

Research and Establishment on Driving Risk Tendency Evaluation System of Truck Drivers

Jiangping SU¹, Yan WANG², Lingyun XIAO²

¹School of Automotive Studies, Tongji University, Shanghai, China, 201804

²AQSIQ Defective Product Administrative Center, Beijing, China, 100101

Email: sujiangping1993@163.com

Abstract: A Naturalistic Driving Study Experiment was conducted by 10 trucks (13 drivers) and 208 near-crash cases are selected. Through image process method, kinematic formulas and vehicle speed obtained from On-Board Diagnostic, information of vehicle and environment is selected. Firstly, multiple threshold segmentation method and BP neural network model method are used to develop a two-level judgment strategy. Then, driving risk tendency evaluation system is established based on all-time natural driving data and dangerous driving behavior. This research makes it possible to conduct on-line monitoring / off-line evaluation of driving behavior and provides feasibility for safe driving operation.

Keywords: dangerous driving behavior; BP neural network; naturalistic driving study; near crash; driving risk tendency

卡车驾驶员驾驶风格评价体系的研究

苏江平¹, 王琰², 肖凌云²

¹同济大学汽车学院, 上海, 中国, 201804

²国家质检总局缺陷产品管理中心, 北京, 中国, 100101

Email: sujiangping1993@163.com

摘要:通过合作, 采集得到 13 名驾驶员、10 辆卡车的自然驾驶数据, 筛选出 208 起具有潜在碰撞风险的危险工况, 并通过车载诊断系统(On-Board Diagnostic, OBD)读取的本车车速和图像处理算法及运动学公式获得样本的车辆运动参数及环境信息。其次, 使用多重阈值分割法和 BP 神经网络模型制定两级判别算法, 实时识别危险驾驶行为并对其危险程度进行评分; 最后, 基于全时段自然驾驶数据和危险驾驶行为事件, 建立了驾驶风格评分体系, 并进行了验证。本项目研究成果实现了对危险驾驶行为的在线监测和驾驶风格的离线评价, 使得进一步规范卡车驾驶员的驾驶行为, 或针对不同驾驶风格的驾驶员建立自适应的辅助驾驶系统控制参数成为可能。

关键词: 危险驾驶行为; BP 神经网络; 自然驾驶; 危险工况; 驾驶风格

1 引言

2015 年中国道路交通事故统计年报显示, 全国共发生 187781 起交通事故, 造成 58022 人死亡^[1]。而造成交通事故的人、车、路三大要素中, “人”具有错误造成的事故就占到了事故总数的 57%, 而其中的 97%的事故是驾驶员的错误操作引发的^[2]。因此, 研究驾驶行为, 建立驾驶风格评分体系, 对规范驾驶员行为, 避免碰撞事故发生意义重大。

由于卡车具有质量大、制动性能差的特点, 且常存在超速超载等行为, 造成的事故往往严重且特殊。统计结果显示, 与 2015 年全国的总体道路交通事故相比, 卡车事故死亡率高出 83.87%^[3]。因此, 对卡车驾驶员的危险驾驶行为进行研究和监督尤为重要。

目前,国外 Elander^[4]和 Sagberg^[5]等人的研究表明驾驶行为与交通事故发生率和燃油消耗率有关。State Farm 公司通过车内装置监测驾驶人的加速、转弯、超速等行为,基于驾驶行为模型实行差异化定价^[6]。Sun 等人通过智能手机采集到加速度等数据,分析驾驶人驾驶风格,并提出了针对不同驾驶模式的干预策略^[7]。

国内,李彦章等人^[8]基于问卷得出驾驶员的应对方式和驾驶行为错误具有相关性。成波等人^[9]提出驾驶风格的 3 层结构并建立其数学描述。以上研究初步脱离主观评判、开始定量研究驾驶风格,但方法仍有待改进。此外,国内对这一领域的研究尚未完成由理论层面向应用层面的转变。

2 危险工况提取与驾驶行为风险程度判别

将自然驾驶数据进行筛选,人为甄别危险驾驶事件并分类,然后对获得的危险驾驶事件的危险程度进行专家主观评分。

本研究第一部分的数据来自于某物流公司,10 辆卡车、13 名驾驶员在自然状态下,即无干扰的日常驾驶状态下,行驶的自然驾驶数据共计 247GB,包括车辆 OBD 数据、六轴加速传感器信息及车内外的 2 个可视化视频。对采集到的数据,由专业研究人员进行筛选,分类如下:

- (1) 事故工况:本车与其他车辆发生碰撞;
 - (2) 危险工况:驾驶员在遇到存在一定危险程度的场景时采取措施,避免了潜在碰撞的发生。
- 共筛选得到 208 起危险工况和 0 起事故工况。

上海联合道路交通安全科学研究中心(Shanghai United Road Traffic Safety Scientific Research Center, SHUFO)是中国第一家从事交通事故专业研究的非盈利机构。该机构自 2006 至 2014 年参与国家质检总局缺陷产品管理中心的“车辆事故深度研究”项目(NAIS),共采集得到 109 起卡车参与的交通事故。将这 109 起事故按照驾驶员碰撞前行为进行深入研究,可得到事故产生的主要原因或事故后果加重的主要诱因,如表 1 所示。

Table 1 Proportional distribution of dangerous driving behavior based on SHUFO

表 1 基于 SHUFO 数据库的危险驾驶行为比例分布

危险驾驶行为类型	事故数量(起)	比例
危险转弯行为	6	5.50%
纵向制动不及时行为	84	77.06%
危险变道行为	4	3.67%
卡车无错误行为	15	13.76%

由表 1 可知,危险转弯行为、纵向制动不及时行为及危险变道行为造成的卡车事故占到全部卡车事故的 86%,因此将这三类危险工况作为依据,将 208 起危险行为事件进行分类,结果如表 2 所示:

Table 2 Classification results of 208 dangerous driving events

表 2 危险驾驶行为分类结果

	危险制动	危险转弯	危险变道
案例数量(起)	92	85	31

对 208 起危险工况数据详细分析,可得如下信息:

- (1) 视频信息:基于 SHUFO 已有的图像算法^[10]和运动学公式,可以得到以时间为序列的,与前方车辆的相对位置,车头时距(Time Head-way, THW)及路面相关信息;
- (2) OBD 数据:以时间为序列的实时车速;
- (3) 六轴传感器数据:以时间为序列的本车纵向加速度、横向加速度、垂向加速度、横摆角速度、俯仰角速度和侧倾角速度。

其中 THW 是常用的驾驶员危险认知参数，指本车到达当前前车位置所需要的时间，即两车相对距离除以本车速度，如式(1)所示。

$$THW = d / V_{\text{本}} \quad (1)$$

采取主观评价的方法进行危险驾驶行为事件严重程度的评价。选取三名成熟驾驶员，对每个事件进行评价（危险 1/不危险 0），得到评价值 E_i 。按式(2)中规则，对所有事件的危险程度进行主观评分。

$$R_i = \begin{cases} 0, & E_A = E_B = E_C = 0 \\ 0.5, & E_A \neq E_B \neq E_C \\ 1, & E_A = E_B = E_C = 1 \end{cases} \quad (2)$$

其中， R_i 表示主观评价的驾驶风险程度值， E_A ， E_B ， E_C 分别为三名专家评分。

3 危险驾驶行为判别模型的建立

采用两级判别算法实现对危险驾驶事件的自动判别^[11]。首先，建立基于多重阈值分割的初级判别算法，判断某一段时间段内的自然驾驶行为是否属于危险驾驶的范畴；然后，基于深度学习的次级判别算法，计算得到该时段行为的危险程度评分。当得分达到一定阈值时，认为该行为确实属于危险驾驶行为，可进行实时提醒和记录。两级判别算法的建立，相比于传统的阈值分割法，消除了偶然性，结果更为客观。流程图如图 1 所示：




Figure 1 Flow chart of discriminant algorithm

图 1 判别算法流程图

3.1 基于多重阈值分割法的初级判别算法

基于多重阈值分割分别对危险制动、危险转向和危险变道行为进行初级判别。

3.1.1 危险制动行为初级判别

随机选取 80 起危险制动行为进行特征分析，结合已有研究成果，提炼最优阈值组合如下：

① 制动开始时刻：

A1: 制动开始时刻纵向减速度 $a_{x0} < 0$;

A2: 制动开始时刻及第二秒纵向减速度和 $SUM(a_{x0} + a_{x1}) < -10$ 。

同时满足条件 A1 与 A2。

② 制动结束时刻：

B1: 制动结束时刻纵向减速度 $a_{xN} > -10$;

B2: 制动结束时刻前一秒纵向减速度 $a_{x(N-1)} > -11$;

B3: 车辆速度 $v_N = 0$ 。

满足 B1 和 B2，或满足 B3。

③ 对危险驾驶行为的定义：

C1: 制动开始时刻跟驰时距 $THW_0 < 2s$;

C2: 制动结束时刻车距 $l_{end} < 2m$;

满足 C1 或 C2。

使用其余 12 例危险制动行为对算法进行验证, 准确性达到 100%。综上, 危险制动行为初级判别算法如图 2 所示。




Figure 2 Elementary discriminant algorithm for critical braking behavior

图 2 危险制动行为初级判别算法

3.1.2 危险转弯行为初级判别

随机选取 63 起危险转弯行为进行特征分析, 结合已有研究成果, 提炼出最优阈值组合如下:

① 转弯开始时刻:

A1: 转弯开始时刻横向加速度绝对值 $|a_{y0}| > 0$;

A2: 转弯开始时刻及第二秒横向加速度绝对值和 $SUM(|a_{y0}| + |a_{y1}|) > 10$ 。

同时满足条件 A1 与 A2。

② 转弯结束时刻:

B1: 转弯结束时刻横向加速度绝对值 $|a_{yN}| < 5.3$;

B2: 转弯结束时刻前一秒横向加速度绝对值 $|a_{y(N-1)}| < 8.6$ 。

同时满足 B1 和 B2。

③ 危险转弯驾驶行为的定义:

C1: 横向加速度均值绝对值 $a_{y-ave} > 0.06g$;

C2: 横向加速度峰值绝对值 $a_{y-max} > 0.15g$;

C3: 侧倾角速度峰值绝对值 $\omega_{x-max} > 0.97^\circ /s$;

同时满足 C1、C2 和 C3。

使用其余 22 例危险转弯行为进行验证, 准确率达到 94%。综上, 危险转弯行为初级判别算法如图 3 所示




Figure 3 Elementary discrimination algorithm for dangerous turning behavior

图 3 危险转弯行为初级判别算法

3.1.3 危险变道行为初级判别

随机选取 23 起危险变道行为进行特征分析，并结合已有研究成果，提炼出最优的阈值组合如下：

① 变道开始时刻：

A1: 变道开始时刻横摆角速度绝对值 $|\omega_{z0}| > 33$;

A2: 变道开始时刻及后二秒横向加速度绝对值和 $SUM(|\omega_{z0}| + |\omega_{z1}| + |\omega_{z2}|) > 97$ 。

同时满足条件 A1 与 A2。

② 变道结束时刻：

B1: 整个变道事件横摆角速度和绝对值 $SUM(|\omega_z(0:N)|) < 310$ 。

③ 危险变道驾驶行为的定义：

C1: 横向加速度均值绝对值 $THW_0 < 2s$;

使用其余 8 起危险变道事件进行验证，准确率可达 80%。综上，危险变道行为初级判别算法如图 4 所示。




Figure 4 Elementary discrimination algorithm for dangerous changing lane behavior

图 4 危险变道行为初级判别算法

3.2 基于神经网络的次级判别算法

分别对三类危险工况选取特征参数，参考主观评价法得到的危险程度评分后，采用深度学习的方式，得到各种工况下危险程度评分与各危险事件特征量的函数关系，即为危险驾驶行为的次级判别算法。深度学习方法采取 BP 神经网络作为算法理论。

由于主观评价部分采取的是 0/0.5/1 的规则进行评分，对危险程度评分采用的激活函数 f 为光滑、连续的 sigmoid 函数。该函数能将危险程度映射到 (0,1) 的空间内，也能减弱奇异值对模型效果的不良影响，sigmoid 函数形式如式 (3) 所示。

$$f(x) = \frac{1}{1 + e^{-ax+b}} \quad (3)$$

使用 R Studio 软件并设定最大迭代次数 1000 次进行训练，获得 166 个事件基于神经网络学习得到的危险驾驶程度评分向量，算法描述如式 (4) 所示

$$R_i = \frac{1}{1 + e^{-\sum \beta_j x_j}} \quad (4)$$

其中， R_i 代表事件 i 的危险程度评分。

① $i=1$ 为危险制动事件， $j = (1,2,3,4,5)$

$x_j =$ (制动开始时刻 THW，制动结束时刻前车车距，制动全程纵向加速度均值绝对值，制动全程纵向加速度峰值绝对值，1)；

$$\beta_j = (-0.2889, -0.4112, 0.0431, 0.0421, 0.227)$$

② $i=2$ 为危险转弯事件， $j = (1,2,3,4)$

$x_j =$ (转弯全程横向加速度峰值绝对值，转弯全程横向加速度均值绝对值，转弯全程速度值均值，1)；

$$\beta_j = (0.0441, 0.1464, 0.0205, -3.3342)$$

③ $i=3$ 为危险变道事件， $j = (1,2,3)$

$x_j =$ (变道全程横摆角速度峰值绝对值，变道开始时刻 THW，1)；

$$\beta_j = (0.0043, -0.9645, 0.0205, -0.3027)$$

最后，用其余事件进行上述次级判别运算，得到神经网络算法对事件危险程度的计算结果与主观评价得到结果相关系数为 0.8682，说明训练效果较好。

4 驾驶员驾驶风格评价体系的建立

两级判别模型主要用于危险驾驶行为的实时监测。而基于两级判别模型记录的危险驾驶事件和自然驾驶全过程的驾驶数据是建立驾驶风格评分体系的基础，可实现离线评价^[12]。

4.1 基于危险驾驶事件的驾驶风险倾向评价

计算每名驾驶员引起的危险事件的危险程度评分计算均值，结果如图 5 所示。其中，10 号和 11 号卡车驾驶员记录的事件平均分数较高，达到 0.6 以上，而 2 号和 5 号卡车驾驶员平均分较低，在 0.3 左右。




Figure 5 Average value of risk degree score

图 5 危险程度评分结果平均值

主观评定为“安全”、“一般危险”和“比较危险”组内，第 20 百分位及第 80 百分位 BP 神经网络评分结果如表 3 所示。为使 80 百分位能够包含较多相应事件，划定 0 ~ 0.30 评分事件为“安全事件”，0.31 ~ 0.65 评分事件为“一般危险事件”，0.66 及以上为“比较危险事件”。

Table 3 Neural network score results distribution in different subjective assessment groups

表 3 不同主观评定组别的神经网络评分结果分布

组别	20 百分位危险评分	80 百分位危险评分
安全	0.093198282	0.30262124
一般危险	0.328416158	0.656742222
比较危险	0.650780973	0.837121137

统计每名驾驶员危险事件中评分大于 0.3 的事件占该驾驶员所有事件的比例，结果如图 6 所示。其中 10 号和 11 号卡车驾驶员比例较高，2 号和 5 号卡车驾驶员比例较低。




Figure 6 Percentage of aggressive event

图 6 危险事件所占比例

统计 13 名驾驶员各自危险事件中评分大于 0.65 的事件占该驾驶员所有事件比例，结果如图 7 所示。除 10 号和 11 号卡车驾驶员以外，6 号驾驶员这一比例也较高，而 2 号 3 号和 5 号卡车驾驶员这一比例为 0。




Figure 7 Percentage of extreme aggressive event

图 7 比较危险事件比例

对 13 名驾驶员各自 50 百分位事件评分和危险事件峰值进行统计，结果如图 8 和图 9 所示。结论与趋势相似。




Figure 8 50 percentile value of risk degree score

图 8 50 百分位事件评分




Figure 9 Maximum number of risk event score

图 9 危险事件评分峰值

根据以上分析，得到基于危险驾驶事件的驾驶员风格评分细则为：

- (1) 所有记录事件危险程度结果的平均得分。输出平均危险程度 α_1 ；
- (2) 危险程度评分大于 0.3 的事件占全部事件的百分比。输出危险事件比例 α_2 ；
- (3) 危险程度评分大于 0.65 的事件占全部事件的百分比。输出危险事件比例 α_3 ；

(4) 50 百分位危险程度评分的危险事件分数。输出 50 百分位危险程度 α_4 ;

(5) 危险程度评分最大的危险事件分数。输出最大危险程度 α_5 ;

依照计算公式 (5)，得到的 13 名驾驶员基于危险驾驶事件的风险评分结果如图 10 所示。总体结果与主观判断相符。

$$N_1 = \sum_1^5 \alpha_i \quad (5)$$




Figure 10 Score based on aggressive driving event
图 10 基于危险驾驶事件评分结果

4.2 驾驶风险倾向综合评价

研究自然驾驶数据，可用于了解驾驶员在真实交通环境中的操作行为，进而评判他的驾驶风格。

13 名驾驶员制动减速度均值分布如图 11 所示，单位为 0.01g。该特征值表征了驾驶员对制动踏板的控制，多分布于 0.04g ~ 0.10g 之间。




Figure 11 Average value of deceleration
图 11 制动减速度分布均值

13 名驾驶员制动减速度大于 0.2g 的时间百分比分布如图 12 所示。根据相关研究，小轿车在自然驾驶状态下 95% 的制动减速度小于 0.3g，考虑到卡车制动性能不如轿车，且自重更大，因此统计 0.2g 及以上的制动信号时间百分比。这一参数用于判断驾驶员的紧急制动倾向。




Figure 12 Time duration percentage with deceleration higher than 0.2g
图 12 制动减速度大于 0.2g 时间百分比

各驾驶员加速度均值分布如图 13 所示，单位为 0.01g。该特征值表征了驾驶员对加速踏板的控制。多分布于 0.05g ~ 0.15g 之间。




Figure 13 Average value of acceleration
图 13 加速度分布均值

各驾驶员加速度大于 0.2g 的时间百分比分布如图 14 所示。有关研究显示，小汽车的加速度大于 0.3g 属于急加速行为。与减速行为类似，统计卡车 0.2g 及以上的加速信号时间百分比。该特征值可以反映驾驶员的急加速倾向。




Figure 14 Time duration percentage with acceleration higher than 0.2g
图 14 加速度大于 0.2g 时间百分比

各驾驶员侧向加速度绝对值均值分布如图 15 所示。该特征值表征了驾驶员对方向盘的控制。多分布在 0.01g ~ 0.04g 之间。




Figure 15 Average value of absolute lateral acceleration
图 15 侧向加速度绝对值均值

根据本研究采集数据显示，在 0.12g 阈值的前提下，驾驶员具有较大差异性，故选取 0.12g 作为门限值。驾驶员侧向加速度绝对值大于 0.12g 的时间百分比分布如图 16 所示。该特征值表征了驾驶员的急转弯倾向。




Figure 16 Time duration percentage with absolute lateral acceleration higher than 0.2g
图 16 侧向加速度均值大于 0.12g 时间比例

根据以上分析，得到基于自然驾驶数据的驾驶员风格评分细则为：

- (1) 制动模式下平均减速度，并除以 20（0.2 单位重力加速度）归一化。输出相对平均制动减速度 β_1 ；
- (2) 制动模式下减速度值>0.2g 的时间百分比。输出急减速比例 β_2 ；
- (3) 加速模式下平均加速度值，并除以 20（0.2 单位重力加速度）归一化。输出相对平均加速度 β_3 ；
- (4) 加速模式下加速度值>0.2g 的时间百分比。输出急加速比例 β_4 ；
- (5) 平均侧向加速度绝对值均值，并除以 12（0.12 单位重力加速度）归一化。输出相对平均侧向加速度 β_5 ；
- (6) 侧向加速度绝对值>0.12g 的时间百分比。输出急转向比例 β_6 。

依据计算公式（6），得到的 13 名驾驶员基于自然驾驶数据风险评分结果如图 17 所示。

$$N_2 = \sum_{i=1}^6 \beta_i \quad (6)$$




Figure 17 Score based on naturalistic driving data
图 17 基于自然驾驶数据评分结果

将 N_1 与 N_2 值相加，获得驾驶员风险倾向的综合得分，如图 18 所示。




Figure 18 Score results of driving risk tendency
图 18 驾驶风险倾向评分结果

对比驾驶风险倾向评分最低和最高的 2 号驾驶员和 11 号驾驶员的评分结果：2 号驾驶员危险驾驶事件得分 1.596 分，自然驾驶得分 0.661 分；而 11 号驾驶员的危险驾驶事件得分达到 3.681 分，自然驾驶部分 1.226 分，分别在所有驾驶员中排名第一名和第五名，总分排名第一。两名驾驶员具体得分如表 4，表 5 所示。

Table 4 Concrete score values for No. 2 and No.11 drivers (1)
表 4 2 号和 11 号驾驶员具体得分 (1)

驾驶员	平均评分	危险事件比例	较危险事件比例	50 百分位事件	危险事件峰值
2	0.319	0.429	0.000	0.284	0.565
11	0.627	0.893	0.536	0.670	0.955

Table 5 Concrete score values for No. 2 and No.11 drivers (2)
表 5 2 号和 11 号驾驶员具体得分 (2)

减速度	急减速	加速度	急加速	侧向加速度	急转弯
5.337	0.019	3.834	0.014	1.954	0.006
9.433	0.116	6.129	0.066	2.946	0.020

根据以上研究可以得到, 具有危险驾驶倾向的 11 号驾驶员相对驾驶行为较为安全的 2 号驾驶员具有以下基本特征:

- ① 被记录的驾驶事件的平均危险评分较高;
- ② 危险评分在 0.3 以上事件及 0.65 以上事件的比例较高;
- ③ 驾驶事件评分的峰值更高, 更有可能造成事故;
- ④ 驾驶过程中急减速、急加速、急转弯操作的频率和强度更高。

可以看出, 危险倾向与安全倾向驾驶员在危险事件的表现和自然驾驶过程中的操作均有明显差异, 说明这种评价方式较为完整地反映驾驶风格倾向。

5 总结与讨论

本研究结论如下: 1. 建立了多重阈值分割法和 BP 神经网络模型的两级判别算法, 实现了从自然驾驶中实时监测危险驾驶行为的目的。2. 对危险驾驶事件和自然驾驶数据评分, 建立了完善的驾驶风险倾向评价体系, 实现对驾驶风格的离线评价。3. 对 13 名驾驶员的驾驶行为分析可知, 风险倾向大的驾驶员较风险倾向小的驾驶员, 在危险驾驶事件评分上、均值、峰值都偏大; 且采用急加速、急减速、急转弯更为频繁, 发生的危险驾驶事件较多, 潜在的事故发生率更高。

本文完成了危险驾驶行为的在线监测和驾驶风格的离线评价, 达到了预期目的。由于时间限制, 仍有一些方面有待进一步研究: 1. 相比于车辆横向加速度, 方向盘转角能更好地表征驾驶员对车辆方向的控制; 未来数据采集需增加这一信息, 并对算法进行优化。2. 采取马尔科夫模型^[13]、支持向量机^[14]、随机森林^[14]等其他深度学习方法, 与 BP 神经网络方法对比, 选择更优算法。

致 谢 (Acknowledgement)

同济大学的王宏雁教授在论文撰写上给予了很大帮助, 李天琪同学论文做了大量前期工作, 在此一并感谢。

参考文献 (References)

- [1] 公安部交通管理局. 中华人民共和国道路交通事故统计年报 (2015 年度). 无锡: 公安部交通管理科学研究所, 2016.
- [2] K.Rumar. Human Behavior and Traffic Safety[A]. Symposium on "Human Behavior and Traffic Safety" held at the General Motors Research Laboratories[C].1985
- [3] 王琦. 基于事故工况的重型货车追尾碰撞控制策略研究. 同济大学, 2017.
- [4] Summala H, Rajalin S, Radun I. Risky driving and recorded driving offences: A 24-year follow-up study. Accident Analysis & Prevention, 2014, 73: 27-33
- [5] Sagberg F, Piccinini G F B, Engström J. A review of research on driving styles and road safety. Human Factors, 2015, 57(7): 1248-1275.
- [6] Jose Antonio Diego-Mas. Using Kinect_sensor in observational methods for assessing postures at work . Applied Ergonomics, 2014.15: 976-985.
- [7] Sun R, Ochieng W Y, Feng S. An integrated solution for lane level irregular driving detection on highways . Transportation Research Part C: Emerging Technologies, 2015, 56: 61-79.
- [8] 李彦章, 贾杰, 等. 汽车驾驶员应对方式与驾驶行为和事故的关系. 中华行为医学与脑科学杂志, 2012.21(1): 73-75.
- [9] 成波, 徐少兵, 等. 激进驾驶状态识别算法研究. 汽车工程, 2014.36(7): 785-787.
- [10] 陈伟. 基于中国交通现状的 ADAS 测试场景研究. 同济大学, 2016.
- [11] 李天琪. 卡车驾驶员的危险驾驶行为研究. 同济大学, 2017.
- [12] 李国法. 基于模式转移和操控特性的驾驶风格评测研究. 清华大学, 2016.
- [13] 肖献强, 任春燕, 王其东. 基于隐马尔可夫模型的驾驶行为预测方法研究. 中国机械工程, 2013, (21): 2972-2976.
- [14] 杨洁, 闫清东, 梅向辉. 基于支持向量机的车辆行为分析方法研究. 南京邮电大学学报(自然科学版), 2015, (04): 74-80.
- [15] 高林, 刘英, 等. 基于随机森林模型的短时交通流预测方法. 微型机与应用, 2016, 35(10): 46-49.