

doi: 10.11918/j.issn.0367-6234.2015.09.022

# 自然驾驶条件下驾驶人换道行为实时预测

彭金栓<sup>1</sup>, 付锐<sup>2</sup>, 郭应时<sup>2</sup>

(1.重庆交通大学 交通运输学院, 400074 重庆; 2. 长安大学 汽车学院, 710064 西安)

**摘要:** 为降低车道变换的风险性, 提出一种基于驾驶人视觉特性与车辆运动状态预测车道变换行为的方法. 应用视觉追踪系统、毫米波雷达等仪器设备, 进行了真实环境下的实车驾驶试验. 基于换道前驾驶人后视镜注视特性确定换道意图时窗大小为 5 s, 构建换道行为预测的表征指标体系. 设计 BP 神经网络结构, 构建换道行为预测模型. 结果表明: 模型可以至少提前 1.5 s 预测驾驶人的换道行为, 且预测精度达到 95.58%. 与基于转向灯状态预测驾驶人换道行为相比, 其预测精度及时序特性均有显著提升, 证明了预测指标及预测方法的有效性.

**关键词:** 驾驶行为; 实车试验; 车道变换; 行为预测; BP 神经网络; 意图时窗

**中图分类号:** U471.15      **文献标志码:** A      **文章编号:** 0367-6234(2015)09-0119-05

## Real-time prediction of lane-changing behaviors under naturalistic driving conditions

PENG Jinshuan<sup>1</sup>, FU Rui<sup>2</sup>, GUO Yingshi<sup>2</sup>

(1.School of Transportation, Chongqing Jiaotong University, 400074 Chongqing, China;

2.School of Automobile, Chang'an University, 710064 Xi'an, China)

**Abstract:** To reduce the risk of lane changing behaviors, based upon drivers' visual characteristics and vehicle motion states, a method for lane change prediction is proposed. By using visual tracking system, millimeter-wave radar and so on, the research group conducts experiments under real road environment. Based on drivers' fixation characteristics of the rearview mirrors before lane change occurs, lane changing intent time window is determined as 5 s, the characteristic index for predict lane changing behavior is further built. By designing BP neural network, the lane change prediction model is constructed. Results show that the model may predict drivers' lane changing behavior for at least 1.5 s in advance, and the prediction accuracy can reach 95.58%. As compared to predict lane change behavior via turn signals, the prediction accuracy and time series characteristics are both improved remarkably, thus verifying the effectiveness of the predictive index and method.

**Keywords:** driving behavior; real-world experiment; lane change; behavior prediction; BP neural network; intent time window

随着汽车保有量的增加及人们出行需求的日益扩张, 交通供需不均衡的矛盾持续困扰着我国, 并触发了大量的道路交通事故. 2012 年全国共发生 204 196 起交通事故, 其中由换道处置不当而触发的事件数占总量的 4%<sup>[1]</sup>. 为降低车道变换时的风险性, 诸多学者对驾驶人的换道行为进行了深入研究, 换道辅助系统相关领域的探索成为一个研究热点. McCall 等<sup>[2]</sup> 构建一种基于车辆横向位置、车辆运行

参数和驾驶人头部运动的车道变换意图识别系统 DIIS, 采用计算机视觉方法来识别和跟踪车道位置信息和驾驶人头部运动, 结合真实环境下实车试验采集的数据, 利用稀疏贝叶斯学习方法对驾驶人的车道变换意图进行了分析. Liu 等<sup>[3]</sup> 在一个模拟驾驶研究中利用隐马尔可夫模型 HMM 来预测车辆向左换道的操作, 该模型在操作开始后 0.5 s 识别出了 50% 的车道变换, 但该模型仅采用了车辆方向盘转角作为输入信息, 可靠性有待检验. Nishiwaki 等<sup>[4]</sup> 基于隐马尔可夫模型 HMM 对不同驾驶人的车道变换行为进行建模, 预测车辆车道变换时的行驶轨迹, 考虑的参数包括车辆在车道中的位置、行驶速度及车辆间相对运动关系. Toledo-Moreo 等<sup>[5]</sup> 基于速度及惯性测量单元, 构建了一种交互式多体模型, 系统能够在直线和弯道行驶条件下提前预测出驾驶人的

收稿日期: 2014-03-12.

基金项目: 国家自然科学基金(61503049, 51178053); 教育部高等学校博士学科点专项基金(20135522110003); 中央高校基本科研业务费专项资金(2014G1502015).

作者简介: 彭金栓(1982—), 男, 博士, 副教授;

付锐(1965—), 女, 教授, 博士生导师.

通信作者: 付锐, pengjinshuan@163.com.

换道行为. Salvucci 等<sup>[6-7]</sup>借助模拟驾驶试验,构建了一种对驾驶人车道变换行为进行实时检测的系统. 该系统能够在操作开始 0.5 s 内检测出 82% 的换道操作. 彭金栓等<sup>[8-9]</sup>研究了换道车辆与目标车道后车的博弈行为,基于驾驶人眼动及头动信息,构建了识别驾驶人换道意图的交互模型,识别成功率达到 90% 以上. 本文在以上研究的基础上,尝试基于实车试验,结合眼动、头动、车辆运行状态等多源参数信息,构建基于 BP 神经网络的驾驶人换道行为预测模型.

### 1 试验

本文围绕人因安全研究构建了一套驾驶行为特性检测系统,基于试验车集成了眼动仪、生理测试仪、毫米波雷达等传感设备,定量采集驾驶人的视觉及心理状态、车辆运行状态等相关参数,如图 1 所示. 选择 G25 长深高速长兴至湖州南区段为主要试验路段,路线全长约 25 km,双向 4 车道,中间绿化带分隔. 试验前对路线各时段内断面交通量进行了持续一周的监控,选择交通量相对较为稳定的时段进行试验,以尽量削弱交通量的大小对驾驶人换道行为特性的影响.

研究小组在浙江省湖州市组织招募了 51 名职业驾驶人作为试验被试,其中 40 名男性,11 名为女性. 所有的驾驶人均为自愿参加,对试验无抵触情绪. 试验前组织被试参加体检,确认无视觉及听觉疾病,且裸视均在 1.3 以上.

驾驶人按照预设的试验路线,完全按照自己的驾驶期望及驾驶习惯,完成自主驾驶试验. 试验完成后,工作人员结合试验录像与试验数据,按照驾驶行为模式分类,截取换道样本. 依据车辆横向位置与方向盘转角在时间序列上的变化趋势,确定换道起始时刻及换道截止时刻<sup>[10]</sup>. 限于篇幅,在此不再赘述.



图 1 驾驶行为采集平台

### 2 意图时窗确定

为预测驾驶人换道行为,必须截取相应换道意图样本,首先要确定意图时窗宽度. Lee 等<sup>[11]</sup>认为驾驶人换道前 8 s 内驾驶人会表现出典型的行为特性,故将之确定为换道意图表征时窗宽. Fitch 等<sup>[12]</sup>通过对比换道前 8 s 与 3 s 内驾驶人的行为特征差异,认为意图时窗应修正为 3 s. 本文提出一种基于后视镜注视特性的换道意图时窗确定方法. 首先预置一个初始时窗宽度为 10 s,确定时窗内驾驶人对后视镜区域(包括内后视镜、左右两侧后视镜)的注视次数为自然数,则将驾驶人首次关注后视镜的时刻距换道起始时刻的时间差确定为该样本的意图时窗. 统计 51 名驾驶人换道样本意图时窗分布,均值约为 4.92 s. 图 2 给出了随机挑取的其中 16 名被试意图时窗的总体分布,且编号 1~16 的驾驶人意图时窗依次为 3.03、3.48、2.49、3.21、2.89、3.74、2.70、3.35、1.96、2.82、2.58、3.11、3.27、4.35、2.48、2.77 s. 依据图 2,除 8 号驾驶人外,其他驾驶人意图时窗的 75 分位数在 5 s 虚线以下,且所有被试意图时窗均值均未溢出 5 s 阈值,故将之确定为最终的换道意图时窗. 这样既不会引起意图数据的流失,也不会引入过多的车道保持数据,影响意图特征指标的提取.

确定意图时窗后,需要提取时窗内车道保持样本与换道意图样本的特征差异. 车道保持样本与换道意图样本均采取试验完成后的离线筛选,其中车道保持样本为跟车、自由行驶等驾驶人没有明显换道意图时,截取 5 s 时窗宽度后得到,而换道意图样本则为从换道起始时刻起向前截取 5 s. 按照以上方法,最终从所有被试的试验中筛选车道保持样本 401 次,意图样本 406 次. 其中各 200 次作为训练样本,其余作为待预测样本.

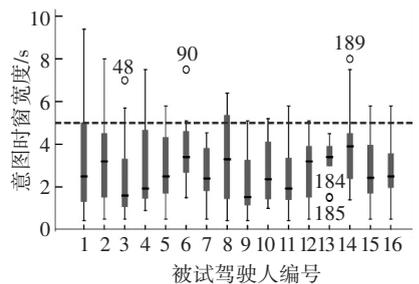


图 2 不同被试换道意图时窗总体分布

### 3 预测指标

换道行为是否发生取决于两个要素,一是驾驶人是否有换道意图,二是目标车辆周围的环境是否具备换道可行性<sup>[10]</sup>. 本研究结合驾驶人换道意图

与换道可行性检测对驾驶人的换道行为进行预测. Doshi 等<sup>[13]</sup>认为相比眼睛运动,头部转动可以更早地体现驾驶人的换道意图. 基于此结论,本文选择以头部水平方向转动角度标准差  $\theta$  来衡量驾驶人的换道意图. 图3为车道保持与换道意图阶段水平转动角度标准差统计结果,车道保持阶段样本多低于  $3^\circ$ ,而意图阶段的对应值则主要分布于  $5^\circ \sim 15^\circ$  之间,且意图阶段该参数的四分位数显著高于车道保持阶段. 此外,转向灯的操作(0—1分类变量为  $S$ ,其中“1”为开启,“0”为未开启)可以作为驾驶人有换道意图的一个指标,但从研究团队试验获取的转向灯操纵数据来看,截止至换道操纵起始时刻,转向灯的开启率仅为 48.4% (见图4),表明单独依靠转向灯识别驾驶人换道意图并不可靠,需要配合其他指标共同使用.

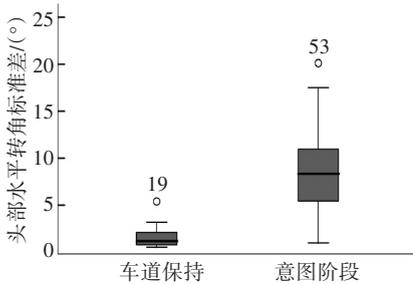


图3 头部水平转动角度标准差

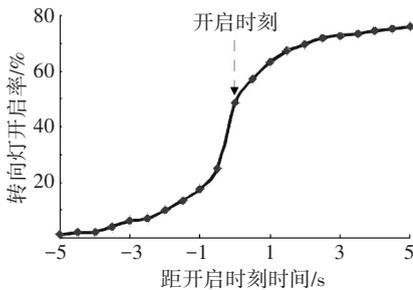


图4 转向灯开启率变化趋势

车辆是否具备车道变换的可能性主要取决于距离及时间两个维度的期望是否可以被满足,即是否具备足够的插车间隙,以及交通冲突时间  $T_{tc}$  值是否足够保证安全. 基于以上分析,可以确定与换道可行性相关的指标主要有自身车速  $V_1$ 、周围目标车辆与自车相对距离(自车与当前车道前车的距离为  $D_1$ ,自车与目标车道后车的距离为  $D_2$ )、交通冲突时间等参数(自车与当前车道前车为冲突时间为  $T_{tc1}$ ,自车与目标车道后车的冲突时间为  $T_{tc2}$ )<sup>[9]</sup>. 综合以上分析可知,最终确定预测指标集合  $P_0 = (V_1, S, D_1, T_{tc1}, D_2, T_{tc2}, \theta)$ .

## 4 BP神经网络模型建立

驾驶人是否执行车道变换,在实际行车过程中

受到众多因素的耦合制约,因此换道行为预测是一个内部机制较为复杂的系统问题. BP神经网络已被广泛证明可以实现任何复杂非线性映射的功能,因此本文尝试基于BP神经网络构建换道行为预测模型.

### 4.1 BP网络设计

#### 4.1.1 网络结构确定

BP网络的输入、输出层的维数是由用户按照自身个性需求确定的. 输入层神经元个数原则上就是特征指标的数量,由构建的预测指标体系可知,输入层的维数为7,输出层维数由预测结果的模式种类确定. 本文预测结果可以分为车道变换和车道保持两类,令  $z = 1$  表示车道变换,  $z = 0$  表示车道保持,故输出层的维数设为1,输出向量以  $T(z)$  表示. 定义在闭区间内的任意一个连续函数都可以用隐含层数为1的BP网络来逼近. 本文采用含有1层隐含层的3层BP网络,输入向量  $P_0 = (V_1, S, D_1, T_{tc1}, D_2, T_{tc2}, \theta)$ ,输出量  $T = T(z)$ ,表1随机给出了几个样本的网络输入输出模式.

3层BP网络隐层神经元数目可基于  $n_2 = 2n_1 + 1$  进行确定. 其中  $n_2$  为隐层神经元数目,  $n_1$  为输入层维数. 由于输入层维数为7,则隐层神经元数目为15.

#### 4.1.2 传递函数

对输入向量进行预处理后,元素值均在0—1之间,因此隐含层神经元传递函数可采用S型正切函数  $\text{tansig}$ . 同样地,鉴于输出模式为0—1方式,输出层神经元传递函数拟采用S型对数函数  $\text{logsig}$ . 运用收敛速度较快的  $\text{trainlm}$  函数进行系统训练,其对应的算法为Levenberg-Marquardt反传算法<sup>[14]</sup>.

表1 网络输入输出模式

样本编号	输入向量	目标输出	类型
1	[64.02, 1, 14.145, 60.4, 30, 25.6, 9.744]	$z = 1$	车道变换
2	[62.94, 0, 16.243, 81.7, 30, 22.5, 2.755]	$z = 0$	车道保持
3	[71.49, 1, 12.255, 62.5, 30, 37.6, 5.792]	$z = 1$	车道变换
4	[64.02, 0, 30, 155.9, 30, 59.9, 4.462]	$z = 0$	车道保持

### 4.2 数据预处理

#### 4.2.1 数据归一化

若输入的原始数据离散度较大,进入网络后较大的测量值会占据神经网络的学习过程,这样便不能反映较小测量值的变化,即较小的数据容易被淹没,从而影响预测精度. 为提高训练效率,需要对测量数据进行归一化处理. 本文采用以下方式对数据进行归一化处理,即

$$y = (y_{\max} - y_{\min})(x - x_{\min}) / (x_{\max} - x_{\min}) + y_{\min}. \tag{2}$$

式中:  $x$  为原始数据,  $y$  为目标数据, 即归一化之后的数据;  $x_{\max}$ 、 $x_{\min}$  分别为采集的原始数据中的最大值和最小值;  $y_{\max}$  和  $y_{\min}$  分别对应数据归一化之后  $y$  的最大值和最小值. 根据本文换道行为预测的特性, 取  $y_{\max} = 1$ ,  $y_{\min} = 0$ .

#### 4.2.2 相对距离 $D$ 和 $T_{tc}$ 的处理

当前车道前方有慢车时诱发车道变换的主要原因. 当两车距离较近时, 此时可基于毫米波雷达的数据获取  $D_1$  值及  $T_{tc1}$  值. 当两车距离超过毫米波雷达有效测量距离, 或者前车速度大于自车时, 为了保证模型的适用性, 需要对相关参数进行空缺赋值. 当效测量范围内不存在前方车辆时, 令  $D_1 = 200$  m,  $T_{tc1} = 60$  s; 当存在前方车辆时,  $D_1$  取实际值, 而  $T_{tc1}$  分以下几种情形: 若自车速度  $V_1$  大于前方车辆速度  $V_2$ , 且  $T_{tc1} \geq 30$  s 时, 令  $T_{tc1} = 30$  s; 若  $T_{tc1} < 30$  s, 取实际值; 若  $V_1 < V_2$ , 则直接令  $T_{tc1} = 30$  s. 自车与目标车道后方车辆的相对距离  $D_2$  和碰撞时间  $T_{tc2}$  采用类似的方法进行处理.

#### 4.3 模型训练及性能检验

模型在训练时, 以  $t_0$  时刻的参数 ( $V_1, S, D_1, T_{tc1}, D_2, T_{tc2}, \theta$ ) 值作为输入向量  $P_0$ . 目标输出量为  $T(z)$ , 对于车道变换,  $T(z) = 1$ , 对于车道保持,  $T(z) = 0$ . 本文选取换道意图与车道保持样本各 200 组作为训练样本. 神经网络的训练是主要是借助 MATLAB 软件进行的, 训练参数设置为: 训练次数 1 000 次, 训练误差目标为 0.01, 学习速率为 0.1.

通过网络训练, 可以不断修正权值和阈值, 使得网络的输出误差达到最小. 进行参数设置后即可开始网络训练. 设计网络经过 9 次训练后, 误差收敛至 0.009 24, 小于训练目标 0.01, 表明模型具有良好的分类性能.

### 5 换道行为预测

BP 网络模型建立完成并检验性能良好以后, 即可基于建立的模型, 对待预测样本进行换道行为预测. 由于网络输出数值是 0~1 之间的小数, 设立对应的切割阈值 (取为 0.5), 即当  $T(z) \geq 0.5$  时, 即认为驾驶人即将执行车道变换; 满足  $T(z) > 0.5$  时, 判定驾驶人即将执行车道保持操作. 通过比较待预测样本中其真实属性与预测属性, 即可以判断出模型预测的精度.

为了比较不同参数对换道行为预测所起作用的差异性, 选取不同的特征指标组合作为输入, 基于学习样本建立 BP 网络模型, 再对待预测样本进行属性识别, 预测结果如表 2 所示. 当输入向量仅有转向灯信号时, 预测精度仅有 30.71%, 而当属于向量

中加入头部水平转角标准差时, 预测精度迅速上升至 70%, 表明头部运动特性对换道行为预测起重要作用. 当输入向量包含所有的特征指标时, 预测精度达到 95.58%, 表明构建的 BP 模型对预测驾驶人的换道行为为具有较强的适用性及信度.

表 2 不同向量组合的预测结果

组合编号	向量元素	准确率/ %
1	[S]	30.71
2	[S, $\theta$ ]	70.02
3	[S, $T_{tc2}$ , $D_2$ , $\theta$ ]	71.99
4	[V, S, $D_1$ , $\theta$ ]	80.59
5	[V, S, $T_{tc1}$ , $T_{tc2}$ ]	86.24
6	[V, S, $T_{tc1}$ , $D_1$ , $T_{tc2}$ , $D_2$ ]	88.70
7	[V, S, $T_{tc1}$ , $\theta$ ]	89.93
8	[V, S, $D_1$ , $T_{tc1}$ , $\theta$ ]	90.66
9	[V, S, $T_{tc1}$ , $T_{tc2}$ , $\theta$ ]	92.38
10	[V, S, $T_{tc1}$ , $D_1$ , $T_{tc2}$ , $D_2$ , $\theta$ ]	95.58

在评价预测模型效能时, 除考虑预测信度外, 还经常评价模型在时轴上的表现效果<sup>[15]</sup>. 在此对换道行为预测的时序特性进行讨论, 而不考虑车道保持行为. 以换道起始点为起始时刻, 以 0.5 s 为固定时窗单位向前滑动, 基于待识别样本换道前 3 s 内各典型时刻向量集 ( $V_1, S, D_1, T_{tc1}, D_2, T_{tc2}, \theta$ ) 对应的各参数值输入建立的预测模型, 最终得到各典型时刻预测精度的变异特性, 如图 5 所示. 图中横轴为距转向灯开启时刻的时间, -3~0 表示换道前 3 s 至换道起始点的各典型时刻. 在换道前 3 s 时刻, 模型预测精度约为 58%. 随着时间推移, 预测精度迅速提高, 至换道前 1.5 s 时刻, 预测精度上升至 85.44%, 换道前 1 s 时刻, 提高至 88.83%. 截止至换道起始时刻, 预测精度最终达到 95.58%. 如果以 85% 作为判定预测效度的阈值, 可以认为构建的 BP 模型至少可以保证在换道前 1.5 s 时刻精确预测出驾驶人的换道行为. 与文献[3]相比, 不仅预测精度更高, 而且具有显著的时序特性优势.

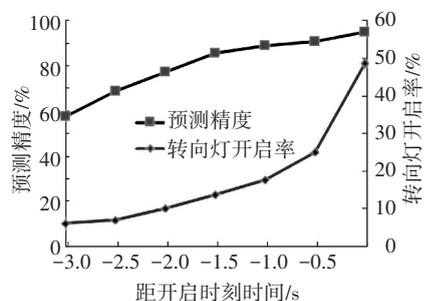


图 5 预测时序特性

## 6 结 论

1) 依据驾驶人换道前对后视镜区域的注视特性,换道意图时窗确定为 5 s,该方法避免了因主观确定意图时窗所引发的数据缺失或紊乱。

2) 结合驾驶人视觉搜索特性、车辆运动状态及驾驶环境等特征参数,可以有效预测驾驶人的换道行为。

3) 基于构建的 BP 神经网络模型,可以至少提前 1.5 s 预测驾驶人的换道行为,预测精度达到 95.58%,研究结论可为换道辅助系统的改进奠定一定的理论基础。

## 参考文献

- [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[R]. 北京:公安部交通管理局,2013.
- [2] MCGALL J C, WIPF D P, TRIVEDI M M, et al. Lane change intent analysis using robust operators and sparse Bayesian learning [J]. IEEE Intelligent Transportation Systems, 2007, 8(3): 431-440.
- [3] LIU A, PENTLAND A. Towards real-time recognition of driver intentions [C]//Intelligent Transportation System. Boston: IEEE, 1997: 236-241.
- [4] NISHIWAKI Y, MIYAJIMA C, KITAOKA N. Generating lane-change trajectories of individual drivers [C]// Proceedings of the IEEE International Conference on Vehicular Electronics and Safety. Columbus Ohio: IEEE, 2008: 271-275.
- [5] TOLEDO-MOREO R, ZAMORA-LZQUIERDO M A. IMM-based lane-change prediction in highways with low-cost GPS/INS [J]. IEEE Transactions on Intelligent Transportation Systems, 2009, 10(1): 180-185.

- [6] SALVUCCI D D, LIU A. The time course of a lane change: driver control and eye-movement behavior [J]. Transportation Research Part F: Traffic Psychology and Behaviour, 2002, 5(2): 123-132.
- [7] SALVUCCI D D, MANDALIA H M, KUGE N, et al. Lane-change detection using a computational driver model [J]. Human Factors, 2007, 49(3): 532-542.
- [8] 彭金栓,付锐,郭应时. 驾驶人车道变换决策机制及视觉特性分析[J]. 中国安全科学学报, 2013, 23(2): 34-38.
- [9] PENG Jinshuan, GUO Yingshi, SHAO Yiming. Lane change analysis based on drivers' perception-judgment and game theory[J]. Applied Mechanics and Materials, 2013, 361-363: 1875-1879.
- [10] 彭金栓,付锐,郭应时,等. 基于驾驶人视觉特性的换道意图识别方法[J]. 武汉理工大学学报, 2013, 35(3): 73-79.
- [11] LEE S E, OLSEN E C B, WIERWILLE W W. A comprehensive examination of naturalistic lane-changes [R]. Virginia: Virginia Tech Transportation Institute, 2004.
- [12] FITCH G M, LEE S E, KLAUER S. Analysis of lane-change crashes and near-crashes [R]. Virginia: Virginia Tech Transportation Institute, 2009.
- [13] DOSHI A, MORRIS B T, TRIVEDI M M. On-road prediction of driver's intent with multimodal sensory cues [J]. IEEE Pervasive Computing, 2011, 10(3): 22-34.
- [14] XIAO Zhi, YE Shijie, ZHONG Bo, et al. BP neural network with rough set for short term load forecasting [J]. Expert Systems with Applications, 2009, 36(1): 273-279.
- [15] 李冀,莫蓉,孙惠斌. 基于复杂网络的产品服务系统评价[J]. 计算机集成制造技术, 2013, 19(9): 2355-2363.

(编辑 魏希柱)