DOI:10.16016/j.2097-0927.202203057

基于心率变异性和呼吸频率的驾驶疲劳识别模型研究

向洪义[1],张琼敏[2],王俊杰[2],王思平[2],廖志康[1],孙丽璐[3],李 奎[1],赵 辉[1] 400042 重庆,陆军特色医学中心军事交通伤防治研究室[1];400054 重庆,重庆理工大学:计算机科学与工程学院[2],管理学院[3]

[**摘要**] **目的** 建立结合心率变异性(heart rate variability,HRV)和呼吸频率(respiratory rate,RESP)的驾驶疲劳识别机器学习模型并明确最优特征子集。**方法** 2021年6-12月,从陆军军医大学招募20名年龄在20~30岁之间的健康男性志愿者参加疲劳驾驶试验。记录正常睡眠和睡眠剥夺后驾驶员在驾驶任务中的心电信号,提取18维疲劳相关HRV特征值,选择清醒与疲劳状态下存在差异的HRV特征结合RESP作为特征集。比较支持向量机(support vector machines,SVM)、K最邻近(k-nearest neighbor,KNN)、朴素贝叶斯(naive Bayes,NB)、决策树(decision tree,DT)和逻辑回归(logistic regression,LR)这五种经典机器学习方法,筛选最优特征子集,并建立疲劳识别模型。**结果** 低频功率(low frequency,LF)与高频功率(high frequency,HF)的比值LF/HF、RESP、平均RR间隔(mean RR interval,Mean RR)、样本熵(sample entropy,SampEn)、去趋势波动分析(detrended fluctuation analysis,DFA)短期斜率DFA α1五个特征是疲劳识别的有效特征子集,在SVM中分类效果最好,疲劳识别的准确性、敏感性、特异性分别为87.03%、87.07%、87.13%。其中LF/HF和RESP是最为重要的驾驶疲劳识别指标,两个维度下各个模型的准确性均能达到80%以上,SVM与LR整体表现更好,准确性、敏感性、特异性分别为84.99%、85.13%、82.65%和84.43%、86.49%、82.02%。**结论** LF/HF、RESP是驾驶疲劳识别的有效特征,在基于HRV特征和RESP的驾驶疲劳识别中SVM与LR的整体表现优于其他模型。

[**关键词**] 军用车辆;驾驶疲劳;心率变异性;呼吸频率;机器学习
[**中图法分类号**] R331.18;R332.2;R338.63 [**文献标志码**] A

Driving fatigue recognition model based on heart rate variability and respiratory rate

XIANG Hongyi[1], ZHANG Qiongmin[2], WANG Junjie[2], WANG Siping[2], LIAO Zhikang[1], SUN Lilu[3], LI Kui[1], ZHAO Hui[1] [1]Department of Military Traffic Injury Prevention and Treatment, Army Medical Center of PLA, Chongqing, 400042; [2]College of Computer Science and Engineering, [3]College of Management, Chongqing University of Technology, Chongqing, 400054, China

[**Abstract**] **Objective** To establish a machine learning model for driving fatigue recognition based on heart rate variability (HRV) and respiratory rate (RESP), and identify the optimal subsets of features. **Methods** From June 2021 to December 2021, 20 healthy male volunteers between the ages of 20 and 30 were recruited from the Army Medical University to participate in the fatigue driving experiment. The electrocardiographic (ECG) signals under normal sleep and sleep deprivation during driving tasks were recorded, and 18-dimensional fatigue-related HRV feature values were extracted. The HRV features that differ between awake and fatigue states were selected, which were further combined with RESP as the feature set. Moreover, 5 classic machine learning methods were adopted and compared, including support vector machines (SVM), k-nearest neighbor (KNN), naive Bayes (NB), decision tree (DT) and logistic regression (LR).

[**基金项目**] 军队医学科技青年培育计划拔尖项目(20QNPY031);重庆市在渝院士牵头科技创新引导专项(cstc2019yszx-jscxX0002)
[**通信作者**] 赵 辉,E-mail:box.zhaohui@163.com

2097-0927/Copyright © 2022,陆军军医大学(第三军医大学)。这篇开放获取文章遵循 CC BY 许可协议(https://creativecommons.org/licenses/by/4.0/)

The optimal feature subset was screened, and then a fatigue recognition model was established. **Results** The ratio of low frequency power to high frequency power (LF/HF), RESP, mean RR interval (Mean RR), sample entropy (SampEn), and detrended fluctuation analysis short-term slope (DFAα1) constituted the effective feature subsets of fatigue recognition, which achieved the best classification effect in SVM, with an accuracy of 87.03%, a sensitivity of 87.07% and a specificity of 87.13% in fatigue recognition. Among them, LF/HF and RESP were found as the most important indicators of driving fatigue identification, with an accuracy of each model in the above 2 dimensions reaching more than 80%. In addition, SVM and LR showed better overall performance, with an accuracy, sensitivity and specificity of 84.99%, 85.13%, 82.65% for SVM and 84.43%, 86.49%, 82.02% for LR, respectively. **Conclusion** LF/HF and RESP are the effective features for driving fatigue recognition. In the driving fatigue recognition model based on HRV features and RESP, the overall performance of SVM and LR models is better than the other models.

[**Key words**] military vehicles; driving fatigue; heart rate variability; respiratory rate; machine learning

Supported by the Top-Notch Project of Youth Cultivation Program for Military Medical Science and Technology (20QNPY031) and the Special Project of Chongqing Academician-Led Scientific and Technological Innovation Guidance (cstc2019yszx-jscxX0002). Corresponding author: ZHAO Hui, E-mail: box.zhaohui@163.com

军用车辆是部队摩托化的机动平台和日常机动保障的主要装备,车辆事故是导致军队非战斗减员的主要因素[1-2]。军车驾驶员作为平台的直接操作者,承受较强心理和生理负荷,容易产生驾驶疲劳。诱发驾驶疲劳的因素多,军车驾驶员因特殊军事任务,更有可能遭受包括昼夜节律、睡眠时间、驾驶时间长度和环境因素等影响而出现驾驶疲劳。陆军在注重能力训练要求中提到强化在职训练,已将抗疲劳驾驶作为重要训练内容。需要指出的是,驾驶疲劳问题在地方道路交通安全中也很突出。

自主神经系统(autonomic nervous system,ANS)通过传入和传出交感神经系统(sympathetic nervous system,SNS)和副交感神经系统(parasympathetic nervous system,PNS)通路调节身体的大部分内部过程(循环、呼吸、消化等),确保身体稳态环境[3]。研究表明疲劳与ANS功能失衡有关[4]。因此通过分析ANS活动情况对驾驶疲劳的进程进行监测,基于心电图(electrocardiogram,ECG)提取的心率变异性(heart rate variability,HRV)被证实与自主神经系统活动密切相关,因ECG信号信噪比高、易检测和分析,HRV被广泛应用于驾驶员疲劳识别。KNN、SVM、AdaBoost和随机森林等机器学习方法被用于建立驾驶疲劳识别模型,模型预测精度参差不齐,HRV特征纳入参数范围也还存在争议[5]。RESP是影响HRV的重要参数,呼吸过程会影响SNS与PNS活动,导致呼吸性窦性心律失常[6],但迄今鲜有研究综合HRV和呼吸频率来识别驾驶疲劳。本研究拟使用HRV和RESP参数进行机器学习,探索具有可实施性、适用于不同疲劳程度的驾驶疲劳识别方法,以提升军用车辆事故防范的技术能力。

1 资料与方法

1.1 试验对象

2021年6-12月从陆军军医大学招募20名年龄在20~30岁之间的健康男性志愿者参加疲劳试验,试验前采用问卷对参与者的驾驶生涯、健康状况和睡眠习惯进行调查。所有志愿者均健康,日常作息规律。试验前24 h无酒精、咖啡及功能性饮料等神经兴奋物质摄入,未参加剧烈的体育运动,正式试验前1 d佩戴可以检测睡眠时间的手环。试验过程中不能嚼口香糖、听音乐及接听电话,避免主动或被动刺激影响驾驶员的状态。本试验已通过陆军特色医学中心伦理委员会审批[医研伦审(2020)第130号],在试验前充分告知受试者试验内容并签署《知情同意书》。

1.2 试验仪器及软件

驾驶模拟平台:具有高仿真度驾驶感受的6自由度驾驶模拟系统(ZG-06,北京紫光基业);微型12导联心电图系统(MIC-12DL,迈尔诺医疗):记录试验全程心电信号,采样频率为500 Hz;HRV分析系统(Kubios HRV Premium 3.5,芬兰):其计算方式与欧洲心脏病协会的指南一致,各HRV指标意义已充分论述[7];4K高分辨率摄像系统(海康威视)。华为4Pro手环:监测驾驶员前一晚睡眠时间。

1.3 驾驶任务

为使模型能够适用于不同疲劳程度下的疲劳识别,增强模型泛化能力,驾驶员参与2次试验,一次为充足睡眠(睡眠时间不小于8 h)条件下的驾驶任务,

另一次采用部分睡眠剥夺(3:00-7:00,4 h 睡眠时间)诱发疲劳后再参与试验。试验前驾驶员有 10 min 时间熟悉模拟器操作,熟悉驾驶环境后开始驾驶任务。两次试验开始时间均为上午 9:00,在模拟器上执行 90 min 的驾驶任务,路面有少量的车辆,驾驶环境为白天,在遵守交通规则、不发生交通事故的前提下,驾驶员可以自行决定车速。室内光线充足,空气流通顺畅,室温 23 ℃。

1.4 数据采集

用酒精棉球擦拭驾驶员胸部后粘贴心电电极片,确保心电信号能正常采集,试验过程中微型心电图系统全程记录驾驶员 ECG。在驾驶员正前方放置摄像系统记录驾驶员驾驶过程中的面部表情及身体活动情况。

1.5 特征提取及标记

采用 Kubios HRV Premium 从 ECG 中提取时域、频域、非线性 HRV 特征及呼吸频率等共计 18 维特征参数。相关参数见表 1。

每 5 分钟对驾驶员的状态进行一次专家评分,3 位睡眠领域专家独立对驾驶员的状态进行判断,在存在不同意见时以 2 位专家的意见为准。根据专家评分结果,将驾驶员 HRV 特征以 5 min 为一段,进行清醒与疲劳两种类别的标签标记,按标签将 HRV 数据分为清醒组、疲劳组。

1.6 统计学分析

试验数据采用 SPSS 25.0 进行统计分析。用 Kolmogorov-Smirnov 检验数据是否服从正态分布,服从正态分布的计量资料以 $\bar{x}\pm s$ 表示,进行独立样本 t 检验。检验水准 $\alpha=0.05$。

1.7 预测模型的建立

1.7.1 初步特征选择　根据统计分析的结果,从 17 维 HRV 特征中筛选出在清醒、疲劳状态下具有统计学差异的 HRV 特征,结合 RESP 这一生理特征,将这些特征作为模型的输入特征。

1.7.2 标准化处理　特征数值分布差异较大,为减少原始特征数值分布差异对模型的干扰,对模型输入数据进行标准化处理,对数据特征集进行均值为 0、方差为 1 的数值分布调整。公式如下:

$$X^{*}=\frac{x-\mu}{\delta}$$

其中 μ 为所有样本数据的均值,δ 为所有样本数据的标准差。

1.7.3 机器学习模型　根据 HRV 特征,利用机器学习模型将驾驶员分为疲劳与清醒两种不同的状态,这种方法可以被归结为机器学习中的二分类问题,即具有两个类别标签的分类任务。本研究采用支持向量机(support vector machines, SVM)、K 最邻近(k-nearest neighbor, KNN)、朴素贝叶斯(naive Bayes, NB)、决策树(decision tree, DT)和逻辑回归(logistic regression, LR)五种常用的二分类经典机器学习模型用于驾驶疲劳识别。

SVM 是经典的有监督学习算法,主要是在特征空间上寻找最优分类超平面,通过最大化类别特征间隔使模型表现出较好的鲁棒性。

KNN 也是一种经典的有监督学习算法,主要基于分类思想。k 近邻在定类决策上是根据特征空间上最近邻的实例类别来决定待分实例的所属类别。因此对特征空间上类域交叉较多的待分实例使用 KNN 方法更为合适。

NBayes 算法是基于贝叶斯定理与特征条件独立假设的分类方法,对于给定的训练数据集,首先基于特征条件独立假设学习输入/输出的联合概率分布,然后基于此模型,对给定的输入 x,利用贝叶斯定理求出后验概率最大的输出 y。它是一种基于特征概率进行分类的方法。

表 1　HRV 特征参数

分类	指标
时域	平均 RR 间隔(mean RR interval, Mean RR);平均心率(mean heart rate, Mean HR);连续 RR 间隔均方差的平方根(root mean square of successive differences, RMSSD);RR 间期直方图宽度(the triangular interpolation of NN interval hietogram, TINN);RR 间期标准差(standard diviation of NN intervals, SDNN);HRV 三角指数;给定的时间内差值大于 50 ms 的相邻 RRI 的对数与总的 RR 间期个数的百分比(percent of the number whose difference between adjacent NN intervalare more than 50 ms, pNN50)
频域	标准化低频功率(normalized low frequency, nLF);标准化高频功率(normalized high frequency, nHF);低频功率/高频功率(LF/HF)
非线性	庞莱加图短轴、RR 间期短期标准差(SD1);庞莱加图长轴、RR 间期的长期标准差(SD2);SD2/SD1;近似熵(approximate entropy, ApEn);样本熵(sample entropy, SampEn);DFAα1;DFA 长期波动斜率 DFAα2
生理指标	RESP

DT是一种树形结构的模型,从根节点开始,对实例的某一特征进行测试判断是否将实例分配到其子节点,每一个子节点对应一个特征属性的测试。递归地对实例进行测试并分配,直至达到叶节点。通常DT子节点分裂的准则是信息增益或信息增益比。

LR虽然名为"回归",但其本质是一种分类方法,常用于二分类问题。利用Sigmoid函数(亦称为Logistic函数),建立代价函数表示预测值与实际值的偏差,偏差越小越好,通过迭代学习的方式求解模型的最优参数。

1.7.4 特征相关性分析 相关系数是用于统计两个随机变量之间线性相关程度的统计量。多个变量间存在高度相关关系,在机器学习模型中称为多重共线性。多重共线性会致使模型的权重参数估计失真或难以估计准确。因此需要进行特征筛选工作,对特征进行降维,避免特征的维度过高增加计算的时间,减少模型的过拟合,增强模型的鲁棒性和泛化能力。

1.7.5 模型训练 为探索HRV特征对模型识别的准确性,选取具有统计学差异的HRV特征建立数据集,作为模型的训练集,采用10折交叉验证的方式训练建立机器学习模型。具体做法为:将不同数量的特征组合后依次分别输入5种机器学习模型(SVM、KNN、NBayes、DT和LR)完成模型训练。

2 结果

2.1 疲劳与清醒状态HRV特征变化

根据专家评估结果,将数据划分为清醒与疲劳两个数据集。20名招募者中2人在试验过程中感觉不适(头晕、恶心等晕车反应)退出,共计18人参加36次试验,每次试验持续约90 min,以5 min为单位对驾驶员状态进行专家评分,每次试验能得到18个被标记为清醒或者疲劳的样本,最终得到数据集共有样本648例。其中清醒标签占比45.7%,疲劳标签占比54.3%。

比较清醒与疲劳状态下各HRV特征值的差异,各HRV特征均值见表2。统计结果显示,除DFA α2外,清醒与疲劳状态下各HRV特征均值具有统计学差异($P<0.05$)。其中Mean HR、nHF、RESP、ApEn、SampEn在疲劳时减小,其他HRV指标在疲劳时均增大。

表2 疲劳与清醒状态下HRV相关指标比较($\bar{x}\pm s$)

指标	清醒($n=296$)	疲劳($n=352$)	t	P	差值95%CI	
					下限	上限
Mean RR/ms	738.47±66.58	770.28±103.56	−3.973	0.000	−47.57	−16.07
SDANN/ms	35.37±11.08	42.18±18.15	−4.910	0.000	−9.54	−4.08
Mean HR/次·min^{-1}	81.87±6.94	79.17±9.66	3.504	0.001	1.18	4.21
RMSSD/ms	27.59±9.30	30.34±14.93	−2.400	0.017	−5.00	−0.50
pNN50	7.85±7.58	10.26±12.00	−2.604	0.010	−4.22	−0.59
HRVti	9.05±2.36	10.64±3.78	−5.478	0.000	−2.16	−1.02
TINN	179.70±57.97	209.21±81.49	−4.626	0.000	−42.05	−16.96
nLF	71.22±13.37	76.99±9.63	−5.636	0.000	−7.78	−3.76
nHF	29.77±12.03	25.10±8.60	5.082	0.000	2.86	6.47
LF/HF	3.09±1.97	3.62±1.81	−3.165	0.002	−0.87	−0.20
RESP/次·s^{-1}	0.30±0.05	0.27±0.05	5.765	0.000	0.02	0.03
SD1	19.53±6.58	21.48±10.57	−2.402	0.017	−3.55	−0.35
SD2	45.87±14.73	55.53±23.65	−5.325	0.000	−13.23	−6.09
SD2/SD1	2.43±0.54	2.67±0.42	−5.642	0.000	−0.32	−0.16
ApEn	1.18±0.08	1.15±0.08	4.572	0.000	0.02	0.05
SampEn	1.63±0.25	1.53±0.21	4.700	0.000	0.06	0.14
DFAα1	1.28±0.18	1.34±0.13	−4.855	0.000	−0.09	−0.04
DFAα2	0.47±0.13	0.49±0.13	−1.691	0.092	−0.04	0.00

2.2 初步特征选择

由于 DFAα2 在清醒与疲劳时无统计学差异,因此认为该特征不是表征疲劳的有效指标。有研究证实 SampEn 比 ApEn 能准确、稳定地衡量生理的时间序列,SampEn 的计算不依赖于数据长度且具有更好的一致性[8-9]。因此本研究从提取的 17 个 HRV 特征中去除 DFAα2 和 ApEn 后,筛选出 15 个 HRV 特征,结合 RESP 共计 16 个特征用于驾驶疲劳识别的机器学习模型。

2.3 特征之间相关性

特征之间相关系数矩阵热力图如图 1 所示。相关系数矩阵直观展示了多个变量的相关性,其中颜色越深表示两者的相关性越强。例如 nHF 与 nLF 之间具有强负相关性(-0.98),SDNN 和 SD2 具有强正相关性(0.99)。RMSSD 与 SD1 相关性为 1,说明两者完全正相关,相关研究已经证实 RMSSD 与 SD1 表征的是相同的 HRV 特征[10]。

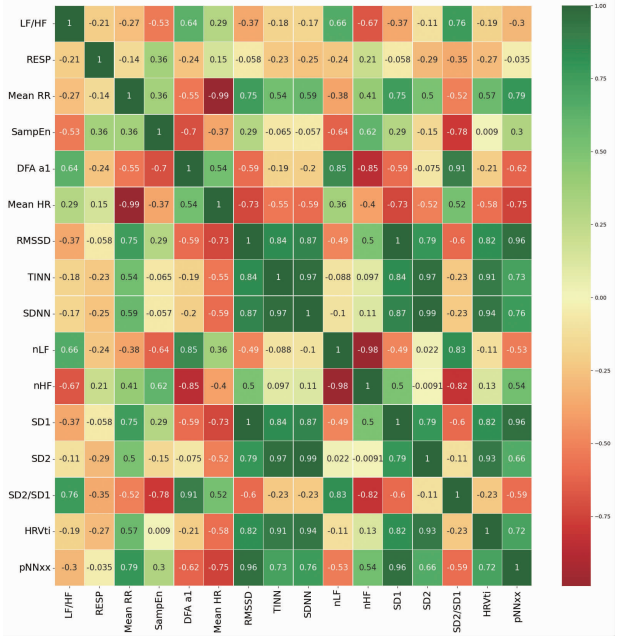


图 1 数据集相关特征矩阵

2.4 特征选择

5 种机器学习模型的特征选择过程如图 2 所示,SVM 模型在本试验具有良好的表现,而且横坐标特征数量为 5 时 SVM 的 F1-Scores 达到最高,此时选取的特征为:LF/HF、RESP、Mean RR、SampEn、DFA α1,并且随着特征数量的增加,SVM 模型与其他模型相比 F1_Score 表现更好。为避免特征过多增加计算的时间导致的过拟合,结合图 2 所示的特征纳入过程,考虑采用 5 个维度的特征作为模型的输入。因此特征选择方面我们选择 LF/HF、RESP、Mean RR、SampEn、DFA α1 作为最终的模型输入特征。

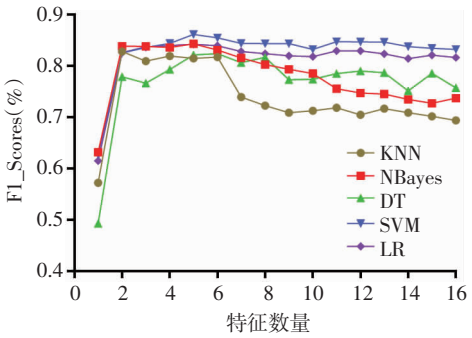


图 2 模型特征选择过程

2.5 分类结果

由图 2 中可以看出,SVM 模型整体表现优于其他模型。因此我们将 SVM 作为最终模型。将选取的 5 维特征输入 SVM 模型,并进行网格搜索和十折交叉验证得到模型最优参数和最好 F1_score 的值模型参数。模型参数见表 3。

表 3 SVM 参数设置

参数名称	取值	参数解释
C	10	目标函数的惩罚系数 C,用来平衡分类间隔 margin 和错分样本
degree	1	多项式核下 degree 决定了多项式的最高次幂,其他情况不生效
gamma	'auto'	核函数的系数
kernel	'poly'	核函数选择有 RBF、Linear、Poly、Sigmoid 等
probability	True	可能性估计是否使用(true or false)

除 SVM 外,对其余 4 个模型在 Mean RR、LF/HF、RESP、SampEn、DFA α1 作为特征输入时,采用敏感性(sensitivity)、特异性(specificity)、精确率(precision)、准确性(accuracy)及 F1_Score 作为模型的性能指标。见表 4。

表 4 五种机器学习模型在 5 个 HRV 特征下的性能指标

分类器	Sens	Spec	Prec	Acc	F1_Score
SVM	0.870 3	0.871 3	0.901 2	0.870 7	0.875 1
KNN	0.824 3	0.829 1	0.862 7	0.826 6	0.830 7
NBayes	0.818 9	0.890 5	0.917 1	0.851 7	0.852 9
DT	0.867 6	0.797 6	0.840 1	0.835 5	0.846 1
LR	0.875 7	0.835 9	0.876 9	0.857 5	0.865 8

从表 4 中可以看出准确性最高的模型是 SVM,其识别准确性、敏感性、特异性分别为 87.07%、87.03%、87.13%,表现优于其他 4 个模型。

由图 2 可知,模型在两个特征下就能取得较好的识别准确性,将 LF/HF 与 RESP 纳入模型后得到 5 种模型的性能指标见表 5。

表 5 五种机器学习模型在 2 个 HRV 特征下的性能指标

分类器	Sens	Spec	Prec	Acc	F1_Score
SVM	0.851 3	0.826 5	0.868 6	0.839 9	0.845 1
KNN	0.818 9	0.852 1	0.876 9	0.834 0	0.834 8
NBayes	0.783 8	0.903 4	0.916 1	0.838 5	0.834 8
DT	0.835 1	0.771 8	0.815 9	0.806 2	0.818 3
LR	0.864 9	0.820 2	0.867 8	0.844 3	0.853 0

在纳入 LF/HF 和 RESP 这两个维度后,各个模型的准确性均能达到 80%以上。SVM 与 LR 整体表现最好,其中 LR 表现出最好的识别准确性,达到 84.43%,敏感性、特异性分别为 86.49%、82.02%;SVM 也有较高的准确性,达到 83.99%,同时敏感性和特异性分别为 85.13%、82.65%。

2.6 交叉验证

各个模型十折交叉验证的 ROC 曲线如图 3 所示。可以看出 SVM 与 LR 表现近似,但 SVM 的分类能力表现最好。

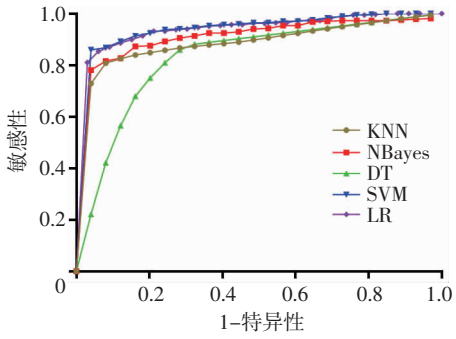


图 3 各个模型 ROC 曲线

3 讨论

驾驶疲劳隐匿性强,对交通安全危害极大。美国高速公路管理局数据显示 2017 年因疲劳导致 9.1 万起交通事故,5 万人受伤,但交通安全、睡眠科学和公共卫生界普遍认为疲劳驾驶的影响仍被低估[11]。对我国 2004-2015 年间 10 人以上伤亡的重大交通事故统计发现,驾驶疲劳是导致事故发生的重要原因[12]。2016 年京沪高速淮安段有 414 起交通事故由疲劳驾驶导致,约占总交通事故数的 52.6%[13]。军用车辆由于遂行特殊军事任务,如高强度机动运输保障和长途跨区远程投送,军人群体更容易因昼夜节律或驾驶时间延长引起睡眠不足。GOOD 等[14]认为,军人睡眠不足普遍存在,由此产生的疲劳会危及人身安全、任务成功甚至国家安全。作者认为,有效识别驾驶疲劳是进行抗疲劳驾驶的关键环节。

研究表明,长时间驾驶和睡眠剥夺使驾驶人驾驶能力明显下降,发生事故概率显著增大[15-16]。针对睡眠剥夺的研究表明,睡眠剥夺会引起 SNS 活动增强、迷走神经活动减弱,HRV 表现为 nLF 增大、nHF 减小及 LF/HF 增大[17]。赵小静等[18]针对不同程度睡眠剥夺后的 HRV 研究结果显示 PNS 活动增强,其中 6 h 的睡眠剥夺后,心率显著下降及 HRV 指标 SDNN、pNN50、RMSSD 均显著上升,与本研究的结论一致。

本研究结果表明,随驾驶时间增加,驾驶员均表现出心率降低,HRV 增大,反映 ANS 总体张力的指标(SDNN、SDANN、TINN、SD2)增大。同时 RMSSD、SD1 等增大,表示 PNS 活动增强。上述指标与 BUENDIA 等[19]的研究具有一致性。

针对 HRV 的特征所代表的生理意义已有相关的共识,但在驾驶疲劳的研究中相关参数的变化情况还有争议。例如,LIANG 等[20]的研究结果显示 nLF 增大、nHF 减小及 LF/HF 增大,但 AWAIS 等[21]的研究结果与之相反。作者认为仅以某几个指标增加或降低来识别驾驶疲劳可能会存在较大局限性,因此,本研究全面分析驾驶员 HRV 特征变化,通过机器学习方法建立疲劳识别模型,进而明确可用于各种状态下进行疲劳识别的特征子集,研究结果对驾驶疲劳识别可起重要作用。

基于 HRV 的驾驶疲劳的机器学习方法已取得较大进展。Persson 等用四个分类器(KNN、SVM、AdaBoost 和随机森林分类器)时,使用随机森林分类器获得了最佳性能,准确率为 85.4%,敏感性为 66.9%,特异性为 90.4%,F1 仅为 65.9%[5]。BABAEIAN 等[22]采用 HRV 频域特征值作为模型输入,采用 SVM 及 KNN 分类器进行疲劳识别,准确性可达到 80%。现有研究在驾驶疲劳识别准确性上较高,但是在模型的特征参数选择时通常根据经验或文献报道选择常见的指标,未对疲劳相关的 HRV 特征进行全面的分析。本研究通过对不同疲劳程度下驾驶任务中各个 HRV 特征进行分析,筛选出适于驾驶疲劳识别的特征,综合呼吸

频率,通过比较 SVM、KNN、NB、DT、LR 等五种经典机器学习方法,筛选出可用于各种状态下的疲劳识别特征。其中 SVM 在选取 LF/HF、RESP、Mean RR、SampEn、DFA α1 这 5 个维度的特征下疲劳识别准确性最高,达到 87.07%,敏感性、特异性分别为 87.03%、87.13%,识别模型的整体性能表现更好。进一步分析发现,LF/HF、RESP 在 LR 和 SVM 模型中都具有较高的准确性和特异性,表明 LF/HF、RESP 指标可适用于驾驶疲劳识别。

SVM 目标在于对特征空间划分最优超平面,核心思想是最大化分类边际。其对异常值不敏感,最终的分类结果由少数的支持向量决定,增删非支持向量对模型无影响。由图 1 相关系数矩阵可知,HRV 特征之间相关性较强,SVM 模型有利于去除冗余特征,选择关键特征,而且算法较为简单,具有较好的鲁棒性,因此在本研究中具有最好的分类表现。

现有驾驶疲劳识别方法较多,基于驾驶员行为特征、车辆行驶特征和驾驶员生理参数的方法广泛应用于驾驶疲劳研究。基于生理参数的驾驶疲劳识别方法被证实更加可靠[23-24]。因为直接测量了驾驶员生理特征,在疲劳发生的早期即可识别,还能避免驾驶环境和个人驾驶习惯等因素造成的干扰。而且相较于脑电信号采集时侵入性强、易受干扰,皮肤电活动易受气温等因素影响,ECG 信号更容易采集、抗干扰能力更强,提取 LF/HF 和 RESP 非常便捷,在实际应用上更具优势。

综上,本研究通过招募志愿者进行模拟驾驶试验,筛选出机器学习方法下表现较好的驾驶疲劳识别关键指标,明确了机器学习方法在驾驶疲劳识别中的有效性。ECG 和 RESP 易于测量,研究结果可为后续驾驶疲劳识别的穿戴设备提供关键技术支撑,对军用车辆事故防范起到重要作用,同时对车辆安全管理也有重要意义。

参考文献:

[1] LE T D, GURNEY J M, NNAMANI N S, *et al*. A 12-year analysis of nonbattle injury among US service members deployed to Iraq and Afghanistan[J]. JAMA Surg, 2018, 153(9): 800-807. DOI:10.1001/jamasurg.2018.1166.

[2] SCHWEIZER M A, JANAK J C, GRAHAM B, *et al*. Nonfatal motor vehicle related injuries among deployed US Service members: Characteristics, trends, and risks for limb amputations[J]. J Trauma Acute Care Surg, 2019, 87(4): 907-914. DOI:10.1097/TA.0000000000002436.

[3] DE ZAMBOTTI M, TRINDER J, SILVANI A, *et al*. Dynamic coupling between the central and autonomic nervous systems during sleep: a review[J]. Neurosci Biobehav Rev, 2018, 90: 84-103. DOI:10.1016/j.neubiorev.2018.03.027.

[4] TANAKA M, TAJIMA S, MIZUNO K, *et al*. Frontier studies on fatigue, autonomic nerve dysfunction, and sleep-rhythm disorder[J]. J Physiol Sci, 2015, 65(6): 483-498. DOI: 10.1007/s12576-015-0399-y.

[5] PERSSON A, JONASSON H, FREDRIKSSON I, *et al*. Heart rate variability for classification of alert versus sleep deprived drivers in real road driving conditions[J]. IEEE Trans Intell Transp Syst, 2020, 22(6): 3316-3325. DOI: 10.1109/TITS.2020.2981941.

[6] VARON C, LAZARO J, BOLEA J, *et al*. Unconstrained estimation of HRV indices after removing respiratory influences from heart rate[J]. IEEE J Biomed Health Inform, 2019, 23(6): 2386-2397. DOI: 10.1109/JBHI.2018.2884644.

[7] MALIK M, BIGGER J T, CAMM A J, *et al*. Heart rate variability: standards of measurement, physiological interpretation, and clinical use[J]. Eur Heart J, 1996, 17(3): 354-381. DOI: 10.1093/oxfordjournals.eurheartj.a014868.

[8] YENTES J M, HUNT N, SCHMID K K, *et al*. The appropriate use of approximate entropy and sample entropy with short data sets[J]. Ann Biomed Eng, 2013, 41(2): 349-365. DOI:10.1007/s10439-012-0668-3.

[9] ESPINOSA R, TALERO J, WEINSTEIN A. Effects of tau and sampling frequency on the regularity analysis of ECG and EEG signals using ApEn and SampEn entropy estimators[J]. Entropy (Basel), 2020, 22(11): 1298. DOI:10.3390/e22111298.

[10] CICCONE A B, SIEDLIK J A, WECHT J M, *et al*. Reminder: RMSSD and SD1 are identical heart rate variability metrics[J]. Muscle Nerve, 2017, 56(4): 674-678. DOI:10.1002/mus.25573.

[11] National Highway Traffic Safety Administration. Drowsy driving[EB/OL]. [2022-03-06]. https://www.nhtsa.gov/risky-driving/drowsy-driving.

[12] LIU G D, CHEN S Y, ZENG Z Q, *et al*. Risk factors for extremely serious road accidents: results from national Road Accident Statistical Annual Report of China[J]. PLoS One, 2018, 13(8): e0201587. DOI: 10.1371/journal.pone.0201587.

[13] WANG J, YU X P, LIU Q, *et al*. Research on key technologies of intelligent transportation based on image recognition and anti-fatigue driving[J]. J Image Video

Proc, 2019, 2019: 33. DOI:10.1186/s13640-018-0403-6.

[14] GOOD C H, BRAGER A J, CAPALDI V F, *et al*. Sleep in the United States military[J]. Neuropsychopharmacology, 2020, 45(1): 176-191. DOI:10.1038/s41386-019-0431-7.

[15] TEFFT B C. Acute sleep deprivation and culpable motor vehicle crash involvement[J]. Sleep, 2018, 41(10). DOI: 10.1093/sleep/zsy144.

[16] CZEISLER C A, WICKWIRE E M, BARGER L K, *et al*. Sleep-deprived motor vehicle operators are unfit to drive: a multidisciplinary expert consensus statement on drowsy driving[J]. Sleep Health, 2016, 2(2): 94-99. DOI:10.1016/j.sleh.2016.04.003.

[17] 黄晓婷. 急性部分睡眠剥夺对医务人员心血管自主神经活动的影响[D]. 福州: 福建医科大学, 2017.
HUANG X T. The effects of acute partial sleep deprivation on cardiovascular autonomic modulation [D]. Fuzhou: Fujian Medical University, 2017.

[18] 赵小静,路海月,王梦悦,等.基于心率变异性的脑力疲劳检测[J].中国医学物理学杂志,2018,35(5):592-597. DOI:10.3969/j.issn.1005-202X.2018.05.017.
ZHAO X J, LU H Y, WANG M Y, *et al*. Mental fatigue detection based on heart rate variability[J]. Chin J Med Physics, 2018, 35(5): 592-597. DOI: 10.3969/j.issn.1005-202X.2018.05.017.

[19] BUENDIA R, FORCOLIN F, KARLSSON J, *et al*. Deriving heart rate variability indices from cardiac monitoring—An indicator of driver sleepiness[J]. Traffic Inj Prev, 2019, 20(3): 249-254. DOI:10.1080/15389588.2018.1548766.

[20] LIANG W C, YUAN J, SUN D C, *et al*. Changes in physiological parameters induced by indoor simulated driving: effect of lower body exercise at mid-term break[J]. Sensors (Basel), 2009, 9(9): 6913-6933. DOI: 10.3390/s90906913.

[21] AWAIS M, BADRUDDIN N, DRIEBERG M. A hybrid approach to detect driver drowsiness utilizing physiological signals to improve system performance and wearability[J]. Sensors (Basel), 2017, 17(9): E1991. DOI:10.3390/s17091991.

[22] BABAEIAN M, MOZUMDAR M. Driver drowsiness detection algorithms using electrocardiogram data analysis[C]//2019 IEEE 9th Annual Computing and Communication Workshop and Conference. IEEE, 2019: 1-6. DOI:10.1109/CCWC.2019.8666467.

[23] RAMZAN M, KHAN H U, AWAN S M, *et al*. A survey on state-of-the-art drowsiness detection techniques[J]. IEEE Access, 2019, 7: 61904-61919. DOI:10.1109/ACCESS.2019.2914373.

[24] DOUDOU M, BOUABDALLAH A, BERGE-CHERFAOUI V. Driver drowsiness measurement technologies: current research, market solutions, and challenges[J]. Int J Intell Transp Syst Res, 2020, 18(2): 297-319. DOI:10.1007/s13177-019-00199-w.

(**收稿**:2022-03-07;**修回**:2022-03-16)

(编辑 邓强庭)