



# 铁路行车调度员工作状态检测实验设计与分析

张光远<sup>1</sup>, 张帆<sup>1,2</sup>, 朱泊霖<sup>1</sup>

(1. 西南交通大学 交通运输与物流学院, 成都 611756; 2. 广州地铁设计研究院股份有限公司, 广州 510010)

**摘要:** 铁路行车调度员在保证铁路行车安全起着重要的作用。研究以调度员在不同情绪中的工作状态作为研究内容, 研究设计了一种用于采集高速铁路调度作业人员在不同情绪状态下, 执行调度任务并采集生理数据的实验模式。通过情绪诱导实验确保调度员分别进入 4 种工作状态, 收集眼动数据并建立 K 近邻(KNN)分类模型和分类与回归树(CART)决策树分类模型进行状态识别, 前者识别精度更高可达 90% 以上, 搭建卷积神经网络-门控循环单元(CNN-GRU)融合模型, 提高疲劳程度预测效果。

**关键词:** 铁路调度员; 安全; 工作状态; 眼部特征

中图分类号: U292.22

文献标志码: A

DOI: 10.12179/1672-4550.20230468

## Experimental Design and Analysis of Railway Traffic Dispatcher Working State Detection

ZHANG Guangyuan<sup>1</sup>, ZHANG Fan<sup>1,2</sup>, ZHU Bolin<sup>1</sup>

(1. School of Transportation and Logistics, Southwest Jiaotong University, Chengdu 611756, China;

2. Guangzhou Metro Design & Research Institute Co., Ltd., Guangzhou 510010)

**Abstract:** High-speed railway dispatcher plays an important role in ensuring railway traffic safety. Taking the working state of dispatchers in different emotions as the research content, an experimental mode is designed to collect the physiological data of high-speed railway dispatchers performing dispatching tasks under different emotional states. The emotion-induction experiment induces the schedulers to enter four working states respectively. Then eye movement data are collected and the K-nearest neighbor classification model and the classification and regression tree decision tree classification model are established for state identification. The identification accuracy of the former is higher, reaching more than 90%. The CNN-GRU fusion model is built to improve the prediction effect of fatigue degree.

**Key words:** railway dispatcher; safety; working state; eye characteristics

铁路行车调度员作为调度指挥的核心, 其决策行为将直接影响铁路行车的安全与效率。大量研究表明, 不良情绪和疲劳状态会对人的注意、决策和判断产生影响, 调度员在不良状态下继续作业将对列车运行安全造成巨大威胁。因此, 对铁路调度员工作状态进行研究具有重要的现实意义和理论价值。文献 [1] 指出, 使用眼动仪测量的眨眼频率和瞳孔大小等特征对情绪有准确的识别率。文献 [2] 指出, 受试者在面对不同程度的视觉刺激材料时, 注视概率、凝视时间及次数都有明显的规律性, 证明了眼动在识别情感内容领域的

可行性。文献 [3] 发现相较于视觉刺激, 情绪刺激会更显著地改变眼动, 文献 [4] 采用视频诱发情绪的方法, 通过方差分析发现眨眼率和瞳孔反应存在显著性差异, 证明了眼动和情绪之间的相关性。文献 [5] 使用基于现有速度的事件分类算法, 同时适用于识别静态视觉刺激与动态视觉刺激下的眼球转动及其振荡。除了直接识别参与者的疲劳特征, 视觉任务下的注意力水平变化也能反应疲劳程度<sup>[6]</sup>。早期眨眼参数就被认为和疲劳具有最直接的特征关系, 随着研究深入, 眼睛闭合时间占时间段的百分比(the percentage of eyelid closure

收稿日期: 2023-10-03

基金项目: 国家自然科学基金面上项目(52472332); 四川省自然科学基金面上项目(2024NSFSC0178); 四川省高等教育人才培养质量和教学改革项目(JG2024-0291)。

作者简介: 张光远, 博士, 正高级实验师, 主要从事交通运输规划与安全行为等方面的研究。E-mail: gyzhang@swjtu.cn

rate over time, PERCLOS)值作为有效的判别手段之一,后来有研究表明扫视相关特征也可用于识别疲劳,可见多项眼动特征指标在疲劳和情绪的研究方面有一定程度的帮助。文献[7]通过眼动仪与脑电仪收集生理特征对行为进行预测。文献[8]通过回顾总结眼动追踪技术在当前航空领域的应用以及所面临的实际问题,提出拓展眼动追踪技术的应用范围,如对非飞行员角色的心理状态监测,以及加深对眼动追踪技术的实际应用。

复杂情绪是人的本能,据统计在主观消极状态下,驾驶员的事故风险增大将近10倍,并且不良情绪的产生会受恐惧、时间压力等的影响<sup>[9]</sup>。铁路行车调度员的连续工作时间达8h以上,加之受各种影响而突发的行车状况会促使调度员各种不良情绪的产生,使行车安全产生巨大隐患。眼部特征信息作为本文对情绪安全行为判别的输入信息具有至关重要的作用,因此在既有线铁路行车调度环境下收集眼部多特征对本文识别情绪行为具有重要作用。

## 1 实验设计

本文研究发现铁路行车调度员的工作状态普遍存在多种负面情绪。相关分析主要基于以下4个方面:近期工作状态评估;影响安全作业的情绪因素及其发生频率;情绪成因及应对方式;工作与生活情绪的相互影响。通过文本分析技术提取情绪描述关键词和情绪相关语句,一共总结出9种情绪:易怒、痛苦、抑郁、厌倦、紧张、委屈、悲伤、担心、焦虑。其中提及频率最高的情绪为厌倦、易怒、紧张。因此本文基于“疲劳、厌倦、易怒、紧张”4种状态,研究铁路行车调度员的工作状态。

### 1.1 实验设备与实验对象

实验过程中记录眼部特征数据的仪器为SMI ETG眼动仪,实验在西南交通大学交通运输国家级实验教学示范中心的综合调度指挥仿真实验室进行,铁路行车调度台有4台显示器,可显示的内容包括:区间图、站场图、列车运行图以及相关调度命令界面<sup>[10-11]</sup>。

实验邀请16名学习铁路行车组织课程的学生作为实验对象,要求所有参与实验的实验员身体健康、情绪稳定,双眼视力5.0以上,平均年龄为23岁,标准差为2岁,掌握铁路调度操作的技能。

### 1.2 眼动实验流程

实验选择在一日当中,调度员最可能出现影响工作状态的时段11:00~16:00进行,每名实验参与者调度员需根据要求严格进行调度实验,在此期间眼动仪以每秒30条数据进行记录,每条记录内容包括注视时间、平均瞳孔大小、扫视速度、眼跳率、眨眼频率以及眨眼时长,眼部数据共108000×16条。实验开始前30min,实验参与者进入实验现场,佩戴眼动仪并熟悉各项操作。

模拟调度实验前,将实验人员平均分为4组进行状态诱导(情绪组诱导时间为10~30min),对第1、2、3组分别进行厌倦、易怒、紧张情绪视频诱导<sup>[12]</sup>,对第4组采取24h睡眠剥夺实验进行疲劳诱导。学员在进行调度实验时,佩戴眼动仪并校正参数,实时记录驾驶员眼动数据。实验时间共60min,厌倦情绪组只监控作业,其他状态组进行计划、执行、联络和解释工作,具体工作细则如表1所示。实验正式开始后,实验参与者需要严格遵守《铁路行车组织规则》对相关事件进行处理。具体实验步骤如图1所示。

表1 铁路行车调度员工作细则

作业类别	任务内容	记录内容
监控	① 监控区段内列车进路情况	① 当前时段将要办理列车进路的数量
	② 监控记录列车运行情况	② 列车进路序列
	③ 监控列车进站情况	③ 列车晚点情况
	④ 监控设施设备情况	④ 调度系统提供的车次是否停稳
计划和执行	① 下达运行计划	⑤ 记录设备是否正常运行
	② 调整运行图	① 使用调度系统批量生成计划图并下达计划
	③ 执行调度命令	② 调整列车进路序列,修改计划线,修改运行线,设置行车限制命令
	④ 拟定调度命令	③ 签收调度命令,根据调度命令内容进行操作,转发调度命令
联络和解释	① 根据调度模拟系统发布调度指令	④ 新建调度命令,输入内容,申请批准并在系统批准后下达
	② 通过调度台按键接听电话	① 使用调度台话筒对调度命令进行传达
	③ 回答实验指导人员对列车运行状态	② 电话内容为询问前方闭塞区间占用情况
		③ 列车进路情况、区间限速及封锁情况的询问

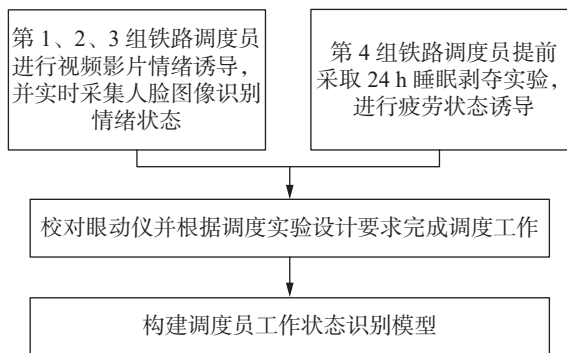


图 1 实验流程示意图

1) 诱导第 1、2、3 组调度员情绪状态并同时  
进行视频监控;

2) 利用视频识别技术根据视频监控确定调度  
员情绪诱导效果, 对诱导成功的调度员进行调度  
实验;

3) 第 4 组直接进行调度实验, 并实时采集面  
部视频信息;

4) 采集眼动指标, 分析调度员工作过程中  
注视时间、瞳孔大小、平均扫视速度等眼动  
数据;

5) 构建调度员工作状态检测模型, 并作出评  
估分析。

通过视频影片完成对调度人员不同情绪状态  
的诱导, 结果如图 2 所示。



(a) 紧张情绪诱导成功

(b) 易怒情绪诱导成功

(c) 厌倦情绪诱导成功

图 2 情绪诱导成功示意图

## 2 铁路行车调度员眼部数据获取及处理

### 2.1 眼动仪实验数据处理

目前国内外众多研究均已把眼动指标作为疲  
劳与情绪监测的主要手段之一, 但是大多基于一个  
或两个的少量指标。为了研究多项眼动指标对  
不同工作状态的影响以及各指标间的相关性, 使用  
MATLAB 设置 5 s 滑窗, 将池化率 10 Hz 从原  
始数据“Saccade、Fixation、Blink”列表中分别提  
取 4 种状态下的 6 项眼动指标: 眨眼率、注视时  
间、扫视速度(眼跳)、眨眼时间、平均瞳孔大小

和眼跳率, 进行预测研究。

为筛选可以有效识别调度员工作状态的眼部  
指标, 进一步分析 6 项眼动指标与工作状态分类  
的正态分布检验结果, 如表 2 所示。

当正态性检验结果显著性大于 0.05 时, 该眼  
动指标数据服从正态分布, 但检验结果中的 5 项  
指标平均瞳孔大小、眨眼频率、眨眼时长、扫视  
速度和工作状态的显著性均小于 0.05 时, 不服从  
正态分布, 此时应采用非参数检验。这里我们选  
用斯皮尔曼相关性分析各项指标与工作状态的相关  
性, 如表 3 所示。

表 2 眼部特征指标与工作状态分类指标的正态分布检验

眼动指标	注视时间	平均瞳孔大小	眨眼频率	眨眼时长	扫视速度	眼跳率	工作状态
显著性系数	0.129	0.001	0.016	0.004	0	0.797	0

表 3 眼部特征指标与工作状态间的斯皮尔曼相关系数

眼动指标	注视时间	平均瞳孔大小	眨眼频率	眨眼时长	扫视速度	眼跳率
斯皮尔曼相关系数	-0.75	0.68	-0.62	0.18	0.52	0.63

当相关性系数的绝对值介于 0.10~0.30 之间  
时, 一般认为变量间存在弱相关; 当相关性系数的  
绝对值介于 0.30~0.50 之间时, 一般认为变量间  
存在中度相关; 当相关性系数的绝对值大于 0.50  
时, 一般认为变量间存在强相关。眨眼时长与工作

状态的相关系数为 0.18, 证明只存在弱相关性, 其  
余指标均在 0.50 以上, 与工作状态存在强相关性。  
因此剔除眨眼时长指标, 并对其余指标做独立性分  
析。注视时间、平均瞳孔大小、眨眼频率、扫视速  
度和眼跳率 5 项指标相关性系数如表 4 所示。

表4 眼部特征指标间的相关性系数

眼动指标	注视时间	平均瞳孔大小	眨眼频率	扫视速度	眼跳率
注视时间	1	—	—	—	—
平均瞳孔大小	-0.141	1	—	—	—
眨眼频率	-0.153	0.152	1	—	—
扫视速度	-0.178	0.125	0.027	1	—
眼跳率	-0.138	0.263	-0.135	0.030	1

由检验汇总可知眼动指标之间相关性系数均小于0.30,只存在弱相关性,证明各指标在工作状态中的独立性显著。综上4种工作状态下的注视时间、平均瞳孔大小、眨眼频率、扫视速度和眼跳率存在差异,可用于表征工作状态。

## 2.2 眼部数据的工作状态表征

实验记录了在“紧张、易怒、厌倦、疲劳”

4种工作状态下的注视时间、平均瞳孔大小、眨眼频率、眼跳率、扫视速度和眨眼时长6项眼动指标。通过筛除掉眨眼时长指标后,对其余5项眼动指标数据进行去噪处理之后计算16名调度被试的眼部指标均值,随机选取每种工作状态下的1名调度被试眼部指标均值分别如表5~表8所示。

表5 紧张行为下的眼部指标均值

眼部指标	注视时间	平均瞳孔大小	眨眼频率	眼跳率	扫视速度
平均值	2.446	5.342	0.790	6.142	63.63
平均值的95%置信区间	下限	2.434	0.780	5.890	58.82
	上限	2.462	0.800	6.401	68.47

表6 易怒行为下的眼部指标均值

眼部指标	注视时间	平均瞳孔大小	眨眼频率	眼跳率	扫视速度
平均值	1.579	6.684	1.560	9.543	73.29
平均值的95%置信区间	下限	1.567	1.472	9.478	69.15
	上限	1.591	6.871	1.649	9.610

表7 厌倦行为下的眼部指标均值

眼部指标	注视时间	平均瞳孔大小	眨眼频率	眼跳率	扫视速度
平均值	1.693	4.954	1.759	12.077	60.21
平均值的95%置信区间	下限	1.686	1.680	11.740	54.37
	上限	1.702	5.182	1.837	12.411

表8 疲劳行为下的眼部指标均值

眼部指标	注视时间	平均瞳孔大小	眨眼频率	眼跳率	扫视速度
平均值	1.840	4.398	1.970	8.050	58.56
平均值的95%置信区间	下限	1.830	1.863	7.810	52.59
	上限	1.851	4.434	2.077	8.200

4组工作状态下的调度被试眼动指标平均值的95%置信区间上下限结果如图3所示。

综上可发现注视时间、平均瞳孔大小、眨眼频率、眼跳率和扫视速度对调度员的“紧

张、易怒、厌倦和疲劳”行为具有表征作用,但单一指标的评估效果并不理想,基于此本文将融合5种眼动指标对4种工作状态构建识别模型。

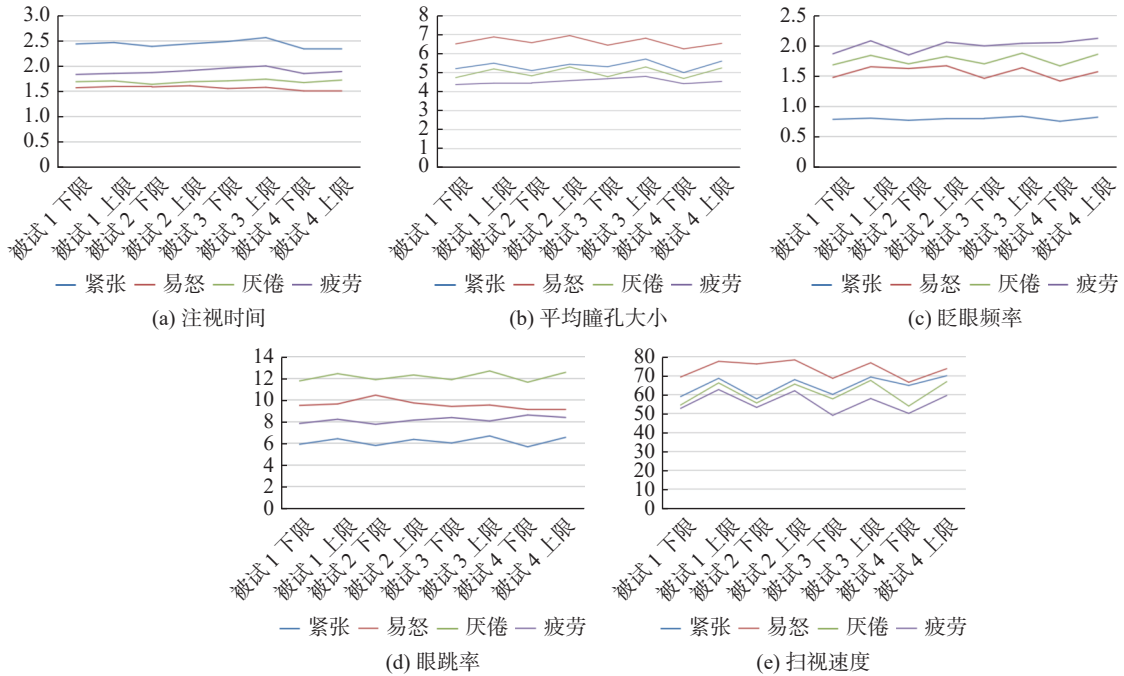


图 3 不同工作状态下的眼部指标均值变化曲线图

### 3 铁路行车调度员工作状态检测实验结果分析

有效识别行车调度员的工作状态是本文的关键，上一节我们筛选了可用于表征调度员工作状态的眼动特征因子，因此在客观确定各工作状态的基础上，需要进一步结合眼部特征指标通过分类器识别。这里本章将采用机器学习领域应用较为广泛的 CART 决策树和 KNN 作为基础算法进行比较。

决策树模型是一种对原始数据的训练样本进行分类的模型<sup>[13]</sup>。该模型已在机动车驾驶员及空管员的疲劳分类<sup>[14]</sup>、人因可靠性<sup>[15]</sup>等领域得到运用。KNN 作为传统的分类算法，受异常值影响较小，且效率高，泛化能力强，也被广泛应用于生理信号的情感识别。

#### 3.1 基于 CART 决策树的铁路行车调度员工作状态实验结果分析

CART 决策树尽可能将每一节点内的样本属性同一化，每一节点只有一种属性时，其杂质度最低，每一节点包含所有属性时，其杂质度最高。如果无杂质，则该节点无需继续分割。4 分类的 CART 决策树模型概况如表 9 所示。

该决策树模型接受者操作特征 (receiver operating characteristics curve, ROC) 曲线和混淆矩

阵如图 4 所示<sup>[16]</sup>。

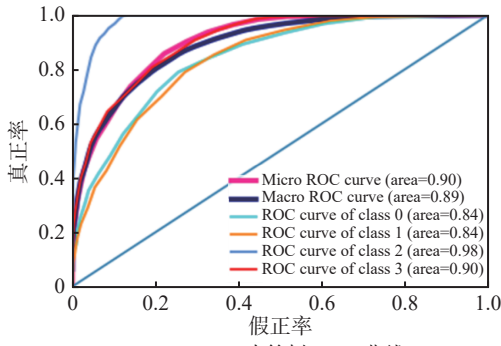
表 9 CART 决策树模型概况

生长方法	CART
因变量	紧张、厌倦、疲劳、易怒
自变量	注视时间、平均瞳孔大小、扫视速度、眨眼频率、眼跳率
最大树深度	5
父节点中最小个案数	100
子节点中最小个案数	50
节点数	31
终结点数	16
树深度	5

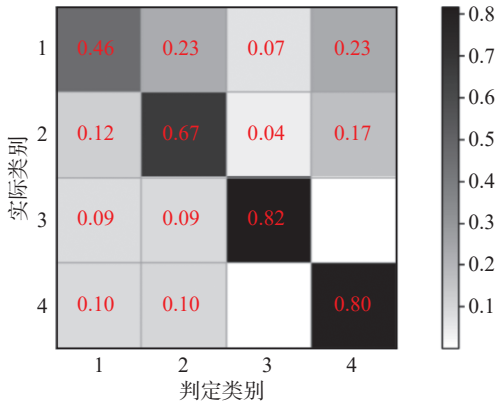
#### 3.2 基于 KNN 的调度员工作状态实验结果分析

KNN 算法通过寻找与预测变量最相似的  $K$  个变量中类别数占比最高的类别。将原始数据集  $T = \{(y_1, z_1), (y_2, z_2) \dots (y_N, z_N)\}$  按 80% 的比例划分训练集  $T_{train} = \{(y'_1, z'_1), (y'_2, z'_2) \dots (y'_j, z'_j)\}$  和测试集  $T_{test} = \{(y''_1, z''_1), (y''_2, z''_2) \dots (y''_j, z''_j)\}$ ，其主要运算过程如下。

1) 循环使用交叉验证法分别求出  $K$  值取整数 1~30 下的模型精度，如图 5 所示，当  $K=13、14、15、16、18$  时，模型精度最大为 0.960。为避免  $K$  值太小产生过拟合，筛选  $K=18$  作为  $n\_neighbors$  值。

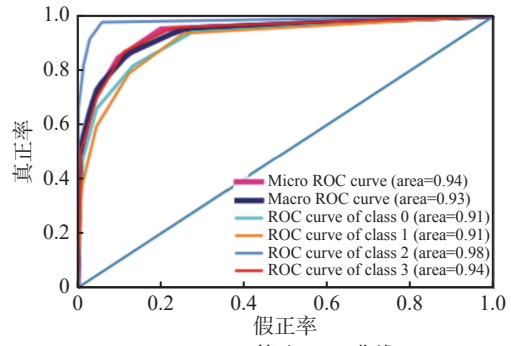


(a) CART 决策树 ROC 曲线




(b) CART 决策树混淆矩阵

图 4 决策树算法 ROC 曲线与混淆矩阵图



(a) KNN 算法 ROC 曲线



(b) KNN 算法混淆矩阵

图 6 KNN 算法 ROC 曲线与混淆矩阵图

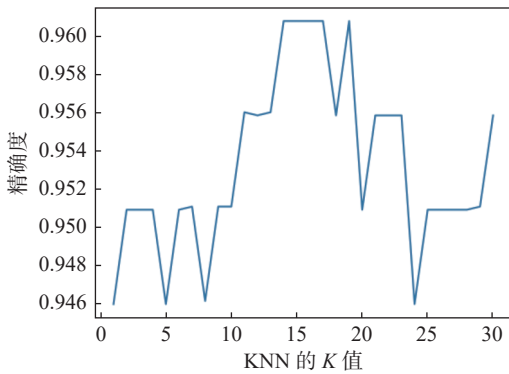


图 5 K 值结果

2) 分别计算测试集的每个样本向量  $y_i''$  与训练集所有向量  $y_j'$  之间的欧氏距离, 由式(1)可得:

$$L_{xy} = \sqrt{\sum_{j=1}^m (y_i'' - y_j')^2} \quad (i = 1, 2, 3, \dots, I) \quad (1)$$

取数值最小的前 18 个  $L_{xy}$  对应的向量所在的工作状态  $z$ , 并统计其中出现频率最高的工作状态即为测试样本分类  $z$ 。KNN 模型 ROC 曲线和混淆矩阵如图 6 所示。

决策树与 KNN 模型的准确率和  $F$  度量评价指标对比如表 10 所示。

表 10 模型评价指标对比

指标	CART决策树模型	CHAID决策树模型	KNN模型
$F1_{micro}$	0.90	0.93	0.96
$F1_{macro}$	0.89	0.92	0.96
准确率/%	69	74	90

### 3.3 基于 CNN-GRU 模型的铁路行车调度员疲劳状态程度变化预测

#### 3.3.1 人脸特征检测模型搭建

通过 5 项眼部特征指标有效识别了调度员的 4 种工作状态, 在不良状态产生后如何对调度员采取合理的干预措施, 需要进一步利用眼部特征预测工作状态的变化程度。根据现场实验现象可知, 疲劳行为下调度员的生理、心理耗竭会逐渐加深, 情绪行为却会因个体差异和外界刺激产生短期的恢复效果, 因此本文认为只有疲劳行为具备等级预测的可行性, 基于此在前文对不同工作状态进行识别的实验基础上, 采集疲劳组调度员时序眼部特征作为训练和测试数据, 提取实时双眼高宽比作为标记准则, 采用神经网络作为基础算法进行比较。

搭建人脸特征检测模型: 对疲劳组调度员调度工作人脸视频设置 30 f/s 提取图像, 计算每块区

域不相同的像素获得方向梯度直方图(histogram of oriented gradient, HOG)向量集,对所有的图像特征集进行向下拼接组成  $n$  维矩阵,输入支持向量机(support vector machine, SVM)分类器判断每帧

人脸数量是否相同。调用 `dlib` 库的 68 特征分类器进行定位,循环人脸检测的位置,检测出人脸的位置信息,遍历字典中 37~48 位  $(x, y)$  坐标值如图 7 所示。

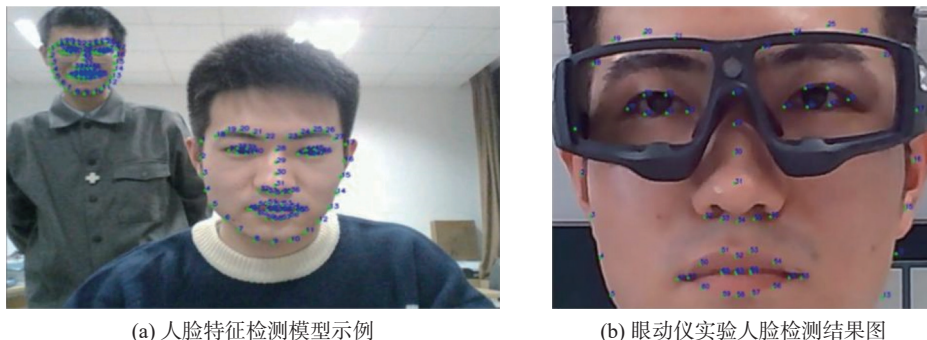


图 7 人脸 68 个特征点检测图

左眼高宽值由式(2)和式(3)计算可得:

$$D_S = \frac{|O_{38} - O_{42}| + |O_{39} - O_{41}|}{2} \quad (2)$$

$$D_L = |O_{37} - O_{40}| \quad (3)$$

式中:  $D_S$  表示左眼上下眼睑距离即眼高,  $D_L$  表示左眼内外眼角距离即眼宽,  $O$  表示对应点坐标。同理计算右眼高宽值,取左右眼高宽值平均数并做高宽比值计算,结果如图 8 所示。




图 8 调度员疲劳状态变化程度

### 3.3.2 CNN-GRU 的疲劳状态程度预测模型建立

此处采用上文提取的眼睛高宽比值作为输出端疲劳程度量化指标,输入端为第 4 组调度员眼动数据。CNN 和循环神经网络(recurrent neural network, RNN)是深度学习的基础模型,前者可以有效挖掘提取平均瞳孔大小、眨眼次数等眼动数据与调度员疲劳程度有关的特征;后者可以发现时序特征的隐藏状态,并且为解决数据量大而产生的梯度爆炸和消失问题,换用 RNN 的变体 GRU 进行建模。实验结果表明, CNN-GRU 融合网络可以大幅度提高调度员疲劳程度预测的准确度。

本文输入层眼动数据属于二维数组,一维是 5 项眼动指标,另一维是时间维度。不同于其他学者的整段数组直接输入一维卷积神经网络,本研究在训练前对数据重塑拼接成  $4 \times 5$  的矩阵(每条数据含有 4 组眼动数据,每组眼动数据包括平均瞳孔大小等 5 项指标),每层卷积层分别设置 128、64、32 个卷积核大小为 1 的 Filters(过滤器),通过核为 2 的最大池化层 MaxPooling1D 对上层卷积输出矩阵进行缩放,使用 Relu 激活函数输出为调度员疲劳程度值,如图 9 所示。

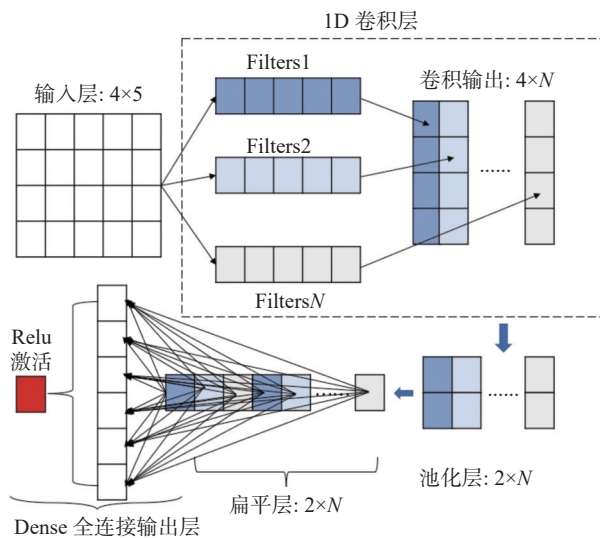


图 9 CNN 流程图

GRU 模型通过运行两个输入层:当前时刻的眼动指标  $X_t$ , 包含上一时刻相关信息的隐状态  $S_{t-1}$ , 输出得到当前时刻的疲劳程度  $Y_t$  和包含当前时刻相关信息的隐藏状态  $S_t$ , 如图 10 所示。

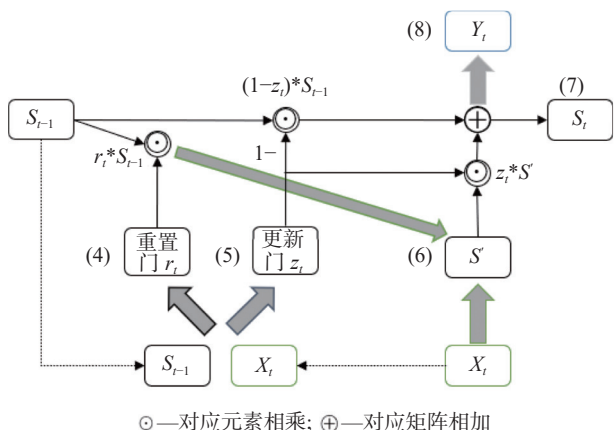


图 10 GRU 网络流程图

GRU 的内部受重置门  $r$  和更新门  $z$  控制。更新门用于控制上一时刻疲劳程度信息的保留权重, 通过 sigmoid 激活函数缩放拼接后的前一时刻疲劳隐状态和当前时刻眼动指标至  $[0,1]$  区间, 由式(4)可得:

$$z_t = \text{sigmoid}(W_z[X_t, S_{t-1}]) \quad (4)$$

重置门用于将当前时刻之前的历史信息保留到隐藏状态  $S_t$  被输出前的数据  $S'$  中, 由式(5)可得:

$$r_t = \text{sigmoid}(W_r[X_t, S_{t-1}]) \quad (5)$$

经过门控处理后, 通过 tanh 激活函数缩放重置门数据  $r_t$  至  $[-1,1]$  区间, 由式(6)可得:

$$S' = \tanh(W_{s'}[r_t * S_{t-1}, X_t]) \quad (6)$$

此时的  $S'$  已经保留了对当前时刻眼动数据的输入和部分隐藏状态。筛选和保留更新门输出结果  $z_t$  得到当前状态的疲劳隐藏状态  $S_t$ , 由式(7)可得:

$$S_t = (1 - z_t) * S_{t-1} + z_t * S' \quad (7)$$

通过选择性遗忘  $S_{t-1}$  的信息, 并对当前时刻的眼动输入信息进行保留。最后输出 sigmoid 函数激活后的当前时刻疲劳隐状态  $S_t$ , 即当前眼动指标  $X_t$  下的疲劳程度值  $Y_t$ , 由式(8)可得:

$$Y_t = \text{sigmoid}(W_t[S_t]) \quad (8)$$

### 3.3.3 基于 CNN-GRU 模型的实验结果分析

为构建 CNN-GRU 调度员疲劳程度预测模型, 利用一维卷积和最大值池化提取特征权重求得特征矩阵, 输入 GRU 模型进行时序预测, 链接全连接层输出模型的预测值。CNN 卷积层可以降低模型复杂度, 减少对异常值的敏感度, GRU 的重置门和更新门可对上层长序列调度员眼动特征信息进行有效的遗忘与保留。对第 4 组调度员的眼动数据进行疲劳值预测, 计算疲劳值的平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方根误差(RMSE)作为评价指标, CNN、GRU 模型对照如表 11 所示。

表 11 评价指标结果

模型	MAE	MAPE	RMSE
CNN	0.066 516 258	38.629 059 788	0.068 132 409
GRU	0.009 685 969	5.711 664 804	0.010 986 835
CNN-GRU	0.004 575 089	2.596 587 667	0.005 901 513

在 3 类评价指标中可见, CNN-GRU 模型的拟合效果显著, CNN 的效果最差, 说明疲劳程度在时序方面表现出了较强的相关性。为更直观地观测拟合效果截取了 3 种模型的损失函数和预测结果, 如图 11 所示。

## 4 结果分析

1) 本文通过人脸表情识别实验成功判别了调度员的 3 种不良情绪状态, 保证了情绪诱导实验的准确性以及眼动数据的客观性。发现不良情绪状态具有恢复性但疲劳状态会逐渐加剧, 因此通过人脸特征识别实验, 提取疲劳组调度员的眼睛高宽比值来量化疲劳程度, 保证了疲劳量化数据

的客观性。

2) 选取决策树和 KNN 两种积极与不积极学习领域的经典分类算法对调度员的 4 种不良工作状态进行实验结果分析, 发现 KNN 模型从各项指标上均优于决策树模型, 总体识别率达到 90.7%, 表明调度员工作状态的分类模式更适合简单暴力的惰性分类模型。因此本文将采用 KNN 模型作为既有线调度员工作状态分类模型, 验证了铁路行车调度员工作状态与眼动数据的相关性以及研究的可行性, 对铁路调度员的不良工作状态识别提供了理论支撑。

3) 在对疲劳状态识别的基础上作进一步研究, 以疲劳组眼动数据为输入端, 眼睛高宽比值

为疲劳程度预测模型输出端，搭建 CNN-GRU 融合模型，先输入卷积层简化眼动特征矩阵然后输入 GRU 层进行时序关联性挖掘，通过与 CNN、GRU 两种模型进行对比。结果表明预测效果有了

显著提高，并验证了该实验的可行性以及铁路调度员疲劳状态下眼动数据与眼睛高宽比值的相关性，对铁路调度员疲劳程度的衡量提供了更加客观科学的理论依据。

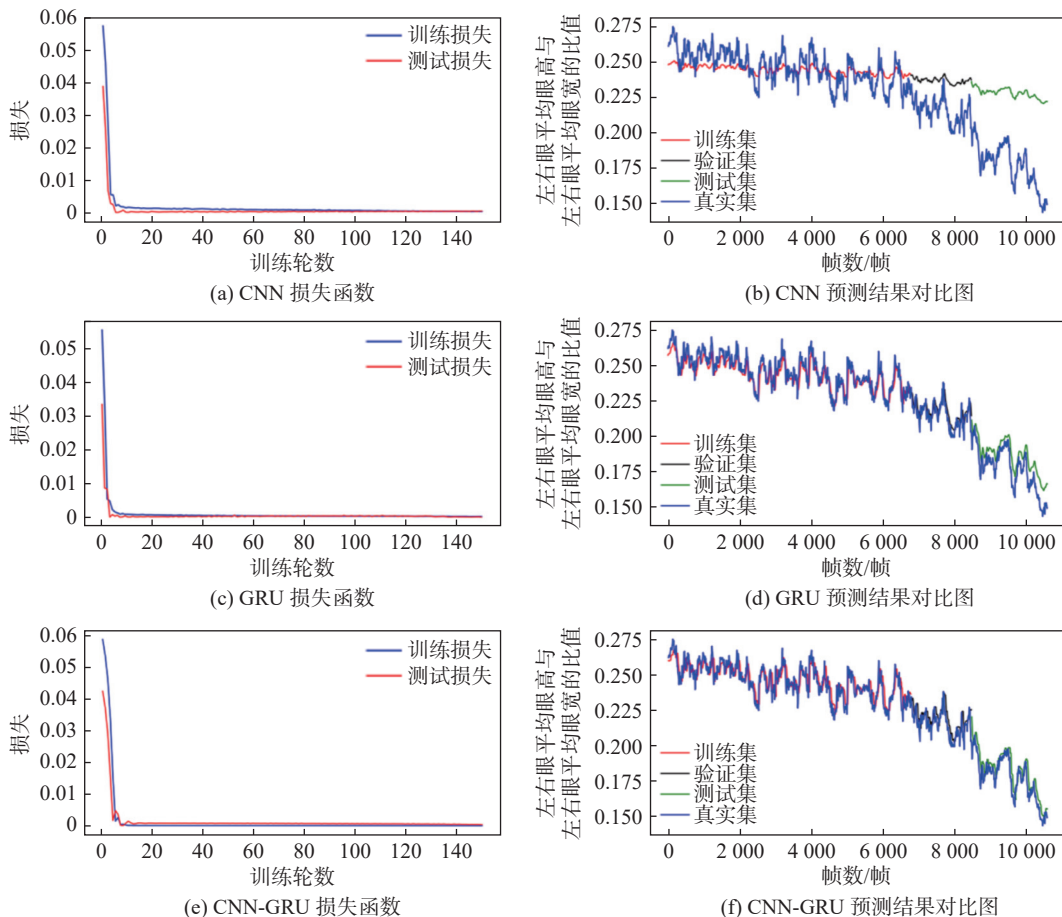


图 11 损失函数和预测结果图

### 5 结束语

本文实现了基于既有线铁路行车调度员眼部特征信息的模型对安全行为的评估作用，建立了以既有线铁路行车调度员工作状态为背景的安全行为判定方法研究。判定模型选用机器学习与深度学习模型，通过模型之间的评价指标对比，确定 KNN 模型在安全行为的识别上有着较高的准确率；确定 CNN-GRU 网络在对调度员安全行为预测方上有着更高预测效果。研究成果对既有线铁路行车调度员的不安全工作识别和预测提供了更加科学的方法及依据，体现在如下 3 个方面。

1) 确定了既有线铁路行车调度员的不良情绪行为

现有关于铁路行车调度员工作状态的识别研

究主要针对生理疲劳行为，缺少因调度员心理耗竭产生的不良情绪行为的具体探讨。针对现有研究不足，本文在调度员疲劳行为的基础上额外考虑不同工作情境下情绪行为的发生，分析总结出“紧张、厌倦、易怒、疲劳”4 种不良行为作为本文的安全行为评估目标。

2) 构建了既有线行车调度员眼部特征下的安全行为识别模型

通过正态分布检验与斯皮尔曼相关性分析，筛选出可表征调度员安全行为的眼动特征因子：平均瞳孔大小、注视时间、眼跳率、眨眼频率和扫视速度。结合机器学习算法构建安全行为识别模型，并在 KNN 模型中取得了最有效验证。

3) 客观描述了安全行为的变化规律并构建安

### 全行为程度预测模型

如何在调度员的不良安全行为产生时提出阻控措施,是构建安全行为预测模型的主要目的。本文基于眼部特征量化安全行为的变化规律,通过分析情绪行为与疲劳行为的恢复性差异,针对疲劳行为展开神经网络预测模型的构建,利用眼部高宽比量化疲劳程度,并在 CNN-GRU 融合神经网络中取得了有效验证。

### 参考文献

- [1] DE LEMOS J, SADEGHNIA G R, ÓLAFSDÓTTIR Í, et al. Measuring emotions using eye tracking[C]// Proceedings of Measuring Behavior, Maastricht: Noldus, 2008: 226.
- [2] NIU Y Q, TODD R M, KYAN M, et al. Visual and emotional salience influence eye movements[J]. ACM Transactions on Applied Perception, 2012, 9(3): 1-18.
- [3] HUMPHREY K, UNDERWOOD G, LAMBERT T. Salience of the lambs: A test of the saliency map hypothesis with pictures of emotive objects[J]. *Journal of Vision*, 2012, 12(1): 22.
- [4] SOLEYMANI M, PANTIC M, PUN T. Multimodal emotion recognition in response to videos[J]. *IEEE Transactions on Affective Computing*, 2012, 3(2): 211-223.
- [5] DAR A H, WAGNER A S, HANKE M. REMoDNaV: Robust eye-movement classification for dynamic stimulation[J]. *Behavior Research Methods*, 2021, 53(1): 399-414.
- [6] MADLEŇÁK R, MAŠEK J, MADLEŇÁKOVÁ L. An experimental analysis of the driver's attention during train driving[J]. *Open Engineering*, 2020, 10(1): 64-73.
- [7] QU J, GUO H, WANG W, et al. Prediction of human-computer interaction intention based on eye movement and electroencephalograph characteristics[J]. *Frontiers in Psychology*, 2022, 13: 816127.
- [8] MENGTAO L, FAN L, GANGYAN X, et al. Leveraging eye-tracking technologies to promote aviation safety-a review of key aspects, challenges, and future perspectives[J]. *Safety Science*, 2023, 168: 106295.
- [9] CUNNINGHAM M L, REGAN M A. Are happy drivers better drivers? the impact of emotion, life stress and mental health issues on driving performance and safety[EB/OL]. (2018-03-01)[2023-09-03]. <https://trid.trb.org/view/1503465>.
- [10] 张光远, 龚迪, 王坤. 库存管理与自动化仓储虚拟仿真实验教学[J]. *实验技术与管理*, 2020, 37(12): 149-154.
- [11] 张光远, 彭其渊, 刘晓波, 等. 基于运输智能化的国家地方联合工程实验室建设[J]. *实验技术与管理*, 2017, 34(5): 233-237.
- [12] NASS C, JONSSON I M, HARRIS H, et al. Improving automotive safety by pairing driver emotion and car voice emotion[C]//CHI'05 Extended Abstracts on Human Factors in Computing Systems, Portland: ACM, 2005: 1973-1976.
- [13] 赵小强. 交通事故持续时间预测理论与方法[D]. 北京: 清华大学, 2010.
- [14] 胥川, 王雪松, 陈小鸿, 等. 基于决策树的驾驶疲劳等级分析与判定[J]. *同济大学学报(自然科学版)*, 2015, 43(1): 75-81.
- [15] 李海峰, 李文权, 武喜萍. 基于全决策树的空管人因可靠性研究[J]. *人类工效学*, 2010, 16(2): 34-39.
- [16] 张光远, 胡晋, 文原劲, 等. 高速铁路调度员疲劳程度分级及预测方法研究[J]. *铁道学报*, 2021, 43(5): 18-26.

编辑 葛晋