

中文引用格式:顾清华,殷书檀,王丹,等. 基于改进 YOLOv8 的矿卡司机疲劳驾驶检测[J]. 中国安全科学学报, 2025, 35(1): 60-66.  
英文引用格式:GU Qinghua, YIN Shutan, WANG Dan, et al. Mining truck driver fatigue driving detection based on improved YOLOv8 [J]. China Safety Science Journal, 2025, 35(1): 60-66.

# 基于改进 YOLOv8 的矿卡司机疲劳驾驶检测\*

顾清华<sup>1,2</sup>教授, 殷书檀<sup>1,2</sup>, 王丹<sup>1,2</sup>, 李学现<sup>1,2</sup>, 尹慧民<sup>3</sup>

(1 西安建筑科技大学 资源工程学院, 陕西 西安 710055; 2 西安市智慧工业感知、  
计算与决策重点实验室, 陕西 西安 710055; 3 哈密市和翔工贸有限责任公司, 新疆 哈密 839200)

中图分类号: X910 文献标志码: A DOI: 10.16265/j.cnki.issn1003-3033.2025.01.0147

基金项目: 国家自然科学基金资助(52374135); 金属矿智能开采理论及技术创新团队项目(2023-CX-TD-12)。

**【摘要】** 为解决露天矿区卡车司机疲劳驾驶检测漏检率和误检率高、鲁棒性较差的问题, 构建基于改进 YOLOv8 的露天矿卡车司机疲劳驾驶检测模型(EBS-YOLO), 提高疲劳检测的整体性能。首先, 以 YOLOv8 为疲劳检测基础模型, 通过添加小目标检测层, 增强模型对小目标关注; 其次, 引入瓶颈注意力(BAM)模块, 强化模型对小目标特征提取能力, 尤其是对眼部特征提取能力; 最后, 将主干网络中跨阶段聚合模块(C2f)全部替换为高效多尺度注意力(EMA)模块, 进而有效降低模型参数量和计算开销, 以满足模型轻量化需求。结果表明: 改进后的 YOLOv8 模型检测效果较好, 准确率、召回率、平均检测精度分别达到了 93.6%、93.9%、96.5%, 且模型内存大小仅有 4.9 MB。相比于 YOLOv8 模型, 改进后的模型能够快速准确识别出矿卡司机疲劳状态, 满足实时性要求, 从而有效预防疲劳驾驶事故发生。

**【关键词】** 露天矿; 疲劳驾驶检测; 卡车司机; 小目标检测; YOLOv8

## Mining truck driver fatigue driving detection based on improved YOLOv8

GU Qinghua<sup>1,2</sup>, YIN Shutan<sup>1,2</sup>, WANG Dan<sup>1,2</sup>, LI Xuexian<sup>1,2</sup>, YIN Huimin<sup>3</sup>

(1 School of Resource Engineering, Xi'an University of Architecture and Technology, Xi'an Shaanxi 710055, China; 2 Key Laboratory of Perception, Computing and Decision Making for Intelligent Industry, Xi'an Shaanxi 710055, China; 3 Hami Hexiang Industry and Trade Co., Ltd., Hami Xinjiang 839200, China)

**Abstract:** To address the high rates of missed detections and false alarms, as well as the poor robustness in fatigue driving detection for open-pit mine truck drivers, a fatigue driving detection model for mine truck drivers (EBS-YOLO) based on the improved YOLOv8 is constructed to enhance the overall performance of fatigue detection. Firstly, YOLOv8 was used as the basic model for fatigue detection, and a small target detection layer was added to enhance the model's attention to small targets. Secondly, the bottleneck attention module (BAM) was used to improve the model performance to extract small target features, especially eye features. Finally, all cross-stage aggregation modules (C2f) in the backbone network were replaced with efficient multi-scale attention (EMA) modules, thereby effectively reducing model

parameters and computational overhead to meet the requirements of a lightweight model. The results showed that the improved YOLOv8 model had a great detection effect with the accuracy, recall rate, and average detection accuracy reaching 93.6%, 93.9%, and 96.5%, respectively, and the memory size of the model was only 4.9 MB. Compared with the YOLOv8 model, the improved model can quickly and accurately identify the fatigue state of mining truck drivers, meet real-time requirements, and effectively prevent fatigue-driving accidents.

**Keywords:** open-pit mines; fatigue driving detection; truck driver; detection of small targets; YOLOv8

## 0 引言

随着露天矿的持续发展,运输设备需求量逐渐增加,矿山道路交通安全正面临严峻挑战。据统计,公路运输导致的交通伤亡事故一直高居露天矿各类事故之首,其中,疲劳驾驶引发的安全事故约占运输事故总量的65%,这已成为影响露天矿区交通事故的关键因素之一<sup>[1]</sup>。因此,实时精确检测卡车司机驾驶状态,对于预防疲劳驾驶事故发生具有重要意义。

目前,国内外学者针对疲劳驾驶检测研究方法主要包含3类:驾驶员生理特征、机动车行为特征和计算机视觉特征。其中,对于驾驶员生理特征研究,主要通过检测心电信号、体表温、脑电波等生理特征数据判别疲劳驾驶状态<sup>[2]</sup>,该方法具有较高的准确率,但需要佩戴相关仪器,成本高且影响正常驾驶<sup>[3-4]</sup>。对于机动车行为特征研究,主要通过检测车辆特征参数判别驾驶员疲劳状态<sup>[5]</sup>,该方法不直接接触驾驶员,但受天气、道路状况等因素影响大<sup>[6]</sup>。对于计算机视觉特征研究,主要通过机器视觉、图像处理等手段判别驾驶员疲劳状态<sup>[7-10]</sup>,该方法成本低、无接触、准确率较高<sup>[11]</sup>。随着成像技术与图形处理器等软硬件快速更新,深度学习技术在该领域应用日益增多。胡习之等<sup>[12]</sup>提取面部疲劳特征参数改进了目标检测算法,解决了光线变化、肤色干扰等问题;LIU Mingzhou 等<sup>[13]</sup>提出一种基于卷积神经网络和长短期记忆的疲劳检测方法,克服了光照、背景、角度和个体差异的影响;方浩杰等<sup>[14]</sup>增加了YOLOv5模型特征采样次数,结合双向特征金字塔网络提升了模型整体的检测能力。

综上,随着深度学习不断发展,图像识别技术在疲劳监测应用中愈发成熟,但由于露天矿运输环境的特殊性,基于视觉疲劳驾驶检测技术在露天矿区的应用效果差。为此,提出一种模型小、精度高、速度快的疲劳驾驶检测模型,可实时监测露天矿卡车司机眼部、嘴部和头部疲劳状态,进而预防疲劳驾驶

事故,以提高露天矿区安全管理水平。

## 1 基于改进 YOLOv8 的疲劳驾驶检测模型

在实际应用场景中,YOLOv8 在小目标检测方面效果相对较差,而EBS-YOLO改进了YOLOv8算法,在保障检测速度的同时提升小目标特征检测性能。图1为EBS-YOLO网络结构。其中,主干网络负责从输入的图像中提取关键特征,颈部网络则对主干网络提取的特征进行整合和增强,最后由检测头输出最终的检测结果,具体改进方法如下:

1) 小目标检测的性能优化。YOLOv8模型对小目标检测效果不佳,主要因为小目标特征尺寸较小,而YOLOv8模型采样倍数较大,这导致小目标特征信息在深层次特征图中难以捕捉<sup>[15]</sup>。因此,在颈部网络中添加小目标检测层,并新增160×160像素小目标检测头。通过将低层次的特征图与高层次的特征图进行融合,然后将合并的特征图送入小目标检测头进行分析,从而显著提高模型对小目标的检测准确性。

2) 加强特征提取。瓶颈注意力(Bottleneck Attention Module, BAM)模块,一种通过结合通道注意力机制和空间注意力机制的模块,其可自适应地调节不同通道的特征响应,帮助模型集中精力关注重要的信息,有效增强模型对关键特征的提取能力。通过在小目标检测头前引入BAM模块可强化模型对眼部小目标特征提取能力,从而进一步提升对眼部疲劳状态检测性能。

3) 模型轻量化。高效多尺度注意力(Efficient Multi-Scale Attention, EMA)模块,一种基于跨空间学习且无需降维即可高效运作的多尺度注意力模块。EMA的特征分组和多尺度结构能够提取复杂背景下图像相关特征,同时,减少参数数量和计算开销。将主干网络中跨阶段聚合模块(C2f)模块全部替换为EMA模块,可有效区分驾驶员面部特征与车

内的复杂背景,在保证模型检测精度的前提下,减少模型参数数量和计算量消耗,使检测模型更符合轻量化需求。

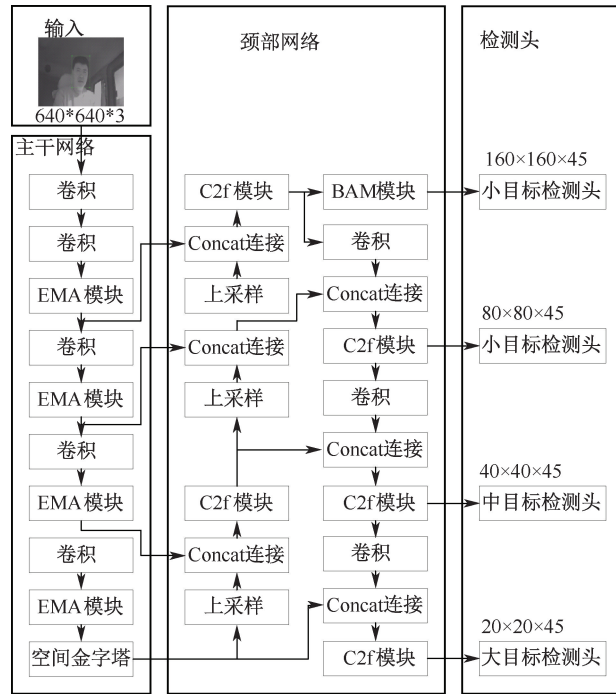


图1 EBS-YOLO 网络结构

Fig.1 EBS-YOLO network structure

## 2 疲劳驾驶检测结果分析

### 2.1 疲劳驾驶数据集获取与处理

数据来源于4个大型露天矿区中卡车司机现场实际工作环境,通过在矿用卡车驾驶室内安装面部抓拍摄摄像头、监控摄像头,实时拍摄卡车司机面部特征红外照片或视频,并将采集图片格式修改为640×640像素,图片类型分为人脸、睁眼、闭眼、张嘴、闭嘴、打哈欠、戴口罩和低头8类。其中,将讲话和正常张嘴统一归为张嘴类,低头表示打瞌睡时的低头行为,共计1200张图片。为提高试验模型泛化能力,将图片通过镜像、旋转、高斯降噪和锐化等方法将图片增至6000张。

### 2.2 试验模型评价指标

1) 模型检测性能评价指标。准确率(Precision,  $P$ )指所有被预测为正样本的结果中,实际为正样本的比例。召回率(Recall,  $R$ )指所有实际为正样本的数据中,模型成功预测为正样本的比例。均值平均精度(mean Average Precision, mAP)衡量模型检测性能;mAP越大,表示模型精度越高。其

中,mAP@0.5表示在置信度阈值为0.5时的mAP,当模型预测的置信度大于或等于0.5时,计算模型对所有类别的平均精度,然后取平均精度的平均值;mAP@0.5:0.95表示在置信度阈值从0.5到0.95的范围内,以0.05为步长变化时的mAP均值。

各指标的计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (1)$$

$$R = \frac{TP}{TP + FN} \quad (2)$$

$$mAP = \frac{1}{N} \sum_{i=0}^n AP_i \quad (3)$$

式中:TP为预测正确的正样本数量;FP为预测错误正样本数;FN为预测错误负样本数量;AP为不同召回率水平下平均精确度值; $N$ 为不同目标类别总数; $n$ 为类别序号,从0到 $N-1$ ; $i$ 为类别索引; $AP_i$ 为第 $i$ 个类别平均精度。

2) 模型轻量化评价指标。模型参数量(Parameters, Params)是指模型训练过程中参数总量,包括权重、偏置值等,用于衡量模型空间复杂度和规模。模型计算量(Giga Floating-point Operations Per Second, GFLOPs)是指模型一次前向传播时浮点运算数量,用于评估模型计算资源消耗情况。每秒帧数(Frames Per Second, FPS)是衡量图像处理或模型推断速度的指标,FPS越高,模型处理速度越快。模型大小是指机器学习或深度学习模型所占存储空间大小。

### 2.3 检测结果分析

1) 消融试验结果与分析。表1为各注意力机制的消融试验,从中可以发现,通过添加小目标检测层,增强YOLOv8对小目标检测能力,在精度上提升了2.9%。为继续优化小目标检测性能,在160×160小目标检测头前分别引入全局注意力(Global Attention Mechanism, GAM)模块、卷积块注意力(Convolutional Block Attention Module, CBAM)模块、简易注意力(Similarity-Aware Activation Module, SimAM)模块、双层路由注意力(Bi-Level Routing Attention, Biformer)模块和BAM模块进行对比试验。其中,GAM、CBAM模块较为常用,但在精度方面提升幅度均相对较小;CBAM模块受到许多改进研究的广泛应用,但精度无法得到有效提升;轻量级GAM模块,通过减少信息缩减来提高深度神经网络的性能,但精度仅仅提升0.2%;无参数注意力模块SimAM和Biformer在精度上提升也不明显。对比以

上模块,引入 BAM 模块后模型检测性能得到有效提升,检测精度提升 2.2%,增强了模型对关键特征提取能力。

表 2 为总体模型消融试验。可以看出,引入小目标检测层和 BAM 模块后,模型的准确率提高了 5.1%。然而,这种改进以模型参数量、计算量和模型大小的显著增加为代价。为了解决这一问题,采用 EMA 模块来替换主干网络中的 C2f 模块,与 YOLOv8 模型相比,改进后的模型在参数量上减少了 24.3%,模型权重大小也减少了 22.2%,使得模型更加轻量化,同时保持了高效的检测性能。

表 2 总体模型消融试验

Table 2 Overall model ablation test

序号	小目标	BAM	EMA	mAP@0.5/%	mAP@0.5-0.95/%	Params/M	FLOPs/G	模型大小/MB
1	—	—	—	91.2	53.2	3.01	8.1	6.3
2	√	—	—	94.9	54.9	10.95	37.8	22.1
3	√	√	—	96.3	56.1	11.53	38.9	22.3
4	√	√	√	96.5	56.7	2.28	10.7	4.9

2) 轻量化对比试验结果与分析。为验证改进后模型实际性能,使用目前主流目标检测网络与其对比分析,结果见表 3。可以看出,在相同试验条件下,单阶段目标检测模型中,YOLO 系列模型检测精度相对较低,单次多框检测模型 (Single Shot MultiBox Detector, SSD) 检测精度相对较高,但模型计算复杂度和体积都相对增加;对于两阶段的目标检测模型,快速卷积模型 (Fast Region-based Convolutional Network, Fast-RCNN) 虽拥有较高检测精度,但是模型权重太大,不便部署,并且检测速度太低,难以满足疲劳驾驶实时检测需求。改进后模型兼顾了精度、轻量化和速度三者之间平衡,具有更高精度、更少参数量和较小计算量,同时较小模型体积和较高检测速度更适合复杂检测环境,契合露天矿卡车司机疲劳驾驶检测系统需求中轻量化、高精度和快速度的特点,更适合部署于计算资源有限设备。

3) 检测效果分析。表 4 为改进前后精度对比结果。可以看出,改进后的模型对眼部和嘴部的检测精度明显提升,模型的整体检测性能得到有效增强。此外,从检测热力图分析,改进后的模型更加关

表 4 改进前后精度对比

Table 4 Accuracy comparison before and after improvements

模型	人脸	睁眼	闭眼	张嘴	闭嘴	打哈欠	戴口罩	低头	P/%	R/%	mAP@0.5/%
YOLOv8n	97.9	85.6	85.8	89.3	87.7	92.2	94.6	96.5	88.4	87.8	91.2
EBS-YOLO	98.5	95.4	96.2	96.6	95.9	96.5	97.1	95.8	93.6	93.9	96.5

表 1 注意力模块对比

Table 1 Comparison of attention modules

模型	mAP@0.5/%	Params/M	FLOPs/G	模型大小/MB
YOLOv8n	91.2	3.01	8.1	6.3
小目标	94.1	10.95	37.8	22.1
小目标+Biformer	94.8	10.98	38.4	22.4
小目标+GAM	94.3	11.28	38.1	22.5
小目标+SimAM	94.6	10.94	37.8	22.3
小目标+CBAM	94.5	11.62	39.2	23.1
小目标+BAM	96.3	11.53	38.9	22.3

表 3 轻量化对比试验结果

Table 3 Lightweight comparison test results

模型	mAP@0.5/%	Params/M	FLOPs/G	FPS/(帧·s <sup>-1</sup> )	模型大小/MB
YOLOv8n	91.2	3.01	8.1	51	6.3
YOLOv3-tiny	85.3	105.7	292.2	5	206.8
YOLOv5s	91.4	4.9	14.9	44	13.2
YOLOv6n	89.5	4.5	12.8	43	8.9
YOLOv7-tiny	90.5	6.7	15.1	41	72.6
SSD	93.8	26.4	107.8	25	93.5
Fast-RCNN	92.3	42.6	134.5	10	106.5
EBS-YOLO	96.5	2.28	10.7	49	4.9

注眼部区域疲劳特征,对小目标的检测更加优越,如图 2 所示。从检测效果分析,YOLOv8 模型对眼部特征检测出现漏检和误检情况,而改进后 EBS-YOLO 模型检测完全正确;在曝光情况下,改进后的模型对人脸识别的检测效果更好,如图 3 所示。综上,改进后的模型在各疲劳特征检测精度上有明显提高,对小目标检测效果更加显著。

4) 试验验证分析。为验证模型性能,采用公开的疲劳检测数据集 YawDD 作为评估模型性能的标准数据集。该视频数据集包含不同环境下驾驶状态,其




图2 小目标检测热力图  
Fig.2 Small target detection heatmap



图3 检测效果对比  
Fig.3 Detection effect comparison


中,将眼部、嘴部状态分为睁眼、闭眼、张嘴、闭嘴和打哈欠状态。为验证 EBS-YOLO 模型的性能,将整理后数据集分别在目前主流网络模型和改进后模型进行训练和测试,见表 5。可以发现,改进后模型在准确率、召回率和平均精度方面具有明显优势,并且模型检测速度达到了 49 帧/s,模型大小仅有 4.9 MB。

表 5 模型性能对比表


Table 5 Model performance comparison

模型	P/ %	R/ %	mAP @ 0.5/%	FPS/ (帧·s <sup>-1</sup> )	模型大小/MB
YOLOv8n	91.4	91.0	92.4	52	6.3
YOLOv5s	92.1	85.0	91.9	46	13.2
YOLOv6n	84.1	88.2	89.2	44	8.9
YOLOv7-tiny	90.7	90.4	94.2	40	72.2
SSD	94.0	83.6	94.1	28	93.5
Fast-RCNN	92.9	82.1	93.3	19	106.5
EBS-YOLO	96.8	96.5	97.4	49	4.9


图 4 为不同光照情况下 6 个模型对应的检测图。其中,a 和 b 代表正常光源图,c 和 d 代表低照度光源图,e 和 f 代表复杂光源图。在 a、b 中, YOLOv6n 和 SSD 出现误检,把张嘴状态识别成闭嘴状态;在 c、d 中, YOLOv5s、YOLOv6n、YOLOv7-tiny 和 Fast-RCNN 出现误检,把闭眼状态识别成睁眼状态, YOLOv7-tiny 还出现检测框重叠的多检情况,将打哈欠状态识别成打哈欠和张嘴两种状态。在 e、f 中,除改进后模型外均出现对闭眼状态的误检,此外, YOLOv5s 出现检测框重叠的多检情况, YOLOv7-tiny、SSD 和 Fast-RCNN 出现非疲劳区域的误检情况,把非疲劳特征部位识别为疲劳状态。综上,在相同数据集训练情况下,改进后的模型检测效果更加优越,拥有更高准确性、更小模型内存和更快检测速度。



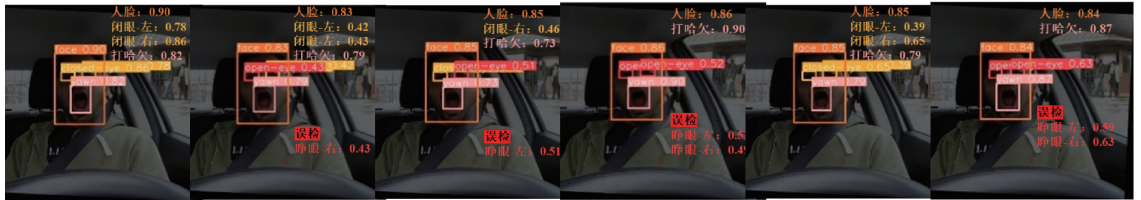
(a) 正常光源图



(b) 正常光源图




(c) 低照度光源图



(d) 低照度光源图



(e) 复杂光源图



(f) 复杂光源图

图 4 模型检测对比

Fig. 4 Model detection comparison

### 3 结论

1) 添加小目标检测层和引入 BAM 模块后,疲劳驾驶检测模型整体检测能力得到有效提升,改进后的模型平均检测精度高达 96.3%,较原模型提高 5.1%。

2) 将主干网络中 C2f 模块替换为 EMA 后,模型参数量和体积大小分别减小 24.3%和 22.2%,改

进后模型不仅更加轻量化,且检测性能保持良好。

3) 改进后的检测模型在露天矿区复杂多变驾驶场景下具有良好检测效果,其中准确率、召回率和 mAP 分别达到 93.6%、93.9%、96.5%。对比单阶段目标检测模型,该模型具有检测效果好、识别精度高的优势。对比两阶段目标检测模型,该模型具有参数量和计算量小、检测速度快、实时性好的优势。

### 参考文献

- [1] WANG Yi, HE Zhengxiang, WANG Liguang. Truck driver fatigue detection based on video sequences in open-pit mines[J]. Mathematics, Multidisciplinary Digital Publishing Institute, 2021, 9(22): 2 908-2 922.
- [2] 胡剑锋, 王涛涛. 基于脑电信号模糊熵的驾驶疲劳检测分析[J]. 中国安全科学学报, 2018, 28(4): 13-18.  
HU Jianfeng, WANG Taotao. Analysis of driving fatigue detection based on fuzzy entropy of EEG signals [J]. China Safety Science Journal, 2018, 28(4): 13-18.
- [3] ZHANG Pengbo, WANG Xue, CHEN Junfeng, et al. Feature weight driven interactive mutual information modeling for heterogeneous bio-signal fusion to estimate mental workload[J]. Sensors, 2017, 17(10): 2 315-2 339.

- [4] WANG Fuwang, WANG Hong, FU Rongrong. Real-time ECG-based detection of fatigue driving using sample entropy[J]. *Entropy*, 2018, 20(3): 196-212.
- [5] 程文冬, 付锐, 袁伟, 等. 驾驶人疲劳监测预警技术研究与应用综述[J]. *中国安全科学学报*, 2013, 23(1): 155-160.  
CHENG Wendong, FU Rui, YUAN Wei, et al. Overview of researches on driver fatigue monitoring and prewarning technologies and their applications [J]. *China Safety Science Journal*, 2013, 23(1): 155-160.
- [6] ZHANG Jun, WU Zhongcheng, LI Fang, et al. A deep learning framework for driving behavior identification on in-vehicle can-bus sensor data[J]. *Sensors, Multidisciplinary Digital Publishing Institute*, 2019, 19(6): 1 356-1 373.
- [7] 辛嵩, 宋明达, 王泽明, 等. 针对特定驾驶员的疲劳驾驶检测方法[J]. *安全与环境学报*, 2023, 23(1): 147-152.  
XIN Song, SONG Mingda, WANG Zeming, et al. Fatigue driving detection method for specific drivers [J]. *Journal of Safety and Environment*, 2023, 23(1): 147-152.
- [8] MAGAN E, SESMERO M P, ALONSOWEBER J M, et al. Driver drowsiness detection by applying deep learning techniques to sequences of images[J]. *Applied Sciences*, 2022, 12(3): 1 145-1 170.
- [9] HUANG Rui, WANG Yan, LI Zijian, et al. RF-DCM: multi-granularity deep convolutional model based on feature recalibration and fusion for driver fatigue detection[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(1): 630-640.
- [10] 杨艳艳, 李雷孝, 林浩. 提取驾驶员面部特征的疲劳驾驶检测研究综述[J]. *计算机科学与探索*, 2023, 17(6): 1 249-1 267.  
YANG Yanyan, LI Leixiao, LIN Hao. A review of fatigue driving detection research based on extracting driver's facial features[J]. *Computer Science and Exploration*, 2023, 17(6): 1 249-1 267.
- [11] LI Kening, GONG Yunbo, REN Zijiang. A fatigue driving detection algorithm based on facial multi-feature fusion[J]. *IEEE Access*, 2020, 8(8): 101 244-101 259.
- [12] 胡习之, 黄冰瑜. 基于面部特征分析的疲劳驾驶检测方法[J]. *科学技术与工程*, 2021, 21(4): 1 629-1 636.  
HU Xizhi, HUANG Bingyu. Fatigue driving detection system based on face feature analysis[J]. *Science Technology and Engineering*, 2021, 21(4): 1 629-1 636.
- [13] LIU Mingzhou, XU Xin, HU Jing, et al. Real time detection of driver fatigue based on CNN-LSTM[J]. *IET Image Processing*, 2022, 16(2): 576-595.
- [14] 方浩杰, 董红召, 林少轩, 等. 多特征融合的驾驶员疲劳状态检测方法[J]. *浙江大学学报:工学版*, 2023, 57(7): 1 287-1 296.  
FANG Haojie, DONG Hongzhao, LIN Shaoxuan, et al. Driver fatigue state detection method based on multi-feature fusion [J]. *Journal of Zhejiang University: Engineering Science*, 2023, 57(7): 1 287-1 296.
- [15] 刘子洋, 徐慧英, 朱信忠, 等. Bi-YOLO:一种基于YOLOv8改进的轻量化目标检测算法[J]. *计算机工程与科学*, 2023, 46(8): 1 444-1 454.  
LIU Ziyang, XU Huiying, ZHU Xinzong, et al. Bi-YOLO: an improved lightweight object detection algorithm based on YOLOV8[J]. *Computer Engineering and Science*, 2023, 46(8): 1 444-1 454.

作者简介: 顾清华 (1981—),男,山东诸城人,博士,教授,博士生导师,主要从事矿业系统工程方面的研究。E-mail:qinghuagu@126.com。