

基于灰色神经网络的车辆跟驰模型研究

蒋华涛^{2,3}, 常琳¹, 娄玉强^{2,3}, 李庆^{1,2}, 陈大鹏^{1,2,3}

(1 中国科学院微电子研究所, 北京 100029; 2 中国科学院物联网研究发展中心, 江苏 无锡 214135;

3 中国科学院大学, 北京 100049)

摘 要: 在传统的基于最小安全距离的车辆跟驰模型基础上, 把灰色模型与神经网络模型结合起来, 利用采集的车辆速度信息预测前车未来车速, 提前预知前车制动迹象, 使自车能在前车制动前减速, 有效减少了制动距离对自车司机反应时间的依赖. 最后通过 MATLAB /Simulink 以及 Carsim 软件进行联合仿真, 验证了本文所述模型的有效性.

关键词: 跟驰模型; 反应时间; 制动距离; 灰色神经网络; MATLAB /Simulink

中图分类号: TP391.9

文献标识码: A

文章编号: 1000—7180(2018)02—0122—06

Research on Car-following Model Based on Grey Neural Network

JIANG Hua-tao^{2,3}, CHANG Lin¹, LOU Yu-qiang^{2,3}, LI Qing^{1,2}, CHEN Da-peng^{1,2,3}

(1 Institute of Microelectronics of Chinese Academy of Sciences, Beijing 10029, China;

2 CAS R&D Center For Internet of Things, Wuxi 214135, China;

3 University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: In this paper, the grey model and neural network model are combined on the basis of the traditional car-following model based on the minimum safe distance, the local vehicle using the collected vehicle speed information to predict the front vehicle speed and perceived front car will brake earlier. so, the local car can slow down before the front car, so driver reaction time has little effect on braking distance. MATLAB /Simulink and Carsim will be used to build model to verify the effectiveness of the model in this paper.

Key words: car-following model; reaction time; braking distance; Grey Neural Network; MATLAB /Simulink

1 引言

在目前已有的车辆跟驰模型中, 传统方法为基于安全距离的跟驰模型, 考虑了驾驶员反应时间的影响, 但在如何消除反应时间影响方面的研究较少.

近年来, 许多学者将车速预测引入车辆跟驰模型, 试图更精确地反应道路真实情况. 在利用神经网络进行预测车速方面, 文献[1]首先对历史车速进行处理分析, 建立车辆不同行驶状态下的 BP 神经网络模型, 然后又用遗传算法对该模型进行优化, 预测未来时刻车速状况; 这种模型的不足之处是对数据量的需求较大. 在基于卡尔曼模型进行速度预测方

面, 文献[2]利用车流密度作为状态变量、车速作为观测变量, 首先创建了非线性的交通状况预测模型, 然后通过引入卡尔曼滤波理论来解决非线性模型中存在的多步预测问题, 并利用实例对所建立的模型进行了验证. 但是卡尔曼模型的不足之处在于参数的选择和计算比较复杂. 在灰色预测方面, 文献[3]中说明了相对于其他的模型而言, 灰色预测模型具有建模时不但所需数据量少而且能保证信息的“新鲜”性的优点, 特别适合应用于实时的控制系统.

本文在传统的基于安全距离车辆跟驰模型基础上, 结合灰色神经网络模型来预测前车下一阶段的速度状况, 从而提前预测到前车的制动迹象, 使得后

车在前车制动前提前制动,从而有效消除后车驾驶员反应时间对制动距离的影响.

2 基于灰色神经网络的安全距离模型

2.1 安全距离模型^[4]

汽车跟驰过程中安全距离模型是根据车间距离、自车和前车行驶距离进行决策,该模型由三部分构成,即:自车刹车距离 X_1 、前后两车之间的间距 d 和前车行驶的距离 X_2 . 若要保证车辆安全行驶,则应使: $X_1 + d_0 < X_2 + d$ 成立. d_0 为两车之间所要保持的安全距离,一般值为 $2 \sim 5$ m.

由以上安全距离模型可以得出,车间安全距离由自车的速度、加速度和前方车辆的速度、加速度决定.

2.2 灰色神经网络模型

灰色神经网络(grey neural network, GNN)在灰色理论中引入了神经网络的思想,通过网络反馈的形式不断对系统进行学习. 该模型在汽车行驶过程中,后车不断更新所采集的数据从而重新训练 GNN 模型,使得此模型具有对车速进行实时预测的功能.

2.2.1 GNN 模型建立

灰色模型首先进行数据的采集,然后将得到的数据进行累加,使得累加之后的结果具有某种规律然后用特定曲线来拟合该结果.

时间序列:

$$X_{(n)}^{(0)} = \{X_{(1)}^{(0)}, X_{(2)}^{(0)}, \dots, X_{(k)}^{(0)}, \dots, X_{(N)}^{(0)}\},$$

$$k \in 1, 2, \dots, N;$$

对 $X_{(n)}^{(0)}$ 做一次累加得到新的数据序列 $X_{(n)}^{(1)}$, 即:

$$X_{(n)}^{(1)} = \{X_{(1)}^{(1)}, X_{(2)}^{(1)}, \dots, X_{(k)}^{(1)}, \dots, X_{(N)}^{(1)}\}, \text{ 其中}$$

$$X_{(k)}^{(1)} = \sum_{j=1}^k X_{(j)}^{(0)}, j = 1, 2, \dots, k.$$

根据所得到的新的序列建立白化方程(即一阶单变量的线性微分方程) $\frac{dX_{(n)}^{(1)}}{dt} + aX_{(n)}^{(1)} = u$, 式中 a 为发展系数, u 为灰色作用量, 求解该微分方程, 得出解为

$$\hat{X}_{k+1}^{(1)} = [X_1^{(0)} - \frac{u}{a}]e^{-ak} + \frac{u}{a}$$

$\hat{X}_{k+1}^{(1)}$ 为序列 $X_{k+1}^{(1)}$ 序列的估计值, 对 $\hat{X}_{k+1}^{(1)}$ 做一次累减得到原始序列的估计值为 $\hat{X}_{k+1}^{(0)} = \hat{X}_{k+1}^{(1)} - \hat{X}_k^{(1)}$.

以上建模分析便是传统的灰色模型预测数据序列的基本步骤, 本文将神经网络与传统灰色模型进行结合, 使传统灰色模型的预测结果更加准确, 更能

实现实时预测功能, 且适应性大大增强.

对一个不确定的系统进行预测时, 该不确定系统特征值原始序列为 $x_i^{(0)} (t = 0, 1, 2, \dots, N-1)$, 将此序列做累加运算后所得的序列 $x_i^{(1)}$ 为指数增长规律, 所以不妨用微分方程来模拟该序列. 该灰色神经网络模型中的符号说明如下: 把原始序列 $x_i^{(0)}$ 设为 $x(t)$, 经过累加后得到的序列 $x_i^{(1)}$ 设为 $y(t)$, 预测结果 $\hat{x}_i^{(1)}$ 设为 $z(t)$, 则有 n 个输入 1 个输出的 GNN 模型所对应的微分方程可以表示为

$$\frac{dy_1}{dt} + ay_1 = b_1y_2 + b_2y_3 + \dots + b_{n-1}y_n$$

式中, $y_2, \dots, y_n$ 为输入变量, y_1 为输出变量, $a, b_1, b_2, \dots, b_{n-1}$ 为微分方程系数. 则上述方程的时间响应为

$$z(t) = ((y_1(0) - d) - y_1(0) \cdot \frac{1}{1 + e^{-at}} + 2d \cdot \frac{1}{1 + e^{-at}}) \cdot (1 + e^{-at})$$

$$\text{其中, } d = \frac{b_1}{a}y_2(t) + \frac{b_2}{a}y_3(t) + \dots + \frac{b_{n-1}}{a}y_n(t)$$

由响应 $z(t)$ 得到的神经网络结构如图 1 所示.




图1 GNN 结构图

在以上的结构中, t 为输入的变量序号, $y_2(t), \dots, y_n(t)$ 为网络输入变量, $w_{21}, w_{22}, \dots, w_{2n}, w_{31}, w_{32}, \dots, w_{3n}$ 为网络权重, y_1 为预测结果, LA, LB, LC, LD 为 GNN 模型的四层.

GNN 模型训练步骤如下^[5]:

① 初始化 GNN 模型的网络结构, 初始化参数 a, b , 并计算 u

$$u_1 = \frac{2b_1}{a}, u_2 = \frac{2b_2}{a}, \dots, u_{n-1} = \frac{2b_{n-1}}{a}$$

② 由网络权重的定义得到

$$w_{21}, w_{22}, \dots, w_{2n}, w_{31}, w_{32}, \dots, w_{3n}$$

$$w_{11} = a, w_{21} = -y_1(0), w_{22} = u_1, w_{23} = u_2, \dots,$$

$$w_{2n} = u_{n-1}$$

$$w_{31} = w_{32} = \dots = w_{3n} = 1 + e^{-at}$$

$$\theta = (1 - e^{-at})(d - y_1(0))$$

③ 对每一个输入序列 $(t, y(t)), t = 1, 2, 3, \dots, N$ 计算每层的输出

LA 层: $a = \omega_{11}t$;

LB 层: $b = f(\omega_{11}t) = \frac{1}{1 + e^{-\omega_{11}t}}$

LC 层:

$c_1 = b\omega_{21}, c_2 = y_2(t)b\omega_{22}, \dots, c_n = y_n(t)b\omega_{2n}$

LD 层:

$d = \omega_{31}c_1 + \omega_{32}c_2 + \dots + \omega_{3n}c_n - \theta_{y1}$

④ 计算模型预测值与期望得到的值之间的误差,由此误差来更新权重和阈值

LD 层误差:

$\delta = d - y_1(t)$

LC 层误差:

$\delta_1 = \delta(1 + e^{-\omega_{11}t}), \delta_2 = \delta(1 + e^{-\omega_{11}t}), \dots,$

$\delta_n = \delta(1 + e^{-\omega_{11}t})$

LB 层误差:

$$\delta_{n+1} = \frac{1}{1 + e^{-\omega_{11}t}}(1 - \frac{1}{1 + e^{-\omega_{11}t}})(\omega_{21}\delta_1 + \omega_{22}\delta_2 + \dots + \omega_{2n}\delta_n)$$

根据预测误差调整权值:

调整 LB 到 LC 的连接权值, $\omega_{21} = -y_1(0), \omega_{22} = \omega_{22} - \mu_1\delta_2b, \dots, \omega_{2n} = \omega_{2n} - \mu_{n-1}\delta_nb$

调整 LA 到 LB 的连接权值, $\omega_{11} = \omega_{11} + at\delta_{n+1}$

调整阈值:

$$\theta = (1 + e^{-\omega_{11}t})(\frac{\omega_{22}}{2}y_2(t) + \frac{\omega_{23}}{2}y_3(t) + \dots + \frac{\omega_{2n}}{2}y_n(t) - y_1(0))$$

⑤ 判断训练是否结束,若否,则返回 ③

2.2.2 GNN 模型训练

近年来,车联网的发展为保证行车安全、提高出行效率提供了良好的数据支撑. 本文训练 GNN 模型数据通过车车通信获得,后车采集到前车的速度之后,作为训练数据,对以上建立的 GNN 模型进行训练,训练好模型之后,便可以预测前车未来时刻的速度变化情况.

本文利用美国 Cohda Wireless 公司生产的 MK5 车载通信设备来采集车速信息,采集的车速用于训练所建立的神经网络. 此 MK5 在 1 秒钟采集 10 个车速数据,为了减少数据量,从一秒钟十个车速中选取一个具有代表性的车速. 本文中利用的是前车 1 分钟内的速度信息(60 个),然后将采集的这些速度数据进行分析处理,最后用处理后的数据训练 GNN 模型,从而预测出前方车辆在将来 6 个时

刻的车速情况. 在前车行驶过程中,后车不断更新所采集的数据从而重新训练 GNN 模型,使得此模型具有对车速进行实时预测的功能.

本文采用的训练方式为,利用输入的 5 个车速信息来预测出未来 1 个时刻的车速状况. 因此,若要实现一次得到未来 6 个时刻的车速(6 个速度可以反映车速变化),则最终需要调用 6 个 GNN 模型,这六个模型分别预测出未来第 1~6 时刻相应的车速状况.

因此为了实现每个模型输入 5 个初速后输出一个预测车速的效果,对采集到 1 min 内的 60 个的数据做如下处理:将 60 个车速从 1~60 编号,按表 1 的方式提取相应编号所对应的车速.

表 1 车速数据处理

组号	前 5 个车速	v_1	v_2	v_3	v_4	v_5	v_6
1	1-2-3-4-5	6	7	8	9	10	11
2	2-3-4-5-6	7	8	9	10	11	12
...	...	...	...	...	...	...	...
49	49-50-51-52-53	54	55	56	57	58	59
50	50-51-52-53-54	55	56	57	58	59	60

表 1 中 $v_1 \sim v_6$ 中的编号车速是与前 5 个车速对应的 6 个子模型预测的速度,即输入 5 个车速, M1 预测出 v_1 , M2 预测出 $v_2 \dots$ M6 预测出 v_6 . 对于第一个模型 M1,本文用前 30 组数据训练,用 31~36 组数据做验证,其余的 5 个模型按此思路进行训练预测,得到的预测结果,如图 2~7 所示.




图 2 M1 模型预测结果

根据上述模型预测出的结果可以说明, GNN 模型利用少量数据能够比较准确的拟合出未来 6 个时刻车速的变化情况,提前提醒驾驶员采取相应动作.




图 3 M2 模型预测结果




图 6 M5 模型预测




图 4 M3 模型预测结果




图 7 M6 模型预测




图 5 M4 模型预测

与传统的灰色模型相比,本模型综合了灰色模型所需数据量少、操作简单以及神经网络容错能力强,自适应能力强等优点,这样得到的 GNN 模型有所需要的样本数据量少,原理比较简单并且预测

精度在短期内比较精确的特点. 同时克服了单一灰色模型预测结果波动大的缺点.

3 灰色神经网络下的制动模型分析

通过上一部分可知,本文所采用的灰色神经网络模型能够比较准确的拟合出未来时刻前车的速度状况,从而使得后车在预测到前车即将制动前提前制动,减轻了对驾驶员反应时间的要求.

在此灰色神经网络模型之下,从前车制动开始时刻把前后辆车看成一个系统,则在此系统中,由于后车提前制动,相对于前车而言后车一开始就开始做减速运动,从而忽略了传统制动模型中前车制动时后车要先做匀速运动的阶段(匀速运动阶段为后车驾驶员的反应时间),所以说在本文的系统中,从后车角度分析,后车所经历的阶段为减速度线性增长阶段和持续刹车阶段. 后车整个制动过程中速度与加速度变化曲线如图 8 和图 9 所示.




图 8 后车制动过程中速度变化曲线




图 9 后车制动过程中加速度变化曲线

图 8 与图 9 中 t_p 时间段所对应的虚线部分为提前预测时段后车速度和加速度的变化情况;其余实线部分为前车制动开始对应的后车速度和加速度变化情况。

3.1 减速度线性增长阶段

由于后车提前预测到前车将会制动,所以后车将先于前车制动,当前车制动时,后车已经制动且减速度线性增长(即忽略传统模型后车匀速运动部分),假设后车制动到前车制动这段时间为 t_p ,后车最大的减速度为 $a_{\max}$,后车初始的速度为 v_a ,前车开始制动到后车减速度线性增长至最大的时间为 t_1 ;先计算前车开始制动时,后车经过制动时间 t_p 所达到的速度(由于后车在预测后提前刹车,预测时间远远大于驾驶员反应时间,所以在此忽略驾驶员的反应时间),由于减速度基本是线性的,利用下式假设

$$\frac{dv}{dt} = kt, k = \frac{a_{\max}}{t_1 + t_p}, \text{后车初速度为 } v = v_a.$$

因此,前车制动时后车的速度为: $v_0 = v_a - \int$

$$\frac{a_{\max}}{t_p + t_1} t dt = v_a - \frac{a_{\max}}{2(t_p + t_1)} t^2, \text{ 即 } v_0 = v_a -$$

$$\frac{a_{\max}}{2(t_p + t_1)} t_p^2; \text{从前车制动开始到后车减速度到达最}$$

大的 t_1 时间内,后车的速度表达式为 $v = v_0 - \int$

$$\frac{a_{\max}}{t_p + t_1} t dt = v_a - \frac{a_{\max}}{2(t_p + t_1)} t_p^2 - \frac{a_{\max}}{2(t_p + t_1)} t^2$$

在减速度持续增长时间段 t_1 内,后车的位移为

$$S_1 = \int_{t_0}^{t_1} (v_a - \frac{a_{\max}}{2(t_p + t_1)} t_p^2 - \frac{a_{\max}}{2(t_p + t_1)} t^2) dt = (v_a - \frac{a_{\max}}{2(t_p + t_1)} t_p^2) t_1 - \frac{a_{\max}}{6(t_p + t_1)} t_1^3$$

3.2 持续制动阶段

持续制动阶段可以分为两部分,即保持最大加速度不变进行制动阶段和加速度调整以适应前车加速度阶段.假设后车在时间段 t_2 内保持最大加速度制动,初速度为 v_1 ;时间段 t_3 内进行加速度调整,此时间段后车初速度为 v_2 .则在时间段 t_2 内,后车运动的距离为

$$s_{21} = v_1 t_2 - \frac{1}{2} a_{\max} t_2^2,$$

$$\text{式中, } v_1 = v_a - \frac{a_{\max}}{2(t_p + t_1)} t_p^2 - \frac{a_{\max}}{2(t_p + t_1)} t_1^2.$$

在时间段 t_3 内,后车运动的距离为 $s_{22} = v_2 t_3 + \frac{a_{\max} - a_t}{6} t_3^2$, 式中, $v_2 = v_1 - a_{\max} t_2$;

综上,持续制动阶段后车走过的距离为: $S_2 = s_{21} + s_{22}$.

因此,后车在减速度线性增长阶段和持续制动阶段运动的距离为

$$X_1 = S_1 + S_2.$$

3.3 前车制动期间运行的距离

车联网环境下,后车不断采集前车运动信息,能够比较准确的计算出前车下一时刻的运动距离 $X_2 = v_1 t + \frac{1}{2} a_t t^2$, 其中 $t = t_1 + t_2 + t_3$.

本文中假设前车的减速度保持恒定.

最后,由安全距离模型

$$X_1 + d_0 < X_2 + d$$

求得安全距离 $d = X_1 - X_2 + d_0$,之后由此式建立模型验证.

4 基于灰色神经网络的车辆跟驰模型实现方法

4.1 系统设计思路

首先通过车车通信获取前车状态信息,然后对所获得数据进行处理作为建立的 GNN 模型的训练数据,模型训练完毕之后,利用最新的前车速度信息输入到训练好的模型中预测未来时刻前车的速度变

化趋势;若预测到前车将会制动,则利用本文改进的制动模型进行相关安全距离的计算. 该系统的实现框图如图 10 所示.




图 10 系统结构框图

4.2 模型仿真验证

对上述分析的制动模型进行验证并与传统制动模型比较. 首先在 carsim 中设置车辆模型的参数,之后通过 carsim 和 Matlab/Simulink 对上文中建立的模型进行仿真,对前方避撞安全距离进行模拟. 在此仿真中假设驾驶员不做转向操作,只进行纵向制动.

建立模型时,后车速度设定为 60~120 km/h 线性增长,前车速度设定为 45~100 km/h 线性增长,仿真时间设定为 20 s. 其他所用到的参数如表 2 所示.

表 2 模型参数设置

新模型		传统模型	
t_p	4 s	反应时间	0.8 s
t_1	1 s	持续减速时间	0.2 s
t_2	2 s	匀减速时间	2 s
t_3	2 s	加速度调整时间	2 s
$a_{\max}$	10 m/s ²	$a_{\max}$	10 m/s ²
a_t	5 m/s ²	a_t	5 m/s ²
d_0	5 m	d_0	5 m

按表 2 中的参数在 simulink 中建立传统模型和本文改进的模型进行仿真验证,得到的安全距离变化如图 11 所示.

图 11 中实线为传统模型,虚线为本文改进后的模型,可以看出,本文改进后的模型较传统的模型在

安全距离上有了较大的减小;即相比传统模型,基于灰色神经网络的制动模型更能在较小的安全距离下实现比较好的制动效果,从而防止追尾等事件;此外车间安全距离的减小,优化了车间间距,提高了道路的利用率,并且该模型提前预知前车制动趋势,也使得后车有充足的时间来进行减速,从而避免了紧急刹车,提高了驾驶员的舒适度.




图 11 模型仿真结果

5 结束语

本文利用灰色神经网络来预测前车未来的速度状况,从而提前告知后车前车即将制动,使后车提前于前车刹车,大大减小了制动距离对驾驶员反应时间的依赖;基于本模型,本文对传统的制动模型进行了改进,即有了提前预测前车状况部分便可以忽略驾驶员反应时间,经过逻辑推导以及搭建 Matlab/Simulink 联合仿真模型,证明了改进后的模型较传统模型使得刹车安全距离得到减小,从而优化了车间间距,提高了道路利用率.

参考文献:

[1] 谢浩. 基于 BP 神经网络及其优化算法的汽车车速预测[D]. 重庆:重庆大学, 2014.

[2] 朱琳. 城市快速路交通态势评估理论与方法研究[D]. 北京:北京交通大学, 2013.

[3] 肖聚亮, 王国栋, 阎祥安, 等. 变步长灰色预测模糊控制研究与应用[J]. 天津大学学报, 2007, 40(7): 859-863.

[4] 孔金生, 郭非, 王希萍. 基于安全距离模型的汽车防追尾避撞方法[J]. 微计算机信息, 2008, 24(32): 251-252.

[5] 杨盼盼. 汽车未来行驶车速预测[D]. 重庆:重庆大学, 2015.

TSemSim 算法有更好的 F 值.




图 3 应用于法院判决文本上的
聚类结果在 F-度量值上比较

5 结束语

本文提出一种基于主题模型的法院文本典型案例推荐模型,在模型中不仅能有效降低文本模型的维度,还考虑到了文本隐含语义信息以及采用多粒度特征来表示文本,有效避免粒度太细造成的稀疏性.最后从相似度最大的文本中利用基于正则和加权的方法,根据法院文本中判决年限和对应刑法给出推荐.实验结果表明,本文提出的基于主题模型的文本相似度计算方法跟传统的方法相比能够取得更好的 F 值.

参考文献:

[1] 李素建. 基于语义计算的语句相关度研究[J]. 计算机工程与应用, 2002, 38(7): 75-76.

[2] 詹志建, 杨小平. 基于语言网络和语义信息的文本相似度计算[J]. 计算机工程与应用, 2014 (5): 33-38.

[3] 张永安. 审判案例自动抽取与标注模型研究[J]. 现代图书情报技术, 2013 (6): 23-29.

[4] Blei D M, Ng A Y, Jordan M I. Latent dirichlet allo-

cation[J]. Journal of machine Learning research, 2003, 3(Jan): 993-1022.

[5] Si X, Liu Z, Li P, et al. Content-based and Graph-based Tag Suggestion [C]//DC @ PKDD/ECML. 2009.

[6] Wilson A T, Chew P A. Term weighting schemes for latent dirichlet allocation[C]//human language technologies: The 2010 annual conference of the North American Chapter of Association for Computational Linguistics. Association for Computational Linguistics, 2010: 465-473.

[7] Iwata T, Yamada T, Ueda N. Modeling social annotation data with content relevance using a topic model [C]//Advances in Neural Information Processing Systems. 2009: 835-843.

[8] 黄承慧, 印鉴, 侯昉. 一种结合词项语义信息和 TF-IDF 方法的文本相似度量方法[J]. 计算机学报, 2011, 34(5): 856-864.

[9] Kashyap A, Han L, Yus R, et al. Robust semantic text similarity using LSA, machine learning, and linguistic resources[J]. Language Resources and Evaluation, 2016, 50(1): 125-161.

[10] Wang F, Xu T, Tang T, et al. Bilevel feature extraction-based text mining for fault diagnosis of railway systems[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(1): 49-58.

作者简介:

吕 斌 男,(1973-),硕士,副高级工程师,研究方向为信息法律知识认知技术和法律知识图谱构建.
E-mail: lb@thunisoft.com.

侯伟亮 男,(1984-),学士,研究方向为以大数据为中心的多元诉讼服务技术和产品开发.

(上接第 127 页)

[6] Song J, Wu Y, Xu Z, et al. Research on car-following model based on SUMO[C]// IEEE, InternationalConference on Advanced Infocomm Technology. Hangzhou, China, IEEE, 2014:47-55.

作者简介:

蒋华涛 男,(1991-),硕士研究生.研究方向为汽车电子和车联网.

常 琳 女,(1983-),博士,副研究员.研究方向为汽车电子和车联网.

娄玉强 男,(1991-),硕士研究生.研究方向为机器学习与图像处理.

李 庆(通讯作者) 男,(1972-),博士,研究员.研究方向为汽车电子和车联网. E-mail:liqing@ime.ac.cn.

陈大鹏 男,(1968-),博士,研究员.研究方向为汽车电子和车联网.