

文章编号:1001-7372(2016)10-0118-08

# 基于无侵入测量指标的个体差异化 驾驶疲劳检测

胥川<sup>1,2</sup>, 裴赛君<sup>3</sup>, 王雪松<sup>3</sup>

(1. 西南交通大学 交通运输与物流学院, 四川 成都 610031; 2. 西南交通大学 综合交通运输智能化国家地方联合工程实验室, 四川 成都 610031; 3. 同济大学 道路与交通工程教育部重点实验室, 上海 201804)

**摘要:**针对现有一些疲劳驾驶检测方法因未考虑个体差异而导致检测精度较低的问题,在考虑个体差异的基础上建立疲劳驾驶检测模型,以适应驾驶人在驾驶行为和生理特征上存在的个体差异。通过高仿真驾驶模拟器对值夜班8 h后的受试人员进行疲劳驾驶模拟试验,采集每位驾驶人的数据并从中提取出19个驾驶行为指标和4个眼动指标。试验过程中通过主观问询方式获取驾驶人疲劳程度信息,在此基础上建立考虑个体差异的分层有序Logit(MOL)模型,以及未考虑个体差异的有序Logit(OL)模型和人工神经网络(ANN)模型来评估疲劳程度。结果表明:23个变量中,闭眼时间比例、平均瞳孔直径、车道偏移标准差、方向盘反转次数是疲劳检测中最重要的4个变量;3个模型中分层有序Logit模型的检测精度最高,表明考虑个体差异确实可以提高模型检测精度。

**关键词:**交通工程;疲劳检测;分层有序线性模型;无侵入测量指标;眼动;驾驶行为;驾驶模拟器  
**中图分类号:**U491.254 **文献标志码:**A

## Driver Drowsiness Detection Based on Non-intrusive Metrics Considering Individual Difference

XU Chuan<sup>1,2</sup>, PEI Sai-jun<sup>3</sup>, WANG Xue-song<sup>3</sup>

(1. School of Transportation and Logistics, Southwest Jiaotong University, Chengdu 610031, Sichuan, China; 2. National United Engineering Laboratory of Integrated and Intelligent Transportation, Southwest Jiaotong University, Chengdu 610031, Sichuan, China; 3. Key Laboratory of Road and Traffic Engineering, Ministry of Education, Tongji University, Shanghai 201804, China)

**Abstract:** Aimed at the problem of detection inaccuracy for drowsy driving due to neglect of individual difference in current detection methods, a drowsy driving detection model considering individual difference was built to accommodate the difference of drivers in driving behavior and physiological feature. The drowsy driving simulation experiment was carried out for participants after having worked for 8 hours in night shift by driving simulator with high fidelity. Data of each driver were collected and 19 driving behavior indicators and 4 eye movement indicators were extracted. In the experiment process, subjective enquiry method was adopted to obtain the information about drowsiness degree of driver. On this basis, a multilevel ordered Logit (MOL) model considering individual difference, an ordered Logit (OL) model without considering individual difference and an artificial neural network (ANN) model were established to evaluate

收稿日期:2016-02-10

基金项目:“十二五”国家科技支撑计划项目(2014BAG01B03);中央高校青年教师百人计划项目(2682015BR006)

作者简介:胥川(1987-),男,四川西充人,讲师,工学博士,E-mail:xuchuan@swjtu.edu.cn.

通讯作者:王雪松(1977-),男,山西忻州人,教授,博士研究生导师,工学博士,E-mail:wangxs@tongji.edu.cn.

drowsiness degree. The results show that among 23 variables, four variables including percentage of eyelid closure time, average pupil diameter, standard deviation of lane departure and reversal rate of steering wheel are most important. MOL model has the highest drowsiness detection accuracy, which indicates that consideration of individual differences helps to improve the detection accuracy for drowsiness.

**Key words:** traffic engineering; drowsiness detection; multilevel ordered logit model; non-intrusive metric; eye movement; driving behavior; driving simulator

## 0 引言

疲劳驾驶是引发交通事故的主要原因之一,严重威胁着道路交通安全。近期的自然驾驶研究表明,疲劳驾驶状态下发生事故或接近发生事故的风险是清醒驾驶状态下的 4~6 倍<sup>[1-2]</sup>。从世界各地的交通事故数据中也能看出疲劳驾驶的危害:2009 年,美国因疲劳驾驶引发的交通事故造成 800 余人死亡和 30 000 余人受伤<sup>[3]</sup>;欧洲大约有 20% 的交通事故由疲劳驾驶所致<sup>[4]</sup>;根据公安部交管局的统计,中国仅 2007 年就有 1 768 人死于疲劳驾驶导致的事故。高速公路的长里程以及行驶环境的单调性使其成为疲劳驾驶事故多发场地,发生在高速公路上的疲劳事故通常具有车速高、无制动、驶离车道等特点,因而事故后果特别严重。近几年中国高速公路里程快速增长,在 2002~2011 年间里程平均每年增长 14%,到 2012 年已达到 85 000 km,有效降低疲劳驾驶风险的研究尤为重要。

开发车载疲劳预警系统,对驾驶人或车辆运行状态进行实时监控并择机进行干预被视为重要的防治疲劳驾驶的措施,而疲劳检测是其中的核心技术<sup>[5]</sup>。疲劳检测指标可分为侵入测量指标和无侵入测量指标。侵入测量指标包括脑电指标<sup>[6]</sup>、心电指标<sup>[7]</sup>等,虽然这类指标与疲劳程度的相关度较高,但其测量方式对正常驾驶有干扰,一般仅局限于试验研究。无侵入测量指标包括驾驶行为指标、眼动指标,这类指标对正常驾驶的干扰较小,更适合用于真实驾驶中的疲劳检测<sup>[8]</sup>。

在以往的研究中,关于驾驶行为和眼动特征等无侵入测量指标的个体差异性已被多次提及。关于驾驶行为,Ingre 等<sup>[9]</sup>指出了车道偏移标准差(SDLP)的个体差异,其研究发现同一疲劳程度下不同驾驶人的 SDLP 不同;另一项研究也指出了车道偏离行为的个体差异<sup>[10]</sup>;Thiffault 等<sup>[11]</sup>指出方向盘角速度标准差的个体差异。关于眼部特征,很多

研究指出了眨眼时间和闭眼时间比例的个体差异<sup>[9,12-13]</sup>。在疲劳检测模型方面,目前常见的疲劳检测建模方法包括决策树、Logistic 回归、贝叶斯网络<sup>[14]</sup>、人工神经网络<sup>[7]</sup>、支持向量机<sup>[15]</sup>等,但这些方法都未区分来自不同驾驶人的数据。

本文通过驾驶模拟试验,提取出驾驶行为指标、眼动指标和驾驶人疲劳程度,基于上述数据建立分层有序 Logit 模型,此模型会考虑驾驶人之间的个体差异,此外还建立未考虑个体差异的有序 Logit 模型和神经网络模型用于对比。

## 1 试验概况

### 1.1 受试人员

试验招募了 16 名男性受试人员,年龄(32.8±5)岁(平均值±标准差)。要求所有受试人员持有效驾照,身体状况良好,无与睡眠相关的疾病,在试验前 1 个月内无药物服用史,测试前 24 h 内不允许饮酒,测试前 12 h 内不允许饮用咖啡、功能性饮料。受试人员在测试前需要填写描述试验要求和权利的《试验知情同意书》,并且根据测试时间向每位受试人员支付报酬。

### 1.2 试验设备

眼动数据通过四通道 SmartEye 眼动仪进行采集。该眼动仪可实现六自由度头部跟踪和二自由度目光跟踪。在车辆前方放置 4 个照相装置,用于捕捉驾驶人的面部特征,跟踪头部运动,并通过瞳孔检测及定位,确定驾驶人的视线方向。

驾驶行为数据通过同济大学高仿真度驾驶模拟器采集,驾驶模拟器如图 1 所示。该驾驶模拟器具有 8 自由度运动系统,驾驶舱为封闭刚性结构,试验车辆为真车,车辆去除了发动机,并加装了方向盘、制动力反馈系统及数据输入输出设备,投影系统通过 5 个内置于驾驶舱的投影仪将场景投影到柱形幕上,场景的水平视角为 250°。模拟平台使用法国 OKTAL 公司开发的 SCANeR™控制软件。



(a) 驾驶模拟器内景



(b) 驾驶模拟车辆内景

图1 驾驶模拟器概况

Fig. 1 General Profile for Driving Simulator

### 1.3 试验过程

#### 1.3.1 试验设计

试验场景道路是一条长 20 km 的双向六车道环形一级公路,由直线路段、大半径圆曲线路段及连接曲线构成,如图 2 所示。其中,有 6 段直线路段,每段长 2 km,编号为 1,3,5,9,11,13;2 段圆曲线路段,每段半径为 700 m,长度为 2 km,编号为 7,15;以上路段之间用大半径 S 曲线连接,编号为 2,4,6,8,10,12,14,16。本文研究中只对直线路段采集的数据进行分析。为了增加驾驶环境的真实感,试验场景道路两旁设置绿草地、树木和少量的村落建筑。




图2 试验场景道路线形及各路段编号

Fig. 2 Ring Shape of Road in Experimental Scenes and Numbers of Segments

为了重点评估在较高疲劳程度下的驾驶表现,受试人员在值夜班后早晨 8 点接受测试。试验前受试人员先填写驾驶人基础信息调查表和测试前疲劳状态调查表,然后进行 5 min 试驾以熟悉驾驶模拟器。试验正式开始后,为了创造单调的驾驶环境以

使驾驶人在有限的试验时间内能够较快进入疲劳状态,驾驶人需将车速保持在  $120 \text{ km} \cdot \text{h}^{-1}$  左右,行驶过程中不允许听广播或音乐,道路上设置少量环境车辆,无隧道,无不良天气。试验结束后,驾驶人填写试验后疲劳状态调查表。

#### 1.3.2 主观疲劳等级

为了记录驾驶人疲劳程度,驾驶人行驶至每圈中点处时需要报告其主观疲劳程度(Karolinska Sleepiness Scale, KSS),驾驶人需要按照 KSS 量表对自己的疲劳状态进行评价。KSS 分为 9 个等级,面向预警无需区分出所有的疲劳等级,但需要区分出事故风险高的疲劳等级。一些研究<sup>[14,16]</sup>中表明,当 KSS 值小于 7 时,不会出现行为和生理的明显变化。KSS 值等于 7 表示“疲倦,但仍然清醒”,KSS 值等于 8 或 9 表示“需要努力保持清醒状态”。因此,本试验将疲劳程度(Drowsiness Level, DL)划分为 3 个层次:第 1 层次(DL 等于 1),KSS 值介于 1~6,清醒或轻微疲劳;第 2 层次(DL 等于 2),KSS 值等于 7,中度疲劳;第 3 层次(DL 等于 3),KSS 值介于 8~9,重度疲劳<sup>[17]</sup>。

#### 1.3.3 数据准备

试验中共采集了四大类原始数据:生理信号、操作参数、车辆运行特征参数、KSS 主观疲劳等级。其中生理信号包括:眼动仪采集的眼睑张开程度、瞳孔直径、眨眼频率等眼动信号;运动监测仪采集的心率、体温、呼吸信号。操作参数包含了驾驶人对于方向盘、油门踏板、刹车踏板的控制信号。车辆运行特征参数包含了车辆的横向速度、纵向速度、车道偏移值。KSS 主观疲劳等级是指通过询问方式获取的驾驶人的主观疲劳程度。

本文从原始数据中提取出驾驶行为指标和眼动指标进行分析。“驾驶行为”是指操作参数及车辆运行特征参数,在阅读了大量参考文献的基础上,对驾驶行为相关的数据(方向盘转角、油门开度、制动踏板力、车道偏移值、速度)进行判断和筛选,选择最有可能提取出疲劳驾驶特征的车道偏移数据和方向盘转角数据进行重点分析。车道偏移特征分析考虑 2 个角度,即“统计特征的角度”和“车道越线事件角度”;方向盘转角特征主要针对其角速度进行特征提取。眼动指标是从眼动仪记录的数据中进行特征提取,根据眼动参数计算得出。眼动指标主要包括闭眼时间比例、平均瞳孔直径、平均眨眼频率、平均眨眼时间。具体的分析指标及其数值见表 1<sup>[18]</sup>。

表 1 驾驶行为和眼部特征指标

Tab. 1 Metrics for Driving Behavior and Eye Feature

指标符号	指标描述	均值	标准差
LP_stdev	车辆偏移值的标准差/m	0.306	0.134
LP_avg	车辆偏移值的平均值/m	0.214	0.269
LD_Area	越线时空面积/(m·s)	1.627	4.207
LD_TArea	越线时间加权的越线时空面积/(m·s)	6.129	35.383
LD_Frequency	单个路段越线次数	0.660	1.118
LD_Speed	越线期间横向平均速度/(m·s <sup>-1</sup> )	0.046	0.099
LD_Tc	车辆中心越线时间比例	0.002	0.017
LD_Te	车辆边缘越线时间比例	0.021	0.045
SW_Speed_stdev	方向盘角速度标准差/[(°)·s <sup>-1</sup> ]	0.012	0.008
SW_Area_MA	方向盘角度值与自回归滑动均值的面积之和	0.440	0.257
SWM_Re	单个路段方向盘反转次数	190.485	29.522
SW_Range_1	方向盘角速度为 0~2.5(°)·s <sup>-1</sup> 的时间比例	0.876	0.085
SW_Range_2	方向盘角速度为 2.5~5(°)·s <sup>-1</sup> 的时间比例	0.077	0.037
SW_Range_3	方向盘角速度为 5~7.5(°)·s <sup>-1</sup> 的时间比例	0.024	0.020
SW_Range_4	方向盘角速度为 7.5~10(°)·s <sup>-1</sup> 的时间比例	0.010	0.012
SW_Range_5	方向盘角速度大于 10(°)·s <sup>-1</sup> 的时间比例	0.013	0.024
Speed	平均速度/(km·h <sup>-1</sup> )	117.424	6.650
Speed_stdev	速度标准差/(km·h <sup>-1</sup> )	2.866	2.860
Speeding_T	超速时间比例(即速度大于 120 km·h <sup>-1</sup> 的时间比例)	0.311	0.372
Blink_Frequency	平均眨眼频率/(次·s <sup>-1</sup> ) <sup>[8]</sup>	0.504	0.318
Blink_duration	平均眨眼时间/s	0.402	0.054
PERCLOS	闭眼时间比例 <sup>[8]</sup>	0.132	0.099
Pupil	平均瞳孔直径/mm	3.807	0.894

## 2 数学模型

试验数据集被分为训练集和测试集<sup>[19]</sup>,训练集用于建立模型,测试集用于检验模型。为了保证 2 个数据集都包含每位测试者每个疲劳程度的数据,从每位测试者的每一疲劳程度的数据中随机选取 70% 的数据组成训练集,剩余数据组成测试集。

以  $D$  为因变量,表 1 中的所有变量作为自变量,在考虑个体差异的基础上建立了分层有序 Logit (MOL) 模型;同时也建立了 2 个不考虑个体差异的模型作为对比,分别为有序 Logit (OL) 模型和人工神经网络(ANN)模型。

### 2.1 分层有序 Logit 模型

以  $D_{ij}$  表示第  $i$  名测试者在第  $j$  个路段的疲劳等级,该模型认为存在 1 个与离散变量  $D_{ij}$  对应的连续隐变量  $D_{ij}^*$ ,而离散的  $D_{ij}$  取值则根据建立的一系列阈值和  $D_{ij}^*$  所在的区间来确定。

分层有序 Logit 模型与有序 Logit 模型的不同之处在于,分层有序 Logit 模型针对每位测试者都采取了一组不同的阈值  $r_{ki}$  ( $k=1,2$ ),从而对每位测试者的个人行为作出了解释,而有序 Logit 模型对

所有测试者只有一组阈值。除此之外,分层有序 Logit 模型与有序 Logit 模型的建模过程类似。因此,本文只对分层有序 Logit 模型的建模过程进行详细阐述。

分层有序 Logit 模型的表达式如下

$$D_{ij} = \begin{cases} 1 & D_{ij}^* \leq \gamma_{1i} \\ 2 & \gamma_{1i} < D_{ij}^* \leq \gamma_{2i} \\ 3 & D_{ij}^* > \gamma_{2i} \end{cases} \quad (1)$$

$D_{ij}^*$  可按照常规线性回归模型写成如下形式

$$D_{ij}^* = \theta_{ij} + \xi_{ij}, \theta_{ij} = \sum_{p=1}^n \beta_p x_{pij} \quad (2)$$

式中: $x_{pij}$  表示第  $i$  名驾驶人在第  $j$  个路段上的第  $p$  个协变量; $n$  为协变量的个数; $\beta_p$  为回归系数; $\xi_{ij}$  是误差项,并假设误差项服从二重指数分布,其累积分布函数为  $F$ ,则

$$P_{ij(k)} = \Pr(D_{ij}^* \leq \gamma_{ki}) = F(\gamma_{ki} - \theta_{ij}) = \frac{\exp(\gamma_{ki} - \theta_{ij})}{1 + \exp(\gamma_{ki} - \theta_{ij})} \quad (3)$$

对上述累积分布函数进行 Logit 函数变换,即

$$\text{Logit}(P_{ij(k)}) = \log\left(\frac{P_{ij(k)}}{1 - P_{ij(k)}}\right) =$$

$$\log\left(\frac{\Pr(D_{ij}^* \leq \gamma_{ki})}{\Pr(D_{ij}^* > \gamma_{ki})}\right) = \gamma_{ki} - \theta_{ij} \quad (4)$$

对单个驾驶人,采用  $\gamma_{ki}$  表示不同驾驶人的疲劳阈值,即

$$\gamma_{ki} = \gamma_k + b_i \quad (5)$$

式中:截距  $\gamma_k$  表示所有驾驶人疲劳阈值中的常量;随机成分  $b_i$  用于表示各受试人员之间的多样性。

内部相关系数  $I_{cc}$  通常用于检验特定个体之间的差异性

$$I_{cc} = \frac{\sigma_b^2}{\sigma_b^2 + \sigma_w^2} \quad (6)$$

式中: $\sigma_w^2$  为组内方差; $\sigma_b^2$  为组间方差。

如果  $I_{cc}$  数值接近 0 则表示不同主体之间的差异性很小,适合采用无分层结构的模型进行数据分析;否则,更适合采用分层结构的模型。

## 2.2 人工神经网络模型

人工神经网络模型是较流行的一种智能计算模型,由于其能够处理大批量的多维度数据,模型灵活且预测功能强,因此广泛应用于疲劳检测。本文中采用迭代方法建立了一个前馈神经网络,设置 1 个隐藏层,只考虑相邻两层的神经元链接。

在模型建立之前,首先进行数据归一化

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

式中: $x^*$  为归一化后的值; $x$  为样本值; $x_{\min}$  为样本中的最小值; $x_{\max}$  为样本中的最大值。

其基本的计算单元称为节点。每个节点从外部或其他节点获得输入值。每个节点都有 1 个权重  $\omega_s$ ,在训练过程中可以不断修正神经突触的学习能力。隐藏层中第  $t$  个节点的计算式如下

$$Z_t = \sum_s \omega_s (x_s + b_t) \quad (8)$$

$s = 1, 2, \dots, N; t = 1, 2, \dots, M$

式中: $Z_t$  为隐藏层中第  $t$  个节点的输入值; $\omega_s$  为输入层中第  $s$  个节点到隐藏层第  $t$  个节点的权重; $x_s$  为输入层中第  $s$  个节点的值; $b_t$  表示隐藏层中第  $t$  个节点的偏离值; $N$  为输入层中节点的数目; $M$  为隐藏层中节点的数目。

节点的输出由输入和激活函数共同决定。激活函数可以使用正弦函数、双曲正切函数、回归函数。本文中采用双曲正切函数作为隐藏层的激活函数,其计算式为

$$H_t = f(Z_t) = \tanh(Z_t) = \frac{e^{2Z_t} - 1}{e^{2Z_t} + 1} \quad (9)$$

式中: $H_t$  为隐藏层中第  $t$  个节点的输出值。

在本文中,为了使 ANN 模型的输出值尽可能地被解释为绝对目标变量,输出值在 0~1 之间变化并且加和为 1,在输出层采用了一个 Softmax 激活函数,计算式如下

$$O_{k'} = \frac{\exp(Z_{k'})}{\sum_{m=1}^c \exp(Z_m)} \quad (10)$$

式中: $O_{k'}$  为输出层中第  $k'$  个节点的输出值; $c$  为目标变量的类别数目; $Z_{k'}$  表示第  $k'$  个节点的输入值; $Z_m$  表示第  $m$  个节点的输入值。

在训练过程中,通常模型的输出值与预期输出值不相等,因此,需要计算输出误差来衡量模型输出结果与期望结果之间的差别。如果输出误差超出了容许误差,就需要根据输出误差修正关联权重  $\omega_{ij}$ ,然后再次将训练集数据输入模型并且计算输出值,直至输出满足容许误差为止。

## 3 模型结果与分析

### 3.1 MOL 模型和 OL 模型

在 MOL 模型中,首先对 23 个自变量进行显著性分析,得到 5 个显著变量:PERCLOS, Pupil, Blink\_duration, SWM\_Re, LP\_stdev。对这 5 个显著变量进行 Pearson 相关性分析,发现 PERCLOS 与 Blink\_duration 高度相关(相关系数为 0.378),Pupil 与 SWM\_Re 的相关度次之(相关系数为 0.207);但是闭眼时间比例 PERCLOS 与因变量  $D$  相关性更强,因此,Blink\_duration 这一变量也被剔除。最终得到 4 个显著变量:PERCLOS, Pupil, SWM\_Re, LP\_stdev,将其作为模型的解释变量。

MOL 模型与 OL 模型的参数估计结果如表 2 所示。在 MOL 模型中,阈值  $\gamma_1$  显著(Sig 值等于 0.025,小于 0.05),而  $\gamma_2$  不显著(Sig 值等于 0.669,大于 0.05),所有解释变量都显著。PERCLOS, SWM\_Re, LP\_stdev 的系数为正,说明指标的值越大,疲劳程度越高;Pupil 的系数为负,说明这一指标的值越大,疲劳程度越低。用于表示随机效应的指标  $I_{cc}$  为 0.402,这表明存在很大的组间差异性和组内一致性。在 OL 模型中,阈值  $\gamma_1$  不显著, $\gamma_2$  显著,所有的解释变量均显著。每个变量的系数大小与 MOL 模型不同,但反映的自变量与因变量之间的正负相关性是一致的。

表 2 MOL 模型与 OL 模型的参数估计结果

Tab.2 Estimated Results for Parameters of MOL and OL Models

模型	变量名称		效果评估		t 值	Sig 值	95%置信区间	
			平均值	偏差			下限	上限
MOL 模型	阈值	$\gamma_1$	-3.778	1.675	-2.255	0.025	-7.070	-0.486
		$\gamma_2$	-0.712	1.666	-0.427	0.669	-3.986	2.562
	固定效应	PERCLOS	5.226	2.129	2.455	0.014	1.043	9.410
		Pupil	-1.780	0.318	-5.600	0.000	-2.403	-1.156
		SWM_Re	0.010	0.005	2.182	0.030	0.001	0.020
		LP_stdev	5.227	1.007	5.193	0.000	3.249	7.206
	随机效应	组间方差	3.496					
		组内方差	5.195					
		Icc	0.402					
OL 模型	阈值	$\gamma_1$	-0.545	0.694	-0.786	0.432	-1.907	0.816
		$\gamma_2$	1.914	0.698	2.742	0.006	0.544	3.283
	固定效应	PERCLOS	9.891	1.441	6.865	0.000	7.063	12.719
		Pupil	-1.065	0.121	-8.779	0.000	-1.303	-0.827
		SWM_Re	0.011	0.003	3.212	0.001	0.004	0.017
		LP_stdev	3.606	0.833	4.329	0.000	1.971	5.240

3.2 ANN 模型

本文中使用了 23 个无侵入指标, MOL 模型从中筛选出了 4 个显著变量, 为了检测 MOL 模型筛选出的变量是否合理, 在 ANN 模型中采用 10 个神经元将所有的 23 个变量放入隐藏层中, 进行重要度分析。每个变量的重要度如图 3 所示。由图 3 可知, 将变量按重要性进行排序后, 发现 PERCLOS, Pupil, Blink\_duration, SWM\_Re 以及 LP\_stdev 是用于预测疲劳程度的最重要的 4 个变量。此结论与 MOL 模型得出的结论一致。




图 3 神经网络模型中各指标重要度

Fig.3 Indicators Importance in ANN Model

另外, 重要度最高的 4 个变量中有 3 个变量都是眼部特征变量, 这说明在进行疲劳检测时眼部特征变量可能比驾驶行为变量更有效。采用眼动指标

和驾驶行为指标建立 ANN 模型, 其检测精度为 57.8%; 若只保留驾驶行为变量, ANN 模型的检测精度降至 45.8%; 若只保留眼部特征变量, ANN 模型的检测精度降至 49.3%。这说明在进行疲劳检测时, 同时采用眼动指标和驾驶行为指标可以使得检测精度提高。此外, 由于眼部特征指标是通过拍照和影像等方法进行检测, 这些检测方法可靠性较低, 而驾驶行为特征作为补充因素可以检测系统的可靠性。

3.3 模型精度对比

计算 3 个模型的疲劳检测精度如表 3 所示。由表 3 可知: 无论是训练集还是测试集, 3 个模型中 MOL 模型的检测精度都是最高的, 但是, MOL 模型在训练集和测试集之间检测精度的差异也是最大的, 这说明 MOL 模型的泛化误差最大。另 2 个模型中, ANN 模型比 OL 模型要好。3 个模型最可能出现的 3 种检测错误也是一致的, 即: 把 1 误认为 2, 把 3 误认为 2 和把 2 误认为 1, 而把 1 误认为 3 或把 3 误认为 1 发生的可能性较小。

结果显示, 在这 3 个模型中, MOL 模型检测精度最高, 这说明通过考虑个体差异来改善 Logit 模型比使用复杂算法(如 ANN)来改善 Logit 模型更有效。

另外, 对疲劳程度的等级划分也会影响最终检测精度。以往的一些研究将疲劳程度划分为 2 个等级, 其检测精度较高。在本文中, 使用了 3 个等级的

表3 模型精度分析  
Tab.3 Accuracy Analysis for Models %

模型	数据集	观测值	预测值			准确率	总体预测精度
			1	2	3		
MOL 模型	训练集	1	67.90	31.00	1.20	67.90	68.40
		2	22.80	68.90	8.30	68.90	
		3	1.90	29.60	68.50	68.50	
	测试集	1	64.17	30.28	5.56	64.17	64.15
		2	27.13	63.33	9.54	63.33	
		3	5.00	29.68	65.32	65.32	
OL 模型	训练集	1	59.52	39.29	1.19	59.52	54.80
		2	40.00	51.67	8.33	51.67	
		3	3.70	43.52	52.78	52.78	
	测试集	1	50.00	50.00	0.00	50.00	52.70
		2	30.83	52.50	16.67	52.50	
		3	1.19	42.86	55.95	55.95	
ANN 模型	训练集	1	54.17	40.28	5.56	54.17	57.80
		2	26.67	63.33	10.00	63.33	
		3	9.09	36.36	54.55	54.55	
	测试集	1	47.92	52.08	0.00	47.92	56.04
		2	30.00	65.83	4.17	65.83	
		3	12.20	36.59	51.22	51.22	

疲劳程度。若使用2个疲劳程度,在MOL模型中检测精度将由64.15%提高到88.6%,在ANN模型中检测精度将由56.04%提高到83.3%。这说明疲劳程度等级越多,模型的检测精度越低,但是2个疲劳程度不足以在交通事故发生前对驾驶人给予准确的预警,同时,对KSS水平分类越少,KSS数据反映出来的驾驶人之间的个体差异越不明显<sup>[19]</sup>,但是采用过多的KSS水平又会对数据分析造成不便,并且试验通过主观询问获取的KSS数据本身也存在一定误差。

## 4 结 语

(1)基于疲劳驾驶模拟试验采集疲劳驾驶原始数据,在此基础上计算了23个无侵入测量指标,包括驾驶行为指标和眼部特征指标两大类。基于以上指标,建立了考虑个体差异的MOL模型,检测3个不同层次的疲劳程度。为了进行模型对比,还建立了未考虑个体差异的OL模型和ANN模型。

(2)在23个变量中,闭眼时间比例、平均瞳孔直径、车辆偏移值标准差、方向盘反转次数这4个变量是用于预测疲劳程度的最重要的变量;在驾驶疲劳检测中眼部特征指标比驾驶行为指标更为有效。

(3)3个模型中,分层有序Logit模型的检测精度最高,表明考虑个体差异确实可以提高模型检测

精度,而且比使用复杂算法(如ANN)来改善Logit模型更为有效。

(4)本文研究结果对于提高疲劳驾驶检测精度具有一定意义,但本文研究方法未考虑数据时序特征,后续研究可采用时序、贯序分析等方法进一步提高疲劳检测精度;另外,本文中对疲劳等级的划分较为主观,后续可考虑采用脑电等更客观的方法划分疲劳等级。

## 参 考 文 献:

### References:

- [1] Central Intelligence Agency. The World Factbook [R]. Washington DC: CIA, 2010.
- [2] 《中国公路学报》编辑部. 中国交通工程学术研究综述·2016[J]. 中国公路学报, 2016, 29(6): 1-161. Editorial Department of *China Journal of Highway and Transport*. Review on China's Traffic Engineering Research Progress; 2016 [J]. *China Journal of Highway and Transport*, 2016, 29(6): 1-161.
- [3] NHTSA. Traffic Safety Facts; A Brief Statistical Summary[R]. Washington DC: NHTSA, 2011.
- [4] MAYCOCK G. Sleepiness and Driving: The Experience of UK Car Drivers[J]. *Accident Analysis & Prevention*, 1997, 29(4): 453-462.
- [5] KLAUER S G, DINGUS T A, NEALE V L, et al. The Impact of Driver Inattention on Near-crash/Crash Risk: An Analysis Using the 100-Car Naturalistic Driving Study Data[R]. Washington DC: NHTSA, 2006.
- [6] LI W, HE Q C, FAN X M, et al. Evaluation of Driver Fatigue on Two Channels of EEG Data[J]. *Neuroscience Letters*, 2012, 506(2): 235-239.
- [7] PATEL M, LAL S K L, KAVANAGH D, et al. Applying Neural Network Analysis on Heart Rate Variability Data to Assess Driver Fatigue[J]. *Expert Systems with Applications*, 2011, 38(6): 7235-7242.
- [8] 马 勇, 付 锐. 驾驶人视觉特性与行车安全研究进展[J]. 中国公路学报, 2015, 28(6): 82-94. MA Yong, FU Rui. Research and Development of Drivers Visual Behavior and Driving Safety[J]. *China Journal of Highway and Transport*, 2015, 28(6): 82-94.
- [9] INGRE M, AKERSTEDT T, PETERS B, et al. Subjective Sleepiness, Simulated Driving Performance and Blink Duration: Examining Individual Differences [J]. *Journal of Sleep Research*, 2006, 15(1): 47-53.
- [10] JO J, LEE S J, PARK K R, et al. Detecting Driver

- Drowsiness Using Feature-level Fusion and User-specific Classification[J]. *Expert Systems with Applications*, 2014, 41(4): 1139-1152.
- [11] THIFFAULT P, BERGERON J. Fatigue and Individual Differences in Monotonous Simulated Driving[J]. *Personality and Individual Differences*, 2003, 34(1): 159-176.
- [12] HAMADA T, ITO T, ADACHI K, et al. Detecting Method for Drivers' Drowsiness Applicable to Individual Features[C]//IEEE. *Proceedings of Intelligent Transportation Systems*. New York: IEEE, 2003: 1405-1410.
- [13] WIERWILLE W W, WREGGIT S S, KIRN C L, et al. Research on Vehicle-based Driver Status/Performance Monitoring; Development, Validation, and Refinement of Algorithms for Detection of Driver Drowsiness. Final Report [R]. Washington DC: NHTSA, 1994.
- [14] YANG G, LIN Y, BHATTACHARYA P. Driver Fatigue Recognition Model Based on Information Fusion and Dynamic Bayesian Network[J]. *Information Sciences*, 2010, 180(10): 1942-1954.
- [15] HU S, ZHENG G. Driver Drowsiness Detection with Eyelid Related Parameters by Support Vector Machine[J]. *Expert Systems with Applications*, 2009, 36(4): 7651-7658.
- [16] AKERSTEDT T, GILLBERG M. Subjective and Objective Sleepiness in the Active Individual[J]. *International Journal of Neuroscience*, 1990, 52(1/2): 29-37.
- [17] 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.
- XU Chuan, WANG Xue-song, CHEN Xiao-hong, et al. Driver Drowsiness Level Analysis and Prediction Based on Decision Tree[J]. *Journal of Tongji University: Natural Science*, 2015, 43(1): 75-81.
- [18] 胥 川, 王雪松, 陈小鸿. 无侵入测量指标的驾驶疲劳检测性能评估[J]. *西南交通大学学报*, 2014, 49(4): 720-726.
- XU Chuan, WANG Xue-song, CHEN Xiao-hong. Evaluating Performance of Non-intrusive Indicators on Drowsy Driving Detection[J]. *Journal of Southwest Jiaotong University*, 2014, 49(4): 720-726.
- [19] SANDBERG D, WAHDE M. PARTICLE Swarm Optimization of Feed Forward Neural Networks for the Detection of Drowsy Driving[C]//IEEE. *Proceedings of 2008 IEEE International Joint Conference on Neural Networks*. New York: IEEE, 2008: 788-793.

(上接第 104 页)

- SHAO Jian, LI Yan-ming, MIAO Yu-bin, et al. Information Acquisition and Processing Technology of the Intelligent Transit System[J]. *Computer Engineering*, 2008, 34(12): 274-276.
- [15] 姜桂艳, 常安德, 张 玮. 基于 GPS 浮动车采集交通信息的路段划分方法[J]. *武汉大学学报: 信息科学版*, 2010, 35(1): 42-45, 50.
- JIANG Gui-yan, CHANG An-de, ZHANG Wei. Road Division Method Based on the GPS Floating Car Traffic Information Collection[J]. *Journal of Wuhan University: Information Science*, 2010, 35(1): 42-45, 50.
- [16] 孙棣华, 赖云波, 廖孝勇, 等. 公交浮动车辆到站时间实时预测模型[J]. *交通运输工程学报*, 2011, 11(2): 84-89.
- SUN Di-hua, LAI Yun-bo, LIAO Xiao-yong, et al. A model on Real-time Prediction of Arrival Time for Floating Transit Vehicle[J]. *Journal of Transportation Engineering*, 2011, 11(2): 84-89.
- [17] SHALABY A, FARHAN A. Prediction Model of Bus Arrival and Departure Times Using AVL and APC Data[J]. *Journal of Public Transportation*, 2004, 7(1): 41-61.
- [18] 李继伟. 城市主次干路的路段行程时间估计与预测方法研究[D]. 长春: 吉林大学, 2012.
- LI Ji-wei. Estimation and Prediction of Link Travel Time for Urban Trunk and Secondary Streets[D]. Changchun: Jilin University, 2012.
- [19] 刘同明, 夏祖勋, 解洪成. 数据融合技术及其应用[M]. 北京: 国防工业出版社, 1998.
- LIU Tong-ming, XIA Zu-xun, XIE Hong-cheng. Data Fusion Techniques and Its Application[M]. Beijing: National Defense Industry Press, 1998.
- [20] 吕德潮, 范江涛, 韩刚瓮, 等. 粒子滤波综述[J]. *天文研究与技术*, 2013, 10(4): 397-409.
- LU De-chao, FAN Jiang-tao, HAN Gang-weng, et al. A Review of Particle Filters[J]. *Astronomical Research and Technology*, 2013, 10(4): 397-409.
- [21] BAR-SHALOM Y, LI X R, KIRUBARAJAN T. Estimation with Applications to Tracking and Navigation: Theory Algorithms and Software [M]. New York: John Wiley & Sons, 2004.