

基于智能驾驶员模型算法的长期跟车车速预测研究*

缴文政 孙志强 付景顺 孙凤

(沈阳工业大学, 沈阳 110870)

【摘要】针对新能源汽车能量管理中难以长期、精准地预测车速的问题,提出了一种基于模型的参数化车速预测方法,利用传感器和GPS提供的前瞻数据预测车辆的速度轨迹。首先根据整车动力学和车辆停车转弯趋势建立基于智能驾驶员模型(IDM)的车速预测算法;然后,从NGSIM公开数据集中筛选数据用于参数标定及仿真;最后,利用遗传算法(GA)对算法参数进行标定。仿真验证结果表明,优化后的车速预测算法在通畅或拥堵的交通环境中,对于长期车速预测均有较高的精度,误差可控制在8%~13%范围内。

关键词: 车速预测算法 智能驾驶员模型 NGSIM 遗传算法 参数标定

中图分类号:U469.72 文献标识码:A DOI: 10.19620/j.cnki.1000-3703.20220992

Research on Long-Term Vehicle Following Speed Prediction Based on IDM Algorithm

Jiao Wenzheng, Sun Zhiqiang, Fu Jingshun, Sun Feng

(Shenyang University of Technology, Shenyang 110870)

【Abstract】For the energy management of new energy vehicles, it is difficult to predict the vehicle speed in a long-term and accurate way, this paper proposed a model-based parametric prediction method to predict the vehicle speed trajectory using the forward-looking data provided by sensors and GPS. Firstly, the speed prediction algorithm based on Intelligent Driver Model (IDM) was established in term of vehicle dynamics and vehicle stop-turn trend; secondly, data was selected from the NGSIM public data set for parameter calibration and simulation; then the algorithm parameters were calibrated using Genetic Algorithm (GA). The results show that the optimized speed prediction algorithm has high accuracy for long-term speed prediction in both unobstructed and congested traffic environments, the error can be controlled in the range of 8%~13%.

Key words: Vehicle speed prediction algorithm, Intelligent Driver Model (IDM), NGSIM, Genetic Algorithm (GA), Parameter calibration

【引用格式】缴文政,孙志强,付景顺,等.基于智能驾驶员模型算法的长期跟车车速预测研究[J].汽车技术,2023(9):27-34.

JIAO W Z, SUN Z Q, FU J S, et al. Research on Long-Term Vehicle Following Speed Prediction Based on IDM Algorithm [J]. Automobile Technology, 2023(9): 27-34.

1 前言

当前,车速预测算法总体分为随机型车速预测算法和确定型车速预测算法^[1]。基于马尔可夫链(Markov Chain, MC)的算法是具有代表性的随机型车速预测算法^[2-6]。虽然通过建立多级马尔可夫链模型能够提升车速预测的准确性,但会导致算法体量呈指数级增长。

确定型车速预测算法可分为参数型车速预测算法

和非参数型车速预测算法^[7]。基于非参数型车速预测算法的研究已经得到了广泛的应用;支持向量机(Support Vector Machine, SVM)主要用于在较短的时间间隔内预测车速^[8-9];神经网络可用于数据驱动型算法^[10],其因良好的非线性映射能力、较强的鲁棒性,已广泛应用于车速预测领域^[11-15],但这种方法依赖大量的训练数据。

基于参数型车速预测的算法中,Rezaei等人^[16]使用自回归移动平均(Autoregressive Moving Average,

*基金项目:国家自然科学基金项目(52005345);国家重点研发计划项目(2020YFC2006701);辽宁省“揭榜挂帅”科技重大专项(2022JH1/10400027)。

通讯作者:孙志强(1990—)男,蒙古族,讲师,博士,研究方向为新能源汽车动力学控制及能量管理,sun-zhiqiang@sut.edu.cn。

ARMA)模型,其参数通过历史数据确定,但随着视距增加,该模型会出现预测精度下降的问题;Kesting 等人^[17]利用一种新的恒定加速度启发式(Constant-Acceleration Heuristic, CAH)算法对智能驾驶员模型(Intelligent Driver Model, IDM)进行扩展;Li 等人^[18]针对驾驶员的参数校准提出了一种新的方法;James 等人^[19]对比了校准驾驶员模型中常用的8种方法,证明IDM有较高的车速预测性能。

预测精度和速度往往无法兼顾。Lefevre 等人^[20]比较了参数型和非参数型车速预测算法,在相同的试验环境和试验条件下,非参数模型的表现优于参数模型,然而对于长期预测,选取先进的参数模型更为合适。这主要是由于IDM等参数模型都被设计为具有约束车辆长期行为的稳定性特性,而非参数模型仅被训练为表示2个时间步之间目标车辆的行为。

新能源汽车的能量管理策略需要精确的车速预测作为前置条件。本文以车辆自身的速度轨迹预测为主要研究对象,以GPS、离线地图数据库、前视测距传感器为信息源,建立基于智能驾驶员模型的车速预测算法。

2 IDM算法建模

受车辆、驾驶员等多重因素的影响,理论上满足约束条件车速预测的解无穷多。为了计算出单一的速度轨迹,以更精确地预测车速,假设驾驶员对外部交通环境的反应遵循一套通用的规则。虽然相对于实际驾驶员的驾驶行为进行了很大程度的简化,但许多驾驶员模型在此基础上都能够很好地反映实际驾驶员的驾驶行为。

2.1 智能驾驶员模型

Treiber 等人^[21]最早提出智能驾驶员模型。IDM的参数都具有明确的物理意义,可以直观地展示驾驶行为的变化情况,并且该模型可以同时适用于通畅与拥堵状态下的车速预测^[20]:

$$\frac{dV}{dt} = \alpha \left[1 - \left(\frac{V}{V_0} \right)^\delta - \left(\frac{S_{\min}}{S_L} \right)^2 \right] \quad (1)$$

$$S_{\min} = S_0 + VT_{\text{gap}} + \frac{V(V - V_L)}{2\sqrt{\alpha\beta}} \quad (2)$$

式中, S_0 为拥堵状态的最小车距; S_{\min} 为期望最小车距; T_{gap} 为最小安全车头时距; α 为最大加速度; β 为期望减速度; V 为主车车速; V_0 为当前环境期望车速; V_L 为前车的速度; S_L 为主车与前车的距离。

该算法由加速策略和减速策略2个部分组成:加速策略为 $V_{\text{acc}}(V) = \alpha[1 - (V/V_0)^\delta]$,其中 δ 为驾驶员加速度指数;减速策略为 $V_{\text{brake}}(S_{\min}, V, S_L) = -\alpha(S_{\min}/S_L)^2$,当主车和前车的

距离与期望的安全间距接近时, S_{\min} 开始发挥作用。主车加速行为由期望速度 V_0 、最大加速度 α 和驾驶员加速度指数 δ 体现,当 $\delta=1$ 时,加速度随车速线性下降,当 $\delta \rightarrow \infty$ 时加速度恒定。有效的最小车距 S_{\min} 由最小车距 S_0 (仅与低速有关)、与速度相关的距离 VT_{gap} (对应于以恒定的期望时间间隔 T_{gap} 跟随前车)和与前车的动态车速差 $(V-V_L)$ 决定。

为提高IDM的车速预测精度,需要足够多可供预测的输入数据。本文通过考虑3个方面将不同类型的输入数据集成到改进的智能驾驶员模型中:

- 加速度极限 α_{\max} ,用于模拟车辆动力系统提供牵引力的能力;
- 速度限制 V_{lim} ,用于整合交通环境的速度限制、停车和转弯;
- 最小车距 S_0 、行车时距 T_{gap} 、驾驶员加速度指数 δ 、驾驶员减速度指数 β 及法定限速的驾驶员偏差系数 γ ,用于参数化表示驾驶员行为。

本文使用改进的驾驶员行为模型实现基于模型的速度预测,IDM的输入分别为 V_{lim} 、 V_L 和 S_L ,考虑到车速预测过程中驾驶员的减速行为直接影响预测精度,将减速策略中的固定指数2改为可调的驾驶员减速度指数 b ,以便于后续参数标定。优化后算法如下:

$$\hat{S}(k+1) = S(k) + V(k) \cdot T_s \quad (3)$$

$$\hat{V}(k+1) = V(k) + \alpha_{\max}(V(k)) \cdot \left[1 - \left(\frac{V(k)}{V_{\text{lim}}(S, \gamma)} \right)^\delta - \left(\frac{S_{\min}(V, V_L)}{S_L} \right)^b \right] \cdot T_s \quad (4)$$

$$S_{\min}(V, V_L) = S_0 + V(k)T_{\text{gap}} + \frac{V(k) \cdot (V(k) - V_L(k))}{2\sqrt{\alpha_{\max}\beta_{\max}}} \quad (5)$$

式中, $\hat{V}(k+1)$ 为 $(k+1)$ 时刻的预测速度; $\hat{S}(k+1)$ 为 $(k+1)$ 时刻预测的覆盖距离; T_s 为采样时间; V_{lim} 为所需的期望速度或在探测器探测范围内交通环境对车速的限制; $S(k)$ 为 k 时刻预测车辆行驶的距离; $V(k)$ 为 k 时刻的主车车速; $V_L(k)$ 为 k 时刻的前车车速; β_{\max} 为最大减速度。

图1所示为速度预测器的方法和架构。




图1 速度预测器框架

2.2 车辆动力系统限制

在传统的IDM研究中,多数研究者将IDM的加速汽车技术

度计算为恒定的最大加速度 α_{\max} ,但其通常无法充分表达复杂的动力系统行为和动力系统极限。在动力系统的限制下,加速度应与车速相关,车速提高,车辆的加速度减小。动力传动极限会直接影响车辆的速度曲线,导致速度预测的准确性下降。

车辆在不同速度下的外力可计算为:

$$V(k+1) = V(k) + \frac{(F_{\text{drag}} + F_{\text{prop}})}{M_{\text{eq}}} T_s \quad (6)$$

$$S(k+1) = S(k) + V(k) T_s \quad (7)$$

$$F_{\text{drag}} = -\text{sgn}[V(k)] \left[\frac{\rho C_d A [V(k)]^2}{2} + mg C_{\text{roll}} \cos \theta + mg \sin \theta \right] \quad (8)$$

$$F_{\text{inertia}} = \frac{m}{T_s} \cdot (V(k) - V(k-1)) \quad (9)$$

式中, F_{drag} 为由空气、滚动摩擦和路面坡度施加的力; M_{eq} 、 m 分别为车辆的等效惯量和质量; F_{prop} 为车辆牵引或制动系统施加的力; ρ 为空气密度; C_d 为空气阻力系数; A 为迎风面积; C_{roll} 为滚动摩擦因数; θ 为以弧度表示的道路坡度; F_{inertia} 为车辆的惯性力。

为使车辆加速,施加在车轮的驱动力必须能够抵抗车辆运动时受到的外力。根据牛顿第二定律,发动机产生的多余力与合成加速度成正比。车辆最大加速度曲线如图2所示。




图2 α_{\max} 曲线

2.3 交通环境的速度限制

基于交通环境的限制车速 V_{lim} 决定了在没有前车情况下车辆的加速度。当前车速 $V(k)$ 与 V_{lim} 的比值决定了驾驶员对车辆加速或减速的期望:如果 $V(k)/V_{\text{lim}} > 1$,改进IDM算法将产生减速请求;在没有前车或与前车距离较远的情况下, $V(k)/V_{\text{lim}} < 1$,改进IDM算法将产生加速请求。由车辆传感器探测到的前方路况和线上实时交通数据等信息都将纳入 V_{lim} 的考虑范围,主要包括当前路段的法定车速限制、交通拥堵时的动态车速限制、停止标识限制、车辆转弯时的车速限制。

式(4)中交通环境的速度限制 V_{lim} 实现方法为^[17]:

$$V_{\text{lim}} = \min(V_{L1}, V_{L2}, V_{L3}, V_{L4}, \dots) \quad (10)$$

其中:

$$\begin{cases} V_{L1} = V_{\text{sl}}(S) \cdot \gamma \\ V_{L2} = V_{\text{traffic}} \\ V_{L3} = V_{\text{sl}}(S) \cdot \left(1 - \sum_i [1 - f_{\text{stop}}(S - S_{\text{stop},i})] \right) \\ V_{L4} = V_{\text{sl}}(S) \cdot \left(1 - \sum_i [1 - f_{\text{turn}}(S - S_{\text{turn},i})] \right) \end{cases} \quad (11)$$

式中, V_{L1} 为法定限速限制; V_{L2} 为动态交通平均速度限制; V_{L3} 为车辆停止-起步速度限制; V_{L4} 为车辆转弯速度限制; V_{sl} 为车辆行驶位置的法定限速度; V_{traffic} 为交通拥堵造成的动态平均速度限制; $S_{\text{stop},i}$ 、 $S_{\text{turn},i}$ 分别为第 i 个停止位置和转向位置与预测初始点的距离; f_{stop} 、 f_{turn} 分别为车辆停止位置和转弯位置的车速限制系数。

图3所示为经大量实车行驶车速数据拟合而成的停止和转弯的车速限制系数,对停止和转弯事件具有良好的预测性,也体现了车辆在停止和转弯位置的速度变化情况,可使车速预测模型具有更高的精度。




图3 停止和转弯的车速限制系数

2.4 驾驶员参数

在改进的IDM中主要用5个参数对驾驶员行为进行参数化: S_0 、 T_{gap} 、 γ 、 δ 、 b 。其中, δ 可直接影响车辆的加速过程, b 可直接影响车辆的减速过程, γ 直接决定车辆的稳定行驶速度。而 S_0 和 T_{gap} 相对更难确定,存在很多不确定因素,但二者对于车速预测的精度影响较小。

3 验证数据的来源及处理

本文所使用的仿真分析数据主要来自NGSIM (Next Generation Simulation)数据集,其具有数据开源、采集频率高、数据精准、车辆信息类型丰富等优点。基于以上优点,本文利用其中的US-101数据集对改进的IDM的参数进行标定,该数据包的数据种类及释义如表1所示。

由于数据过于庞杂,并非所有数据均满足改进的IDM参数调试、标定的需求,因此必须从数据集的原始数据中筛选出满足相关要求的数据。具体筛选条件为:

- 只选取一直位于同一车道上的车辆。
- 所选取的车辆前方应一直存在车辆,即车队中的第1辆车不作为主车。
- 不同车型的车辆性能存在较大差异,因此选取主

车时应排除摩托车和卡车车型,只选取小型汽车作为主车。虽然不同品牌、不同排量的家用轿车也存在性能差异,但由于NGSIM项目中的US-101公路数据为交通相对拥堵时的数据,因此小型汽车之间的性能差异可以忽略。

表1 数据种类及数据释义

数据名称	数值	说明
车辆ID(Vehicle ID)	26	
本组数据帧数(Frame ID)	64 帧	
此车辆总帧数(Total Frames)	438 帧	
全局时间(Global Time)	1 118 846 985 300 ft (341 024 561 119 m)	从1970年1月1日0时起
相对于研究区域道路起点的X向偏移量(Local X)	13.696 ft(4.175 m)	
相对于研究区域道路起点的Y向偏移量(Local Y)	71.006 ft(21.643 m)	
相对于加利福尼亚州平面Ⅲ在NAD83大地基准的X向偏移量(Global X)	6 451 163.521 ft(1 966 314.574 m)	
相对于加利福尼亚州平面Ⅲ在NAD83大地基准的Y向偏移量(Global Y)	1 873 320.302 ft(570 988.028 m)	
车身长度(Vehicle Length)	11.5 ft(3.505 m)	
车身宽度(Vehicle Width)	7 ft(2.134 m)	
车辆种类(Vehicle Class)	2	1-摩托车; 2-汽车; 3-载货汽车
当前车辆速度(Vehicle Velocity)	28.64 ft/s(8.729 m/s)	
当前车辆加速度(Vehicle Acceleration)	-11.13 ft/s ² (-3.392 m/s ²)	
当前车辆所在车道(Lane Identification)	2	
前车的ID(Preceding Vehicle)	22	
后车的ID(Following Vehicle)	32	
当前车辆与前车的车头间距(Spacing)	45.68 ft(13.923 m)	
当前车辆与前车的车头时距(Headway)	1.6 s	

部分筛选结果如表2所示。

表2 部分筛选结果示例

主车ID	数据帧编号	主车速度/m·s ⁻¹	主车加速度/m·s ⁻²	前车编号	前车速度/m·s ⁻¹	车头距离/m	与前车时距/s
26	64	8.729	-3.39	22	20.390	13.923	1.60
26	65	8.403	-3.41	22	20.180	13.981	1.66
26	66	8.169	-1.58	22	19.931	14.085	1.72
26	67	8.138	1.09	22	19.815	14.207	1.75

4 参数标定及校核

改进的IDM的参数标定及校对过程可视为非线性规划问题求最优解的过程,本文的参数标定通过优化算法寻优的方法完成。

标定过程主要包含仿真输入、仿真算法、仿真步长及仿真结果输出4个部分。仿真输入主要包括主车的速度、主车的加速度、前车的速度、主车与前车的距离和时距等。仿真算法即为2.1节中改进的车速预测模型。

4.1 优化算法的选取

遗传算法(Genetic Algorithm, GA)用于解决寻优问题,吸取了Darwin的进化论和Mendel的遗传学理论,具有良好的自适应和寻优能力^[22-24]。

目标函数是预测车速与实际车速的误差,需优化的变量是车速预测模型参数,约束是模型参数的物理边界。由于对目标函数的收敛要求,本文采用MATLAB搭建遗传算法来求解近似最优值,遗传算法框架如图4所示。

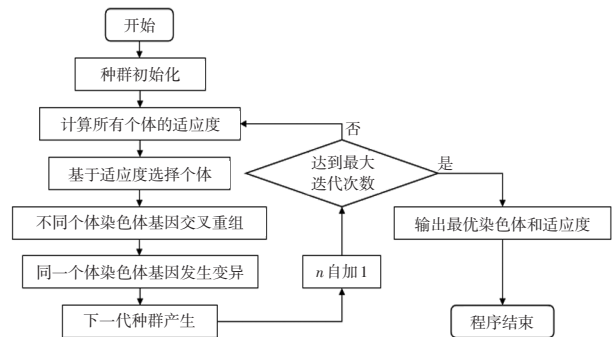


图4 遗传算法框架

- 初始化。确定种群规模 N 、交叉概率、变异概率和终止进化准则;随机生成个体作为初始种群 $X(0)$ 。
- 计算或估计 $X(t)$ 中各个体的适应度。
- 选择母体。从 $X(t)$ 中运用选择算子选择出 $M/2$ 对母体($M \geq N$)。
- 交叉重组。对所选择的 $M/2$ 对母体,依概率执行交叉形成 M 个中间个体。
- 发生变异。对其中 M 个个体分别独立依照概率执行变异,形成 M 个候选个体。
- 选择子代。从 M 个候选个体中依适应度选择 N 个个体组成新一代种群 $X(t+1)$ 。
- 结束程序。如已满足终止准则或达到最大迭代次数则终止程序,输出最优染色体和适应度。

本文具体校准程序选择Ossen和Hoogendoorn推荐的目标函数^[25]:

$$j = \frac{\sqrt{\sum_{h=1}^H (a_h^{\text{real}} - a_h^{\text{sim}})^2}}{\sqrt{\sum_{h=1}^H (a_h^{\text{real}})^2} - \sqrt{\sum_{h=1}^H (a_h^{\text{sim}})^2}} \quad (12)$$

式中, H 为预测样本总量; a_h^{sim} 为车辆 h 预测的加速度; a_h^{real} 为车辆 h 的实际加速度。

4.2 车速预测模型参数标定结果

根据 NGSIM 项目中的实际数据及遗传算法的应用,可以得到改进后的 IDM 最优取值,如表 3 所示, α_{max} 已在前文中确定。

表 3 参数标定结果

模型参数	$\beta_{\text{max}}/\text{m}\cdot\text{s}^{-2}$	S_0/m	T_{gap}/s	δ	b	γ
参数取值	2.13	3.17	1.39	2	2.1	0.99

5 车速预测算法的仿真结果

本文仿真采用的计算机的中央处理器为酷睿 i9-10980XE,在 Simulink 模块中建立控制算法和整车动力学模型,然后接入 PreScan 软件中进行联合仿真^[26],仿真架构如图 5 所示。




图 5 联合仿真框架

5.1 车速预测算法仿真环境的建立

5.1.1 交通环境设置

建立与 US-101 数据采集路段相同的路况。

5.1.2 车辆模型配置

车辆模型包括主车的车型和前方车辆的车型。试验中车辆过多会使仿真速度变慢,可适当简化环境中的车辆。

5.1.3 主车传感器配置

选择 2 个独立技术传感器(Technology Independent Sensor, TIS)负责信号接收,均布置在主车的车头,配置如表 4 所示。

表 4 传感器配置

传感器编号	TIS1	TIS2
角度/(°)	9	80
距离/m	150	30
检测目标数量/个	32	32

5.1.4 主车和前车驾驶数据设定

本文以 NGSIM 项目的 US-101 数据集为基础数据, 2023 年 第 9 期

选取主车及对应的前车,即可得到两车的速度等相关数据,在仿真过程中,为与实际数据相吻合,在 Simulink 中插入两车的速度插值表分别与两车的动力学模型连接,直接由插值表控制两车车速。

5.2 预测结果

大量文献显示,短期车速预测时长多集中在 1 min 以内,而长期车速预测多数可以超过 1 min^[27],本文研究的车速预测时长为 80 s。

本文将主车置于同一路段的不同交通环境下行驶,通过改变交通环境的车流量、车流速度、不同前车、不同车道等交通环境信息得到了 80 s 的大量仿真结果。本文预抽取预测精度最低和最高的 2 组数据和 1 组转弯停车行驶数据进行分析。

交通拥堵对车速有直接的影响,利用一段道路上的动态平均限速度 V_{traffic} 、法定限速 V_{sl} 和车辆在 i 时刻交通动态平均速度 V_i (共 n 个时刻),构建交通拥堵程度评价函数 T_{severity} ,可以更直观地表达交通拥堵情况:

$$T_{\text{severity}} = \frac{1}{\frac{V_{\text{traffic}}}{V_{\text{sl}}} - \frac{1/n \sum_i^n (V_i)}{V_{\text{sl}}}} \quad (13)$$

从式(13)中可以看出,交通拥堵程度总是正数,但由于交通过度拥堵时车速可能为 0,故设定 T_{severity} 的最大阈值为 20。3 次仿真过程的交通拥堵情况如图 6 所示。





图 6 交通拥堵情况


在拥堵路段,前车速度是影响主车的主要因素,主车的速度主要通过前车的行为预测。IDM 的速度预测结果如图 7 所示,仅利用速度限制作为输入数据的预测,获得的预测车速会随速度限制的变化而变化。

图 8 所示为 3 次仿真的车速误差。从图 8a 和图 8b 中可以明显地看出,由于仿真 1 的交通环境拥堵程度相对于仿真 2 的更低,所以预测误差更小,同时可以看出,加、减速转换过程中误差相对较大,由于不同的驾驶员对于前方车辆的大幅度加减速转变所采取的反应有所不同,且反应能力不同,因此会产生较大误差。由图 7c 和图 8c 可以看出,车速预测算法中加入停止和转弯的车速限制系数控制车辆在转弯和停止处的车速可以很好地模拟驾驶员行为趋势,减小车速预测算法在转弯和停车行为中的误差。根据上述仿真结果可以确定,优化


后的车速预测算法在交通拥堵、路况复杂的环境中仍可
实现较高的车速预测精度。



(a) 仿真1




(b) 仿真2




(c) 仿真3


图7 车速预测结果



(a) 仿真1




(b) 仿真2




(c) 仿真3

图8 仿真车速误差


图9所示为3次仿真的加速度对比结果,由图9可知,当车速升高时,车辆的加速能力普遍不足,加速能力随车速和挡位的升高而降低,这也更符合实际行驶中车辆的动力学性能。此外,该模型还对前车紧急制动后的加速行为表现出了一定的预判,但是,由于模型预测较为保守,预测获得的车辆加速度相较于真实值偏低,这主要与 δ 和 b 相关,但是由于每个驾驶员的驾驶习惯不同,将这2个参数调高反而会影响到此算法对其他车辆的预测精度。



(a) 仿真1



(b) 仿真2



(c) 仿真3

图9 仿真加速度对比

本文使用的预测精度评价指标是均方根误差 E_{rms} 、平均绝对百分比误差 E_{map} :

$$E_{rms} = \sqrt{\frac{1}{u} \sum_{k=1}^u [\hat{x}(k) - x(k)]^2} \quad (14)$$

$$E_{map} = \frac{1}{u} \sum_{k=1}^u \left| \frac{\hat{x}(k) - x(k)}{\hat{x}(k)} \right| \quad (15)$$

式中, $\hat{x}(k)$ 、 $x(k)$ 分别为模型预测的数据和车辆的真实数据; u 为数据数量。

表5列出了3次仿真结果的车速预测误差,由于车辆在停止(车速为0)时会引起式(14)、式(15)的失常,带来计算上的错误,故在进行性能评价时忽略了车辆的停止持续时间。从图6中可以看出,由于仿真1相对于仿真2的交通情况更加简单,故仿真1的预测精度高于

仿真2的预测精度,不同的驾驶员行为所带来的差异更大,驾驶员的操作差异更加难以预料,故仿真2的误差更大。从图7c中可以看出,仿真3虽然存在车辆转弯和停止等事件,但加入停止和转弯的车速限制系数控制后,仍然有着较高的车速预测精度。


表5 车速预测误差分析

项目	仿真1	仿真2	仿真3
均方根误差 $E_{rms}/m \cdot s^{-1}$	1.089 9	1.119 8	1.095 1
平均绝对百分比误差 $E_{map}/\%$	8.89	12.67	10.06


查阅大量资料发现,在复杂的交通环境下长期车速预测平均百分比误差通常在10%以上,而本文采用IDM跟车车速预测方法平均百分比误差可控制在8%~13%。

路程预测结果会作为输入重新返回到改进的IDM中,也会影响整体模型的预测精度。如图10所示,由于车速的预测结果精度很高,路程预测结果也有着很高的精度。


由于平均绝对百分比误差是从数据整体进行评估,故对路程预测的评价只从平均绝对百分比误差方面分析,仿真1~仿真3平均绝对百分比误差分别为0.024%、0.408%、0.575%,车速预测结果虽然有一定的波动性,但整体的路程预测精度依然很高。



(a) 仿真1



(b) 仿真2



(c) 仿真3

图10 仿真路程对比

6 结束语

本文系统地概括了影响车辆速度的道路交通特征
2023年 第9期

和相应的前瞻数据,建立了具有车辆和车辆动力系统的参数化模型及基于前瞻性数据的速度预测器,通过对2条性质不同路线的仿真研究,证明了预测器处理不同水平的前瞻信息和提供准确预测的能力。

此外,可以观察到预测精度最低和最高水平的前瞻数据之间的差异取决于交通环境的特征。高速公路行驶工况下,观察到有关停车标志和转弯的前瞻性数据几乎没有增加优势,因为高速公路上缺乏此类道路特征。然而,在城市的交通环境中,与仅限速的前瞻数据相比,本算法具有显著优势。

参 考 文 献

- [1] LIU K, ASHER Z D, GONG X, et al. Vehicle Velocity Prediction and Energy Management Strategy Part 1: Deterministic and Stochastic Vehicle Velocity Prediction Using Machine Learning[J]. SAE Technical Paper, 2019-01-1051, 2019.
- [2] SHIN J, SUNWOO M. Vehicle Speed Prediction Using a Markov Chain with Speed Constraints[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(9): 3201-3211.
- [3] LIN C C, WANG M S. Vehicle Speeding Early Warning Model Using Frame Feature Detection and HMM[C]// IEEE International Conference on Consumer Electronics. Singapore: IEEE, 2011.
- [4] MARTIS R, POP-PIGLESAN F, COSMAN S, et al. Considerations on Design, Development and Testing of Electrical Machines for Automotive HVAC[J]. MATEC Web of Conferences, 2020, 322.
- [5] XIE Y, TANG S, XIANG Y, et al. Resisting Web Proxy-Based HTTP Attacks by Temporal and Spatial Locality Behavior[J]. IEEE Transactions on Parallel and Distributed Systems, 2013, 24(7): 1401-1410.
- [6] AI C, JIA L J, HONG M, et al. Short-Term Road Speed Forecasting Based on Hybrid RBF Neural Network with the Aid of Fuzzy System-Based Techniques in Urban Traffic Flow[J]. IEEE Access, 2020, 8: 69461-69470.
- [7] 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.
XIE H. Vehicle Speed Prediction Based on BP Neural Network and Its Optimization Algorithm[D]. Chongqing: Chongqing University, 2014.
- [8] REN S, HAN L, LI Z X, et al. Spatial-Temporal Traffic Speed Bands Data Analysis and Prediction[C]// 2017 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM). Singapore: IEEE, 2017: 808-812.
- [9] SATRINIA D, SAPTAWATI G A P. Traffic Speed Prediction

- from GPS Data of Taxi Trip Using Support Vector Regression [C]// 2017 International Conference on Data and Software Engineering (ICoDSE). Palembang, Indonesia: IEEE, 2017: 1-6.
- [10] GMIRA M, GENDREAU M, LODI A, et al. Travel Speed Prediction Based on Learning Methods for Home Delivery [J]. EURO Journal on Transportation and Logistics, 2020, 9 (4).
- [11] HUANG X, TAN Y, HE X. An Intelligent Multifeature Statistical Approach for the Discrimination of Driving Conditions of a Hybrid Electric Vehicle[J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 12(2): 453-465.
- [12] 刘吉超,陈阳舟. 基于GA-PSO混合优化的BPNN车速预测方法[J]. 交通运输系统工程与信息, 2017, 17(6): 40-47.
- LIU J C, CHEN Y Z. BPNN Vehicle Speed Prediction Method Based on GA- PSO Hybrid Optimization[J]. Transportation Systems Engineering and Information, 2017, 17(6): 40-47.
- [13] CHEN D Q, YAN X D, LIU X B, et al. A Multiscale-Grid-Based Stacked Bidirectional GRU Neural Network Model for Predicting Traffic Speeds of Urban Expressways[J]. IEEE Access, 2021, 9: 1321-1337.
- [14] MOZAFFARI L, MOZAFFARI A, AZAD N L. Vehicle Speed Prediction via a Sliding- Window Time Series Analysis and an Evolutionary Least Learning Machine: A Case Study on San Francisco Urban Roads[J]. Engineering Science and Technology, an International Journal, 2015, 18 (2): 150-162.
- [15] DELL'ACQUA P, BELLOTTI F, BERTA R, et al. Time-Aware Multivariate Nearest Neighbor Regression Methods for Traffic Flow Prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(6): 3393-3402.
- [16] REZAEI A, BURL J B. Prediction of Vehicle Velocity for Model Predictive Control[J]. IFAC-Papers on Line, 2015, 48(15): 257-262.
- [17] KESTING A, TREIBER M, HELBING D. Enhanced Intelligent Driver Model to Access the Impact of Driving Strategies on Traffic Capacity[J]. Philosophical Transactions of the Royal Society A: Mathematical, Physical, and Engineering Sciences, 2010, 368(1928): 4585-4605.
- [18] LI L, CHEN X Q, ZHANG L. A Global Optimization Algorithm for Trajectory Data Based Car-Following Model Calibration[J]. Transportation Research Part C, 2016, 68: 311-332.
- [19] JAMES R M, HAMMIT B E, BOYLES S D. Methods to Obtain Representative Car- Following Model Parameters from Trajectory-Level Data for Use in Microsimulation[J]. Transportation Research Record, 2019, 2673(7): 62-73.
- [20] LEFÈVRE S, SUN C, BAJCSY R, et al. Comparison of Parametric and Non-Parametric Approaches for Vehicle Speed Prediction[C]// 2014 American Control Conference. Portland, OR, USA: IEEE, 2014: 3494-3499.
- [21] TREIBER M, HENNECKE A, HELBING D. Congested Traffic States in Empirical Observations and Microscopic Simulations[J]. Physical Review E, 2000, 62(2): 1805-1824.
- [22] HOLLAND J H. Adaptation in Natural and Artificial Systems[M]. Ann Arbor: University of Michigan Press, 1975.
- [23] DE JONG K A. The Analysis of the Behavior of a Class of Genetic Adaptive Systems[D]. Ann Arbor: University of Michigan, 1975.
- [24] Holland J H. Genetic Algorithms[J]. Scientific American, 1992, 267(1): 66-73.
- [25] 顾海燕. 车联网环境下高速公路车辆跟驰模型及仿真研究[D]. 南京: 东南大学, 2017.
- GU H Y. Vehicle Following Model and Simulation Study of Highway Vehicles in Connected Vehicle Environment[D]. Nanjing: Southeast University, 2017.
- [26] 罗文发,陈晓磊. 商用车自适应巡航控制系统[C]// 汽车电子技术分会第七届年会论文集. 青岛: 中国汽车工程学会, 2011: 146-152.
- LUO W F, CHEN X L. Adaptive Cruise Control System for Commercial Vehicles[C]// Proceedings of the 7th Annual Conference of the Automotive Electronics Technology Branch. Qingdao: SAE China, 2011: 146-152.
- [27] HEGDE B, AHMED Q, RIZZONI G. Velocity and Energy Trajectory Prediction of Electrified Powertrain for Look Ahead Control[J]. Applied Energy, 2020, 279.

(责任编辑 斛 畔)

修改稿收到日期为2023年2月3日。