

基于电生理的机器学习在驾驶疲劳识别中的应用

向洪义，朱细燕，廖志康，赵辉

陆军军医大学大坪医院军事交通伤防治研究室,重庆 400042

摘要：

道路交通事故(RTA)导致大量人员伤亡和财产损失,驾驶疲劳是导致RTA的重要因素之一。电生理信号作为神经系统调节身体机能的一种信息反馈,能够反映出驾驶员的疲劳状态,但目前针对电生理信号作为信息输入并采用机器学习的方法进行驾驶疲劳识别的相关研究缺乏系统综述。通过调研疲劳相关文献,本文总结疲劳的神经调节机制,阐明驾驶疲劳是由于心理及生理的双重负荷所导致并汇总驾驶疲劳相关的诱发因素,归纳当前与驾驶疲劳识别相关的电生理信号及其生理机制和相关指标。机器学习算法被广泛应用于驾驶疲劳识别中,本文汇总现有研究中以电生理信号作为信息输入源并采用各种机器学习算法构建的驾驶疲劳识别模型,比较各种机器学习算法的有效性,介绍有监督机器学习的优缺点;并指出应用于驾驶疲劳识别时应根据样本情况和模型特征值选取合适的分类算法;多种电生理信号作为信息源有助于提高疲劳识别模型的准确性,但模型输入特征值增加并不能有效提高模型准确性。最后指出基于电生理信号的疲劳识别方法的研究进展,为驾驶疲劳识别提供了新机遇。

关键词：交通安全；驾驶疲劳；机器学习；生理机制；电生理信号

Application of electrophysiology-based machine learning in identifying driving fatigue XIANG Hongyi, ZHU Xiyan, LIAO Zhikang, ZHAO Hui (Department of Military Traffic Medicine, Daping Hospital, Third Military Medical University, Chongqing, 400042, China)

Abstract:

Road traffic accidents (RTA) can cause a large number of casualties and property losses. Driving fatigue is one of the important factors leading to RTA. Electrophysiological signals, as a kind of information feedback for the nervous system to regulate body functions, can reflect drivers' fatigue state. However, there is a lack of systematic reviews on the current research on electrophysiological signals as information input of machine learning methods for driving fatigue recognition. By investigating fatigue-related literature, the current paper summarized the neural regulation mechanism of fatigue, clarified that driving fatigue is caused by both psychological and physiological loads, recognized inducing factors related to driving fatigue, and summed up electrophysiological signals now in use of driving fatigue recognition, as well as their physiological mechanisms and related indicators. Machine learning algorithms are widely used in identifying driving fatigue. Based on existing studies that used electrophysiological signals as information input source and applied various machine learning algorithms to build driving fatigue identification models, this paper compared the effectiveness of various machine learning algorithms, and described the advantages and disadvantages of supervised machine learning. It is pointed out that suitable classification algorithms should be selected according to sample conditions and model eigenvalues when applied to driving fatigue recognition. In addition, a variety of electrophysiological signals as information sources can help improve the accuracy of a fatigue recognition model, but the increase of model input eigenvalues cannot. Finally, the research progress of identification methods based on electrophysiological signals provided new opportunities for identifying driving fatigue.

Keywords: traffic safety; driving fatigue; machine learning; physiological mechanism; electrophysiological signal



DOI [10.11836/JEOM21310](https://doi.org/10.11836/JEOM21310)

基金项目

重庆院士创新项目(cstc2019yszx-jscxX0002);军队青年培育项目(20QNPY031)

作者简介

向洪义(1991—),男,硕士生;
E-mail: 13996373694@163.com

通信作者

赵辉, E-mail: box.zhaohui@163.com

伦理审批 不需要

利益冲突 无申报

收稿日期 2021-07-11

录用日期 2022-01-12

文章编号 2095-9982(2022)04-0459-06

中图分类号 R135

文献标志码 A

▶引用

向洪义,朱细燕,廖志康,等.基于电生理的机器学习在驾驶疲劳识别中的应用[J].环境与职业医学,2022,39(4):459-464.

▶本文链接

www.jeom.org/article/cn/10.11836/JEOM21310

Funding

This study was funded.

Correspondence to

ZHAO Hui, E-mail: box.zhaohui@163.com

Ethics approval Not required

Competing interests None declared

Received 2021-07-11

Accepted 2022-01-12

▶To cite

XIANG Hongyi, ZHU Xiyan, LIAO Zhikang, et al. Application of electrophysiology-based machine learning in identifying driving fatigue[J]. Journal of Environmental and Occupational Medicine, 2022, 39(4): 459-464.

▶Link to this article

www.jeom.org/article/en/10.11836/JEOM21310

道路交通事故(road traffic accident, RTA)每年在全球造成了巨大的人员伤亡和财产损失。据WHO统计,2018年全球RTA中死亡135.4万人,驾驶员伤亡

39.2 万人，其中疲劳驾驶是主要原因之一。驾驶疲劳引发的 RTA 是全球交通安全面临的共同威胁。美国国家公路安全管理局 2017 年数据显示，警方报告的 9.1 万起车祸涉及司机疲劳驾驶，事故导致大约 5 万人受伤，近 800 人死亡^[1]。据中国公安部 2022 年 1 月 11 日公布数据 (<https://app.mps.gov.cn/gdnps/pc/content.jsp?id=8322369mtype=>) 显示，我国 2021 年机动车保有量已达 3.95 亿辆，汽车驾驶人 4.44 亿人；又据公安部交通管理局发布的《2019 年中华人民共和国道路交通事故统计年报》统计，我国 2019 年疲劳驾驶导致死亡 764 人，受伤 1720 人。但疲劳诱发的 RTA 在事故成因鉴定时很难认定，导致疲劳对事故的发生影响程度被严重低估。

预防驾驶疲劳是道路交通安全领域的重点关注内容，驾驶疲劳识别是防范驾驶疲劳的前提条件。驾驶疲劳识别方法已取得极大发展，若干驾驶疲劳识别技术（车道偏离、图像识别等）已应用于部分车辆。然而，因疲劳发生机制复杂，影响因素众多以及个体表现差异较大等原因，驾驶疲劳识别的实践应用还存在诸多困难，以致当前重点道路交通事故仍需通过调整或控制驾驶时间来避免疲劳驾驶。本文通过复习相关文献，总结疲劳发生机制，梳理驾驶疲劳影响因素，比较驾驶疲劳的电生理信号识别方法，最后指出驾驶疲

劳研究的新机遇，以期为科研人员开展驾驶疲劳识别研究提供参考。

1 驾驶疲劳发生机制及诱发因素

疲劳是指因高强度或长时间持续活动导致的工作能力减弱，工作效率下降，错误率增加并伴有身体不适的状态。脑力、体力或二者过度活动均可引起疲劳，疲劳是一种渐进的工作效能降低的过程^[2]，并被世界卫生组织列为人类生命和健康的主要危险因素^[3]。诱发疲劳的因素除高强度工作外，自身的免疫调节也起着重要作用，研究证明，神经炎症是导致疲劳的主要原因^[4]，中枢神经系统是导致疲劳的重要因素，其直接或间接影响自身免疫并导致许多相关疾病^[5]。

疲劳包括生理和心理疲劳，两种疲劳均可导致人的警觉性和工作效能降低。驾驶员长时间作业过程中承受心理及生理的双重负荷，随作业时间延长产生中枢及外周神经系统的疲劳，导致生理和心理机能失调，引起驾驶效能受损，因此驾驶疲劳是心理疲劳与生理疲劳共同作用的结果。

诱发驾驶疲劳的因素众多，包括睡眠不足、昼夜节律、运动、持续驾驶以及性格等，相关内在和外在因素相互作用，对疲劳进展起不同程度的促进作用。驾驶疲劳的相关因素见表 1。

表 1 诱发驾驶疲劳的因素及相关理论依据

Table 1 Factors inducing driving fatigue and related theoretical basis

诱发因素	疲劳原因
睡眠不足	睡眠是消除身体疲劳的主要方式，睡眠可缓解疲劳，恢复机能，睡眠时间减少可使出现疲劳的概率更高 ^[6]
昼夜节律	昼夜节律是人体的一种生物钟，昼夜节律打破后会导致生理因素紊乱，例如活动能力、体温、睡眠(觉醒)机制、血压和工作效能等受影响，导致警觉性降低，工作效能受损，心情变差以及产生疲劳的感觉 ^[7]
剧烈运动	运动会致外周疲劳，同时也会导致中枢神经细胞内代谢物质改变继而诱发中枢疲劳；剧烈运动后还会产生疲惫感
环境因素	噪声、震动、环境温度、驾驶员受到刺激的频率和种类都会影响到驾驶员的警觉性；来自感觉器的一系列冲动与大脑皮层的反馈相结合，刺激了网状激活系统，维持了中枢神经系统的高度准备状态。当刺激很少时，感觉器冲动会减少，大脑的激活水平降低，从而增加导致疲劳的机会。单调路况下驾驶员由于缺乏刺激更容易产生疲劳 ^[8] ，与其对比之下，在路况多变的环境下驾驶员有着更好的驾驶效能以及更高的警觉性 ^[9]
持续驾驶	疲劳是一个连续的积累过程，任何活动如果维持的时间足够长，都会产生疲劳感。随着驾驶时间增加，驾驶员承受生理和心理的双重压力，更容易产生疲惫感
消极情绪	消极情绪与驾驶疲劳的关联性强，消极情绪会导致驾驶员活动减少、焦虑和疲劳惯性增加 ^[10]
性格	不同性格和气质的司机会有不同的疲劳体验 ^[11]

2 疲劳的神经调节机制与电生理信号的关系

疲劳作为一种生理、心理的感受，其本质是一种机体的自我保护机制，神经系统是机体调控过程的关键节点。电生理信号作为神经传导活动的一种信息反馈，反映了疲劳这一渐进生理过程的神经调控过程。电生理信号可提取与疲劳相关的特征值，作为疲劳识

别理论模型中的变量输入，是疲劳识别理论模型的关键节点。常见的驾驶疲劳生理信号及常用指标见表 2。

在中枢神经系统疲劳识别中，最常见的技术是脑电图，研究表明心理疲劳和脑电图的活动密切相关^[12-14]，人们很早就认识到心理上的变化，比如压力、疲倦、紧

张等情绪均与中枢神经系统的活动相关^[15]。外周神经系统的调节也可反映出疲劳的生理特征,心电图的心率变异性分析可以体现出迷走神经和交感神经活动的情况,被广泛用于疲劳识别^[16-17],同时外周疲劳导致肌肉的电传导特性变化也可通过肌电图得到^[18]。与疲

劳相关的行为及生理特征的变化也可以用电信号表征,如眼电图可反映眼部活动的电位变化,皮肤电活动可间接反应交感神经活动情况,相关特征可以作为疲劳识别的有效判据,也可被作为识别疲劳的电生理信号^[19-21]。

表 2 常用于驾驶疲劳识别的生理信号及常用指标

Table 2 Physiological signals and common indicators for driving fatigue recognition

生理指标	生理机制	常用指标
脑电图	大脑活动时,大量皮质锥体神经元会产生抑制性和兴奋性突触后电位,该信号在皮层水平被整合并传播到头皮,是脑神经细胞的电生理活动在大脑皮层或头皮表面的总体反映	频域信息: δ (0.5~4 Hz), θ (8~13 Hz), α (4~8 Hz), β (13~30 Hz), α/β , $(\theta+\alpha)/\beta$, θ/β , $(\theta+\alpha)/(\alpha+\beta)$
心电图	心电图信号包含了交感神经系统与副交感神经系统的活动情况(外周神经系统)	时域特征: HR, RRI, RMSSD, mean NN, RRSD; 频域特征: LF(0.04~0.15 Hz), HF(0.15~0.4 Hz), LF/HF; 非线性特征: 分形维数, SD ₁ , SD ₂ 及相关维, 信息维, 等
眼电图	眼电图用于记录眼部运动,可以测量在视网膜色素上皮和光感受器细胞之间存在的视网膜静电位,其幅值范围通常为0.05~3.5 mV	平均闭眼速度, 眨眼时间, 闭眼百分比(PERCLOS), 眨眼频率, 眨眼幅度, 睁眼延时, 等
肌电图	外周疲劳的主要外在表现为肌肉功能的变化,因此常用外周肌肉的生物电特性来评估外周神经的疲劳状态	肌电振幅、方差、中心频率, 相对频谱功率、峰度和形状因子
皮肤电活动	皮肤电活动亦称皮肤电反应(galvanic skin response, GSR),其受到皮肤汗腺分泌物的影响,汗腺由交感神经进行调节。疲劳时,交感神经活动减弱从而减少出汗,因此皮肤表现出电阻增加(电导率减小)	皮肤电导率

[注] HR: 心率; RRI: 心电图信号中相邻两个 R 波峰值的时间间隔; RMSSD: 相邻 RRI 之差的均方根值; mean NN: 平均心率间隔; RRSD: RR 间期的标准差; LF: 低频; HF: 高频; SD₁: 心电 Poincare 散点图短轴, 反映迷走神经变化; SD₂: 心电 Poincare 散点图长轴, 反映交感神经变化。

3 基于电生理信号的机器学习算法在驾驶疲劳中的应用

当前对电生理信号进行驾驶疲劳识别主要用机器学习的方法,采用电生理信号作为信息输入,对电生理信号进行预处理之后提取有意义的特征值,这种建立疲劳识别模型的驾驶疲劳识别方法被广泛使用^[22-23]。对驾驶员的疲劳程度分类,并按照疲劳识别模型进行驾驶疲劳识别。因此对驾驶疲劳识别可以归结为模式识别问题,而其中建立疲劳识别模型的核心是选取合适的分类器。Watling 等^[24]已经对利用生理信号的疲劳测量方法进行了系统回顾。

驾驶疲劳的机器学习主要使用监督学习法,该方法将基本事实疲劳信号分为训练集、验证集和测试集。实施过程中,通过训练集对提取的生理特征值训练模型并确定参数,验证集用于确定网络结构以及调整模型的超参数,测试集对训练好的模型进行评价。受样本限制,训练集较小时还需要采用交叉验证的方式评估模型的预测性能。

不同的分类器具有自身的算法特征,需根据样本量大小、信号特征值多少等因素选取合适的分类算法,不同类型的分类器,如 logistic 回归、K 最近邻(K-nearest neighbor, KNN)、支持向量机(support vector machine, SVM),它们对于数据的假设,表示抽取的能

力都存在差异。选取同类型的分类器,但使用不同的特征参数也会影响到模型的表现。因此在利用电生理信号特征作为模型输入,建立疲劳识别模型时,输入特征值和分类器的选择会对最终的疲劳识别模型的效能产生影响。作者梳理近年多个课题组的驾驶疲劳实验研究,列举、比较多种分类器对不同电生理信号进行驾驶疲劳识别的受试者工作特征曲线下面积(area under curve, AUC)以及准确性、敏感性和特异性等数据(见表 3)。

表 3 所示,针对相同的电生理信号作为输入信息时,在采用不同的分类器时灵敏性和特异性存在较大差异,且不同研究之间采用相同识别模型也出现敏感性和特异性的差异。差异产生原因除了输入电生理信号提取的特征值差异外,样本含量较少导致的个体差异性也可能产生影响;与此同时,相同的特征值输入不同的分类器,受分类器自身特性影响,得到的结论可能会存在差异,如数据不均衡时采用了决策树作为分类器等。现有疲劳识别模型在疲劳相关电生理信号特征值提取方法上虽然有相关共识(如心率变异性分析时长为 5 min, 频域 LF、HF 及非线性域 SD₂/SD₁ 等指标为疲劳相关的有效指标),但在模型的特征值选取上的差异可能是导致模型有效性不一致的主要原因。

表3 基于电生理信号的多种算法比较的驾驶疲劳识别研究方法回顾

Table 3 Review of driving fatigue recognition studies based on comparison of various algorithms with physiological signals

研究	样本含量	环境	信号	分类器	AUC/%	准确性/%	敏感性/%	特异性/%				
Kim, et al (2021) ^[25]	10	—	14通道脑电图、PERCLOS	线性回归	—	92.0	94.0	90.0				
				KNN	—	95.0	94.0	97.0				
				SVM	—	95.0	93.0	98.0				
				随机森林	—	98.0	97.0	98.0				
Khare, et al (2021) ^[26]	16	—	单通道脑电图	基于树结构的分类器、人工神经网络、KNN、SVM、线性判别分析、线性回归、朴素贝叶斯、袋装决策树、集成增强树和集成随机欠采样增强分类器	—	97.2*	97.0*	97.5*				
					—	—	—	—				
Chui, et al (2020) ^[27]	18	公路	心电图	多目标遗传算法优化的深度多核学习SVM	97.1	—	99.0	98.3				
				网格搜索方法	89.2	—	90.3	91.5				
				随机森林	—	85.0	65.9	89.3				
				KNN	—	77.9	74.3	78.9				
Persson, et al (2020) ^[28]	86	公路	心电图	SVM	—	79.9	48.3	88.4				
				AdaBoost	—	82.1	69.8	85.4				
				Barua, et al (2019) ^[29]	30	模拟器	脑电图、眼电图、PERCLOS、睡眠-觉醒时间	基于案例的推理	—	83.0	85.0	81.0
				KNN	—	75.0	79.0	69.0				
Mårtensson, et al (2019) ^[30]	86	公路	脑电图、眼电图、心电图、睡眠-觉醒时间	SVM	—	77.0	82.0	70.0				
				随机森林	—	77.0	81.0	71.0				
				随机森林	94.1	94.1	86.5	95.7				
				KNN	—	86.0~94.0*	88.0*	80.0*				
Mahmoodi and Nahvi (2019) ^[31]	13	模拟器	肌电图	线性SVM	—	82.0*	82.0*	80.0*				
				高斯SVM	—	90.0*	83.0*	98.0*				
				AdaBoost	—	92.0*	88.5*	97.0*				
				—	—	—	—	—				
Chen, et al (2018a) ^[32]	12	模拟器	30通道脑电图	KNN	—	90.0	77.0	92.0				
				回归树	—	84.0	61.0	89.0				
				SVM	—	84.0	61.0	88.0				
				朴素贝叶斯模型	—	78.0	68.0	81.0				
Chen, et al (2018b) ^[33]	12	模拟器	30通道脑电图	用于回归的学习者集合	—	75.0	52.0	79.0				
				支持向量机回归模型	—	73.0	54.0	75.0				
				新型融合特征的极限学习机	98.0	95.0	95.7	94.3				
				SVM	95.0	89.3	87.1	91.4				
Chai, et al (2017) ^[34]	43	模拟器	32通道脑电图、反应时间	KNN	—	98.6	98.8	98.9				
				SVM	—	96.9	96.3	96.2				
				logistic回归	—	90.9	91.0	91.0				
				决策树	—	94.9	96.9	93.3				
Chen, et al (2017) ^[35]	9	公路	心电图、GSR、呼吸频率	稀疏-深度置信网络	—	93.1	93.9	92.3				
				贝叶斯神经网络	—	84.3	84.3	83.0				
				深度置信网络	—	90.6	90.8	90.4				
				人工神经网络	—	79.3	80.8	77.8				
Min, et al (2017) ^[36]	12	模拟器	30通道脑电图、反应时间	SVM	—	89.7	88.5	94.2				
				极限学习机	—	89.2	88.2	94.1				
				反向传播神经网络	—	98.3	98.3	98.2				
				SVM	—	96.7	96.2	96.9				
San, et al (2016) ^[37]	5	模拟器	32通道脑电图	随机森林	—	96.4	96.9	96.0				
				KNN	—	93.7	93.0	94.2				
				基于混合深度通用模型的SVM	—	73.3	91.1	55.5				
				基于功率谱密度的SVM	—	61.0	70.0	52.0				
Pritchett, et al (2011) ^[38]	45	模拟器	脑电图、身体运动数据	混合源算法	78.3	—	95.4	75.8				
				单一源算法	76.4	—	95.5	74.2				

[注] —：表示文章没有相关数据；*：集成增强树数据；#：Mårtensson等^[30]文中该几类分类器的准确性、敏感性、特异性为趋势图，表中数据为近似值。

需要注意的是,由于当前采用电生理信号进行疲劳驾驶研究时的被试样本通常较少,在采用低偏差和高方差的分类器(如KNN)时,易发生过拟合,此时高偏差和低方差的分类器(如朴素贝叶斯)更为合适。随着被试样本的增大,数据偏差减小,此时则需要低偏差和高方差的分类器。没有一种算法能解决所有的问题,应当根据样本的特征选取合适的分类算法构建疲劳识别模型。

研究表明,增加特征值数量并不一定会增加驾驶员疲劳检测系统的敏感性和特异性^[29],但多种生理信号的疲劳识别方法具有更高的敏感性和特异性^[30,39-40]。在利用生理信号进行疲劳识别时,需要注意的是不能为了提高疲劳识别模型准确性,盲目追求更多的生理信号以及提取更多的特征值。

4 总结和展望

驾驶疲劳的识别方法已从传统的单一信号特征值进行统计分析,发展到多源信息的多模态融合的机器学习算法。随着机器学习算法在驾驶疲劳识别领域的广泛应用,基于生理电信号的疲劳识别方法取得了较大的进展,为驾驶疲劳识别提供了新机遇。然而,由于驾驶疲劳研究在数据预处理、模型的特征值选取等方面缺乏规范,导致研究结果数据质量的完整性、一致性较差,不利于总结现有研究成果,若能在疲劳相关电生理信号的特征提取方法这一领域形成相关行业标准,实现电生理信号在疲劳识别研究方向的聚焦,可促进基于电生理的疲劳识别方法研究水平提升。

电生理信号因其有效性在疲劳识别中具有重要的价值。随着生理信号的处理和分析技术的发展,从时域、频域、非线性以及熵等多个角度对脑电图、心电图等复杂电生理信号进行解析,特别是人工智能算法的进一步发展,为高效提取生理信号的驾驶疲劳信息提供了有效工具。但因受限于信号的采集方式和佩戴的舒适性,该技术的应用推广受限。所幸的是,近年来利用穿戴设备进行疲劳识别的研究日益增多^[41-42]。可穿戴式传感器,尤其是柔性传感器在电生理信号、生物物理信号及生化信号测量领域的极大发展^[43],为驾驶疲劳微弱生理信号的多模态信号长时间动态测量提供了技术支撑,是未来穿戴式驾驶疲劳识别的重要方向。柔性传感器所具有的无侵入感、不影响人体活动等优势,在未来的疲劳识别领域具有广阔的应用前景。

参考文献

- [1] NHTSA. Drowsy driving[EB/OL]. [2021-11-17]. <https://www.nhtsa.gov/risky-driving/drowsy-driving>.
- [2] BROWN ID. Driver fatigue[J]. *Hum Factors*, 1994, 36(2): 298-314.
- [3] YANG X, LI F, LIU Y, et al. Study on the correlation between NF- κ B and central fatigue[J]. *J Mol Neurosci*, 2021, 71(10): 1975-1986.
- [4] LACOURT TE, VICHAYA EG, CHIU GS, et al. The high costs of low-grade inflammation: persistent fatigue as a consequence of reduced cellular-energy availability and non-adaptive energy expenditure[J]. *Front Behav Neurosci*, 2018, 12: 78.
- [5] ZIELINSKI M R, SYSTROM D M, ROSE N R. Fatigue, sleep, and autoimmune and related disorders[J]. *Front Immunol*, 2019, 10: 1827.
- [6] MAIA Q, GRANDNER M A, FINDLEY J, et al. Short and long sleep duration and risk of drowsy driving and the role of subjective sleep insufficiency[J]. *Accid Anal Prev*, 2013, 59: 618-622.
- [7] BONNET M H. Effect of sleep disruption on sleep, performance, and mood[J]. *Sleep*, 1985, 8(1): 11-19.
- [8] THIFFAULT P, BERGERON J. Monotony of road environment and driver fatigue: a simulator study[J]. *Accid Anal Prev*, 2003, 35(3): 381-391.
- [9] FARAHMAND B, BOROUJERDIAN A M. Effect of road geometry on driver fatigue in monotonous environments: a simulator study[J]. *Transp Res Part F: Traffic Psychol Behav*, 2018, 58: 640-651.
- [10] LAL S K L, CRAIG A. Driver fatigue: psychophysiological effects[C]// Proceedings of the 4 th International Conference on Fatigue and Transportation. Murdoch, Western Australia: ARRB, 2000: 21.
- [11] BROWN I D. Car driving and fatigue[J]. *Triangle*, 1967, 8: 131-137.
- [12] PIRES FO, SILVA-JÚNIOR FL, BRIETZKE C, et al. Mental fatigue alters cortical activation and psychological responses, impairing performance in a distance-based cycling trial[J]. *Front Physiol*, 2018, 9: 227.
- [13] LI G, JIANG Y, JIAO W, et al. The maximum eigenvalue of the brain functional network adjacency matrix: meaning and application in mental fatigue evaluation[J]. *Brain Sci*, 2020, 10(2): 92.
- [14] DIMITRAKOPOULOS G N, KAKKOS I, DAI Z, et al. Functional connectivity analysis of mental fatigue reveals different network topological alterations between driving and vigilance tasks[J]. *IEEE Trans Neural Syst Rehabil Eng*, 2018, 26(4): 740-749.
- [15] MULDER G, MULDER —HAJONIDES VAN DER MEULEN W R E H. Mental load and the measurement of heart rate variability[J]. *Ergonomics*, 1973, 16(1): 69-83.
- [16] 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.
- [17] PERSSON A, JONASSON H, FREDRIKSSON I, et al. Heart rate variability for driver sleepiness classification in real road driving conditions[J]. *Annu Int Conf IEEE Eng Med Biol Soc*, 2019, 2019: 6537-6540.
- [18] 王世娟, 张忠彬, 王生, 等. 表面肌电描记术在工作相关肌肉骨骼损伤研究中的应用[J]. 环境与职业医学, 2017, 34(9): 812-816.
WANG SJ, ZHANG ZB, WANG S, et al. Application of surface electromyography to work-related musculoskeletal disorders research[J]. *J Environ Occup Med*, 2017, 34(9): 812-816.
- [19] JACKSON M L, KENNEDY G A, CLARKE C, et al. The utility of automated measures of ocular metrics for detecting driver drowsiness during extended wakefulness[J]. *Accid Anal Prev*, 2016, 87: 127-133.
- [20] ZHENG W L, GAO K, LI G, et al. Vigilance estimation using a wearable EOG device in real driving environment[J]. *IEEE Trans Intell Transp Syst*, 2020, 21(1): 170-184.
- [21] MOMOSE H, MORIMITSU N, IKEDA E, et al. Eyes closing and drowsiness in human subjects decrease baseline galvanic skin response and active

- palmar sweating: relationship between galvanic skin and palmar perspiration responses [J]. *Front Physiol*, 2020, 11: 558047.
- [22] CUI J, LAN Z, LIU Y, et al. A compact and interpretable convolutional neural network for cross-subject driver drowsiness detection from single-channel EEG [J]. *Methods*, 2021, DOI: 10.1016/j.ymeth.2021.04.017
- [23] FUJIWARA K, ABE E, KAMATA K, et al. Heart rate variability-based driver drowsiness detection and its validation with EEG [J]. *IEEE Trans Biomed Eng*, 2019, 66(6): 1769-1778.
- [24] WATLING CN, HASAN M, LARUE GS. Sensitivity and specificity of the driver sleepiness detection methods using physiological signals: a systematic review [J]. *Accid Anal Prev*, 2021, 150: 105900.
- [25] KIM K J, LIM K T, BAEK J W, et al. In low-cost real-time driver drowsiness detection based on convergence of IR images and EEG signals [C]// Proceedings of 2021 International Conference on Artificial Intelligence in Information and Communication (ICAIC). Jeju Island, Korea (South): IEEE, 2021: 438-443.
- [26] KHARE SK, BAJAJ V. Entropy-based drowsiness detection using adaptive variational mode decomposition [J]. *IEEE Sens J*, 2021, 21(5): 6421-6428.
- [27] CHUI KT, LYTRAS M D, LIU R W. A generic design of driver drowsiness and stress recognition using MOGA optimized deep MKL-SVM [J]. *Sensors (Basel)*, 2020, 20(5): 1474.
- [28] 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*, 2021, 22(6): 3316-3325.
- [29] BARUA S, AHMED M U, AHLSTRÖM C, et al. Automatic driver sleepiness detection using EEG, EOG and contextual information [J]. *Expert Syst Appl*, 2019, 115: 121-135.
- [30] MÅRTENSSON H, KEELAN O, AHLSTRÖM C. Driver sleepiness classification based on physiological data and driving performance from real road driving [J]. *IEEE Trans Intell Transp Syst*, 2019, 20(2): 421-430.
- [31] MAHMOODI M, NAHVI A. Driver drowsiness detection based on classification of surface electromyography features in a driving simulator [J]. *Proc Inst Mech Eng, Part H: Eng Med*, 2019, 233(4): 395-406.
- [32] CHEN J, WANG H, HUA C. Electroencephalography based fatigue detection using a novel feature fusion and extreme learning machine [J]. *Cogn Syst Res*, 2018, 52: 715-728.
- [33] CHEN J, WANG H, HUA C. Assessment of driver drowsiness using electroencephalogram signals based on multiple functional brain networks [J]. *Int J Psychophysiol*, 2018, 133: 120-130.
- [34] CHAI R, LING S H, SAN P P, et al. Improving EEG-based driver fatigue classification using sparse-deep belief networks [J]. *Front Neurosci*, 2017, 11: 103.
- [35] CHEN LL, ZHAO Y, YE P F, et al. Detecting driving stress in physiological signals based on multimodal feature analysis and kernel classifiers [J]. *Expert Syst Appl*, 2017, 85: 279-291.
- [36] MIN J, WANG P, HU J. Driver fatigue detection through multiple entropy fusion analysis in an EEG-based system [J]. *PLoS One*, 2017, 12(12): e0188756.
- [37] SAN P P, LING S H, CHAI R, et al. EEG-based driver fatigue detection using hybrid deep generic model [C]// Proceedings of the 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Orlando, FL, USA: IEEE, 2016: 800-803.
- [38] PRITCHETT S, ZILBERG E, XU Z M, et al. Comparing accuracy of two algorithms for detecting driver drowsiness — Single source (EEG) and hybrid (EEG and body movement) [C]// Proceedings of the 7th International Conference on Broadband Communications and Biomedical Applications. Melbourne, VIC, Australia: IEEE, 2011: 179-184.
- [39] BUNDELE M M, BANERJEE R. ROC analysis of a fatigue classifier for vehicular drivers [C]// Proceedings of 2010 5th IEEE International Conference Intelligent Systems. London, UK: IEEE, 2010: 296-301.
- [40] GUO M, LI S, WANG L, et al. Research on the relationship between reaction ability and mental state for online assessment of driving fatigue [J]. *Int J Environ Res Public Health*, 2016, 13(12): 1174.
- [41] LENG L B, GIIN L B, CHUNG W Y. Wearable driver drowsiness detection system based on biomedical and motion sensors [C]// Proceedings of 2015 IEEE SENSORS. Busan, Korea (South): IEEE, 2015: 1-4.
- [42] JEONG I C, BYCHKOV D, SEARSON P C. Wearable devices for precision medicine and health state monitoring [J]. *IEEE Trans Biomed Eng*, 2019, 66(5): 1242-1258.
- [43] CHEN Y, ZHANG Y, LIANG Z, et al. Flexible inorganic bioelectronics [J]. *npj Flexible Electron*, 2020, 4(1): 2.

(英文编辑：汪源；责任编辑：丁瑾瑜)

· 告知栏 ·

《环境与职业医学》出版伦理声明

《环境与职业医学》遵循出版道德委员会 (Committee on Publication Ethics, COPE) 的指导方针调查和处理不当行为的指控或怀疑。

对于作者：①所投稿件必须是作者的原创作品，之前不得以印刷或在线形式发表，或同时投给其他出版物，如文中使用先前发表的资料(如图、表格)需要提供相关的归属权和许可证明；②作者应保证所投稿件不存在任何学术不端行为，学术不端行为定义见 CY/T 174—2019《学术出版规范—期刊学术不端行为界定》；③所有作者在投稿时需签署“利益冲突声明”，声明是否存在实际或潜在的利益冲突。

对于编辑与审稿人：编辑和审稿人必须公开任何实际或潜在的竞争性利益，包括所有被合理视为与审稿有关的经济利益或非经济利益；有关竞争性利益和其他道德问题的更详细信息，请参阅 COPE 指导方针。

《环境与职业医学》编辑部

2022 年 4 月 25 日