

基于LSTM的跟驰车辆反应时间预测模型

耿志军¹,程 陆²,李舟洋²,柏海舰²,汪雪松³

(1. 安徽省综合交通研究院股份有限公司,安徽省合肥市,230088;

2. 合肥工业大学,安徽省合肥市,230009;3. 认知智能国家重点实验室,安徽省合肥市,230088)

摘要 影响跟驰反应时间的主客观因素较为复杂,目前利用深度学习对跟驰反应时间的预测的研究较少。首先对数据集中跟驰轨迹的刺激点和反应点进行筛选,并计算每条轨迹的反应时间。其次,建立基于LSTM的跟驰反应时间预测模型,对数据集中的跟驰车辆反应时间进行预测。最后,对模型进行测试,通过测试结果可知:该模型可以对车辆的跟驰反应时间进行较好的预测,其预测值与真实值具有较高的拟合度,并且其预测结果较于BP跟驰车辆反应时间预测模型具有较高的精准度。

关键词 跟驰模型;反应时间;LSTM;数据驱动

中图分类号:U491 文献标识码:B

文章编号:1008-0899(2024)08-0071-03

车辆跟驰行为是描述同一车道上前两车在行驶车队中的相互作用,是研究微观交通流的基础交通行为^[1],而跟驰反应时间对于跟驰行为以及跟驰模型的建立尤为重要。国内外学者对预测驾驶员跟驰反应时间的研究一直在不断的深入:Kho-dayar^[2]等基于观察到的车辆轨迹数据,将处于跟驰状态下前后车相对速度发生突变后,直至后车加速度出现突变前这段时间定义为反应时间,但并未给出具体公式计算反应时间。Zheng^[3]等人认为驾驶员更容易感知车头间距的变化,因此将车头间距发生突变之后,后车速度发生突变之前这段时间定义为反应时间。

因为影响跟驰反应时间的主客观因素较为复杂,目前利用深度学习对跟驰反应时间的预测的研究较少,因此本文提出了基于LSTM的跟驰反应时间预测模型,对跟驰数据中的跟驰反应时间进行预

测,选取跟驰轨迹的车头间距、后车速度、相对速度和后车加速度作为预测模型的输入,计算跟驰数据中的反应时间。

1 刺激点与反应点的筛选

驾驶员的跟驰反应时间即跟驰轨迹中刺激点出现的时刻与反应点出现的时刻之间的时间间隔。考虑到在跟驰过程中,驾驶员对前后车车头间距变化的感知能力强于对前后车相对速度变化的感知能力,因此将前后车车头间距轨迹发生突变的点定义为刺激点,将跟驰车辆速度轨迹发生突变的点定义为反应点。

由于Ozaki反应时间预测模型^[4]的标定较为复杂和其准确性较差等因素。本文采用LSTM神经网络模型预测跟驰轨迹的反应时间,因此需要获得带有跟驰反应时间标签的训练集。本文在图1中所示的标记的箭头中的时刻即为本文当中设定的跟驰反应时间。车头间距突变点的判断,如公式(1)所示,其中 t_0 时刻为突变点, $\Delta x(t_0)$ 为 t_0 时刻的车头间距, i 为时间步;对于后车速度突变点的判断见公式(2),突变时刻为 t_1 , $v(t_1)$ 为 t_1 时刻的后车速度;满足公式(1)~(2)的条件,即可将 t_0 时刻记做刺激点, t_1 时刻记做反应点;公式(3)中, τ 即为反应时间,最大取2s。

$$\text{当前车减速时} \begin{cases} \Delta x(t_0) - \Delta x\left(t_0 \pm \frac{i}{10}\right) \geq 0, i = 1, 2, \dots, m \\ v(t_1) - v\left(t_1 \pm \frac{i}{10}\right) \geq 0, i = 1, 2, \dots, m \end{cases} \quad \#(1)$$

基金项目:安徽省自然科学基金面上项目:面向自主协同的拟人驾驶复杂行为决策方法研究(JZ2022AKZR0413);认知智能国家实验室开放课题:考虑交通状态时空演变的CAV专用道动态规划与智能管控(W2022JSKF0504)

作者简介:耿志军(1980~),男,汉族,河北蔚县人,硕士,高级工程师要研究方向:智能交通。

$$\text{当前车加速时} \begin{cases} \Delta x(t_0) - \Delta x\left(t_0 \pm \frac{i}{10}\right) < 0, i = 1, 2, \dots, m \\ v(t_1) - v\left(t_1 \pm \frac{i}{10}\right) < 0, i = 1, 2, \dots, m \end{cases} \quad \#(2)$$

$$\tau = t_1 - t_0, 0 \leq \tau \leq 2\#(3)$$

式中： t_0 :刺激点时刻; $\Delta x(t_0)$: t_0 时刻前后车车头间距, m; t_1 :反应点时刻; $v(t_1)$: t_1 时刻后车速度, m/s; τ :反应时间, s; i :时间步长; m :任意正整数, 由于 $0 \leq \tau \leq 2$, 本文 m 取20。

NGSIM I-80数据集是美国联邦公路管理局收集的 交通数据集, 并将所收集的数据集公开。本文首先从NGSIM I-80数据集中提取出跟驰轨迹, 然后通过选用对称指数滑动平均法^[5]对跟驰轨迹进行平滑处理, 得到平滑后的跟驰轨迹数据, 然后基于上文公式(1)~(3)的筛选规则, 通过程序筛选出4896组刺激反应点。

在对筛选出的刺激反应点进行检查时发现其中含有许多无效的刺激反应点。因为这些刺激反应点在左右邻域的突变幅度或者突变范围较小, 大都是驾驶员在驾车时车辆运行状态的波动, 所以判断出这些点是无效刺激反应点。重新对刺激点进行分析, 通过人工辨识发现真实刺激点具备突变范围较大, 突变持续的时间也较长的特点, 因此对突变幅度和突变范围额外增加附属约束:

$$|\Delta x(t_0)| \geq a\# \quad (4)$$

$$|v(t_1)| \geq b\# \quad (5)$$

式中: $\Delta x(t_0)$: t_0 时刻前后车车头间距, m; $v(t_1)$: t_1 时刻后车速度, m/s; a 据统计数据, 本文取0.5; b 据统计数据, 本文取2.5。

在NGSIM I-80数据集中每一条跟驰轨迹中, 记录每一个刺激反应点, 最终得到518组准确的刺激反应点。并将518组准确的刺激反应点选取80%作为训练集, 训练反应时间预测模型的训练集, 剩余20%作为模型的测试集, 测试模型的预测结果。选取一条标注好刺激反应点的跟驰轨迹展示, 见图1。图1所示的是前车ID为243, 后车ID为250的车头间距与后车速度轨迹。从图1可以看出, 增加附属约束选出的轨迹, 在箭头两端的突变点, 是本文需要的刺激反应点。




图1 有效刺激反应点

对增加附属约束筛选的反应时间分布情况进行分析, 在增加附属约束后筛选的最小跟驰反应时间为0.2s, 最大跟驰反应时间为3.5s, 其中大多数分布在1s附近。当反应时间大于2.5s时, 样本量累计百分比已经达到了99.2%, 因此得出驾驶员的跟驰反应时间主要集中在0.2s~2.5s。

2 基于LSTM的跟驰车辆反应时间预测模型

LSTM作为循环神经网络(RNN)的一种, 其链式网络结构决定它在处理序列数据时要优于其他种类的神经网络模型, LSTM神经网络在理论上可以考虑超过1000个时间步长的历史信息^[6], 所以, 采用LSTM神经网络对驾驶员反应时间进行建模。本文的模型中, 输入变量是车头间距、后车速度、相对速度、后车加速度, 输出变量是后车反应时间, 基于以上的输入和输出变量, 确定了采用多对一的LSTM神经网络。

LSTM网络结构采用控制门的机制, 由记忆细胞、输入门、输出门、遗忘门组成。下面介绍各个控制门的计算原理。

首先计算输入门在 t 时刻输入细胞的候选状态值 $\tilde{c}(t)$, 公式如下:

$$\tilde{c}(t) = \tanh(w_c[h(t), x(t)] + b_c)\# \quad (6)$$

其次, 计算在 t 时刻遗忘门的激活值, 公式如下:

$$\sigma_f = \sigma(W_f[h(t), x(t)] + b_f)\# \quad (7)$$

$$\sigma_u = \sigma(W_u[h(t), x(t)] + b_u)\# \quad (8)$$

$$\sigma_o = \sigma(W_o[h(t), x(t)] + b_o)\# \quad (9)$$

由以上两步的计算, 就可以计算出 $t + 1$ 时刻的细胞状态更新值 $c(t + 1)$, 公式如下

$$c(t + 1) = \sigma_u * \tilde{c}(t + 1) + \sigma_f * c(t)\# \quad (10)$$

在计算得到细胞状态更新值后, 最后就可以计算输出门的值, 其计算公式如下:

$$h(t+1) = \sigma_o * \tanh(c(t+1)) \# \quad (11)$$

$$T(t+1) = W_a h(t+1) + b_a \# \quad (12)$$

公式(6)-(12)是LSTM一个单元的结构,公式(12)是一个全连接层,将单元中的高维数据映射到一维, $\theta = \{W_c, W_u, W_f, W_o, b_c, b_u, b_f, b_o, W_a, b_a\}$, $T(t+1)$ 是第 n 辆车在 $t+1$ 时刻的反应时间预测值。通过以上的计算,LSTM就可以有效地利用输入来使其具有长时期的记忆功能。

3 模型的验证与分析

在18epoch之后,LSTM的反应时间预测模型的损失函数随epoch的变化,训练集和测试集的损失函数都保持在较低水平,并且其二者的损失函数值较为一致,由此可见并未出现过拟合的问题。

基于结构的反应时间预测模型预测驾驶员反应时间。在模型结构最优的前提下,再经过多次训练,选择当预测结果最优时对应的模型参数作为反应时间预测模型参数,现得到真实的和预测的反应时间分布图,具体见图2。




图2 预测与真实反应时间分布图

由图2可以直观的看出,预测的反应时间比真实的反应时间分布更为紧凑,且主要集中在1s周围。图2预测的1s反应时间的样本量大致为50。相较相同的反应时间下,预测反应时间的样本量和实际的反应时间的样本量极为接近,说明本文建立的基于LSTM预测反应时间的模型预测准确度较高,对于LSTM网络而言,每输入一步,每一层各自共享参数,使得能大大减少网络中需要学习的参数,从而降低计算复杂度。证明了LSTM时间递归神经网络用于跟驰反应时间预测的优越性。

将每条轨迹的实际的反应时间值同预测的反应时间值进行拟合,拟合结果趋近于正比例函数曲线,说明本文构建的LSTM跟驰车辆反应时间预测模型的预测值与实际值有较高的拟合度。

抽取10条轨迹,并将LSTM跟驰车辆反应时间

预测模型的预测值同BP跟驰车辆反应时间预测模型的预测值与反应时间真实值进行对比。两个预测模型,均可以对每条轨迹的车辆跟驰反应时间进行预测,而LSTM跟驰车辆反应时间预测模型预测结果相较于BP跟驰车辆反应时间预测模型具有更高的精确性。

4 结语

本文首先从NGSIM I-80数据集中筛选出刺激点与反应点,并得出车辆跟驰反应时间,在此基础上将后车速度、相对速度、后车加速度、车头间距四个参数作为反应时间预测模型的输入,将后车跟驰反应时间作为模型的输出,构造了基于LSTM的跟驰反应时间预测模型。通过分析,该模型可以对车辆的跟驰反应时间进行较好的预测,其预测值与真实值具有较高的拟合度,并且其预测结果较于BP跟驰车辆反应时间预测模型具有较高的精准度。

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(01):115-127.
- [2] Khodayari A, Ghaffari A, Kazemi R, et al. A modified car-following model based on a neural network model of the human driver effects[J]. IEEE Transactions on Systems, Man, and Cybernetics-part A: Systems and Humans, 2012,42(6):1440-1449.
- [3] Zheng J, Suzuki K, Fujita M. Car-following behavior with instantaneous driver-vehicle reaction delay: A neural-network-based methodology[J]. Transportation Research Part C: Emerging Technologies, 2013, 36: 339-351.
- [4] Ozakis H, Reaction and anticipation in the car-following behavior[C]. California, USA: the International Symposium on the Theory of Traffic Flow and Transportation, 1993.
- [5] Christian T., Martin T., Arne K. Estimating Acceleration and Lane-Changing Dynamics from Next Generation Simulation Trajectory Data [J]. Transportation Research Record: Journal of the Transportation Research Board, 2008, 2088: 90-101.
- [6] Felix A. Gers, Nicol N. Schraudolph, Juergen Schmidhuber. Learning Precise Timing with LSTM Recurrent Networks[J]. Journal of machine learning research, 2003,3(1).