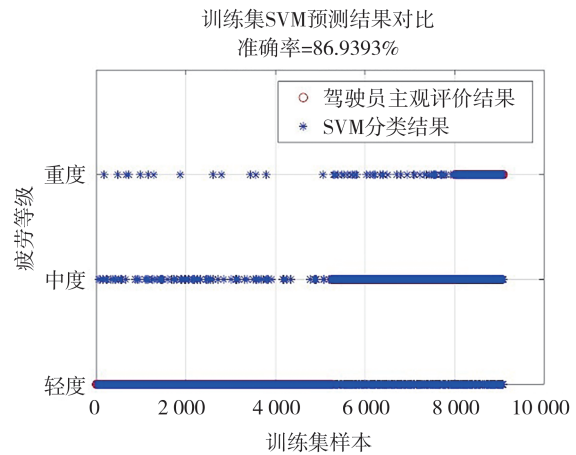


图11 SVM训练集分类效果图




图12 SVM测试集分类效果图

通过分类结果计算出3种疲劳状态类别的分类预测准确率,并绘制混淆矩阵,如图13所示。从图中可以看出,SVM驾驶疲劳状态分类模型对轻度疲劳样本数据的分类预测准确率为97.72%;对中度疲劳样本数据的分类预测准确率为81.12%;对重度疲劳样本数据的分类预测准确率为40.53%。结果表明,SVM具有较好的稳定性与泛化能力,但对于重度疲劳的预测准确率较低,需要对该模型进行进一步的优化,以提高模型在重度疲劳的分类预测准确率。

在使用SVM进行分类预测时,须提前设定惩罚参数 $c$ 和核函数 $\sigma$ 两个参数,这两个参数直接影响SVM的分类效果。因此,为找到更适用于驾驶疲劳状态分类的惩罚参数 $c$ 和核函数 $\sigma$ ,采用鲸鱼算法迭代优化参数,从而提高SVM在模型中的分类预测准确率。




图13 SVM混淆矩阵图

### 4.3 基于WOA-SVM分类模型

#### 4.3.1 WOA方法

WOA是一种基于元启发式优化的方法,其设计灵感源自于座头鲸的气泡网捕食行为,具有控制参数少、全局搜索能力强、操作简单以及易于实现等优点<sup>[26]</sup>。鲸鱼算法在寻求最优解时,可以分为围捕阶段、气泡网包围阶段和探索阶段。

##### (1) 围捕阶段

鲸鱼狩猎过程中,当发现猎物后,会迅速向猎物的方向靠拢。而在优化的过程中,这种行为被模拟为向最优解(猎物)方向更新搜索代替初始解(鲸鱼)的位置。首先须计算鲸鱼与猎物两者之间的距离:

$$\vec{M} = \left| \vec{E} \cdot \vec{Y}^*(t) - \vec{Y}(t) \right| \quad (16)$$

式中: $\vec{M}$ 是当前解向量与最优解之间的距离向量; $\vec{Y}(t)$ 是解向量; $\vec{Y}^*(t)$ 是当前迭代中的最优解向量; $\vec{E}$ 是系数向量。

求解下一个迭代的解向量计算公式可表示为

$$\begin{cases} \vec{Y}(t+1) = \vec{Y}^*(t) - \vec{F} \cdot \vec{M} \\ P \leq 0.5 \\ \vec{F} < 1 \end{cases} \quad (17)$$

式中: $\vec{Y}(t+1)$ 是下一个迭代的解向量; $\vec{F}$ 是系数向量。

系数向量 $\vec{E}$ 和 $\vec{F}$ 的计算公式为

$$\vec{E} = 2 \cdot \vec{r} \quad (18)$$

$$\vec{F} = 2 \cdot \vec{a} \cdot \vec{r} - \vec{a} \quad (19)$$

式中: $\vec{a}$ 从2线性递减到0; $\vec{r}$ 是 $[0, 1]$ 的随机向量。

##### (2) 气泡网包围阶段

当到达猎物位置后,鲸鱼会利用吐出的螺旋状气泡圈来包围猎物,并通过调节气泡网的大小进行包围,气泡网的直径可以具体表示为

$$D = \left| \vec{Y}^*(t) - \vec{Y}(t) \right| \quad (20)$$

式中 $D$ 是气泡网的直径向量。

气泡网包围阶段下一个迭代的解向量计算公式可表示为

$$\begin{cases} Y(t+1) = D \cdot \exp(b \cdot l) \cdot \cos(2\pi l) + \vec{Y}^*(t) \\ P > 0.5 \\ \vec{F} < 1 \end{cases} \quad (21)$$

式中: $b$ 是螺旋形状参数; $l$ 是 $[-1, 1]$ 之间的随机数。

##### (3) 搜索阶段

在捕食过程中,鲸鱼有时会采取随机搜索的策略,并不总是追求最优解。随机搜索阶段下一个迭代的解向量计算公式可表示为

$$\vec{Y}(t+1) = \vec{Y}_{\text{rand}} - \vec{F} \cdot \vec{D}, \quad \vec{F} \geq 1 \quad (22)$$

式中: $\vec{Y}_{\text{rand}}$ 是搜索空间中随机选择的一个解向量; $\vec{D}$ 是该随机解与当前解之间的距离向量。

#### 4.3.2 WOA-SVM驾驶疲劳状态分类模型的建立

基于WOA-SVM的驾驶疲劳分类模型本质上是利用鲸鱼算法的全局寻优能力,寻求SVM中的惩罚参数 $c$ 和核函数 $\sigma$ 的最优解向量。

鲸鱼算法优化SVM的步骤如下。

(1)根据样本数据的大小,本文将种群规模设定为20,最大迭代次数为100。同时,变量上限 $u_b$ 和下限 $l_b$ 分别为 $[0.1, 100]$ 和 $[0.01, 0.1]$ 。

(2)计算适应度函数值,选择适应度函数值最小的作为鲸鱼位置的最佳位置。

(3)当 $P \leq 0.5$ 且 $\vec{F} < 1$ 时,按式(17)计算当前解向量;如果 $P > 0.5$ 且 $\vec{F} < 1$ ,按式(21)计算;而当 $\vec{F} \geq 1$ 时,则按照式(22)计算。

(4)找出最优解向量 $[c, \sigma]$ 。

(5)判断是否满足最大迭代次数的条件。

(6)输出最优解向量 $[c, \sigma]$ 。

#### 4.3.3 WOA-SVM分类预测结果

通过鲸鱼算法优化SVM驾驶疲劳状态分类模型,迭代100次后得到了鲸鱼捕食的全局最优个体

及位置也就是惩罚参数  $c$  和核函数参数  $\sigma$  的最佳线性组合。如图 14 所示,鲸鱼算法的适应度函数值随着迭代次数的增加出现递减的趋势,说明鲸鱼算法在搜寻惩罚参数  $c$  和核函数参数  $\sigma$  时,提升了 SVM 分类模型的性能,且随着迭代次数的增加,适应度函数值达到了最小值。当  $[c, \sigma]$  为  $[11.5572, 0.065416]$  时,适应度函数值达到最小。




图 14 迭代次数与适应度函数值的关系曲线图

如图 15 和图 16 所示,基于 WOA-SVM 的驾驶疲劳状态分类模型训练集的准确率为 96.30%,测试集的准确率为 84.39%。该模型正确预测轻度疲劳 6 560 次,错误识别为中度和重度疲劳 64 次和 9 次;正确预测中度疲劳 3 025 次,错误识别为轻度和重度疲劳 315 次和 87 次;正确预测重度疲劳 1 078 次,错误识别为轻度和中度疲劳 69 次和 163 次。

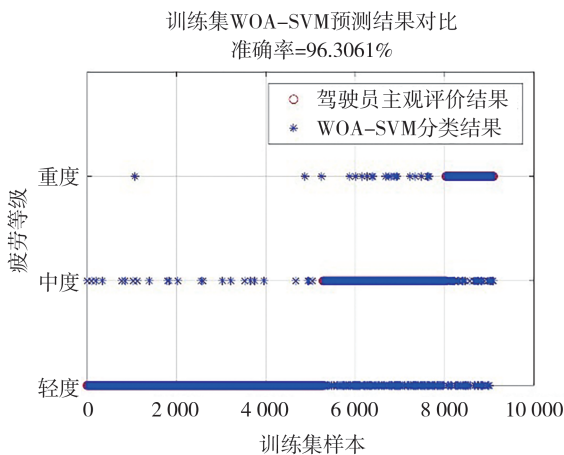


图 15 WOA-SVM 训练集分类效果图

通过分类结果计算出 3 种疲劳状态类别的预测准确率,并绘制如图 17 所示的混淆矩阵。结果表明:WOA-SVM 模型对轻度疲劳样本数据的分类预




图 16 WOA-SVM 测试集分类效果图

测准确率达到了 98.88%;对中度疲劳和重度疲劳样本数据的分类预测准确率分别为 88.59% 和 82.75%。




图 17 WOA-SVM 混淆矩阵图

#### 4.4 分类预测结果对比

根据驾驶疲劳状态分类预测结果,建立如表 4 所示的对比分析。从表 4 可知,对比于 SVM,基于 WOA-SVM 模型在驾驶疲劳状态分类的预测准确率表现出了更高的精度。

表 4 驾驶疲劳状态分类预测结果对比

分类预测算法	训练/%	测试/%	轻度/%	中度/%	重度/%
SVM	86.94	82.89	97.72	81.12	40.53
WOA-SVM	96.30	84.39	98.88	88.59	82.75

## 5 结论

针对长时间驾驶、道路拥堵和复杂道路状况下驾驶员腿部肌肉疲劳的问题,首先通过模拟驾驶实

验采集实验数据,其次采用VMD算法进行噪声滤除,提取12个时频域特征值,最后构建了基于WOA-SVM的驾驶疲劳状态判别模型。本研究的结论如下。

(1)通过VMD算法对肌电信号进行变分模态分解后,得到的5个IMF分量幅值均在零刻度线上下对称振荡,符合sEMG的幅值分布特征,可以有效地滤除实验过程中的噪声干扰,提高了数据质量。

(2)从VMD算法分解得到的5个IMF分量中进行12个时频域特征值的提取,分析其变化趋势,发现随着疲劳程度逐渐加深,时域特征值整体上升,肌肉运动所需代价更大;频域特征值整体下降,运动频率中低频成分增加。

(3)通过元启发式WOA算法对SVM算法中的惩罚参数 $c$ 和核函数参数 $\sigma$ 进行迭代优化,有效地解决了重度疲劳样本量较少、样本不平衡带来的分类预测准确率较低的问题,使得重度疲劳准确率达到82.75%。

(4)WOA-SVM方法对于轻度、中度和重度3种疲劳状态具有较好的判别效果,其准确率可达84%以上。

### 参考文献

- [1] JIANG K, LING F, FENG Z, et al. Why do drivers continue driving while fatigued? an application of the theory of planned behaviour [J]. *Transportation Research Part A: Policy and Practice*, 2017, 98: 141-149.
- [2] ZHANG X, WANG X, YANG X, et al. Driver drowsiness detection using mixed-effect ordered logit model considering time cumulative effect [J]. *Analytic Methods in Accident Research*, 2020, 26: 100114.
- [3] 周继红,杨傲,袁丹凤,等.疲劳驾驶及其评估方法进展[J].*伤害医学(电子版)*, 2021, 10(3):45-50.  
ZHOU J, YANG A, YUAN D, et al. Fatigue driving and evaluation methods[J]. *Injury Medicine (Electronic Edition)*, 2021, 10(3):45-50.
- [4] LI Z, CHEN L, NIE L, et al. A novel learning model of driver fatigue features representation for steering wheel angle [J]. *IEEE Transactions on Vehicular Technology*, 2022, 71:269-281.
- [5] WANG Y, JIN L, LI K, et al. Drowsy driving detection based on fused data and information granulation [J]. *IEEE Access*, 2019, 7: 183739-183750.
- [6] SUN Z, MIAO Y, JEON J Y, et al. Facial feature fusion convolutional neural network for driver fatigue detection [J]. *Engineering Applications of Artificial Intelligence*, 2023, 126: 106981.
- [7] YI Y, ZHOU Z, ZHANG W, et al. Fatigue detection algorithm based on eye multifeature fusion [J]. *IEEE Sensors Journal*, 2023, 23(7): 7949-7955.
- [8] MATEUSZ K, BOGUSLAW C. Driver's fatigue recognition based on yawn detection in thermal images [J]. *Neurocomputing*, 2019, 338: 274-292.
- [9] LIU Y, XIANG Z, YAN Z, et al. CEEMDAN fuzzy entropy based fatigue driving detection using single-channel EEG [J]. *Biomedical Signal Processing and Control*, 2024, 95:106460.
- [10] SUN W, JIANG W, LI C, et al. Study on identification method of driver fatigue considering individual ECG differences [J]. *Cognition, Technology & Work*, 2024, 26(2):301-312.
- [11] LU J, ZHENG X, ZHANG T, et al. Can steering wheel detect your driving fatigue? [J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(6): 5537-5550.
- [12] 王琳,罗旭,姜鑫,等.基于生物力学和颈腰部EMG判别驾驶员疲劳状态[J].*汽车工程*, 2017, 39(8): 955-960,967.  
WANG L, LUO X, JIANG X, et al. Detection on driver fatigue based on biomechanics and EMG of cervical and lumbar muscles [J]. *Automotive Engineering*, 2017, 39(8): 955-960,967.
- [13] 杨巨成,魏峰,林亮,等.驾驶员疲劳驾驶检测研究综述[J].*山东大学学报(工学版)*, 2024, 54(2): 1-12.  
YANG J, WEI F, LIN L, et al. A research survey of driver drowsiness driving detection [J]. *Journal of Shandong University (Engineering Science)*, 2024, 54(2): 1-12.
- [14] 苏瑞芝,唐巾卜,阿地力·吐合提,等.基于生理参数的驾驶疲劳检测方法综述[J].*复旦学报(自然科学版)*, 2023, 62(4): 419-427.  
SU R, TANG J, ADILI T, et al. A review of physiological signals-based driving fatigue detection algorithms [J]. *Journal of Fudan University (Natural Science)*, 2023, 62(4): 419-427.
- [15] SUN J, LIU G, SUN Y, et al. Application of surface electromyography in exercise fatigue: a review [J]. *Frontiers in Systems Neuroscience*, 2022, 16: 893275.
- [16] NA L, RUI Z, BHARATH K, et al. Non-invasive techniques for muscle fatigue monitoring: a comprehensive survey [J]. *ACM Computing Surveys*, 2024, 56(9): 40.
- [17] ZHANG C, WANG H, FU R. Automated detection of driver fatigue based on entropy and complexity measures [J]. *IEEE Transactions on Intelligent Transportation System*, 2014, 15(1): 168-177.
- [18] FU R, WANG H, ZHAO W. Dynamic driver fatigue detection using hidden Markov model in real driving condition [J]. *Expert Systems with Applications*, 2016, 63:397-411.
- [19] WANG L, WANG H, LIU J. Discrimination of driver fatigue based on distortion energy density theory and multiple physiological signals [J]. *IEEE Access*, 2021, 9:151824-151833.
- [20] 王琳,张陈,尹晓伟,等.一种基于驾驶员生理信号的非接触式驾驶疲劳检测技术[J].*汽车工程*, 2018, 40(3): 333-341.  
WANG L, ZHANG C, YIN X, et al. A non-contact driving fatigue detection technique based on driver's physiological signals [J]. *Automotive Engineering*, 2018, 40(3): 333-341.

(下转第969页)

- gineering, 2019, 233(10): 2390-2404.
- [11] 王亓良, 陈鑫, 张英朝, 等. 基于直接CAA与SEA的汽车风噪预测与控制[J]. 汽车工程, 2021, 43(1): 86-93.  
WANG Q L, CHEN X, ZHANG Y C, et al. Prediction and control of vehicle wind noise based on direct CAA and SEA[J]. Automotive Engineering, 2021, 43(1): 86-93.
- [12] LEE H R, KIM H Y, JEON J H, et al. Application of global sensitivity analysis to statistical energy analysis: vehicle model development and transmission path contribution [J]. Applied Acoustics, 2019, 146: 368-389.
- [13] HARTMANN M, OCKER J, LEMKE T, et al. Wind noise caused by the side-mirror and a-pillar of a generic vehicle model [C]. 18th AIAA/CEAS Aeroacoustics Conference (33rd AIAA Aeroacoustics Conference), 2012: 2205-2230.
- [14] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.
- [15] TANG J, LIU G, PAN Q. A review on representative swarm intelligence algorithms for solving optimization problems: applications and trends [J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(10): 1627-1643.
- [16] 唐中华, 贺岩松, 马涛, 等. 汽车声学包轻量化设计[J]. 汽车工程, 2021, 43(1): 113-120.  
TANG Z H, HE Y S, MA T, et al. Lightweight design of automotive sound package [J]. Automotive Engineering, 2021, 43(1): 113-120.

~~~~~

(上接第950页)

- [31] TSUDA S, HOU J, NELSON R L, et al. Prolonged hippocampal cell death following closed-head traumatic brain injury in rats [J]. Neuroreport, 2016, 27(10): 724-729.
- [32] HALL A N B, JOSEPH B, BRELSFOARD J M, et al. Repeated closed head injury in mice results in sustained motor and memory deficits and chronic cellular changes [J]. Plos One, 2016, 11(7): e0159442.
- [33] KAPLAN G B, LEITE-MORRIS K A, WANG L, et al. Pathophysiological bases of comorbidity: traumatic brain injury and post-traumatic stress disorder [J]. Journal of Neurotrauma, 2018, 35(2): 210-225.
- [34] FENG J F, ZHAO X, GURKOFF G G, et al. Post-traumatic hypoxia exacerbates neuronal cell death in the hippocampus [J]. Journal of Neurotrauma, 2012, 29(6): 1167-1179.
- [35] WITGEN B M, LIFSHITZ J, GRADY M S. Inbred mouse strains as a tool to analyze hippocampal neuronal loss after brain injury: a stereological study [J]. Journal of Neurotrauma, 2006, 23(9): 1320-1329.
- [36] HOFFMAN A N, PAODE P R, MAY H G, et al. Early and persistent dendritic hypertrophy in the basolateral amygdala following experimental diffuse traumatic brain injury [J]. Journal of Neurotrauma, 2017, 34(1): 213-219.
- [37] CREED J A, DILEONARDI A M, FOX D P, et al. Concussive brain trauma in the mouse results in acute cognitive deficits and sustained impairment of axonal function [J]. Journal of Neurotrauma, 2011, 28(4): 547-563.
- [38] SMITH D H, NONAKA M, MILLER R, et al. Immediate coma following inertial brain injury dependent on axonal damage in the brainstem [J]. Journal of Neurosurgery, 2000, 93(2): 315-322.

~~~~~

(上接第961页)

- [21] FRASIE A, BERTRAND-CHARETTE M, COMPAGNAT M, et al. Validation of the Borg CR10 Scale for the evaluation of shoulder perceived fatigue during work-related tasks [J]. Applied Ergonomics, 2024, 116: 104200.
- [22] ZHOU Q, CHEN Y, MA C, et al. Evaluation of upper limb muscle fatigue based on surface electromyography [J]. Science China Life Sciences, 2011, 54: 939-944.
- [23] 董洋, 王琳, 张娜娜, 等. 基于变分模态分解与小波阈值结合的表面肌电信号去噪分析与研究 [J]. 沈阳工程学院学报(自然科学版), 2023, 19(2): 79-84.  
DONG Y, WANG L, ZHANG N, et al. Analysis and study of SEMG based on variational mode decomposition and wavelet threshold [J]. Journal of Shenyang Institute of Engineering (Natural Science), 2023, 19(2): 79-84.
- [24] QIN P, SHI X. Evaluation of feature extraction and classification for lower limb motion based on sEMG signal [J]. Entropy, 2020, 22(8): 852.
- [25] 曹昂, 张坤嘉, 刘睿, 等. 基于表面肌电信号的肌肉疲劳状态分类系统 [J]. 计算机应用, 2018, 38(6): 1801-1808.  
CAO A, ZHANG S, LIU R, et al. Muscle fatigue state classification system based on surface electromyography signal [J]. Journal of Computer Applications, 2018, 38(6): 1801-1808.
- [26] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51-67.