



(12) 发明专利

(10) 授权公告号 CN 110555476 B

(45) 授权公告日 2023. 09. 26

(21) 申请号 201910809352.4

(22) 申请日 2019.08.29

(65) 同一申请的已公布的文献号  
申请公布号 CN 110555476 A

(43) 申请公布日 2019.12.10

(73) 专利权人 华南理工大学  
地址 510640 广东省广州市天河区五山路  
381号

(72) 发明人 黄玲 黄子虚 吴泽荣 郭亨聪  
游峰 张荣辉

(74) 专利代理机构 广州市华学知识产权代理有  
限公司 44245

专利代理师 王东东

(51) Int. Cl.

G06F 18/214 (2023.01)

G06N 3/02 (2006.01)

G06Q 10/04 (2023.01)

G08G 1/01 (2006.01)

(56) 对比文件

CN 110146100 A, 2019.08.20

CN 109711557 A, 2019.05.03

CN 109471436 A, 2019.03.15

CN 106926844 A, 2017.07.07

CN 109460023 A, 2019.03.12

CN 107315411 A, 2017.11.03

CN 110085056 A, 2019.08.02

季学武 等. 基于LSTM网络的驾驶意图识别  
及车辆轨迹预测.《中国公路学报》.2019,第32卷  
(第6期),

LING HUANG et al..Capturing Drivers”  
Lane Changing Behaviors on Operational  
Level by Data Driven Methods.《IEEE  
Access:SPECIAL SECTION ON ADVANCED BIG  
DATA ANALYSIS FOR VEHICULAR SOCIAL  
NETWORKS》.2018,第6卷

审查员 赵娟娟

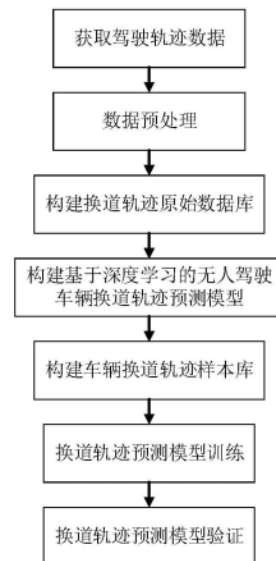
权利要求书2页 说明书6页 附图3页

(54) 发明名称

一种适用于人机混驾环境下智能车辆换道  
轨迹预测方法

(57) 摘要

本发明公开了一种适用于人机混驾环境下  
智能车辆换道轨迹预测方法,包括:S1获取高速  
路段上正在行进的无人驾驶汽车的轨迹数据;S2  
将获取的驾驶轨迹数据进行处理,获取车辆自身  
的空间信息、运动信息及邻近车相对状态的数  
据信息,根据该数据信息筛选出换道数据,生成  
样本数据库;S3构建无人驾驶车辆换道轨迹预  
测模型;S4进行车辆换道轨迹预测模型训练,得  
出最优换道轨迹预测模型结构,最佳训练样本  
容量和最佳历史序列长度;S5对S4训练后的车  
辆换道轨迹预测模型进行验证。



1. 一种适用于人机混驾环境下智能车辆换道轨迹预测方法,其特征在于,包括如下步骤:

S1获取高速路段上行进的无人驾驶汽车的轨迹数据;

S2将获取的驾驶轨迹数据进行处理,获取车辆自身的空间信息、运动信息及邻近车相对状态的数据信息,筛选出换道数据,生成样本数据库,所述样本数据库包括样本数据集和精度验证样本集;

所述空间信息包括车辆所行使车道在车道内的位置;

所述运动信息包括车辆速度、车长及车宽;

所述邻近车相对状态的数据信息具体是指换道车辆*i*与邻近车辆*j*的相对状态向量  $\Delta \vec{s}_{i,j}(t) = \{\Delta x_{i,j}(t), \Delta y_{i,j}(t), \Delta v_{i,j}(t)\}$ ,其中  $\Delta x_{i,j}(t)$ ,  $\Delta y_{i,j}(t)$ ,  $\Delta v_{i,j}(t)$  分别代表车辆*i*和*j*在*t*时刻的相对*x*轴坐标、相对*y*轴坐标和相对速度;

S3构建无人驾驶车辆换道轨迹预测模型,其模型的输入变量为6*N*个,输出变量为2个,*N*为历史样本序列的长度;

所述无人驾驶车辆换道轨迹预测模型是基于长短期记忆神经网络构建;

所述无人驾驶车辆换道轨迹预测模型的6*N*个输入变量为:

①换道目的地  $\overline{TD}_i(t - (n-1)\tau)$

指换道车辆*i*在*t* - (*n*-1)  $\tau$ 时刻的换道目的地,*n*=1,2,⋯,*N*,*N*为历史样本序列长度, $\tau$ 为输入各时间序列之间的时间间隔;

②基础设施信息*M*

将车辆*i*当前位置最近的车道中位线横向*x*轴坐标作为基础设施信息;

③车辆参数*C<sub>i</sub>*

使用车辆*i*的长度、宽度对车辆类型进行表征,即:

$$C_i = \{W_i, L_i\}$$

式中, $W_i$ 、 $L_i$ 分别为车辆*i*的宽度和长度;

④状态向量  $\vec{s}_i(t - (n-1)\tau)$

包括车辆*i*自身的即时速度、换道过程中运动状态的方向和幅度,即:

$$\vec{s}_i(t - (n-1)\tau) = \{x_i(t - (n-1)\tau), y_i(t - (n-1)\tau), v_i(t - (n-1)\tau)\}$$

式中, $x_i(t - (n-1)\tau)$ ,  $y_i(t - (n-1)\tau)$ ,  $v_i(t - (n-1)\tau)$  分别为车辆*i*在*t* - (*n*-1)  $\tau$ 时刻的*x*轴坐标、*y*轴坐标和速度大小;

⑤车辆参数*C<sub>j</sub>*

使用邻近车辆*j*的长度、宽度对车辆类型进行表征,即:

$$C_j = \{W_j, L_j\}$$

式中, $W_j$ 、 $L_j$ 分别为车辆*j*的宽度和长度;

⑥相对状态向量  $\Delta \vec{s}_{i,j}(t - (n-1)\tau)$

包括车辆*i*与*j*的相对速度,换道过程中车辆*i*和*j*的相对运动状态的方向和幅度,即:

$$\Delta \vec{s}_{i,j}(t - (n-1)\tau) = \{\Delta x_{i,j}(t - (n-1)\tau), \Delta y_{i,j}(t - (n-1)\tau), \Delta v_{i,j}(t - (n-1)\tau)\}$$

式中,  $\Delta x_{i,j}(t - (n-1)\tau)$ ,  $\Delta y_{i,j}(t - (n-1)\tau)$ ,  $\Delta v_{i,j}(t - (n-1)\tau)$  分别为车辆*i*和*j*在*t* - (*n*-

1)  $\tau$ 时刻的相对x轴坐标、相对y轴坐标和相对速度大小;

所述无人驾驶车辆换道轨迹预测模型的输出变量为:

①模型对车辆x轴方向的位置预测结果 $x(t+T)$ ;

式中, $T$ 表示预测延迟,取值范围为0.1-1.5s;

②模型对车辆y轴方向的位置预测结果 $y(t+T)$ ;

S4进行车辆换道轨迹预测模型训练,以模型轨迹MSE误差是用于训练模型收敛的条件函数,使用RMSprop优化方法进行训练,采用反向传播算法作为计算梯度基本方法,当模型轨迹MSE误差最小时得出最优车辆换道轨迹预测模型结构及最佳训练样本量,进一步选取最佳历史序列长度;

随机抽取的不同序列长度 $N$ 条件的10000个样本,对LSTM模型进行测试,得到测试历史序列长度;

使用不同的训练样本量对车辆换道轨迹预测模型进行训练,得到最佳训练样本量和最优换道轨迹预测模型结构;

在已知最佳训练样本量和最优换道轨迹预测模型结构的前提下,训练不同历史序列长度的车辆换道轨迹预测模型,得到最佳历史序列长度;

S5利用精度验证样本集中的数据对最优换道轨迹预测模型结构进行验证,验证后的最优换道轨迹预测模型进行换道轨迹预测。

2. 根据权利要求1所述的一种适用于人机混驾环境下智能车辆换道轨迹预测方法,其特征在于,训练样本总数不少于50000个,精度验证样本总数不少于10000个,轨迹精度要求在0.5m以内,样本采样率在1~10Hz之间。

## 一种适用于人机混驾环境下智能车辆换道轨迹预测方法

### 技术领域

[0001] 本发明涉及无人驾驶的技术领域,具体涉及一种适用于人机混驾环境下智能车辆换道轨迹预测方法。

### 背景技术

[0002] 人机混驾交通环境,是指在未来道路系统中人工驾驶车辆与无人驾驶车辆混合运行的交通环境。随着自动驾驶技术的快速发展,在可预见的未来,无人驾驶车辆将进入实际道路交通系统,并将长期在人机混驾交通环境下运行。换道行为是交通基本的驾驶任务,对驾驶安全和交通流的稳定具有重要意义。然而,现有的换道模型精度无法满足实际使用。目前还未有适用于人机混驾环境下基于深度学习的无人驾驶车辆换道轨迹预测方面的文献。

[0003] 经典换道行为研究,主要可分为换道意图预测研究和换道轨迹预测研究两类,典型代表有Gipps模型、元胞自动机模型和马尔可夫模型等。为降低计算难度,这些模型都对驾驶人的换道行为做简化处理,导致模型无法精确地再现车辆换道过程,无法满足人机混驾环境下无人驾驶车辆换道行为模型的要求。近年来,研究人员从数据驱动的角度出发,使用机器学习方法对换道行为进行研究,且大部分研究集中在换道意图预测,部分研究则针对换道时间预测。随着自动驾驶技术的发展,换道轨迹预测成为新的研究热点。然而,目前的无人驾驶车辆换道行为模型,依旧面临着模型过于复杂不适用或精度不足的问题。

### 发明内容

[0004] 为了克服现有技术存在的缺点与不足,本发明提供一种适用于人机混驾环境下智能车辆换道轨迹预测方法。

[0005] 本发明采用如下技术方案:

[0006] 一种适用于人机混驾环境下智能车辆换道轨迹预测方法,包括如下步骤:

[0007] S1获取高速路段上行进的无人驾驶汽车的轨迹数据;

[0008] S2将获取的驾驶轨迹数据进行处理,获取车辆自身的空间信息、运动信息及邻近车相对状态的数据信息,筛选出换道数据,生成样本数据库;

[0009] 所述邻近车相对状态的数据信息具体是指换道车辆*i*与邻近车辆*j*的相对状态向量 $\Delta \bar{s}_{i,j}(t) = \{\Delta x_{i,j}(t), \Delta y_{i,j}(t), \Delta v_{i,j}(t)\}$ ,其中 $\Delta x_{i,j}(t)$ ,  $\Delta y_{i,j}(t)$ ,  $\Delta v_{i,j}(t)$ 分别代表车辆*i*和*j*在*t*时刻的相对*x*轴坐标、相对*y*轴坐标和相对速度;

[0010] S3构建无人驾驶车辆换道轨迹预测模型,其模型的输入变量为6*N*个,输出变量为2个;

[0011] S4进行车辆换道轨迹预测模型训练,得出最优换道轨迹预测模型结构,最佳训练样本容量和最佳历史序列长度;

[0012] S5对S4训练后的车辆换道轨迹预测模型进行验证。

[0013] 所述模型的6*N*个输入变量为:

[0014] ①换道目的地 $\overline{TD}_i(t-(n-1)\tau)$

[0015] 指换道车辆*i*在 $t-(n-1)\tau$ 时刻的换道目的地, $n=1,2,\dots,N,N$ 为历史序列长度, $\tau$ 为输入各时间序列之间的时间间隔;

[0016] ②基础设施信息*M*

[0017] 将车辆*i*当前位置最近的车道中位线横向*x*轴坐标作为基础设施信息;

[0018] ③车辆参数 $C_i$

[0019] 使用车辆*i*的长度、宽度对车辆类型进行表征,即:

[0020]  $C_i = \{W_i, L_i\}$

[0021] 式中, $W_i, L_i$ 分别为车辆*i*的宽度和长度;

[0022] ④状态向量 $\vec{s}_i(t-(n-1)\tau)$

[0023] 包括车辆*i*自身的即时速度、换道过程中运动状态的方向和幅度,即:

[0024]  $\vec{s}_i(t-(n-1)\tau) = \{x_i(t-(n-1)\tau), y_i(t-(n-1)\tau), v_i(t-(n-1)\tau)\}$

[0025] 式中, $x_i(t-(n-1)\tau), y_i(t-(n-1)\tau), v_i(t-(n-1)\tau)$ 分别为车辆*i*在 $t-(n-1)\tau$ 时刻的*x*轴坐标、*y*轴坐标和速度大小;

[0026] ⑤车辆参数 $C_j$

[0027] 使用邻近车辆*j*的长度、宽度对车辆类型进行表征,即:

[0028]  $C_j = \{W_j, L_j\}$

[0029] 式中, $W_j, L_j$ 分别为车辆*j*的宽度和长度;

[0030] ⑥相对状态向量 $\Delta\vec{s}_{i,j}(t-(n-1)\tau)$

[0031] 包括车辆*i*与*j*的相对速度,换道过程中车辆*i*和*j*的相对运动状态的方向和幅度,即:

[0032]  $\Delta\vec{s}_{i,j}(t-(n-1)\tau) = \{\Delta x_{i,j}(t-(n-1)\tau), \Delta y_{i,j}(t-(n-1)\tau), \Delta v_{i,j}(t-(n-1)\tau)\}$

[0033] 式中, $\Delta x_{i,j}(t-(n-1)\tau), \Delta y_{i,j}(t-(n-1)\tau), \Delta v_{i,j}(t-(n-1)\tau)$ 分别为车辆*i*和*j*在 $t-(n-1)\tau$ 时刻的相对*x*轴坐标、相对*y*轴坐标和相对速度大小。

[0034] 所述模型的输出变量为:

[0035] ①模型对车辆*x*轴方向的位置预测结果 $x(t+T)$ ;

[0036] 式中, $T$ 表示预测延迟,取值范围为0.1-1.5s;

[0037] ②模型对车辆*y*轴方向的位置预测结果 $y(t+T)$ 。

[0038] 所述S4中采用RMSprop作为优化方法,采用反向传播算法作为计算梯度基本方法。

[0039] 优选的,训练样本总数不少于50000个,精度验证样本总数不少于10000个,轨迹精度要求在0.5m以内,样本采样率在1~10Hz之间。

[0040] 优选的,所述车辆自身的空间信息具体是指道路信息及车辆所在道路位置;所述运动信息是指速度信息。

[0041] 本发明的有益效果:

[0042] 1、本发明方法与传统的换道轨迹预测方法相比,对驾驶人的换道过程进行了精确的再现,并且由于其基于深度学习方法,在实施时具有简单易行的优点。

[0043] 2、本发明采用深度学习的建模方法,能够处理更高维度的输入参数,通过获取更

多输入信息达到对真实驾驶行为的还原。同时本发明将驾驶员的预测能力和记忆效应集成到模型中。因此,本发明方法比传统换道轨迹预测方法具有更高的精度。

[0044] 3、本发明从数据驱动的角度出发,通过实际驾驶车辆轨迹数据进行模型训练,得到的换道轨迹预测模型能够根据实际数据的特征自动进行调整,具有良好的自适应性和鲁棒性。

[0045] 4、本发明不仅仅可以对人机混驾环境下的无人驾驶车辆换道轨迹进行预测,在未来实现完全无人驾驶车辆环境下仍然可以作为无人驾驶车辆驾驶轨迹预测模型的基础,具有很大的实际推广价值。

## 附图说明

[0046] 图1是本发明的工作流程图;

[0047] 图2(a)及图2(b)是本发明的研究路段图;

[0048] 图3是本发明的模型结构示意图;

[0049] 图4是本发明训练样本流程图。

## 具体实施方式

[0050] 下面结合实施例及附图,对本发明作进一步地详细说明,但本发明的实施方式不限于此。

[0051] 实施例

[0052] 如图1-图3所示,一种适用于人机混驾环境下智能车辆换道轨迹预测方法,包括如下步骤:

[0053] S1获取高速路段上正在行进的无人驾驶汽车的轨迹数据;

[0054] S2将获取的驾驶轨迹数据进行处理,获取车辆自身的空间信息、运动信息及邻近车相对状态的数据信息,根据该数据信息筛选出换道数据,生成模型所需样本数据库。

[0055] 首先对获得的数据进行初步筛选,提出缺失信息的车辆数据,得到车辆自身的空间信息、运动信息及邻近车相对状态的数据信息,根据上述信息筛选出换道数据,生成序列长度为N的样本数据库。

[0056] 所述车辆空间信息包括车辆所行驶车道及车辆在车道内的位置。

[0057] 所述车辆运动信息包括车辆速度,车长及车宽等信息。

[0058] 所述邻近车相对状态主要是指换道车辆*i*与邻近车辆*j*的相对状态向量  $\Delta \vec{s}_{i,j}(t) = \{\Delta x_{i,j}(t), \Delta y_{i,j}(t), \Delta v_{i,j}(t)\}$ , 其中  $\Delta x_{i,j}(t)$ ,  $\Delta y_{i,j}(t)$ ,  $\Delta v_{i,j}(t)$  分别代表车辆*i*和*j*在*t*时刻的相对*x*轴坐标、相对*y*轴坐标和相对速度。

[0059] 从处理得到的换道数据中做车辆历史数据缺失的筛选,剔除数据中数据异常的换道数据;根据所需要的历史序列长度N生成样本库。

[0060] S3构建无人驾驶车辆换道轨迹预测模型,其模型的输入变量为6N个,输出变量为2个,N为样本序列的长度;

[0061] 对步骤S2得到的数据进行处理,得到包括训练样本集和精度验证样本集,获得训练样本超过110000个,精度验证样本37440个。

[0062] 所述模型的6个输入变量为:

[0063] ①换道目的地 $\overline{TD}_i(t-(n-1)\tau)$

[0064] 指换道车辆*i*在 $t-(n-1)\tau$ 时刻的换道目的地, $n=1,2,\dots,N$ , $N$ 为历史序列长度, $\tau$ 为输入各时间序列之间的时间间隔,考虑到当前智能网联车(Intelligent Connected Vehicle,ICV)数据采集技术的发展及速度数据精度要求,取值范围为0.05-0.4s。

[0065] ②基础设施信息M

[0066] 将车辆*i*当前位置最近的车道中位线横向x轴坐标作为基础设施信息;

[0067] ③车辆参数 $C_i$

[0068] 使用车辆*i*的长度、宽度对车辆类型进行表征,即:

$$[0069] C_i = \{W_i, L_i\}$$

[0070] 式中, $W_i$ 、 $L_i$ 分别为车辆*i*的宽度和长度;

[0071] ④状态向量 $\vec{s}_i(t-(n-1)\tau)$

[0072] 包括车辆*i*自身的即时速度、换道过程中运动状态的方向和幅度,即:

$$[0073] \vec{s}_i(t-(n-1)\tau) = \{x_i(t-(n-1)\tau), y_i(t-(n-1)\tau), v_i(t-(n-1)\tau)\}$$

[0074] 式中, $x_i(t-(n-1)\tau)$ 、 $y_i(t-(n-1)\tau)$ 、 $v_i(t-(n-1)\tau)$ 分别为车辆*i*在 $t-(n-1)\tau$ 时刻的x轴坐标、y轴坐标和速度大小;

[0075] ⑤车辆参数 $C_j$

[0076] 使用邻近车辆*j*的长度、宽度对车辆类型进行表征,即:

$$[0077] C_j = \{W_j, L_j\}$$

[0078] 式中, $W_j$ 、 $L_j$ 分别为车辆*j*的宽度和长度;

[0079] ⑥相对状态向量 $\Delta\vec{s}_{i,j}(t-(n-1)\tau)$

[0080] 包括车辆*i*与*j*的相对速度,换道过程中车辆*i*和*j*的相对运动状态的方向和幅度,即:

$$[0081] \Delta\vec{s}_{i,j}(t-(n-1)\tau) = \{\Delta x_{i,j}(t-(n-1)\tau), \Delta y_{i,j}(t-(n-1)\tau), \Delta v_{i,j}(t-(n-1)\tau)\}$$

[0082] 式中, $\Delta x_{i,j}(t-(n-1)\tau)$ 、 $\Delta y_{i,j}(t-(n-1)\tau)$ 、 $\Delta v_{i,j}(t-(n-1)\tau)$ 分别为车辆*i*和*j*在 $t-(n-1)\tau$ 时刻的相对x轴坐标、相对y轴坐标和相对速度大小,其计算公式分别为:

$$[0083] \Delta x_{i,j}(t-(n-1)\tau) = x_j(t-(n-1)\tau) - x_i(t-(n-1)\tau)$$

[0084] 式中, $x_i(t-(n-1)\tau)$ 、 $x_j(t-(n-1)\tau)$ 分别为车辆*i*和*j*在 $t-(n-1)\tau$ 时刻的x轴坐标;

$$[0085] \Delta y_{i,j}(t-(n-1)\tau) = y_j(t-(n-1)\tau) - y_i(t-(n-1)\tau)$$

[0086] 式中, $y_i(t-(n-1)\tau)$ 、 $y_j(t-(n-1)\tau)$ 分别为车辆*i*和*j*在 $t-(n-1)\tau$ 时刻的y轴坐标;

$$[0087] \Delta v_{i,j}(t-(n-1)\tau) = v_j(t-(n-1)\tau) - v_i(t-(n-1)\tau)$$

[0088] 式中, $v_i(t-(n-1)\tau)$ 、 $v_j(t-(n-1)\tau)$ 分别为车辆*i*和*j*在 $t-(n-1)\tau$ 时刻的速度大小。

[0089] 所述模型的2个输出变量分别为:

[0090] ①模型对车辆x轴方向的位置预测结果 $x(t+T)$ ;

[0091] 式中, $T$ 表示预测延迟,取值范围为0.1-1.5s;

[0092] ②模型对车辆y轴方向的位置预测结果 $y(t+T)$ 。

[0093] S4进行车辆换道轨迹预测模型训练,得出最优换道轨迹预测模型结构,最佳训练样本容量和最佳历史序列长度;

[0094] 使用不同的神经网络模型结构和不同的样本量对换道轨迹进行建模,选择隐藏层层数和每层节点数具有代表性的神经网络结构,分别使用不同的训练数据量对各网络结构进行训练,获得最佳结构方案和最佳训练样本量;

[0095] 在最佳的网络结构和最佳训练样本量的条件下,训练不同历史序列长度N的换道轨迹预测模型,选取最优历史序列长度N。

[0096] S5对S4训练后的车辆换道轨迹预测模型进行验证。

[0097] 利用验证样本数据对已经训练好的最佳的换道轨迹预测模型进行验证,确定和计算相应的输入变量,包括:  $\overline{TD}_i(t-(n-1)\tau)$ ,  $M, C_i, \overline{s}_i(t-(n-1)\tau), C_j, \Delta \overline{s}_{i,j}(t-(n-1)\tau)$ , 其中  $n=1, 2, \dots, N$ ; 将这些变量输入换道轨迹预测模型,模型输出车辆x轴和y轴方向的位置预测结果  $x(t+T)$  和  $y(t+T)$ ;

[0098] 误差分析指标为均方误差(MSE)。

[0099] 本发明通过一个实施例本方法进行具体说明:

[0100] 首先,选取NGSIM数据集中美国I-101高速公路及I-80高速公路路段上实际驾驶车辆轨迹数据,作为构建换道轨迹样本库的原始数据,包含7:50-8:35a.m.时段的人工驾驶车辆轨迹数据。研究路段如图2(a)及图2(b)所示。

[0101] 然后对所获取的驾驶轨迹数据进行处理,获取车辆自身的空间信息和运动信息,并计算包含邻近车相对状态的数据;对原始数据进行初步的筛选,剔除缺失信息的车辆数据;对获得的数据进行邻近车的判定,并存储相关信息(包括车长,车宽,速度,位置等信息);对获得的具有邻近车的数据进行计算相对状态,并筛选出换道数据;从处理得到的换道数据中做车辆历史数据缺失的筛选,剔除数据中数据异常的换道数据;根据所需历史序列长度N生成样本库。

[0102] 接着构建基于长短期记忆神经网络的无人驾驶车辆换道轨迹预测模型,模型结构如图3所示。

[0103] 根据所述模型的输入和输出变量,对换道轨迹原始数据库进行数据处理,形成人工驾驶车辆换道轨迹样本库,包括训练样本集和精度验证样本集,获得训练样本超过110000个,精度验证样本37440个。

[0104] 随机抽取10,000个对不同历史序列长度N条件下的模型进行测试,得到测试历史序列长度N=5;

[0105] 使用不同的神经网络模型结构和不同的样本量对换道轨迹进行建模,选择隐藏层层数和每层节点数具有代表性的神经网络结构,分别使用不同的训练数据量对各网络结构进行训练,获得最佳结构方案1LS1和最佳训练样本量110000;

[0106] 在最佳的网络结构1LS1和最佳训练样本量110000的条件下,训练不同历史序列长度N的LSTM-LC模型,选取最优历史序列长度N=5;

[0107] 最后应用37440个精度验证样本对训练好的LSTM-LC模型进行精度验证。

[0108] 本实施例的模型验证结果较为理想,构建的基于LSTM的无人驾驶车辆换道轨迹预测模型的均方误差为 $3.18m^2$ ,考虑到车辆换道行为中复杂的具体操作和情况的多样化,这个结果是令人满意的。

[0109] 综上所述,本发明形成一种适用于人机混驾环境下基于深度学习的无人驾驶车辆换道轨迹预测方法,可以利用实测数据为无人驾驶车辆的换道轨迹进行快速、有效的预测,



为开发无人驾驶车辆驾驶轨迹预测模型奠定基础,具有实际推广价值,值得推广。

[0110] 上述实施例为本发明较佳的实施方式,但本发明的实施方式并不受所述实施例的限制,其他的任何未背离本发明的精神实质与原理下所作的改变、修饰、替代、组合、简化,均应为等效的置换方式,都包含在本发明的保护范围之内。

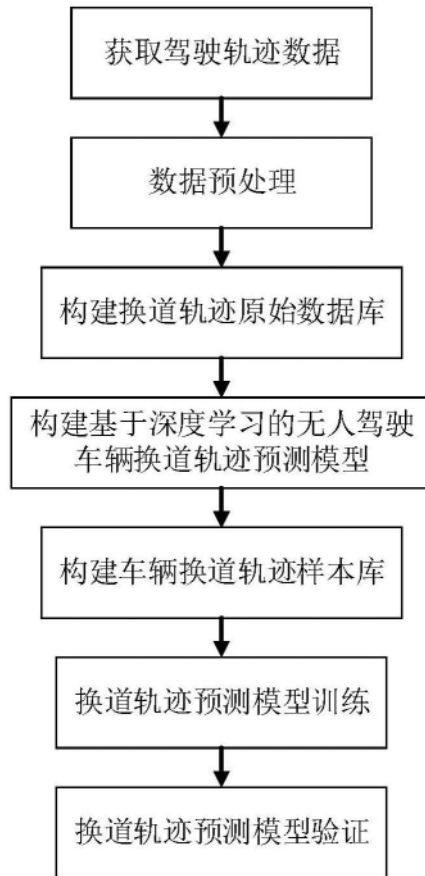


图1




图2(a)




图2(b)




图3

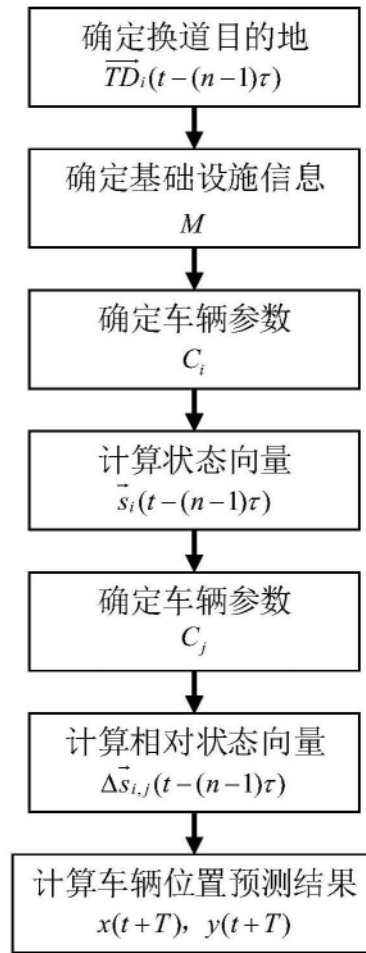


图4