

基于改进 LSTM-NN 的安全性自动驾驶换道轨迹规划模型

熊明强^{1,2}, 谯杰^{1,2}, 夏芹²

(1. 汽车噪声振动和安全技术国家重点实验室, 重庆 401122; 2. 中国汽车工程研究院股份有限公司 重庆 401122)

摘要: 为改善现有的自动驾驶换道轨迹规划模型产生的换道轨迹与真实的换道轨迹存在较大偏差的问题, 提出了一种改进 LSTM-NN 的安全敏感性深度学习模型, 该模型可以缓解当前自动驾驶轨迹规划存在的不足, 输出轨迹既保证了较高的精度又提高了安全性。CarSim 仿真软件模拟了本模型产生轨迹的可跟踪性, 结果显示轨迹非常平滑, 并且自动驾驶车辆可以高效、安全地完成换道。

关键词: 深度学习; 换道执行; 自动驾驶; 安全性; 轨迹规划

中图分类号: U491.2 文献标志码: A DOI: 10.3969/j.issn.2095-1469.2021.06.04

A Lane-Changing Trajectory Planning Model for Automated Vehicles Based on Improved Safety-Sensitive LSTM-NN

XIONG Mingqiang^{1,2}, QIAO Jie^{1,2}, XIA Qin²

(1. State Key Laboratory of Vehicle NVH and Safety Technology, Chongqing 401122, China;
2. China Automotive Engineering Research Institute Co., Ltd., Chongqing 401122, China)

Abstract: To reduce the deviations between the planned and real lane-changing trajectories, this paper proposes an improved safety-sensitive LSTM neural network for lane-changing trajectory planning of autonomous vehicles. The trajectories generated by this model were simulated using CarSim. The results show that the produced trajectories are very smooth and the automated vehicle can complete the lane changing process efficiently and safely following the trajectory planned. The proposed deep learning model produces more accurate output trajectories ensuring higher level of safety.

Keywords: deep learning; lane-changing maneuver; automatic driving; safety; path planning

自动驾驶近年受到全世界广泛关注^[1-10], 普遍认为该技术可以有效解决交通拥堵, 提高交通安全性^[1, 6, 11]。目前一些自动驾驶厂商已经进行了大规模的道路测试, 比如谷歌自动驾驶汽车和苹果自动驾驶汽车。然而, 由于交通系统的复杂性, 现在的自动

驾驶或多或少都存在着一些安全性问题, 导致这些自动驾驶车辆在进行测试时发生了一系列事故, 其主要原因是自动驾驶车辆内部的自动驾驶算法不足以应对动态变化的交通环境。据研究^[12], 目前近三分之一的交通事故是由不安全的换道操作导致的。

收稿日期: 2021-01-13 改稿日期: 2021-02-05

基金项目: 国家重点研发计划 (2017YFB0102604)

参考文献引用格式:

熊明强, 谯杰, 夏芹. 基于改进 LSTM-NN 的安全性自动驾驶换道轨迹规划模型 [J]. 汽车工程学报, 2021, 11(6): 419-426.
XIONG Mingqiang, QIAO Jie, XIA Qin. A Lane-Changing Trajectory Planning Model for Automated Vehicles Based on Improved Safety-Sensitive LSTM-NN [J]. Chinese Journal of Automotive Engineering, 2021, 11(6): 419-426. (in Chinese)



利用机器学习进行人类换道执行模型属于数据驱动模型,其模型参数需要经过大量换道执行数据的训练而确定。目前,利用机器学习进行人类换道轨迹规划的研究还很少^[13-15],YAO Wen 等^[13]将 k 最近邻算法应用到换道轨迹规划中,然而该模型用到的数据量非常有限;考虑到已有的机器学习算法只能预测换道车辆的位置,DING Chenxi 等^[14]构建了两层 BP 神经网络对车辆换道进行实时预测,该模型对 NGSIM 数据^[16]进行学习,在已有研究的基础上扩大了数据量。但是,换道数据是一种时间序列,以上两种机器学习方法只是单一的复制车辆在某个状态下的位置,并没有考虑到换道时每个规划步长之间的换道数据存在联系^[17]。在此基础上,XIE Dongfan 等^[15]构建了 LSTM 神经网络对车辆换道轨迹进行预测,对于人类换道轨迹学习取得了 99% 以上的精度。尽管都是在对人类换道行为进行学习,但这些研究没有考虑到换道过程中产生的安全性问题,而基于规则的换道模型对于换道轨迹的数学描述不统一,产生了大量的轨迹曲线方程,比如极坐标多项式轨迹和五次多项式的轨迹等^[18-27]。此外,对何种方程可以最佳地描述换道轨迹曲线尚无定论,当前对换道过程的运动学模型描述也有较大的误差,考虑到现有方法存在的不足,本文对 LSTM 神经网络进行了改造,提出了一种新的基于安全性敏感的改进长短期记忆网络的自动驾驶换道轨迹规划模型。

1 改进 LSTM 神经网络换道模型

1.1 改进 LSTM 神经网络结构

用传统运动学描述自动驾驶换道轨迹规划的方式存在着误差大、无法发现隐形因素之间的关系、不能充分利用真实数据等方面的不足。LSTM^[28]神经网络可以弥补以上不足,且相对其他深度学习方法可以更好地处理时间序列数据,但经典 LSTM 神经网络无法对换道数据的安全性进行判别和校验,因此选择 LSTM 神经网络进行改进。传统 LSTM 神经网络主要由“遗忘门、输入门、输出门、状态”组成,这些“门”结构实际上是全连接神经网络构成的,如图 1 所示。




图 1 经典 LSTM 神经网络结构

LSTM 神经网络有着高效的学习优势,这种神经网络被认为是研究和预测时间序列极佳的方法,但由于神经网络中隐层神经元的物理作用不明确,训练过程不可控,这样建立的换道轨迹规划模型可能隐含着人类不良驾驶习惯,最终无法满足安全性和舒适性的换道要求,所以在传统 LSTM 神经网络中引入“安全门”,在训练过程中对数据进行安全性监控和校验,有目的地提高模型安全性,“安全门”输入的运动学轨迹包括最优轨迹约束和安全性约束数据,从而提出安全性敏感的自动驾驶换道轨迹规划 LSTM 神经网络模型,嵌入结构如图 2 虚线框所示。




图 2 改进 LSTM 神经网络结构

在这个结构中,神经网络的输入数据 x_t 包括换道车辆以及周边车辆的轨迹数据, x_t 将会同时被传递给各个“门”结构以及嵌入的运动学模型结构,进行神经网络的迭代训练。改进之后的 LSTM 神经网络如图 3 所示。




图 3 改进 LSTM 神经网络结构

1.1.1 神经网络各个部分的计算方式

当前时刻数据传入长短期记忆网络时要决定哪些历史数据需要从细胞状态 h_{t-1} 中删除。这是由遗忘门决定的：

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

式中： W_f 为遗忘门的权重； h_{t-1} 为上一时刻神经网络的状态； x_t 为 NGSIM 数据中换道轨迹规划数据； b_f 为遗忘门的偏置项； σ 为一个 sigmoid 函数，用于增强神经网络的非线性拟合能力，其表达式为：

$$\sigma(x_t) = \frac{1}{1 + e^{-x_t}} \quad (2)$$

此时，神经网络状态为：

$$C_t^0 = f_t \cdot C_{t-1} \quad (3)$$

式中： C_t^0 为数据经过遗忘门之后神经元的状态。

神经元删除历史数据后还需决定哪些新的信息需要被存储进细胞状态：输入门中包括一个类似于遗忘门的结构，用于在训练过程中决定需要更新的数据，然后一个 $\tanh$ 函数会从当前时刻的输入数据中确定更新的向量，从而更新到神经元状态中：

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (5)$$

式中： W_i 为输入门中决定遗忘的数据权重； b_i 为对应的偏置项； $\tilde{C}_t$ 为准备更新的数据矩阵； W_c 为更新数据的权重矩阵； b_c 为更新数据的偏执项。 $\tanh$ 为双曲正切函数，同样用于增强神经网络的非线性拟合能力，其函数表达式为：

$$\tanh(x_t) = \frac{e^{x_t} - e^{-x_t}}{e^{x_t} + e^{-x_t}} \quad (6)$$

确定了需要更新的数据之后还需更新上一时刻的细胞状态，细胞状态移除遗忘门决定的信息；然后确定“输入门”输入“状态”信息，如式（7）所示。

$$C_t^1 = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (7)$$

式中： C_t^1 是数据经过输入门之后的神经元状态。

最后决定将要输出的部分。输出通过一个 sigmoid 函数层来决定 C_t 中哪些部分需要被更新，然后将 C_t 经过一个 $\tanh$ 函数处理（归一化），并将遗忘门里 sigmoid 层的输出相乘，从而决定输出，如式（8）所示。

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (8)$$

式中： O_t 为神经元的预测输出值； W_o 为输出门的输出权重； b_o 为输出门偏置项。

改进后更安全的原因如下，改进前细胞状态为：

$$C_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \cdot \sigma(W_i[h_{t-1}, x_t] + b_i) + C_{t-1} \cdot \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (9)$$

式中： C_t 为当前神经元最终状态。

输出为：

$$h_t = \tanh(C_t) \cdot \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (10)$$

在这个输出中，由于遗忘门决定从 x_t 抛弃一部分数据，而输入门更新的数据同样是从输入 x_t 中挑选了一部分更新到细胞状态，其中：

$$x_t = [a_1, a_2, a_3, \dots, a_n] \quad (11)$$

这样，更新的数据值很有可能等于遗忘的数据值，如初始状态 $[h_{t-1}, 0.5x_t]$ 经过遗忘门之后细胞状态变为 $[h_{t-1}, 0.5x_t]$ ，而输入门更新的数据又恰是 $0.5x_t$ ，那么经过输入门以后，细胞状态变回为 $[h_{t-1}, 0.5x_t]$ 。显然，这对于自动驾驶换道的安全性是无法保证的，所以提出的改进 LSTM 神经网络模型弥补了经典 LSTM 神经网络在自动驾驶车辆换道轨迹规划安全性方面的不足，使训练过程变得部分可控，改进后的细胞状态为：

$$C_t = \tanh(W_g[h_{t-1}, x_t] + b_g) \cdot \sigma(W_i[h_{t-1}, x_t] + b_i) + s_{t-1} \cdot \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (12)$$

输出为:

$$h_t = \tanh(C_t) \cdot \sigma(W_o[h_{t-1}, x_t] + b_o) + \tanh(P_t \cdot W_m). \quad (13)$$

式中: P_t 为车辆在运动学模型经过归一化处理后的动力学输出值。

经过多次试验, 该模型将改进的 LSTM 神经网络的层数设置为两层, 隐层神经元个数为 8 个。输入变量确定为纵向位置 x_0 , 横向位置 y_1 和速度 v_0 , 输出变量为下一时刻规划的速度, 采取的神经网络学习率是 0.01。

1.2 换道轨迹规划运动学模型

由于车辆行驶过程中要求加速度连续变化, 所以自动驾驶换道轨迹所采用的多项式曲线不应少于 3 次, 为了避免多项式曲线次数太高造成的参数求解过于复杂, 将多项式曲线确定为三次多项式曲线。其表达式为:

$$y_n(x_n) = a_0 + a_1 x_n + a_2 x_n^2 + a_3 x_n^3. \quad (14)$$

式中: a_0 、 a_1 、 a_2 、 a_3 为需要后期确定的参数; x_n 为换道车辆纵向位置; y_n 为换道车辆横向位置。

确定各项参数有:

$$y_n(x_n) = \tan \theta_i x_n + \frac{3y_n^f - 2x_n^f \tan \theta_i}{(x_n^f)^2} x_n^2 + \frac{x_n^f \tan \theta_i - 2y_n^f}{(x_n^f)^3} x_n^3. \quad (15)$$




图 4 安全距离示意图

后车紧急制动距离如式 (17) 和式 (18) 所示:

$$x_{n-1}^{\text{stop}} = x_{n-1}(t) - \frac{v_{n-1}^2(t)}{2b_{n-1}}. \quad (17)$$

$$x_n^{\text{stop}} = x_n(t) + \frac{\tau}{2}(2v(t) - a\tau) - \frac{v_n^2(t)}{2b_n}. \quad (18)$$

式中: x_{n-1}^{stop} 、 x_n^{stop} 分别为前车和后车从制动到停车之间的距离; $x_{n-1}(t)$ 为前车 t 时刻位置; $x_n(t)$ 为后车 t

式中: θ_i 为规划步长起点的航向角。

1.3 避撞算法

Gipps 模型^[29] 是领域内经典的车辆安全距离模型, 可以较好地拟合两辆跟驰车辆之间的行驶状态, 但其将车辆视作质点, 没有考虑车辆的车身长度, 所以在经典 Gipps 模型的基础上加入车身长度进行改进, 作为三次轨迹曲线的约束条件。

车辆换道过程中受到周围车辆实时的影响, 为了保证换道过程的安全性, 需要实时检测周围车辆的行驶状态, 并对周围车辆的行驶状态进行预测。

$$\begin{aligned} x_j(t) &= x_j(t_0) + v_j t \\ \text{s.t. } j &= n-1. \end{aligned} \quad (16)$$

式中: j 为车辆 $n-1$; $x_j(t_0)$ 和 v_j 分别为当前状态各个车辆的纵向位置坐标和速度; $x_j(t)$ 为 t 时刻车辆 j 的纵向位置坐标。

Gipps 模型求解的是当前车辆紧急停车时, 后车在经过反应时间 τ 后也采取紧急停车动作, 从而不和前车发生碰撞的速度。在经典的 Gipps 模型中, 车身的长度没有被考虑到, 也没有考虑到实际跟驰过程中前后两车的时变速度, 针对此情况, 对经典 Gipps 模型进行改进, 如图 4 所示。

时刻位置; $v_{n-1}(t)$ 、 $v_n(t)$ 分别为前车和后车 t 时刻的速度; b_{n-1} 为前车最大制动量; b_n 为后车最大制动量; a 为后车实时加速度; τ 为后车的反应时间。

后车制动时, 前后两车刚好不追尾需保持的距离为 $\text{gap}_{\text{safe}}^{n-1}$, $\text{gap}_{\text{safe}}^{n-1}$ 就是 Gipps 最小安全距离。

$$x_{n-1}^{\text{stop}} - \frac{(l_{n-1} + l)}{2} - x_n^{\text{stop}} \geq 0. \quad (19)$$

$$\text{gap}_{\text{safe}}^{n-1} = \frac{v_{n-1}^2}{2b_{n-1}} + \frac{\tau}{2}(2v(t) - a\tau) - \frac{v^2(t)}{2b} \quad (20)$$

式中: l_{n-1} 为前车的车身长度; l 为后车的车身长度。

车辆换道的安全性与车辆速度也有关, 根据改进的 Gipps 安全模型计算车辆的安全速度。由式 (20) 的最小安全间隙 $\text{gap}_{\text{safe}}^{n-1}$, 推算出车辆 n 的安全速度范围。车辆 n 受到车辆 $n-1$ 影响的最大安全速度 $v_n^{n-1}(t)$ 为:

$$v_n^{n-1}(t) = \tau b + \sqrt{b^2 \tau^2 + 2b \left(x(t) + \frac{(l_{n-1} + l)}{2} - x_{n-1}(t) + \frac{v_{n-1}^2}{2b_{n-1}} - \frac{a\tau^2}{2} \right)} \quad (21)$$

2 模型验证

2.1 训练数据和测试数据

使用的是美国联邦高速公路公布的 NGSIM^[16] 数据。作为高精度且高可靠性实车数据, 其被广泛应用于车辆研究^[30-32]。NGSIM 数据包括车辆位置、速度等, 非常符合仿真研究的要求。更多详细的介绍参见相关文献。数据采集选用的两段高速公路路段, 如图 5 所示。




图 5 NGSIM 高速公路路段示意图

2.2 训练结果

对于基于 LSTM 神经网络的换道轨迹规划模型训练和测试, 同样基于 Python 通过深度学习的 Tensorflow 框架搭建所需的 LSTM 神经网络。

在迭代过程中, 训练误差随着迭代次数的增加而变化的情况如图 6 所示。在迭代次数小于 20 次时, 训练误差下降较快, 随着迭代次数的增加, 训练误差下降缓慢。迭代次数达到 25 次左右时, 训练误差




图 6 迭代次数设为 30 次

差趋于收敛。因此, 将基于 LSTM 神经网络的换道轨迹规划模型的迭代次数设为 30 次。

2.3 不同训练结果对比

如图 7 所示, 蓝色曲线是理想的安全性换道轨迹曲线, 黄色曲线是本模型预测的换道轨迹曲线, 绿色曲线是真实换道轨迹曲线。由图可知, 经过本模型的训练和预测, 输出的轨迹曲线更靠近安全性换道轨迹曲线, 又保留了一些人类原始换道轨迹曲线的特征且比人类更早地完成了换道。




图 7 神经网络学习效果

2.4 误差统计

拟用平均绝对误差 (Mean Absolute Error, MAE) 以及平均绝对相对误差 (Root Mean Squared Error, MARE) 这两个统计学中常用的统计量对模型进行误差统计:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |d_{r,i} - d_{s,i}| \quad (22)$$

$$\text{MARE} = \frac{1}{N} \sum_{i=1}^N \frac{|d_{r,i} - d_{s,i}|}{d_{r,i}} \quad (23)$$

式中: N 为测试数据样本数; $d_{r,i}$ 为第 i 辆车的真实值; $d_{s,i}$ 为第 i 辆车的预测值。

针对实际情况, 定义如下: MAE_{real} 和 $\text{MARE}_{\text{real}}$ 分别表示预测值与真实值的平均绝对误差和平均绝对相对误差, 这两个统计量可以表征实际值和预测值的误差。

本节对改进 LSTM 神经网络的输出轨迹和真实轨迹进行误差统计, 结果显示, 两个统计量数值都比较小, 见表 1。

表 1 误差对比表

变量	误差指标	
	MAE _{real}	MARE _{real}
横向位置	0.056	0.029
纵向位置	0.678	0.019
速度	0.070	0.010

2.5 基于 CarSim 的仿真验证

CarSim 是用于车辆动力学的专用仿真软件, 该软件可以对驾驶员、路面条件以及空气动力等方面进行仿真输入, 对车辆制动性、稳定性参数等进行输出。CarSim 可以方便灵活地定义试验环境和试验过程^[33]。

将提出的深度学习模型输出的车辆轨迹数据作为 CarSim 输入, 拟用该软件对模型轨迹进行可跟踪性、平稳性等参数的评估。

图 8 显示了 CarSim 在车辆换道成功场景下的换道轨迹、加速度输出结果的对比。CarSim 对真实换道轨迹跟踪情况如图 8a 所示, 其中红色曲线为 CarSim 仿真软件对于原始数据的跟踪结果, 蓝色曲线为原始轨迹曲线, 可以看出 CarSim 跟踪的换道轨迹曲线和真实换道轨迹曲线相对存在较大误差。CarSim 对本模型预测的换道轨迹曲线的跟踪情况如图 8b 所示, 可以看出 CarSim 能较完美地跟踪本模型输出的换道轨迹, 且轨迹很平滑。CarSim 对真实轨迹的加速度仿真结果如图 8c 所示, 可以看出真实轨迹的加速度变化较为剧烈, 乘客舒适性体验不高。CarSim 对本模型输出轨迹的加速度仿真结果如图 8d 所示, 可见相对真实轨迹的加速度变化而言, CarSim 对于本模型轨迹曲线加速度仿真结果更均匀, 乘客的舒适性体验较好。







图 8 CarSim 仿真结果

3 结论

以研究自动驾驶的车辆换道技术为目的, 在自动驾驶领域提出一种改进 LSTM 神经网络的换道轨迹规划算法。从安全性和效率两个角度入手建立深度学习换道轨迹规划模型, 改进 LSTM 神经网络模型在一定程度上提高了车辆换道过程的安全性, 使车辆一边学习一边利用基于规则算法对轨迹进行安全性监督和修正。另外还验证了改进 LSTM 神经网络模型的舒适性和效率比真实轨迹更高, 并通过 Python 仿真结果分析了换道车辆和周围环境车辆对车辆换道过程的影响。虽然常规换道轨迹规划模型在换道执行过程中对目标轨迹学习精度很高, 但是忽略了车辆周围环境的变化, 换道车辆无法对突发情况做出反应, 因此在安全性方面还存在不足。得到以下主要结论:

(1) 利用本模型可以规划出一条合适的自动驾驶换道轨迹, 且能保证换道车辆更安全、更舒适地完成换道。

(2) 在规划过程中, LSTM-NN 模型可能比人更早完成换道, 主要是因为该模型不仅考虑了安全性还考虑了效率。

(3) CarSim 的仿真显示, 提出的模型所规划出的换道轨迹和速度能够很好地被自动驾驶跟踪, 车辆行驶稳定性良好。

参考文献 (References)

- [1] JACOBSTEIN N. Autonomous Vehicles: An Imperfect Path to Saving Millions of Lives [J]. Science Robotics, 2019, 4(28): aaw8703.
- [2] Li Xiaopeng, AMIR G, XU Zhigang, et al. A Piecewise Trajectory Optimization Model for Connected Automated Vehicles: Exact Optimization Algorithm and Queue Propagation Analysis [J]. Transportation Research Part B: Methodological, 2018, 118: 429-456.
- [3] HAN Y J, AHN S Y. Stochastic Modeling of Breakdown at Freeway Merge Bottleneck and Traffic Control Method Using Connected Automated Vehicle [J]. Transportation Research Part B: Methodological, 2018, 107: 146-166.
- [4] GHIASI A, OMAR H, QIAN Zhen, et al. A Mixed Traffic Capacity Analysis and Lane Management Model for Connected Automated Vehicles: A Markov Chain Method [J]. Transportation Research Part B: Methodological, 2017, 106: 266-292.
- [5] DE ALMEIDA CORREIA G H, VAN AREM B. Solving the User Optimum Privately Owned Automated Vehicles Assignment Problem (UO-POAVAP): A Model to Explore the Impacts of Self-Driving Vehicles on Urban Mobility [J]. Transportation Research Part B-Methodological, 2016, 87: 64-88.
- [6] RAHMAN M S, ABDEL-ATY M, LEE J Y, et al. Safety Benefits of Arterials' Crash Risk Under Connected and Automated Vehicles [J]. Transportation Research Part C: Emerging Technologies, 2019, 100: 354-371.
- [7] LI Li, HUANG Wuling, LIU Yuehu, et al. Intelligence Testing for Autonomous Vehicles: A New Approach [J]. IEEE Transactions on Intelligent Vehicles, 2016, 1(2): 158-166.
- [8] LYGEROS J, GODBOLE D N, SASTRY S. Verified Hybrid Controllers for Automated Vehicles [J]. IEEE Transactions on Automatic Control, 1998, 43(4): 522-539.
- [9] YANG Da, ZHENG Shiyu, WEN Cheng, et al. A Dynamic Lane-Changing Trajectory Planning Model for Automated Vehicles [J]. Transportation Research Part C: Emerging Technologies, 2018, 95: 228-247.
- [10] SÉBASTIEN G, BENOIT V, SAÏD M, et al. Maneuver-Based Trajectory Planning for Highly Autonomous Vehicles on Real Road with Traffic and Driver Interaction [J]. IEEE Transactions on Intelligent Transportation Systems, 2010, 11(3): 589-606.
- [11] WINKLE T. Safety Benefits of Automated Vehicles: Extended Findings from Accident Research for Development, Validation and Testing [J]. Autonomous Driving, 2016: 335-364.
- [12] DE DIEGO I M, SIORDIA O S, CRESPO R, et al. Analysis of Hands Activity for Automatic Driving Risk Detection [J]. Transportation Research Part C: Emerging Technologies, 2013, 26: 380-395.
- [13] YAO Wen, ZHAO Huijing, BONNIFAIT P, et al. Lane Change Trajectory Prediction by Using Recorded Human Driving Data [C]// 2013 IEEE Intelligent Vehicles Symposium (IV), Gold Coast, QLD, Australia. New York: IEEE, 2013.
- [14] DING Chenxi, WANG Wuhong, WANG Xiao, et al. A Neural Network Model for Driver's Lane-Changing Trajectory Prediction in Urban Traffic Flow [J]. Mathematical Problems in Engineering, 2013(1): 1-8.
- [15] XIE Dongfan, FANG Zhezhe, JIA Bin, et al. A Data-Driven Lane-Changing Model Based on Deep Learning [J]. Transportation Research Part C: Emerging Technologies, 2019, 106: 41-60.
- [16] FHWA. Next Generation Simulation (NGSIM) [EB/OL]. (2010-11-02) <https://ops.fhwa.dot.gov/trafficanalysis/tools/ngsim.htm>.
- [17] WANG Yuan, ZHANG Dongxiang, LIU Ying, et al. Enhancing Transportation Systems Via Deep Learning: A Survey [J]. Transportation Research Part C: Emerging Technologies, 2019, 99(2): 144-163.
- [18] NELSON W. Continuous-Curvature Paths for Autonomous Vehicles [C]// Proceedings of 1989 International Conference on Robotics and Automation. New York: IEEE, 1989.
- [19] PIAZZI A, BIANCO C G L. Quintic G/sup 2/-splines for Trajectory Planning of Autonomous Vehicles [C]// Proceedings of the IEEE Intelligent Vehicles Symposium 2000 (Cat. No.00TH8511). New York: IEEE, 2000.

- [20] PAPADIMITRIOU, TOMIZUKA M. Fast Lane Changing Computations Using Polynomials [C]// Proceedings of the 2003 American Control Conference. New York: IEEE, 2003.
- [21] SHIM T, ADIREDDY G, YUAN Hongliang. Autonomous Vehicle Collision Avoidance System Using Path Planning and Model-Predictive-Control-Based Active Front Steering and Wheel Torque Control [J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2012, 226(6): 767-778.
- [22] CHEN Jiajia, ZHAO Pan, MEI Tao, et al. Lane Change Path Planning Based on Piecewise Bezier Curve for Autonomous Vehicle [C]. Proceedings of 2013 IEEE International Conference on Vehicular Electronics and Safety, July 28-30, 2013, Dongguan, China. Piscataway NJ: IEEE, c2013: 17-22.
- [23] MILAM M B. Real-Time Optimal Trajectory Generation for Constrained Dynamical Systems [D]. California: California Institute of Technology, 2003.
- [24] CHEE W, TOMIZUKA M. Vehicle Lane Change Maneuver in Automated Highway Systems [D]. California: California Institute of Technology, 1994.
- [25] CHEE W, TOMIZUKA M. Lane Change Maneuver of Automobiles for the Intelligent Vehicle and Highway System (IVHS) [C]// Proceedings of 1994 American Control Conference-ACC '94, June 29-July 1, 1994, Baltimore, MD, USA. Piscataway NJ: IEEE, c1994: 3586-3587.
- [26] REN Dianbo, ZHANG Jiye, Zhang Jingming, et al. Trajectory Planning and Yaw Rate Tracking Control for Lane Changing of Intelligent Vehicle on Curved Road [J]. Science China Technological Sciences, 2011, 54(3): 630-642.
- [27] ZHANG Sumin, DENG Weiwen, ZHAO Qingrong, et al. An Intelligent Driver Model with Trajectory Planning [C]// 2012 15th International IEEE Conference on Intelligent Transportation Systems, Sept. 16-19, 2012, Anchorage, AK, USA. Piscataway NJ: IEEE, c2012: 876-881.
- [28] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to forget: Continual Prediction with LSTM [J]. Neural Comput, 2000, 12(10): 2451-2471.
- [29] WANG Jiangfeng, ZHANG Qian, ZHANG Zhiqi, et al. Structured Trajectory Planning of Collision-Free Lane Change Using the Vehicle-Driver Integration Data [J]. Science China Technological Sciences, 2016, 59(5): 825-831.
- [30] YANG Da, ZHU Liling, YANG Fei, et al. Modeling and Analysis of the Lateral Driver Behavior in Lane-Changing Execution [J]. Transportation Research Record: Journal of the Transportation Research Board, 2015, 2490(1): 127-137.
- [31] WANG Qi, LI Zhiheng, LI Li. Investigation of Discretionary Lane-Change Characteristics Using Next-Generation Simulation Data Sets [J]. Journal of Intelligent Transportation Systems, 2014, 18(3): 246-253.
- [32] DOU Yangliu, YAN Fengjun, FENG Daiwei. Lane Changing Prediction at Highway Lane Drops Using Support Vector Machine and Artificial Neural Network Classifiers [C]// 2016 IEEE International Conference on Advanced Intelligent Mechatronics (AIM), July 12-15, 2016, Banff, AB, Canada. Piscataway NJ: IEEE, c2016: 901-906.
- [33] XU Liang, GUO Rui, LIU Xiao. Virtual Validation and Verification Method of Brake System Model [J]. Advanced Materials Research, 2014, 1056: 177-181.

作者简介



熊明强 (1993-), 男, 重庆市人, 硕士, 工程师, 主要研究方向为自动驾驶换道轨迹规划及神经网络在车路协同中的应用。

Tel: 13617620897

E-mail: 952481723@qq.com