

doi: 10.3969/j.issn.1002-0268.2023.11.026

面向数据驱动的车辆跟驰行为建模

王少杰^{1,2}, 曲大义^{*1}, 刘浩敏¹, 孟奕名¹, 崔善柠³

(1. 青岛理工大学 机械与汽车工程学院, 山东 青岛 266520; 2. 天津市道路运输事业发展服务中心, 天津 300384;
3. 青岛理工大学 土木工程学院, 山东 青岛 266520)

摘要: 数据驱动类跟驰模型可充分挖掘车辆轨迹数据中的跟驰行为特性, 从而实现对车辆跟驰行为的预测。为研究车辆跟驰行为特性, 基于实测轨迹数据, 运用数据驱动的方法并结合 GM 跟驰模型建模思路, 基于注意力机制与驾驶员进行跟驰行为决策时着重关注重要信息机制相一致的特性, 加入注意力机制, 建立了基于 CNN-BiLSTM-Attention 的车辆跟驰模型。筛选 NGSIM 数据集中符合车辆跟驰特性的轨迹数据并进行降噪处理, 通过试验选择最优模型网络结构, 对模型进行训练, 与 LSTM, GRU, CNN-BiLSTM 等数据驱动类跟驰模型进行对比分析。结果表明: 基于 CNN-BiLSTM-Attention 的车辆跟驰模型与 LSTM 模型相比, MAE 减少约 38.12%, R^2 提高约 2.18%, MSE 减少约 23.45%; 与 GRU 模型相比, MAE 减少约 19.05%, R^2 提高约 1.13%, MSE 减少约 13.95%; 与 CNN-BiLSTM 模型相比, MAE 减少约 1.06%, R^2 提高约 0.15%, MSE 减少约 1.78%, 即模型具有最优的加速度预测性能, 可更好地描述车辆跟驰行为; 基于 CNN-BiLSTM-Attention 的车辆跟驰模型与单一模型相比, 可更好地提取交通数据特征并处理历史数据间的关系, 捕捉历史信息并做出相应决策, 与 CNN-BiLSTM 相比, Attention 机制使得模型着重关注输入特征的重要部分, 从而具有更高的预测精度。该模型可实现车辆加速度预测, 可帮助理解车辆跟驰特性, 未来可为车辆跟驰行为决策提供理论依据。

关键词: 智能交通; 数据驱动; 深度学习; 跟驰模型; 加速度预测

中图分类号: U491

文献标识码: A

文章编号: 1002-0268 (2023) 11-0222-07

Modeling of Car-following Behavior Based on Data-driven Method

WANG Shao-jie^{1,2}, QU Da-yi^{*1}, LIU Hao-min¹, MENG Yi-ming¹, CUI Shan-ning³

(1. School of Mechanical and Automotive Engineering, Qingdao University of Technology, Qingdao Shandong 266520, China;
2. Tianjin Road Transportation Business Development Service Center, Tianjin 300384, China;
3. School of Civil Engineering, Qingdao University of Technology, Qingdao Shandong 266520, China)

Abstract: The data-driven car-following model can fully explore the characteristics of car-following behavior in vehicle trajectory data, so as to realize the prediction of car-following behavior. To study the characteristics of car-following behavior, based on the measured trajectory data, using the data-driven method and combining the GM car-following model modeling ideas, based on the attention mechanism and the characteristics of the driver's attention to the important information mechanism when making car-following behavior decisions, the attention mechanism is added to establish a car-following model based on CNN-BiLSTM-Attention. The trajectory data that conforms to the car-following characteristics in NGSIM is screened and processed for noise reduction. The optimal model network structure is selected for training through experiments, and compared with data-driven car-following models such as LSTM, GRU and CNN-BiLSTM. The result shows that (1) compared with LSTM model, the car-following model based on CNN-BiLSTM-

收稿日期: 2021-12-29

基金项目: 国家自然科学基金项目 (51678320, 52272311)

作者简介: 王少杰 (1996-), 男, 河北定州人, 硕士. (1134846009@qq.com)

* 通讯作者: 曲大义 (1973-), 男, 山东青岛人, 博士, 教授. (dyqu@263.net)

Attention has a decrease of MAE by 38.12%, an increase of R^2 by 2.18%, and a decrease of MSE by 23.45%; (2) compared with GRU model, MAE decreases by 19.05%, R^2 increases by 1.13% and MSE decreases by 13.95%; (3) compared with the CNN-BiLSTM model, MAE decreases by 1.06%, R^2 increases by 0.15% and MSE decreases by 1.78%, indicating that the model has the best acceleration prediction performance and can better describe car-following behavior; (4) compared with the single model, the car-following model based on CNN-BiLSTM-Attention can better extract the features of traffic data and process the relationship among historical data, capture historical information and make corresponding decisions, the attention mechanism allows the model to focus on important parts of the input characteristics, thus providing higher prediction accuracy. The model can be used to predict vehicle acceleration, help to understand car-following characteristics, and provide theoretical basis for car-following behavior decision-making in the future.

Key words: ITS; data-driven; deep learning; car-following model; acceleration prediction

0 引言

随着城市化不断加快, 交通量不断增加, 交通拥堵等现象日益显著。车辆跟驰模型作为交通流领域研究热点, 研究车辆跟驰行为可以理解交通流运行特性, 从而解决拥堵等交通问题。跟驰模型可分为理论驱动类和数据驱动类。理论驱动类是指根据车辆跟驰行为, 运用运动学知识, 构建有明确物理意义的模型, 如 Pipes^[1] 构建的理论驱动类跟驰模型、GHR 模型^[2-3]、Helly^[4] 提出的刺激-反应类跟驰模型、FVD 模型^[5]、IDM 模型^[6]、Gipps 构建的安全距离类跟驰模型^[7]、分子跟驰模型^[8]、基于分子动力学的车流运行态性模型^[9]等。随着智能化的不断发展, 数据驱动模型逐渐兴起, 此类模型基于大量轨迹数据完成建模, 充分发掘数据信息之间的联系, 从而精准预测车辆跟驰行为。Kehtarnavaz 等^[10]应用 BP 神经网络建立车辆跟驰模型; 贾洪飞等^[11]基于 BP 神经网络理论建立模型, 模拟仿真车辆跟驰行为; Wei 等^[12]基于支持向量回归的理论构建跟驰模型, 误差评价指标显示, 该模型有较高的评价精度; Zhou 等^[13]提出了基于 RNN 的跟驰模型, 因输入变量考虑了时间序列数据, 故能够得到驾驶人的反应时间、预测能力或记忆效应, 可较好地重现交通震荡和区分驾驶人特征的能力; Wang 等^[14]应用门控循环单元神经网络结构对车辆跟驰行为进行建模, 该模型输入为最近几个时步的速度、相对速度与位移, 输出为速度, 并进行仿真试验, 预测效果良好; Huang 等^[15]提出基于 LSTM 神经网络的跟驰模型, 仿真结果显示该模型能够较好地捕获非对称驾驶行为; 孙倩等^[16]通过进行实车试验提取轨迹数据, 构建的基于 LSTM 的车辆跟驰模型稳定且可以消散交通

流中的扰动, 抗干扰能力与预测效果良好; 费蓉等^[17]构建了基于门控单元网络的车辆跟驰模型并进行了仿真试验, 仿真验证模型有效性。

上述数据驱动类跟驰模型有效预测驾驶员跟驰行为, 但不能有效提取输入数据特征以及加强对重要特征的关注。基于上述研究成果, CNN 可提取输入数据特征, BiLSTM 能够处理长时间序列数据并可以选择性获取与遗忘历史信息, 与人类驾驶过程中驾驶员根据不同的短期记忆决策一致, 并可以充分提取正向与反向的数据特征, Attention 机制可加强对输入特征中重要部分的重视程度。因此, 本研究构建了基于 CNN-BiLSTM-Attention 的车辆跟驰模型, 利用车辆轨迹数据训练模型与标定相关参数, 与 LSTM, GRU, CNN-BiLSTM 等数据驱动跟驰模型对比, 比较预测精度, 验证模型的预测精度。

1 考虑 GM 的数据驱动型跟驰行为建模

本研究结合 GM 跟驰模型思想, 进行基于 CNN-BiLSTM-Attention 的车辆跟驰模型的构建, 所应用到的理论基础有 GM 跟驰模型、CNN 模型、BiLSTM 神经网络结构、Attention 机制。

1.1 GM 跟驰模型

GM 跟驰模型^[3]是典型的刺激-反应类跟驰模型, 假设跟驰后车加速度与自身车速、两车相对速度和车头间距有关, 表达式为:

$$a_{n+1}(t+T) = \alpha \frac{v_{n+1}^m(t+T)}{[x_n(t) - x_{n+1}(t)]^l} \Delta v(t), \quad (1)$$

式中, $a_{n+1}(t+T)$ 为车辆 $n+1$ 在 $t+T$ 时刻的加速度; $v_{n+1}(t+T)$ 为车辆 $n+1$ 在 $t+T$ 时刻的速度; $\Delta v(t)$ 为两车在 t 时刻的相对速度; $x_n(t)$, $x_{n+1}(t)$ 分别为两车在 t 时刻的位移; T 为反应时间; α 为待标定的灵

敏度参数; m 和 l 为模型标定参数。

理论驱动模型中, 众多刺激-反应类跟驰模型均在 GM 跟驰模型的基础上建立, 该模型较为经典且应用广泛。GM 跟驰模型物理意义明确, 模型结构简单, 故本研究选择结合 GM 跟驰模型的建模思想进行建模。

1.2 CNN 模型

CNN 模型被用于图像识别、语音识别以及交通流预测等相关领域。CNN 模型由输入层、输出层和隐藏层构成, 隐藏层中核心为卷积层和池化层, 可实现提取数据特征、降低数据量的功能, 从而提高训练速度。卷积操作如图 1 所示, 以三阶卷积核为例。

$$\begin{bmatrix} x_{11} & x_{12} & x_{13} & x_{14} & \dots \\ x_{21} & x_{22} & x_{23} & x_{24} & \dots \\ x_{31} & x_{32} & x_{33} & x_{34} & \dots \\ \vdots & \vdots & \vdots & \vdots & \dots \\ x_{m1} & x_{m2} & x_{m3} & x_{m4} & \dots \end{bmatrix} \times \begin{bmatrix} \omega_{11} & \omega_{12} & \omega_{13} \\ \omega_{21} & \omega_{22} & \omega_{23} \\ \omega_{31} & \omega_{32} & \omega_{33} \end{bmatrix} = \begin{bmatrix} c_{11} & c_{12} & \dots \\ \vdots & \vdots & \dots \\ \vdots & \vdots & \dots \end{bmatrix}$$

图 1 卷积操作

Fig. 1 Convolution operation

三阶卷积核的卷积操作表达式为:

$$c_{ij} = \omega_{11}x_{11} + \omega_{12}x_{i(j+1)} + \dots + \omega_{33}x_{(i+2)(j+2)}, \quad (2)$$

式中, c_{ij} 为卷积结果; ω 为卷积核内数值; x 为输入数据。池化层进行特征选择以降低数据量, 从而得到强特征。池化层表达式如下:

$$z_i = \text{pool}(j_i), \quad (3)$$

式中, z_i 为池化层输出; j_i 为池化层输入; pool 为池化运算。CNN 模型可实现输入数据特征提取以及对输入特征内在联系进行深度挖掘, 故本研究选择 CNN 模型进行建模。

1.3 BiLSTM 神经网络结构

具有遗忘门的 LSTM 神经网络可以获取历史信息, 当历史数据信息过时, 可对记忆模块进行重置逐步去除, 这与人类的驾驶过程非常一致, 驾驶人根据不同的短期历史信息做出决策。LSTM 模型由输入层、隐藏层与输出层构成。其中隐藏层主要用于输入数据的特征学习, 其中以记忆模块为主要单元。LSTM 单元包含遗忘门 f_t 、输入门 i_t 和输出门 o_t , 遗忘门控制 $t-1$ 时刻细胞状态 c_{t-1} 遗忘的信息, 输入门控制 t 时刻输入 x_t 保留进入细胞状态 c_t 的信息, 输出门控制 t 时刻细胞状态 c_t 进入隐藏状态 h_t 的信息, 单元结构如图 2 所示。

LSTM 单元相关公式如下:

$$f_t = \sigma(W_{if}x_t + b_{if} + W_{hf}h_{t-1} + b_{hf}), \quad (4)$$




图 2 LSTM 单元

Fig. 2 Unit of LSTM

$$i_t = \sigma(W_{ii}x_t + b_{ii} + W_{hi}h_{t-1} + b_{hi}), \quad (5)$$

$$o_t = \sigma(W_{io}x_t + b_{io} + W_{ho}h_{t-1} + b_{ho}), \quad (6)$$

$$\tilde{c}_t = \tanh(W_{ic}x_t + b_{ic} + W_{hc}h_{t-1} + b_{hc}), \quad (7)$$

$$c_t = f_t \times c_{t-1} + i_t \times \tilde{c}_t, \quad (8)$$

$$h_t = o_t \times \tanh(c_t), \quad (9)$$

式中, W_{if} , W_{hf} , W_{ii} , W_{hi} , W_{io} , W_{ho} , W_{ic} , W_{hc} 为权重矩阵; b_{if} , b_{hf} , b_{ii} , b_{hi} , b_{io} , b_{ho} , b_{ic} , b_{hc} 为偏置。

σ 为 siomoid 激活函数, 公式如下:

$$\sigma = \frac{1}{1 + e^{-x}}. \quad (10)$$

$\tanh$ 为激活函数, 公式如下:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (11)$$

LSTM 只能够获得正向传递而来的历史信息, 导致预测过程中出现滞后现象。BiLSTM 由方向相反的 2 个 LSTM 神经网络单元组成, 可同时考虑正向与反向两方向的数据信息。对正、反向两方向数据进行预测, 2 个独立隐藏层可分别处理两方向数据, 其输出由两方向的输出共同决定, 从而减小预测误差, 故选择 BiLSTM 神经网络进行建模, 如图 3 所示。




图 3 BiLSTM 结构

Fig. 3 Structure of BiLSTM

1.4 Attention 机制

注意力机制是指人脑处理应对特定信息时, 会将注意力集中在关键区域, 以获得重要信息^[18]。注意力机制对输入特征赋予权重, 从而着重关注输入特征重要部分, 结构如图 4 所示。




图 4 Attention 结构

Fig. 4 Structure of Attention

Attention 内部结构相关公式如下:

$$e_i = v \tanh(W h_i + b), \quad (12)$$

$$\alpha_i = \frac{\exp e_i}{\sum_{j=1}^n e_j}, \quad (13)$$

$$c_i = \sum_{j=1}^n \alpha_j h_j, \quad (14)$$

式中, e_i 为 t 时刻特征对应权重; α_i 为 t 时刻特征对应注意力权重; v , W 为共享权重; b 为偏置; c_i 为 t 时刻的输出。Attention 机制可自动调节初始输入特征对应隐藏层状态值, 对输入特征加权, 从而突出输入特征中重要特征。与驾驶员跟驰决策过程中着重关注重要信息机制相一致, 故本研究选择引入 Attention 机制完成模型构建。

1.5 CNN-BiLSTM-Attention 跟驰模型

使用 Keras 完成基于 CNN-BiLSTM-Attention 跟驰模型的构建与训练, 后端使用 TensorFlow。选择合适的输入与输出可提高模型的精确度, 结合 GM 模型思想, 输入为 t 时的跟驰后车速度 $v_{n+1}(t)$ 、两车 t 时速度差 $\Delta v(t)$ 与 t 时两车间距 $\Delta x(t)$ 作为输入, 输出为将下一时间间隔跟驰后车加速度 $a_{n+1}(t+\Delta t)$, 确定输入输出后建立模型, 目标函数如下所示:

$$a_{n+1}(t+\Delta t) = f[v_{n+1}(t), \Delta v(t), \Delta x(t)], \quad (15)$$

CNN-BiLSTM-Attention 模型由 CNN 层、BiLSTM 层、Attention 层与全连接层构成, 如图 5 所示。。CNN 层可实现提取输入数据特征, BiLSTM 可充分提取正向与反向特征, Attention 层加强模型对重要特征的关注。




图 5 CNN-BiLSTM-Attention 模型结构

Fig. 5 Structure of CNN-BiLSTM-Attention model

2 模型参数设置

2.1 数据处理

本研究采用 NGSIM (Next Generation Simulation) 项目中美国加州 I-80 高速公路东行方向收集的车辆轨迹数据作为数据集。数据由架设在毗邻 I-80 高速公路的高楼的 7 台摄像机获取, 帧频为 10 帧/s。数据采集路段长为 503 m, 共 6 个车道, 车道 1 为多乘员车道, 车道 6 为入口匝道, 数据采集路段情况如图 6 所示。




图 6 I-80 路段具体情况 (单位: m)

Fig. 6 Specific situation of I-80 road section (unit: m)

本研究对车辆跟驰行为及其微观特性进行研究, 为充分反映加速度变化交通流状况, 选取道路状况为拥堵时的轨迹数据, 即下午 05:00—05:15 时段数据集。为得到充足的符合车辆跟驰特性的轨迹数据, 以完成跟驰模型的训练与标定, 需对上述数据集进行筛选, 原则如下:

- (1) 筛选车辆类型为 2 的车辆, 即小型车, 避免不同车辆造成跟驰特性的不同;
- (2) 剔除车道 1 和车道 6, 保证驾驶行为一致;
- (3) 剔除前后方都无车的车辆;
- (4) 筛选未变换车道的车辆, 避免变换车道的车辆影响;
- (5) 剔除车头间距小于 5 m, 大于 60 m 的轨迹数据, 视为跟驰行为解除;
- (6) 筛选跟驰时间超过 60 s 的轨迹数据, 确保完整的跟驰过程及充足的轨迹数据。

数据集通过计算机识别技术提取视频图像获取, 存在大量测量误差与异常值, 不能满足车辆微观行

为特性研究需求,需进行数据降噪。通过移动平均法完成数据降噪,以 vehicleID 为 295 的车辆为例,速度与加速度降噪结果如图 7 所示。




图 7 降噪结果

Fig. 7 Result of noise reduction

筛选降噪处理后共得到 266 778 条数据,数据中 80%用于模型训练,其余 20%用于模型验证。对预处理后的数据进行归一化处理,将原始数据映射到 [0-1] 之间,以消除量纲的影响,公式如下:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (16)$$

式中, $x_{\max}$ 为原始数据最大值; $x_{\min}$ 为原始数据最小值。

2.2 评价指标选择

选择平均绝对误差 MAE、拟合系数 R^2 和均方误差 MSE 作为评价指标。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i|, \quad (17)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\tilde{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2}, \quad (18)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2, \quad (19)$$

式中, n 为评价数据样本总数; y_i 为评价数据真实值; $\bar{y}_i$ 为评价数据真实值均值; $\tilde{y}_i$ 为预测值。

2.3 参数设置

模型参数决定了预测精度,为提高模型预测精度,通过试验验证,设置 CNN 层卷积核大小为 1×1 ,

卷积步长设为 1,激活函数设置为 ReLU,优化器选择 Adam,损失函数设置为 MSE,批量大小选择 64。部分超参数如表 1 所示。

表 1 超参数设置

Tab. 1 Hyperparameter setting

参数	设置	参数	设置
卷积核大小	1×1	优化器	Adam
卷积步长	1	损失函数	MSE
激活函数	ReLU	批量大小	64

跟驰模型决策密切依赖历史驾驶行为,历史时间步长影响模型预测精度。对历史时间步长进行试验选择,确定最优历史时间步长和最优模型结构。首先固定模型结构,为节约训练时间,CNN 与 BiLSTM 均采用单隐藏层、神经元个数为 64 的简单结构,分别对 1, 3, 5, 7, 10 s 的历史时间步长进行试验,以 MSE 为依据,确定最优时间步长,结果如图 8 所示,最优时间步长为 5 s,即为 50 步。




图 8 时间步长

Fig. 8 Time steps

对不同结构的模型进行试验,依据评价指标选取预测准确度最高的模型。在 1 层 CNN 时,卷积核数量为 64;在 2 层 CNN 时,各层卷积核数量均为 64;在 3 层 CNN 时,卷积核数量分别为 64, 64, 128。BiLSTM 每层单元数为 64,具体设置如表 2 所示。

表 2 模型深度与宽度设置

Tab. 2 Depth and width settings of models

层数	CNN 卷积核数量/个		BiLSTM 单元数/个	
1	—	—	64	64
2	—	64	64	64
3	128	64	64	64

对不同结构模型进行试验,对比结果如表 3 所示。由表 3 不同模型结构可知,CNN 层数为 3、BiLSTM 层数为 2 时,该模型的 MAE 与 MSE 最小,

R^2 最大, 确定为最佳模型结构。

表 3 不同结构评价结果

Tab. 3 Evaluation result of different structures

CNN 层数	BiLSTM 层数	MAE	R^2	MSE
1	1	0.041 2	0.926 9	0.012 3
	2	0.063 5	0.915 8	0.014 2
	3	0.041 0	0.924 3	0.012 7
2	1	0.042 8	0.927 1	0.012 3
	2	0.047 4	0.927 2	0.012 3
	3	0.040 9	0.925 9	0.012 5
3	1	0.044 4	0.923 1	0.013 0
	2	0.037 3	0.929 0	0.012 0
	3	0.043 2	0.926 3	0.012 4

3 实例验证分析

为验证基于 CNN-BiLSTM-Attention 的车辆跟驰模型的预测精度, 分别选取数据驱动模型中的 LSTM 模型、GRU 模型和 CNN-BiLSTM 模型进行对比分析。LSTM 与 GRU 均设置 2 个隐藏层, 每层 64 个神经元, 其余参数设置均与 CNN-BiLSTM-Attention 保持相同。CNN-BiLSTM 除不加 Attention 层外, 其余参数设置均与 CNN-BiLSTM-Attention 保持相同。为保证公平性, 模型输入与输出保持相同, 评价指标为 MAE, R^2 和 MSE。以 VehicleID 为 2061 的预测数据为例, 各模型对比效果如图 9 所示。

由图 9 可知, LSTM 与 GRU 在加速度剧烈变化时与测试值拟合效果较差, 即预测效果较差, 会出现较大误差的突变。CNN-LSTM 模型与 CNN-BiLSTM-Attention 拟合效果较好, 即可较好地预测加速度, 且 CNN-BiLSTM-Attention 预测精度优于 CNN-BiLSTM。由局部图可知, 在加速度剧烈变化时, CNN-BiLSTM-Attention 仍可以较好地预测, 且预测精度优于其他模型。

由表 4 可知, CNN-BiLSTM-Attention 模型 MAE 与 MSE 最小, R^2 最大, 即该模型对加速度预测精度最高, CNN-BiLSTM-Attention 跟驰模型优于其他跟驰模型。与 LSTM 模型相比, MAE 减少约 38.12%, R^2 提高约 2.18%, MSE 减少约 23.45%。与 GRU 模型相比, MAE 减少约 19.05%, R^2 提高约 1.13%, MSE 减少约 13.95%, CNN-BiLSTM-Attention 模型与单一模型相比, 可更好地提取数据特征并处理历史数据间的关系, 捕捉历史信息并做出相应决策。与 CNN-BiLSTM 模型相比, MAE 减少约 1.06%, R^2 提




图 9 模型预测对比

Fig. 9 Model prediction comparison

高约 0.15%, MSE 减少约 1.78%, 表明由于 Attention 机制突出重要输入特征部分, 提高了模型的预测精度。

表 4 模型预测评价

Tab. 4 Model prediction evaluation

模型	评价指标		
	MAE	R^2	MSE
LSTM	0.060 6	0.914 2	0.014 5
GRU	0.046 3	0.923 6	0.012 9
CNN-BiLSTM	0.037 9	0.932 6	0.011 3
CNN-BiLSTM-Attention	0.037 5	0.934 0	0.011 1

4 结论

本研究筛选了符合跟驰特性的车辆轨迹数据, 经过数据降噪处理得到跟驰数据集。结合 GM 跟驰模型思想, 将 t 时刻的后车速度 $v_{n+1}(t)$ 、两车 t 时的速度差 $\Delta v(t)$ 与车间距 $\Delta x(t)$ 作为输入, 将下一时间间隔跟驰后车加速度 $a_{n+1}(t+\Delta t)$ 作为输出, 构建了基于 CNN-BiLSTM-Attention 的车辆跟驰模型。通过试验确定最优模型结构, 将所建立跟驰模型与 LSTM 跟驰模型、GRU 跟驰模型与 CNN-LSTM 跟驰模型进行对比。结果表明, 基于 CNN-BiLSTM-Attention 的车辆跟驰模型具有更高的预测精度。复杂的网络结构在保证高精度预测的同时, 模型训练时间也随之变长, 未来不断改进模型, 实现在保证

预测精度的同时,减少训练时间。未来可应用不同地区的轨迹数据训练模型,同时实现车辆轨迹预测。

参考文献:

References:

- [1] PIPES L A. An Operational Analysis of Traffic Dynamics [J]. Journal of Applied Physics, 1953, 24 (3): 274-281.
- [2] GAZIS D C, HERMAN R, Potts R B. Car-following Theory of Steady-state Traffic Flow [J]. Operations Research, 1959, 7 (4): 499-505.
- [3] GAZIS D C, HERMAN R, ROTHERY R W. Nonlinear Follow-the-leader Models of Traffic Flow [J]. Operations Research, 1961, 9 (4): 545-567.
- [4] HELLY W. Simulation of Bottlenecks in Single-lane Traffic Flow [J]. Theory of Traffic Flow, 1959: 207-238.
- [5] JIANG R, WU Q, ZHU Z. Full Velocity Difference Model for a Car-following Theory [J]. Phys Rev E Stat Nonlin Soft Matter Phys, 2001, 64: 017101.
- [6] HELBIG D, HENNECKE A, SHVETSOV V, et al. Micro and Macro-simulation of Freeway Traffic [J]. Mathematical and Computer Modelling, 2002, 35 (5/6): 517-547.
- [7] GIPPS P G. A Behavioural Car-following Model for Computer Simulation [J]. Transportation Research Part B Methodological, 1981, 15 (2): 105-111.
- [8] 李娟, 曲大义, 刘聪, 等. 基于分子动力学的跟驰特性及其模型 [J]. 公路交通科技, 2018, 35 (3): 126-131.
- LI Juan, QU Da-yi, LIU Cong, et al. Car-following Characteristics and Its Models Based on Molecular Dynamics [J]. Journal of Highway and Transportation Research and Development, 2018, 35 (3): 126-131.
- [9] 曲大义, 李娟, 刘聪, 等. 基于分子动力学的车流运行动态特性及其模型 [J]. 交通运输系统工程与信息, 2017, 17 (4): 188-194.
- QU Da-yi, LI Juan, LIU Cong, et al. Dynamic Characteristics Model of Traffic Flow Based on Molecular Dynamics [J]. Journal of Transportation Systems Engineering and Information Technology, 2017, 17 (4): 188-194.
- [10] KEHTARNAVAZ N, GROSWOLD N, MILLER K, et al. A Transportable Neural-network Approach to Autonomous Vehicle Following [J]. IEEE Transactions on Vehicular Technology, 1998, 47 (2): 694-702.
- [11] 贾洪飞, 隗志才, 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, 18 (4): 92-94.
- JIA Hong-fei, JUAN Zhi-cai, WANG Xiao-yuan. Development of a Car-following Model Based on Artificial Neural Networks [J]. Journal of Highway and Transportation Research and Development, 2001, 18 (4): 92-94.
- [12] WEI D, LIU H. Analysis of Asymmetric Driving Behavior Using a Self-learning Approach [J]. Transportation Research Part B: Methodological, 2013, 47: 1-14.
- [13] ZHOU M, QU X, LI X. A Recurrent Neural Network Based Microscopic Car Following Model to Predict Traffic Oscillation [J]. Transportation Research Part C: Emerging Technologies, 2017, 84: 245-264.
- [14] WANG X, JIANG R, LI L, et al. Capturing Car-following Behaviors by Deep Learning [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19 (3): 910-920.
- [15] HUANG X, SUN J, SUN J. A Car-following Model Considering Asymmetric Driving Behavior Based on Long Short-term Memory Neural Networks [J]. Transportation Research Part C: Emerging Technologies, 2018, 95: 346-362.
- [16] 孙倩, 郭忠印. 基于长短期记忆神经网络方法的车辆跟驰模型 [J]. 吉林大学学报 (工学版), 2020, 50 (4): 1380-1386.
- SUN Qian, GUO Zhong-yin. Vehicle Following Model Based on Long Short-term Memory Neural Network [J]. Journal of Jilin University (Engineering and Technology Edition), 2020, 50 (4): 1380-1386.
- [17] 费蓉, 刘方, 谢国, 等. 基于门控循环单元的车辆跟驰行为仿真模型 [J]. 系统仿真学报, 2020, 32 (10): 1862-1873.
- FEI Rong, LIU Fang, XIE Guo, et al. GRU-based Car-following Behavior Simulation Model [J]. Journal of System Simulation, 2020, 32 (10): 1862-1873.
- [18] 崔宇, 侯慧娟, 胥明凯, 等. 基于双重注意力机制的变压器油中溶解气体预测模型 [J]. 中国电机工程学报, 2020, 40 (1): 338-347, 400.
- CUI Yu, HOU Hui-juan, XU Ming-kai, et al. A Prediction Method for Dissolved Gas in Power Transformer Oil Based on Dualstage Attention Mechanism [J]. Proceedings of the CSEE, 2020, 40 (1): 338 - 347, 400.