Journal of System Simulation

Volume 32 | Issue 10 Article 3

10-14-2020

GRU-Based Car-Following Behavior Simulation Model

Fei Rong
1. School of Computer Science, Xi'an University of Technology, Xi'an 710048, China; ;

Liu Fang
2. School of Computer Science, Northwestern Polytechnical University, Xi'an 710129, China; ;

Xie Guo
3. College of Automation Information and Engineering, Xi'an University of Technology, Xi'an 710048, China; ;

Hei Xinhong
1. School of Computer Science, Xi'an University of Technology, Xi'an 710048, China; ;

See next page for additional authors

Follow this and additional works at: https://dc-china-simulation.researchcommons.org/journal

Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

GRU-Based Car-Following Behavior Simulation Model

Abstract

Abstract: The accuracy of acceleration prediction can be effectively improved by the driver's memory in car-following behavior. A new car-following model based on the General Motors (GM) and the gate control unit (GRU) is proposed. *The car-following data between small vehicles with similar driving behavior are obtained by data preprocessing. The established model is calibrated by the car-following data, and the optimal parameters and structure of the model are determined.* According to car-following characteristics, the effectiveness of model is verified by simulation. It is confirmed that the model has high robustness and improved simulation accuracy comparing with the traditional models.

Keywords

car-following, GM, GRU, SVR, actual road data

Authors

Fei Rong, Liu Fang, Xie Guo, Hei Xinhong, Shasha Li, and Hu Bo

Recommended Citation

Fei Rong, Liu Fang, Xie Guo, Hei Xinhong, Li Shasha, Hu Bo. GRU-Based Car-Following Behavior Simulation Model[J]. Journal of System Simulation, 2020, 32(10): 1862-1873.

This paper is available in Journal of System Simulation: https://dc-china-simulation.researchcommons.org/journal/vol32/iss10/3

第 32 卷第 10 期 系统仿真学报© Vol. 32 No. 10
2020 年 10 月 Journal of System Simulation Oct., 2020

基于门控循环单元的车辆跟驰行为仿真模型

费蓉[1]，刘方[2]，谢国[3]，黑新宏[1]，李莎莎[1]，胡博[4]
(1. 西安理工大学 计算机学院，陕西 西安 710048；2. 西北工业大学 自动化学院，陕西 西安 710129；
3. 西安理工大学 自动化学院，陕西 西安 710048；4. 北京华电优控科技有限公司，北京 100193)

摘要：驾驶员记忆效应能有效提高车辆跟驰行为中的加速度预测准确率，*结合 General Motors (GM) 跟驰模型与门控循环单元网络建立新的车辆跟驰模型。通过数据预处理获得有相似驾驶行为的小型车间车辆跟驰数据，校准新模型，从而确定模型的最优参数与结构*，依据车辆跟驰特性通过仿真验证了模型有效性，与神经网络、支持向量回归进行对比，仿真结果证明，结合了 L-BFGS 优化的 GRU 车辆跟驰模型比仅考虑前导车与跟驰车间瞬时相互作用的车辆跟驰模型，能得到更高的仿真精度和稳定性。

关键词：车辆跟驰；GM；GRU；SVR；真实道路数据
中图分类号：U491 文献标识码：A 文章编号：1004-731X (2020) 10-1862-12
DOI: 10.16182/j.issn1004731x.joss.20-FZ0438

GRU-Based Car-Following Behavior Simulation Model

Fei Rong[1], *Liu Fang*[2], *Xie Guo*[3], *Hei Xinhong*[1], *Li Shasha*[1], *Hu Bo*[4]
(1. School of Computer Science, Xi'an University of Technology, Xi'an 710048, China; 2. School of Computer Science, Northwestern Polytechnical University, Xi'an 710129, China; 3. College of Automation Information and Engineering, Xi'an University of Technology, Xi'an 710048, China; 4. Beijing Huadian Youkong Technology Co., Ltd., Beijing 100193, China)

Abstract: The accuracy of acceleration prediction can be effectively improved by the driver's memory in car-following behavior. A new car-following model based on the General Motors (GM) and the gate control unit (GRU) is proposed. *The car-following data between small vehicles with similar driving behavior are obtained by data preprocessing. The established model is calibrated by the car-following data, and the optimal parameters and structure of the model are determined.* According to car-following characteristics, the effectiveness of model is verified by simulation. It is confirmed that the model has high robustness and improved simulation accuracy comparing with the traditional models.

Keywords: car-following; GM; GRU; SVR; actual road data

引言

车辆跟驰(Car Following，CF)行为的概念源于 20 世纪 50 年代初，作为一种微观驾驶行为，描述了限制超车的单车道上行驶车队中相邻两车间的相互作用[1]。60 多年来，国外学者对车辆跟驰模型进行了系统的研究。多种领域的学者试图从不同的角度来解释观察到的微观现象[2-3]。

跟驰模型种类繁多，依据其出发点，可分两大类——理论驱动类和数据驱动类。理论驱动类模型运用动力学知识建立车辆跟驰模型，物理意义较明显。而数据驱动类模型使用智能计算方法，建立车辆跟驰模型对大量的高精度车辆轨迹数据进行拟

收稿日期：2020-05-30 修回日期：2020-07-03；
基金项目：国家重点研发计划(2018YFB1201500)，国家自然科学基金(61773313，61873201，U1934222)，陕西省重点研发计划(2019TD-014)；
作者简介：费蓉(1980-)，女，陕西西安，博士，副教授，研究方向为随机系统仿真，无人驾驶等。

Published by Journal of System Simulation, 2020

Journal of System Simulation, Vol. 32 [2020], Iss. 10, Art. 3

合，此类模型没有十分明确的物理意义，但是通过仿真发现，该类模型可以有效的解释理论驱动类模型中无法解释的一些复杂的非线性的驾驶行为[4]。

在理论驱动类模型的发展中，刺激-反应模型是最为经典的模型，GM (General Motors)模型[5]则是其中最为重要的一类，众多刺激-反应模型大多建立在 GM 模型的基础上，形式简单，物理意义明确。但其容易随交通运行状态的变化而变化，不具备通用性。

随着人工智能的日渐普及，数据驱动类模型逐渐成为车辆跟驰模型。BP (BackPropagation)神经网络[6]是目前应用广泛的多层前馈神经网络(Feedforward Neural Network，FNN)。随着神经网络在交通仿真领域的广泛应用，Kehtarnavaz[7]于1998年将BP神经网络模型应用于车辆跟驰行为建模，并验证了其有效性。贾洪飞等[8]也基于 BP 神经网络建立了车辆跟驰模型，其输入为跟驰车的速度、两车的相对速度、两车的车间距和期望车间距，输出为跟驰车的加速度。

由于神经网络模型的输入输出参数与刺激-反应模型的输入输出参数相似，与刺激-反应模型较为相似，有学者就将两者进行了仿真对比实验，评价结果显示，BP 神经网络模型有着更高的预测精度。但其在训练过程中，不能对极端值(如加速度等于零)做出误差较小的预测，模型中车辆跟驰相关理论的缺失，会引起结果的合理性出现偏差[9-10]。

支持向量回归(Support Vector Regression，SVR)[11]是机器学习中的一种算法。它将原问题转化为凸二次规划问题，运用最优化理论进行求解，可获得全局最优解；且引入核(kernel)函数 $K(x,z)$，将输入空间代入非线性映射函数中得到特征空间 H，从而避免了“维数灾难”。

2010 年，Wei[12]提出了基于支持向量回归的车辆跟驰模型，其输入为当前时刻的跟驰车的速度、两车的相对速度和两车的车间距，输出为下一时刻的跟驰车的速度。评价指标显示，该模型获得了较好的仿真效果。之后，随着在线交通仿真技术的产生，王洪鹏[13]建立了基于在线支持向量回归的车辆跟驰模型。

车辆跟驰行为是一个连续过程，因此驾驶员可以通过前一段时间的记忆来做出相应的决策。但现有的模型未充分考虑驾驶员的记忆效应，仅仅考虑了跟驰车与前导车之间的瞬时相互作用。车辆跟驰数据符合时序特性，时序数据历史信息能够有效提高预测精度，而 BP 神经网络模型与支持向量回归模型对记忆能力的支持不足。

深度学习理论是近年来的研究热点。循环神经网络(Recurrent Neural Network，RNN)是将其他神经元和自身神经元接收到的信息作为“历史记忆”，使用随时间反向传播(BackPropagation Through Time，BPTT)等算法进行参数学习的一种神经网络模型[14-15]。

当输入的序列较长时，研究人员发现长期依赖的关系导致参数学习过程中出现梯度爆炸和消失等问题，由此引入了门控机制，如长短时记忆(Long Short-Term Memory，LSTM)[16]网络和门控循环单元(Gated Recurrent Unit，GRU)[17]网络。

Wang 等[18]提出利用 GRU 来对车辆跟驰行为进行建模，将驾驶员的记忆效应嵌入到模型中，为研究交通流理论和交通仿真提供了新思路。

本文在上述研究基础上，结合公路实景环境，基于 GM 跟驰模型结合 GRU 方法，进行车辆跟驰行为模型设计。将前导车速度，跟驰车速度及两车车头间距构造为输入，进而使用车辆跟驰数据对所建立模型进行校准，确定模型的最优参数与最优结构，从而输出下一时刻的跟驰车加速度，仿真验证并与 BPNN 及 SVR 进行对比分析，证明了基于 L-BFGS 优化的 GRU 网络车辆跟驰模型比仅考虑前导车与跟驰车之间瞬时相互作用的车辆跟驰模型具有更高的仿真精度和稳定性。

1 相关理论

1.1 GM 车辆跟驰模型

GM 模型假设车辆在跟驰行驶时不发生超车

https://dc-china-simulation.researchcommons.org/journal/vol32/iss10/3
DOI: 10.16182/j.issn1004731x.joss.20-FZ0438

或变道行为，运用驾驶动力学理论推导得出，其基本公式为：

$$a_{n+1}(t+T)=\lambda v_{n+1}^{m}(t+T)\frac{\Delta v(t)}{[\Delta x(t)]^{l}} \tag{1}$$

式中：$a_{n+1}(t+T)$为跟驰车在$(t+T)$时刻的瞬时加速度；$v_{n+1}(t+T)$为跟驰车在$(t+T)$时刻的瞬时速度；$\Delta v(t)$为两车在 t 时刻的相对速度；$\Delta x(t)$为两车在 t 时刻的车间距；T 为反应时间；λ 为待标定的灵敏度参数；m，l 也均为待标定参数。

1.2 神经网络基础

神经网络是一种高度非线性模型，神经元作为基本单元，接收一组输入信号，并产生一个输出信号，典型结构如图 1 所示。

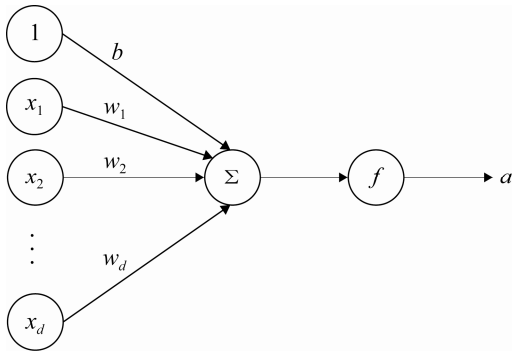

图 1 神经元结构
Fig. 1 Structure of a neuron

其中，输入为 $\boldsymbol{x}=\left[x_1\ x_2\ \cdots\ x_d\right]^{\mathrm{T}}\in\mathbb{R}^d$，权重为 $\boldsymbol{w}=\left[w_1\ w_2\ \cdots\ w_d\right]^{\mathrm{T}}\in\mathbb{R}^d$，$b$ 为偏置单元。用净输入 z 表示输入的加权和，则：

$$z=\boldsymbol{w}^{T}\boldsymbol{x}+b \tag{2}$$

$f(x)$为激活函数(Activation Function)，则输出为：

$$a=f(z) \tag{3}$$

激活函数为非线性函数，常见的激活函数有：

Sigmoid 函数

$$\sigma(x)=1/(1+\mathrm{e}^{-x}) \tag{4}$$

tanh 函数

$$\tanh(x)=(\mathrm{e}^{x}-\mathrm{e}^{-x})/(\mathrm{e}^{x}+\mathrm{e}^{-x}) \tag{5}$$

ReLU 函数

$$\mathrm{ReLU}(x)=\max(0,x) \tag{6}$$

LeakyReLU 函数

$$\mathrm{LeakyReLU}(x)=\max(\alpha x,x) \tag{7}$$

常用的神经网络有前馈网络、反馈网络和图网络。前馈网络不具有记忆性，而反馈神经网络中的神经元具有记忆功能，在不同的时刻具有不同的状态。反馈神经网络(Feedback Neural Network)通过允许神经元接收其他和自身神经元的反馈信号从而拥有记忆性。由此，在本文中采用反馈神经网络。基本结构如图 2 所示。

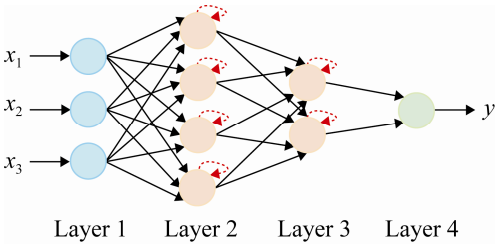

图 2 反馈神经网络
Fig. 2 Feedback NN

在反馈神经网络中，信号可以单向传播，也可以双向传播。本文选择单向传播。

1.3 基于门控的循环神经网络

为了解决循环神经网络在长序列训练过程中的长期依赖问题，引入门控机制，用于选择性地加入新的信息，并选择性地遗忘保留信息。这类网络统称为基于门控的循环神经网络(Gated RNN)，其中，长短时记忆(LSTM)网络和门控循环单元(GRU)网络是目前的研究热点。

1.3.1 长短时记忆网络

LSTM 网络增设了新的内部状态 $\boldsymbol{c}_t$，并且引入了 3 个“门”——遗忘门f_t、输入门i_t和输出门o_t。“门”的取值在(0,1)之间，用于控制通过的信息量。

遗忘门 f_t 控制上一时刻的内部状态 要遗忘的信息量；输入门 c_{t-1} 控制当前时刻的候选状态 $\tilde{c}_t$ 要保留的信息量；输出门 $\tilde{c}_t$ 控制当前时刻的内部状态 c_t 要输出给外部状态 c_t 的信息量。图 3 展示了 LSTM 单元的内部结构。

Published by Journal of System Simulation, 2020

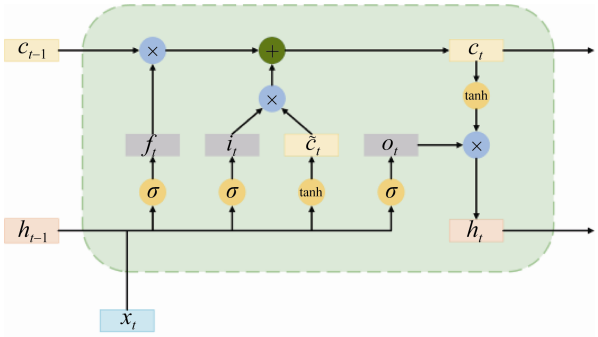

图 3 LSTM 单元
Fig. 3 LSTM unit

图 3 中，⊗代表向量元素乘，⊕代表向量元素加，$\sigma(x)$为 Sigmoid 激活函数。则 3 个门的计算方式分别为：

$$f_t = \sigma(\boldsymbol{U}_f h_{t-1} + \boldsymbol{W}_f x_t + b_f) \tag{8}$$

$$i_t = \sigma(\boldsymbol{U}_i h_{t-1} + \boldsymbol{W}_i x_t + b_i) \tag{9}$$

$$o_t = \sigma(\boldsymbol{U}_o h_{t-1} + \boldsymbol{W}_o x_t + b_o) \tag{10}$$

因此，状态的更新方式为：

$$\tilde{c}_t = \tanh(\boldsymbol{U}_c h_{t-1} + \boldsymbol{W}_c x_t + b_c) \tag{11}$$

$$c_t = f_t \times c_{t-1} + i_t \times \tilde{c}_t \tag{12}$$

$$h_t = o_t \times \tanh(c_t) \tag{13}$$

式(12)与(13)中，×表示向量元素乘。

$\boldsymbol{U}$ 为状态-状态权重矩阵，$\boldsymbol{W}$ 为状态-输入权重矩阵，b 为偏置。

在 LSTM 网络中，单元的内部状态 c_t 能够长时间地保留某些关键信息。因此，可以形象地将 LSTM 单元的上半部分看作“主线”，下半部分看作“支线”。

1.3.2 门控循环单元网络

GRU 网络的内部思想与 LSTM 网络相似，而且能够达到与 LSTM 网络相当的效果，但因其参数减少，训练难度降低而被广泛应用。

LSTM 单元中的输入门和遗忘门是互补关系，GRU 单元将它们合并为一个门——更新 z_t，且删去了 LSTM 单元中的输出门，增加了重置门 r_t，但不引入新的内部状态。其结构如图 4 所示。

其中，更新门控制当前时刻的状态 h_t 要从上一时刻的状态 h_{t-1} 保留的信息量，以及从候选状态 $\tilde{h}_t$ 中接收的新的信息量；重置门控制当前时刻的候选状态 $\tilde{h}_t$ 要保留的上一时刻的状态 h_{t-1} 的信息量。2 个门的计算方式为：

$$z_t = \sigma(\boldsymbol{U}_z h_{t-1} + \boldsymbol{W}_z x_t + b_z) \tag{14}$$

$$r_t = \sigma(\boldsymbol{U}_r h_{t-1} + \boldsymbol{W}_r x_t + b_r) \tag{15}$$

状态的更新方式为：

$$\tilde{h}_t = \tanh(\boldsymbol{U}_h (r_t \times h_{t-1}) + \boldsymbol{W}_h x_t + b_h) \tag{16}$$

$$h_t = z_t \times h_{t-1} + (1 - z_t) \times \tilde{h}_t \tag{17}$$

当 z_t=0，r_t=1 时，GRU 网络退化为简单循环神经网络。若 z_t=0，r_t=0 时，当前状态 h_t 只和当前输入 x_t 相关，和历史状态 h_{t-1} 无关。当 z_t=1 时，当前状态 h_t 等于上一时刻状态 h_{t-1}，和当前输入 x_t 无关。

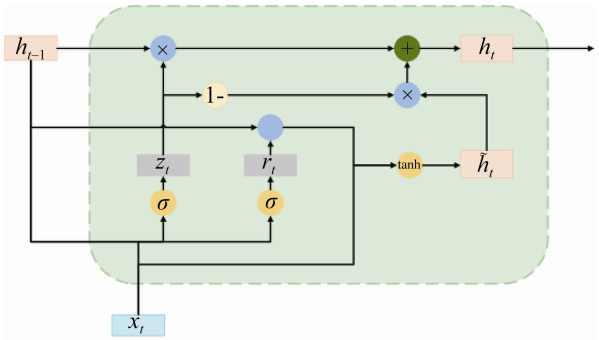

图 4 GRU 单元
Fig. 4 GRU unit

1.4 GRU 车辆跟驰行为仿真建模

本文采用改进的 GRU 网络对车辆跟驰行为进行建模仿真。

合理地设计模型的输入和输出，能够提高模型的仿真精度，从 GM 模型出发，设定模型的输入为 t 时刻的前导车的速度 $v_n(t)$、跟驰车的速度 $v_{n+1}(t)$ 和两车的车间距 $\Delta x(t)$，输出为 $(t+T)$ 时刻的跟驰车的加速度 $a_{n+1}(t+T)$，因此：

$$a_{n+1}(t+T) = f\begin{pmatrix} v_n(t), v_{n+1}(t), \Delta x(t), \\ v_n(t-T), v_{n+1}(t-T), \\ \Delta x(t-T), \cdots, \cdots \\ v_n(t-(N-2)T), \\ v_{n+1}(t-(N-1)), \\ \Delta x(t-(N-1)) \end{pmatrix} \tag{18}$$

其中，N 为“记忆”时间间隔的长度。

相应地，模型结构选择 N vs 1 型，隐藏层使用 GRU 循环单元。令 N=3，见图 5 所示。

https://dc-china-simulation.researchcommons.org/journal/vol32/iss10/3
DOI: 10.16182/j.issn1004731x.joss.20-FZ0438

第 32 卷第 10 期 系统仿真学报 Vol. 32 No. 10
2020 年 10 月 Journal of System Simulation Oct., 2020

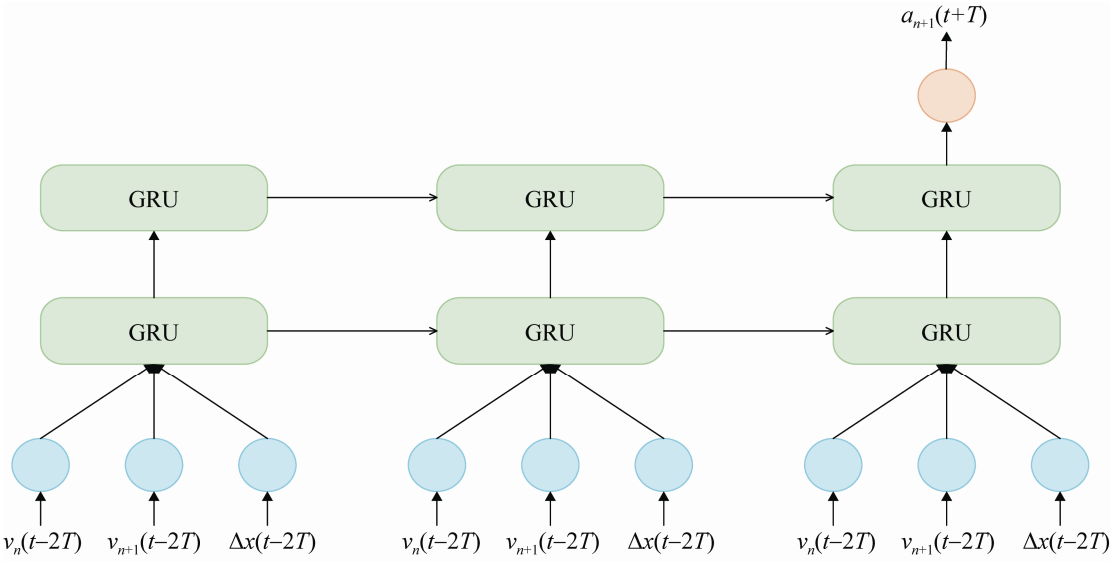

图 5 基于 GRU 网络的车辆跟驰模型
Fig. 5 GRU network-based CF model

因 L-BFGS 的计算量较小，收敛速度快，选择为优化器。

2 数据获取及预处理

2.1 公开数据集 NGSIM

此处采用加利福尼亚州爱莫利维尔市(Emeryville)的I-80州际公路东行方向采集的详细的车辆轨迹数据[19]。数据由安装在位于克里斯蒂大道的高30层的太平洋公园广场大楼上的7台摄像机采集，10 帧/秒。研究路段长 503 m，共分为 6 个车道，其中，车道 1 为多乘员车道(High Occupancy Vehicle Lanes，HOV)，车道 6 为集散车道。

I-80 数据集包括 3 个时段的车辆轨迹数据，道路状况如表 1 所示。

表 1 道路状况
Tab. 1 Road conditions

采集时段	道路状况
16:00 ~ 16:15	由非拥堵至拥堵过渡
17:00 ~ 17:15	拥堵
17:16 ~ 17:30	拥堵

本文主要对车辆跟驰行为及其微观特性进行分析。车辆跟驰行为与道路状况关系密切，为保证车辆跟驰行为的普遍性，此处选用 16:00 ~ 16:15 时段的车辆轨迹数据进行研究，该数据集共有 1 028 575 条轨迹记录，每条记录包含 18 个字段，完整描述如表 2 所示。

表 2 字段描述
Tab. 2 Field descriptions

字段	描述
Vehicle_ID	车辆标识号(按进入的时间递增)
Frame_ID	帧标识号(按开始时间递增)
Global_Time	自 1970.1.1 以来经过的时间(单位：ms)
v_Class	车辆类型 (1：摩托车，2：小型车，3：大型车)
v_Vel	车辆的瞬时速度(单位：feet/s)
v_Acc	车辆的瞬时加速度(单位：feet/s^2)
Lane_ID	车辆当前所在车道的编号
Preceding	前导车的车辆标识号
Following	跟驰车的车辆标识号
Space_Headway	车头间距(单位：feet)

2.2 跟驰车辆数据处理与验证

2.2.1 跟驰车辆数据处理

在本文的研究中，为避免不同类型车辆之间的跟驰行为的潜在不同，只研究小型车(即 *v_Class*=2)之间的跟驰行为；剔除大容量车道(即 *Lane_ID*=1)和集散车道(即 *Lane_ID*=6)上的车辆，以保证所研究的车辆具有相似的驾驶行为，即保证驾驶行为的一致性；车辆在行驶过程采用单车道数据，避免换

道行为对跟驰行为的影响；只保留跟驰时间超过 45 s(即 450 条记录)的数据，以保证跟驰过程的完整性，且有足够多的样本进行模型训练。

数据处理算法步骤如下：

算法 1：车辆轨迹数据的处理

输入：车辆轨迹数据

输出：车辆跟驰数据

1：**for** 车辆标识号 **in** 车辆轨迹数据

2：调用函数 $[LV,FV,delta_x,data_{num}]=get_data(id)$

3：**while** $i<length(data_{num})$ **do**

4：将当前车辆的第i组车辆跟驰数据写入.csv 文件

5：**end while**

6：**end for**

2.2.2 数据验证

为保证车辆跟驰数据可用，此处依据车辆跟驰行为的特性验证数据可靠性。

根据交通流密度的大小，可将车辆的行驶状态分为自由行驶状态和非自由行驶状态。自由行驶状态是指交通流密度大时，行驶在同一条道路上的相邻两车，由于车间距过大，导致引导车对跟驰车的影响较小，从而使得跟驰车处于一个不受引导车约束的状态。相反，由于交通流密度小，导致引导车对跟驰车的影响较大，从而使得跟驰车处于一个受引导车约束的非自由行驶状态。

在非自由行驶状态中，制约性、延迟性和传递性是车辆跟驰中最主要的跟驰特性[20]。

制约性：跟驰车在跟随前导车行驶时，为保证行车安全，有 2 个限制条件：第 1 个是限制车速，即跟驰车的速度不能长时间大于前导车的速度，只能在前导车的速度上下浮动；第 2 个是限制车间距，即跟驰车与前导车之间须保持一个安全距离，使跟驰车有足够的制动距离。车速条件和间距条件一同构成了跟驰的制约性，即前导车的速度制约着跟驰车的速度以及两车之间的车间距。

延迟性：前导车的运动状态发生变化后，跟驰车也将发生变化，但两车运动状态的变化是异步的，这是因为跟驰车的驾驶员对前导车的变化需要一个反应过程；

传递性：前导车的运动状态发生变化后，直接影响第一辆跟驰车，而第一辆跟驰车作为前导车又影响着下一辆跟驰车，以此传递，直至影响着车队中的最后一辆跟驰车。

随机抽取两组车辆跟驰数据，将其可视化，如图 6~7 所示。

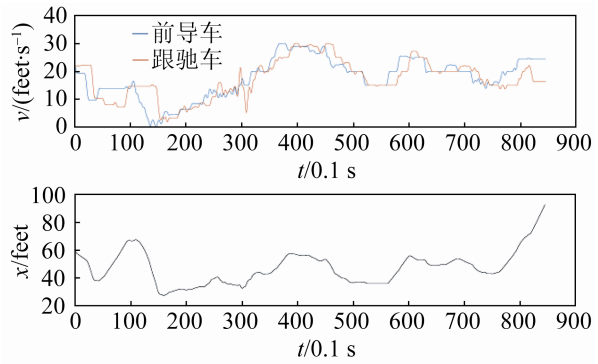

图 6 第一组数据

Fig. 6 Dataset 1

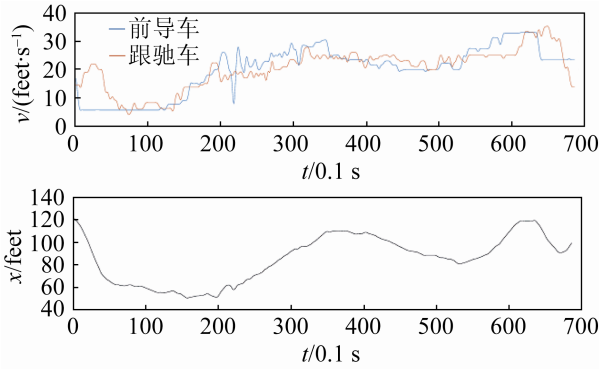

图 7 第二组数据

Fig. 7 Dataset 2

图 6~7 中每组数据的第一幅子图为速度-时间关系，第二幅子图为车间距-时间关系。从图 6~7 可知，2 组数据均满足车辆跟驰特性。则跟驰数据可用于车辆跟驰行为建模设计。

2.3 驾驶员反应时间

驾驶员反应时间指驾驶员从感知到周围环境发生改变到做出响应所需要的时间[21]，也是车辆跟驰模型中的一个重要参数。

https://dc-china-simulation.researchcommons.org/journal/vol32/iss10/3
DOI: 10.16182/j.issn1004731x.joss.20-FZ0438

第 32 卷第 10 期 系统仿真学报 Vol. 32 No. 10
2020 年 10 月 Journal of System Simulation Oct., 2020

依据跟驰的制约性，前导车的运动状态发生变化后，跟驰车也将发生变化，因跟驰车的驾驶员对前导车的变化需要一个反应过程，两车运动状态呈异步变化。反应过程包括感知(Perception)、决策(Judgement)、准备执行(Reaction initiation)和执行(Reaction execution)共 4 部分，所需的时间称为反应时间。设反应时间为 T，则前导车在 t 时刻发生变化，跟驰车在(t+T)时刻才能做出相应的变化。

Summala H[22]根据青年驾驶员与老年驾驶员的制动反应时间对制动反应时间做了分析研究。乔晋[23]使用 SPSS 13.0 进行最小二乘法分析，驾驶员反应时间的加权平均值为 1.077 s。

Lu[24]则通过 63 个样例得出了驾驶员响应时间的相关统计信息，如表 3 所示。

表 3 响应时间统计信息
Tab. 3 Reaction time statistics

评价指标	响应时间 τ/s
平均值	0.701 6
标准误差	0.052 36
中值	0.50
标准差	0.415 62
方差	0.173
变化范围	1.70
最小值	0.30
最大值	2.00

综上考虑，在本文中，将反应时间 T 定为 1 s。由于车辆跟驰数据的相邻两条记录的采集时间间隔为 0.1 s，因此每间隔 1 s (即 10 条记录)截取一条记录，并将新的数据保存以便使用。

3 车辆跟驰模型及对比分析

3.1 模型训练

本节中，使用基于 Python 的深度学习库 Keras 进行基于 GRU 的车辆跟驰模型的构建与训练，后端使用 TensorFlow。

模型训练的过程如下：

首先，为了消除量纲对模型仿真精度与收敛速度的影响，需对原始数据做归一化处理。使用 MinMaxScaler：

$$X_{\text{scaled}} = \frac{x - x.\min}{x.\max - x.\min}(\text{max-min}) + \min \tag{19}$$

式中：max，min 为给定缩放范围的最大值和最小值，即将原始数据缩放到[min, max]之间。特别地，将原始数据缩放到[0,1]之间，则

$$x_{\text{scaled}} = \frac{x - x.\min}{x.\max - x.\min} \tag{20}$$

然后，将前导车速度，跟驰车速度及两车车头间距构造为输入，下一时刻跟驰车的加速度作为输出。由于“记忆”时间间隔的长度 N 与构造数据密切相关，所以它也直接影响着模型预测精度，在本文中，对该参数进行详细的实验。下来，将数据集随机拆分为训练集与测试集。紧接着，选择 ReLU 作为输出层的激活函数，建立 GRU 模型。由于隐藏层的层数和各个隐藏层的神经元的个数有无数种搭配选择，因此，本文需要对多种不同结构的模型分别进行实验，以找出模型的最优结构。使用均方误差(Mean Square Error, MSE)构造损失函数。

$$\text{MSE} = \frac{1}{m}\sum_{i=1}^{m}(y_i - \hat{y}_i)^2 \tag{21}$$

优化器选择上，共轭梯度法(CG)和 L-BFGS 算法结果都可以达到较高的精度，这也与论文[25]结果相符。为了比较二者的差别，表 4 罗列了 2 个反向传播计算过程中的最后迭代的几次误差值。

表 4 CG 和 L-BFGS 重构误差表
Tab. 4 CG and L-BFGS reconstruction error table

CG	L-BFGS
…	…
2.284 28e+01	8.415 71e+00
1.855 91e+01	8.135 60e+00
1.711 01e+01	8.432 35e+00
1.711 01e+01	7.906 84e+00

从表 4 中可以看出，在最小化重构误差的过程中，CG 可以将误差下降到 17.1。而 L-BFGS 算法最后可以下降到 7.9。可见二者结果差距不大。

最后，对模型进行训练与测试，并将结果保存以便分析。

基于 GRU 的车辆跟驰模型伪码如下：

Published by Journal of System Simulation, 2020

Journal of System Simulation, Vol. 32 [2020], Iss. 10, Art. 3

算法 2：基于 GRU 的车辆跟驰模型

输入： $v_n(t), v_{n+1}(t), \Delta x(t), v_n(t-T)$

$v_{n+1}(t-T), \Delta x(t-T), \cdots\cdots$

$v_n(t-(N-1)T), v_{n+1}(t-(N-1)T), \cdots\cdots$

$\Delta x(t-(N-1)T)$

输出： $a_{n+1}(t+T)$

1： 使用 MinMaxScaler 对数据做归一化处理，将原始数据缩放到[0,1]

2: 将输入构造为 $\boldsymbol{X} \in \mathbb{R}^{m \times N \times d}$，输出构造为 $\boldsymbol{y} \in \mathbb{R}^{m \times 1}$

3： 将构造后的数据拆分为训练集与测试集

4： 建立 Sequential()模型，加入结合 L-BFGS 的 GRU 层与 Dense 层

5： 编译模型，损失函数='*MSE*'

6： **while** 模型收敛 **do**

7： 训练模型

8： **end while**

9： 测试模型

根据上述模型训练的流程，需要确定“记忆”时间间隔的最优长度和模型的最优结构，从而使得模型的表现效果最佳。Wang[23]在 NGSIM 数据集上设定深度模型的隐藏层层数为 3 层。基于此进行如下实验：

首先将模型的结构固定。为节约训练时间，采用单隐藏层，神经元的个数为 20 的简单结构，对不同的 值分别进行实验。结果见图 8。

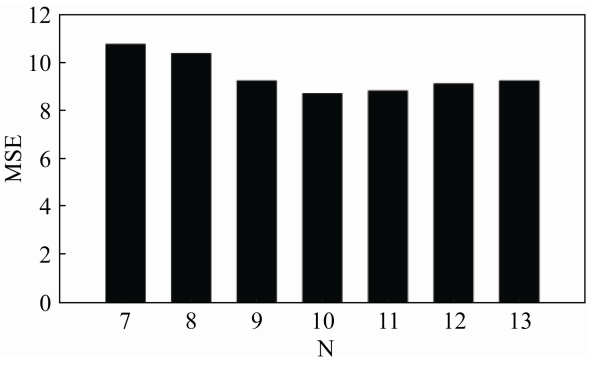

图 8 “记忆”时间间隔的长度影响

Fig. 8 Influence of length of “memory” time interval

从图 8 中可以看出，“记忆”时间间隔的长度为 10 的时候，即跟驰车驾驶员仅考虑前10 T 时间内的历史信息，模型的表现效果最佳。

基于此，令 N=10，对表 5 中的 9 种结构的模型分别进行训练与测试。对于含有 1 层隐藏层的模型(结构 1~3)，结构 3 模型的表现效果最佳；对于含有 2 层隐藏层的模型(结构 4~6)，结构 5 模型的表现效果最佳；对于含有 3 层隐藏层的模型(结构 7~9)，结构 8 模型的预测准确度最优。而对于这 3 种模型的表现效果，结构 3 模型＜结构 5 模型＜结构 8 模型。

表 5 模型的结构

Tab. 5 Structures of model

结构	隐藏层		
	1	2	3
1	10	0	0
2	30	0	0
3	**50**	**0**	**0**
4	10	5	0
5	**30**	**10**	**0**
6	50	20	0
7	10	5	5
8	**30**	**10**	**10**
9	50	20	20

下面，以前导车 *ID* 为 66、跟驰车 *ID* 为 74 的车辆跟驰数据，分别使用结构 3、结构 5 以及结构 8 的模型进行训练，并将仿真结果可视化，详见图 9~12。其中，图 10~12 均由两幅子图组成，其中第一幅图均为仿真数据簇，其分属于 100 个不同的训练模型，第二幅图均为仿真数据簇的含误差条的线图(errorbar)，即均值标准差(mean±std)。

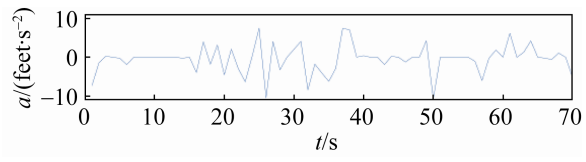

图 9 真实数据仿真

Fig. 9 Simulation of true data

https://dc-china-simulation.researchcommons.org/journal/vol32/iss10/3
DOI: 10.16182/j.issn1004731x.joss.20-FZ0438

第 32 卷第 10 期 系统仿真学报 Vol. 32 No. 10
2020 年 10 月 Journal of System Simulation Oct., 2020

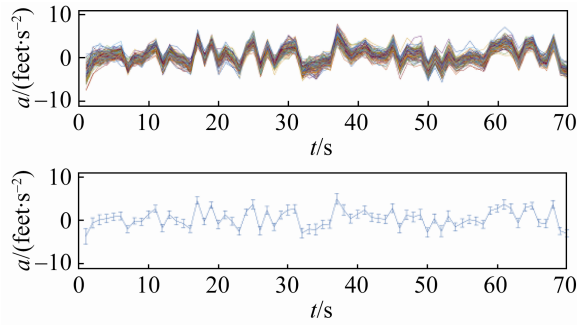

图 10 结构 3 的模型
Fig. 10 Model with Structure 3

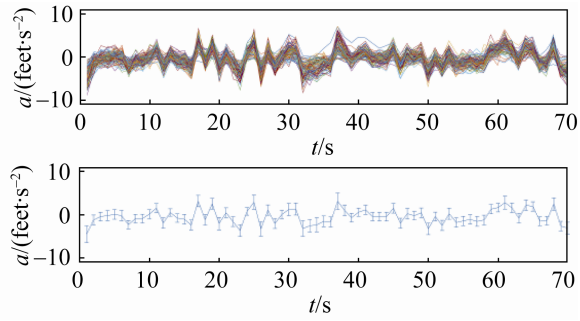

图 11 结构 5 的模型
Fig. 11 Model with Structure 5

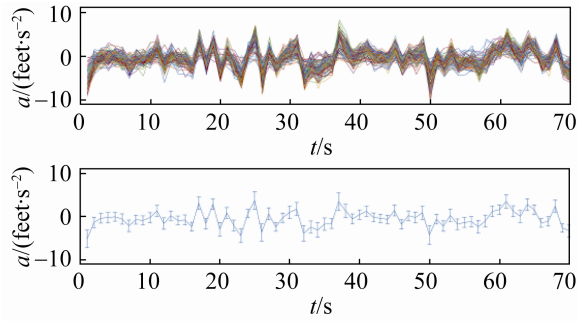

图 12 结构 8 的模型
Fig. 12 Model with Structure 8

综上所述，对于基于 GRU 的车辆跟驰模型，“记忆”时间间隔的长度 N=10，结构为 3 层隐藏层，每个隐藏层的隐状态的特征维度分别为 30、10 和 10 的模型的预测精度最高，并且对于其中的一段连续加、减速行为也有可观的仿真效果。

3.2 模型比较验证

为了检验基于 GRU 的车辆跟驰模型的仿真精度，选取数据驱动类模型中的其他 2 种模型——BP 神经网络模型和支持向量回归模型来进行对比实验。同样地，我们选取 t 时刻的前导车的速度 $v_n(t)$、跟驰车的速度 $v_{n+1}(t)$和两车的车间距$\Delta x(t)$作为模型的输入，$(t+T)$时刻的跟驰车的加速度 $a_{n+1}(t+T)$作为模型的输出，以保证公平性。而模型的评价指标依旧为 *MSE*。

基于 BP 神经网络建立如图 13 所示的模型。根据 Kolmogorov 定理[26]，具有 3 层的反向传播神经网络足以完成从 n 维到 m 维的任何映射。因此，本文选择具有 2 个隐藏层的 BPNN 网络作为基于 BPNN 的 CF 模型的结构，每个隐藏层的神经元的个数设为 20 和 10。神经元的激活函数均使用 tanh 函数。

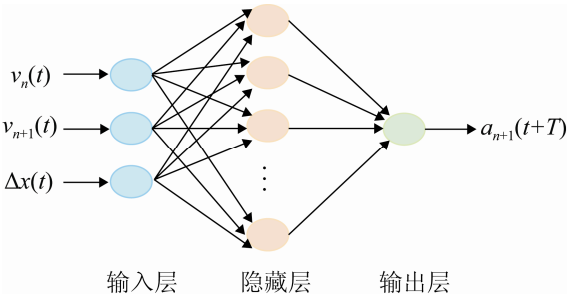

图 13 基于 BP 神经网络的车辆跟驰模型
Fig. 13 BPNN-based CF model

该模型仍使用 Keras 进行构建与训练。在拆分训练集与测试集时可以使用“Hold-Out”等方法随机拆分。

随机地选取前导车 *ID* 为 2771、跟驰车 *ID* 为 2812 的车辆跟驰数据，其仿真结果如图 14 所示。

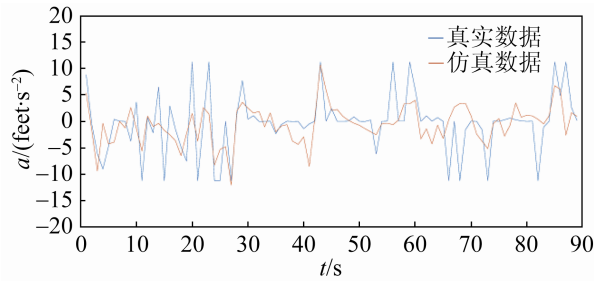

图 14 基于 BPNN 的车辆跟驰模型仿真结果
Fig. 14 Simulation results of BPNN-based CF model

从图 14 中可以看出，由于这组数据的“噪声”较大，即跟驰车处于不断地加、减速的状态，导致模型的仿真精度较低，与真实数据存在一定的误

Published by Journal of System Simulation, 2020

差，但仍旧能够反应出跟驰车加速度的变化趋势，并且模型的结构相对简单，收敛速度较快。

上述实验证明了基于 BPNN 的车辆跟驰模型的有效性。接下来，用基于支持向量回归来建立车辆跟驰模型，见图 15。

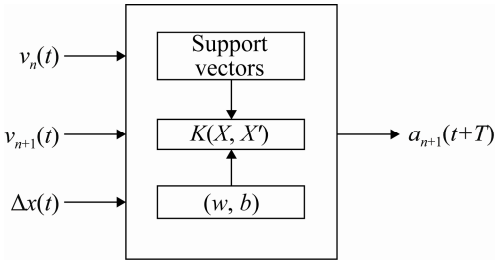

图 15 基于支持向量回归的车辆跟驰模型
Fig. 15 SVR-based CF model

其中，核函数选用高斯核函数。

$$K_{Gaussian}(x,z)=\exp\left(-\frac{\|x-z\|^2}{2\sigma^2}\right) \tag{22}$$

为简化实验流程，我们使用现有的 Scikit-learn 框架中的svm.SVR进行训练与测试，并令svm.SVR的参数 kernel='rbf'。同 BPNN 模型一样，将数据集进行随机拆分。

再次随机选取了一组车辆跟驰数据，这组数据的前导车 *ID* 为 79、跟驰车 *ID* 为 87，并且跟驰车的加、减速行为也很频繁。仿真测试结果见图 16。结果表明，SVR 模型的预测误差相对较小。

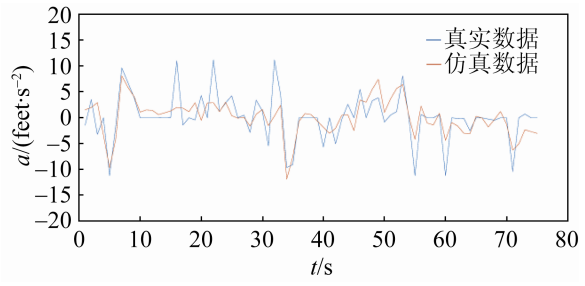

图 16 基于 SVR 的车辆跟驰模型仿真结果
Fig. 16 Simulation results of SVR-based CF model

为公平对比上述 3 种不同的车辆跟驰模型，我们对同一组车辆跟驰数据(前导车 *ID* 为 1503、跟驰车 *ID* 为 1507)分别进行改进 GRU、BPNN 以及 SVM 实验，仿真结果如图 17 所示。

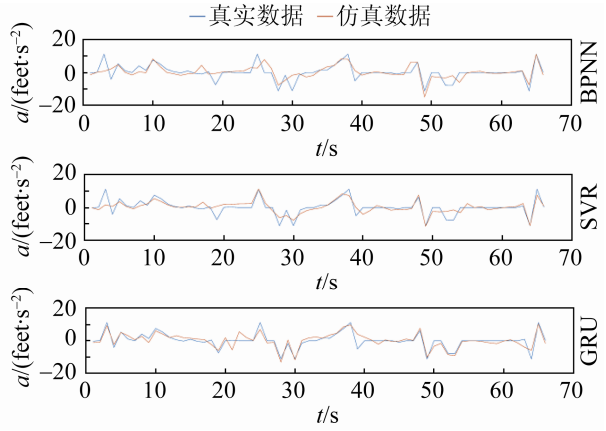

图 17 3 种车辆跟驰模型的仿真结果对比
Fig. 17 Comparison of simulation results of three CF models

在这组车辆跟驰数据中，由于跟驰车的加、减速行为不频繁，且有近 40%的时间处于匀速行驶状态，反映在图中为真实数据的折线相对平滑，所以 3 种模型均有不错的仿真效果，但仍能够明显地观察到，GRU 模型优于 SVR 模型，SVR 模型优于 BPNN 模型。*MSE* 结果如表 6 所示。

表 6 3 种模型对比结果
Tab. 6 Comparison results of three models

评价指标	BPNN	SVR	GRU3
MSE	11.69	7.76	5.29

综上所述，以上 3 种模型不仅可以反应跟驰车加速度的变化趋势，而且可以对数值做较为精确的预测。而对于长时间处在变速行驶状态的车辆，加入了记忆单元的 GRU 模型具有更好的仿真效果，但相应的，其收敛速度也慢于另外两种模型。

4 结论

本文选取了 NGSIM 数据集中的 I-80 州际公路部分的高精度车辆轨迹数据，经过数据预处理得到了车辆跟驰数据，并依据车辆跟驰行为的特性，通过实验验证了数据的正确性，选定反应时间 T=1 s，进一步对车辆跟驰数据做选取。结合 L-BFGS 优化进行门控循环单元(GRU)网络设计，并对车辆跟驰行为进行建模，将模型的输入选定为 t 时刻的前导车的速度、跟驰车的速度和两车的车间距，输出选定为(t+T)时刻的跟驰车的加速度。最后，先对所建

https://dc-china-simulation.researchcommons.org/journal/vol32/iss10/3
DOI: 10.16182/j.issn1004731x.joss.20-FZ0438

立的模型的“记忆”时间间隔的长度和网络结构做了详细的讨论与实验，选取了使得模型表现效果最佳的参数。进而将其与 BP 神经网络模型和支持向量回归模型进行对比，证明了加入记忆单元的模型具有更高的仿真精度，也为开发更高精度的交通仿真系统提供了一个有力的工具。

基于 BP 神经网络和基于支持向量回归的车辆跟驰模型的稳定性较差，即当跟驰车的加、减速行为较为频繁时，这 2 个模型的仿真效果较差。而基于 GRU 网络的车辆跟驰模型由于考虑了前几个时间间隔的相关信息，从而可以做出更准确的预测。本文建立的基于 GRU 的车辆跟驰模型仅研究了小型车之间的跟驰行为，但不同类型车辆间的跟驰行为并不相同。后续将着重研究车辆跟驰数据的动态地选取。在未来的研究中，可以结合实际情况，如非对称驾驶行为、多辆前导车行驶等，进一步改进现有的模型。

参考文献:

[1] 王殿海, 金盛. 车辆跟驰行为建模的回顾与展望[J]. 中国公路学报, 2012, 25(1): 115-127.
Wang Dianhai, Jin Sheng. Review and outlook of modelling of car following behavior[J]. China Journal of Highway and Transport, 2012, 25(1): 115-127.

[2] Ciuffo B, Punzo V, Montanino M, et al. Thirty Years of Gipps' Car-Following Model: Applications, Developments, and New Features[J]. Transportation Research Record (S0361-1981), 2012, 2315: 89-99.

[3] 金盛. 考虑视觉注意特性的车辆跟驰行为建模[D]. 长春: 吉林大学, 2010.
Jin Sheng. Modeling of car following behavior considering visual attention performance[D]. Changchun: Jilin University, 2010.

[4] 鲁斌. 基于数据驱动方法的车辆跟驰行为建模与分析[D]. 成都: 西南交通大学, 2017.
Lu Bin. Modeling and analysis of car-following behavior using data-driven methods[D]. Chengdu: Southwest Jiaotong University, 2017.

[5] Gazis D C, Herman R, Rothery R W, et al. Nonlinear Follow-the-Leader Models of Traffic Flow[J]. Operations Research (S0030-364X), 1961, 9(4): 545-567.

[6] Rumelhart D E, Hinton G E, Williams R J, et al. Learning representations by back-propagating errors[J]. Nature (S0028-0836), 1988, 323(6088): 696-699.

[7] Kehtarnavaz N, Groswold N, Miller K, et al. A Transportable Neural-Network Approach to Autonomous Vehicle Following[J]. IEEE Transactions on Vehicular Technology (S0018-9545), 1998, 47(2): 694-702.

[8] 贾洪飞, 隽志才, 王晓原. 基于神经网络的车辆跟驰模型的建立[J]. 公路交通科技, 2001(4): 92-94.
Jia Hongfei, Juan Zhicai, Wang Xiaoyuan. Development of a car-following model based on artificial neural networks[J]. Journal of Highway and Transportation Research and Development, 2001(4): 92-94.

[9] Kikuchi S, Chakroborty P. Car-following model based on fuzzy inference system[J]. Transportation Research Record (S0361-1981), 1992: 82-82.

[10] Ma X. A Neural-Fuzzy Framework for Modeling Car-following Behavior[C]// 2006 IEEE International Conference on Systems, Man and Cybernetics. Taipei, Taiwan: IEEE, 2006: 1178-1183.

[11] Cortes C, Vapnik V. Support-Vector Networks[J]. Machine Learning (S0885-6125), 1995, 20(3): 273-297.

[12] Wei D, Liu H. Analysis of asymmetric driving behavior using a self-learning approach[J]. Transportation Research Part B-methodological (S0191-2615), 2013: 1-14.

[13] 王洪鹏, 陈锋. 基于在线支持向量回归的车辆跟驰模型研究[J]. 电子技术, 2018, 47(11): 21-28.
Wang Hongpeng, Chen Feng. A car-following model based on online support vector regression[J]. Electronics R & D, 2018, 47(11): 21-28.

[14] Elman J L. Finding Structure in Time[J]. Cognitive Science (S1551-6709), 1990, 14(2): 179-211.

[15] Werbos P J. Backpropagation through time: what it does and how to do it[J]. Proceedings of the IEEE (S0018-9219), 1990, 78(10): 1550-1560.

[16] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation (S0899-7667), 1997, 9(8): 1735-1780.

[17] Cho K, Van Merrienboer B, Gulcehre C, et al. Learning Phrase Representations using RNN Encoder--Decoder for Statistical Machine Translation[C]// Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha, Qatar: Association for Computational Linguistics, 2014, 1724-1734.

[18] Wang X, Jiang R, Li L, et al. Capturing Car-Following Behaviors by Deep Learning[J]. IEEE Transactions on

Journal of System Simulation, Vol. 32 [2020], Iss. 10, Art. 3

Intelligent Transportation Systems (S1524-9050), 2018, 19(3): 910-920.

[19] FHWA. Next Generation Simulation[DB/OL]. [2020-01-01]. https://ops.fhwa.dot.gov/trafficanalysistools/ngsim.htm.

[20] 章三乐, 肖秋生, 任福田. 车辆跟驰理论的实用研究[J]. 北京工业大学学报, 1992(3): 20-27.
Zhang Sanyue, Xiao Qiusheng, Ren Futian. Applied study of car-following theory[J]. Journal of Beijing Polyechnic University, 1992(3): 20-27.

[21] 杨林, 邢翠芳, 赵海冰. 汽车跟驰状态下驾驶员反应时间研究[J]. 计算技术与自动化, 2015, 34(3): 33-37.
Yang Lin, Xing Cuifang, Zhao Haibing. Study on Driver's reaction Time (DRT) during car following[J]. Computing Technology and Automation, 2015, 34(3): 33-37.

[22] Summala H. Brake Reaction Times and Driver Behavior Analysis[J]. Transportation Human Factors (S1093-9741), 2000, 2(3): 217-226.

[23] 乔晋. 车辆跟驰模型参数标定与验证研究[D]. 上海: 上海交通大学, 2008.
Qiao Jin. Reaserching on parameters callbration and verification of car-following models[D]. Shanghai: Shanghai Jiaotong University, 2008.

[24] Lu G, Cheng B, Wang Y, et al. A Car-Following Model Based on Quantified Homeostatic Risk Perception[J]. Mathematical Problems in Engineering (S1024-123X), 2013: 1-13.

[25] Le Q V, Ngiam J, Coates A, et al. On optimization methods for deep learning[C]// ICML 2011. Bellevue, Washington, USA: Omnipress. 2011: 265-272.

[26] Kurková V. Kolmogorov's theorem and multilayer neural networks[J]. Neural Networks (S0893-6080), 1992, 3(5): 501-506.

https://dc-china-simulation.researchcommons.org/journal/vol32/iss10/3
DOI: 10.16182/j.issn1004731x.joss.20-FZ0438