



(12) 发明专利

(10) 授权公告号 CN 111145552 B
(45) 授权公告日 2022. 04. 29

(21) 申请号 202010011237.5
(22) 申请日 2020.01.06
(65) 同一申请的已公布的文献号
申请公布号 CN 111145552 A
(43) 申请公布日 2020.05.12

(73) 专利权人 重庆大学
地址 400044 重庆市沙坪坝区沙坪坝正街
174号
(72) 发明人 刘永刚 周波波 何举刚 梁锋华
文滔 熊周兵 陈峥
(74) 专利代理机构 重庆志合专利事务所(普通
合伙) 50210
代理人 徐传智

(51) Int. Cl.
G08G 1/01 (2006.01)
G08G 1/16 (2006.01)
H04W 4/46 (2018.01)
G06F 30/27 (2020.01)

G06N 3/04 (2006.01)

(56) 对比文件
CN 109739218 A, 2019.05.10
CN 109501799 A, 2019.03.22
CN 110597245 A, 2019.12.20
Ling Huang等. Capturing Drivers' Lane
Changing Behaviors on Operational Level
by Data Driven Methods. 《SPECIAL SECTION
ON ADVANCED BIG DATA ANALYSIS FOR
VEHICULAR SOCIAL NETWORKS》. 2018,
李国法等. 智能汽车决策中的驾驶行为语义
解析关键技术. 《汽车安全与节能学报》. 2019,
(第04期),
王浩等. 基于GRU递归神经网络的城市道路
超车预测. 《中国科技论文》. 2019, (第03期),
王志洪等. 基于禁忌搜索算法的换道轨迹优
化. 《科学技术与工程》. 2013, (第27期),

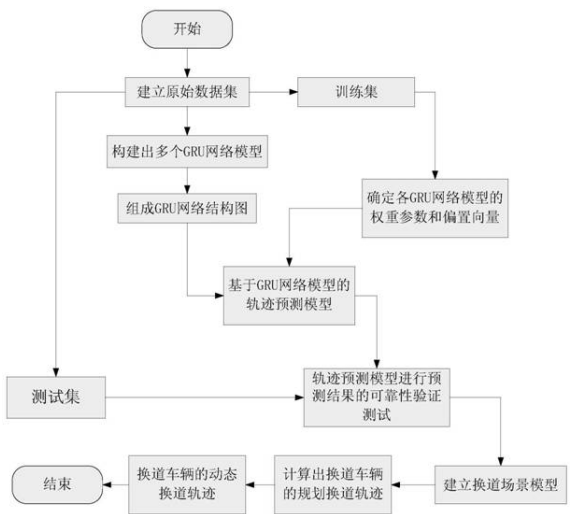
审查员 庞丽丽

权利要求书2页 说明书5页 附图8页

(54) 发明名称
基于5G网络的车辆动态换道轨迹的规划方
法

(57) 摘要
一种基于5G网络的车辆动态换道轨迹的规
划方法, 包括以下步骤: 1) 通过优秀驾驶员在实
际道路环境中进行换道试验, 得到连续的周围车
辆的行驶轨迹点作为原始数据集; 2) 构建出多个
GRU网络模型, 组成用于预测周围车辆的行驶轨
迹的GRU网络结构图; 3) 将步骤1) 得到的原始数
据集分为训练集和测试集; 3-1) 利用训练集确定
各GRU网络模型的权重参数和偏置向量, 得到基
于GRU网络模型的轨迹预测模型; 3-2) 利用测试
集对基于GRU网络模型的轨迹预测模型进行预测
结果的可靠性验证测试; 4) 建立换道场景模型;
5) 计算出换道车辆的换道规划轨迹; 6) 根据实时
交通流情况重复步骤2) 到步骤5), 进行滚动计算
得到实时响应周围交通流变化的换道车辆的动

态换道轨迹。



1. 一种基于5G网络的车辆动态换道轨迹的规划方法,其特征在于:包括以下步骤:

1) 通过优秀驾驶员在实际道路环境中进行换道试验,利用5G网络通过全球定位系统和车对车通信系统(V2V)采集换道车辆周围的车辆的行驶轨迹数据,对换道车辆和周围车辆的轨迹坐标进行坐标统一化,得到连续的周围车辆的行驶轨迹点作为原始数据集;

2) 在步骤1)得到的原始数据集的数据中,将t时刻前n个时间段($t-n+1, t-n+2, \dots, t$)的数据作为GRU网络模型的输入,t+1时刻的数据作为GRU网络模型的输出,构建出多个GRU网络模型,组成用于预测周围车辆的行驶轨迹的GRU网络结构图;

3) 将步骤1)得到的原始数据集分为训练集和测试集;

3-1) 通过训练集的数据训练步骤2)得到的GRU网络结构图中的各GRU网络模型,确定各GRU网络模型的权重参数和偏置向量,得到基于GRU网络模型的轨迹预测模型;

3-2) 利用测试集的数据对步骤3-1)得到的基于GRU网络模型的轨迹预测模型进行预测结果的可靠性验证测试;

4) 将步骤3-1)中通过预测结果的可靠性验证测试的基于GRU网络模型的轨迹预测模型作为换道车辆的换道决策和轨迹规划的约束条件,并建立换道场景模型;

5) 利用步骤4)建立的换道场景模型中满足约束条件的代价函数构建换道车辆的动态换道轨迹规划模型,计算出换道车辆的换道规划轨迹;

6) 将换道车辆的换道规划轨迹的用时分成若干时间步长,每一个时间步长中换道车辆根据实时交通流情况采集周围车辆的行驶轨迹数据,重复步骤2)到步骤5)进行滚动计算,得到每一个时间步长内的实时换道规划轨迹,并将各时间步长的实时换道规划轨迹进行组合,得到实时响应周围交通流变化的换道车辆的动态换道轨迹。

2. 根据权利要求1所述的基于5G网络的车辆动态换道轨迹的规划方法,其特征在于:步骤1)中所述的行驶轨迹数据为t时刻车辆的状态信息,包括位置信息和速度信息,即(x_t, y_t, v_t)。

3. 根据权利要求1所述的基于5G网络的车辆动态换道轨迹的规划方法,其特征在于:步骤2)中所述的GRU网络模型由以下公式表示:

$$z_t = \text{sigmoid}(W_z \cdot [h_{t-1}, x_t])$$

$$r_t = \text{sigmoid}(W_r \cdot [h_{t-1}, x_t])$$

$$\tilde{h}_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t])$$

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

式中, r_t 表示GRU网络模型的重置门, z_t 表示GRU网络模型的更新门, x_t 表示当前节点的输入, \tilde{h}_t 表示当前节点输出的候选隐藏状态, h_t 表示当前节点输出的隐藏状态。

4. 根据权利要求1所述的基于5G网络的车辆动态换道轨迹的规划方法,其特征在于:步骤3-1)中确定各GRU网络模型的权重参数和偏置向量的步骤如下:

首先初始化GRU网络的权重参数和偏置向量,使用初始学习率将步骤3)得到的训练集的数据送入GRU网络模型进行训练处理,取t时刻前n个时间段的数据作为样本数据,取t+1时刻的数据作为标签数据,采用梯度下降法(Gradient Descent Optimization)最小化GRU网络模型的损失函数,多次迭代后,完成GRU网络模型的训练,得到GRU网络模型的权重参数

和偏置向量。

5. 根据权利要求1所述的基于5G网络的车辆动态换道轨迹的规划方法, 其特征在于: 步骤5) 中所述的满足约束条件的代价函数如下:

$$\text{cost} = f(x_f, j)$$

式中, x_f 为车辆最小化换道的纵向距离, j 为车辆加速度的变化值。

6. 根据权利要求5所述的基于5G网络的车辆动态换道轨迹的规划方法, 其特征在于: 所述代价函数中 x_f 满足以下公式作为约束条件:

$$x_f > \frac{6y_f u}{\sqrt{6y_f a_{rl\max}}}$$

式中,

y_f 为换道纵向距离, u 为车辆速度, $a_{rl\max}$ 为换道车辆侧翻的最大侧向加速度。

7. 根据权利要求1所述的基于5G网络的车辆动态换道轨迹的规划方法, 其特征在于: 步骤5) 中所述的计算出换道车辆的换道轨迹的方法采用的是内点法。

基于5G网络的车辆动态换道轨迹的规划方法

技术领域

[0001] 本发明涉及汽车领域,具体涉及一种基于5G网络的车辆动态换道轨迹的规划方法。

背景技术

[0002] 车辆换道行为的可靠性、安全性和效率与车辆的行驶安全性和道路通畅有着紧密的关系。因此,智能车辆换道行为的研究一直是自动驾驶的关键之一。

[0003] 自动驾驶汽车需要具备预测周围车辆运动轨迹的能力,进而为无人驾驶汽车的行为决策和轨迹规划提供参考,进而充分确保无人驾驶汽车的安全性和舒适性。目前关于换道轨迹规划的研究中普遍对换道的实时性和安全性考虑不足。主要体现在以下几个方面:第一,现有研究中的换道轨迹规划场景比较简单,大都假设在换道过程中换道车辆周围的车辆速度保持不变,且换道车辆周围车辆较少;第二,换道轨迹的规划大都在换道开始前完成,对换道过程中周围车辆运动状态的实时变化考虑不足,导致按换道前规划好的轨迹进行换道操作存在潜在碰撞危险;第三,未考虑周围车辆未来运动轨迹对换道车辆轨迹规划的影响,导致规划的轨迹不适应周围车辆未来运动轨迹的变化,进而对换道的安全性构成威胁。

发明内容

[0004] 本发明的目的是针对现有技术对应的不足,提供一种基于5G网络的车辆动态换道轨迹的规划方法,利用5G网络的大带宽、低时延和车对车通信系统(V2V)实时、准确获取换道车辆周围的车辆的状态信息,建立GRU(Gate Recurrent Unit)网络模型预测周围车辆运动轨迹,通过对换道安全性、换道效率、换道舒适性三个指标来计算换道车辆的最优动态换道轨迹,使换道车辆在复杂多变的真实交通场景下实现动态换道轨迹规划,提高换道车辆的换道规划的实时性、安全性和可靠性。

[0005] 本发明的目的是采用下述方案实现的:一种基于5G网络的车辆动态换道轨迹的规划方法,包括以下步骤:

[0006] 1)通过优秀驾驶员在实际道路环境中进行换道试验,利用5G网络通过全球定位系统和车对车通信系统(V2V)采集换道车辆周围的车辆的行驶轨迹数据,对换道车辆和周围车辆的轨迹坐标进行坐标统一化,得到连续的周围车辆的行驶轨迹点作为原始数据集;

[0007] 2)在步骤1)得到的原始数据集的数据中,将 t 时刻前 n 个时间段($t-n+1, t-n+2, \dots, t$)的数据作为GRU网络模型的输入, $t+1$ 时刻的数据作为GRU网络模型的输出,构建出多个GRU网络模型,组成用于预测周围车辆的行驶轨迹的GRU网络结构图;

[0008] 3)将步骤1)得到的原始数据集分为训练集和测试集;

[0009] 3-1)通过训练集的数据训练步骤2)得到的GRU网络结构图中的各GRU网络模型,确定各GRU网络模型的权重参数和偏置向量,得到基于GRU网络模型的轨迹预测模型;

[0010] 3-2)利用测试集的数据对步骤3-1)得到的基于GRU网络模型的轨迹预测模型进行

预测结果的可靠性验证测试；

[0011] 4) 将步骤3-1)中通过预测结果的可靠性验证测试的基于GRU网络模型的轨迹预测模型作为换道车辆的换道决策和轨迹规划的约束条件,并建立换道场景模型；

[0012] 5) 利用步骤4)建立的换道场景模型中满足约束条件的代价函数构建换道车辆的动态换道轨迹规划模型,计算出换道车辆的换道规划轨迹；

[0013] 6) 将换道车辆的换道规划轨迹的用时分成若干时间步长,每一个时间步长中换道车辆根据实时交通流情况采集周围车辆的行驶轨迹数据,重复步骤2)到步骤5)进行滚动计算,得到每一个时间步长内的实时换道规划轨迹,并将各时间步长的实时换道规划轨迹进行组合,得到实时响应周围交通流变化的换道车辆的动态换道轨迹。

[0014] 步骤1)中所述的行驶轨迹数据为t时刻车辆的状态信息,包括位置信息和速度信息,即 (x_t, y_t, v_t) 。

[0015] 步骤2)中所述的GRU网络模型由以下公式表示：

$$[0016] \quad z_t = \text{sigmoid}(W_z \cdot [h_{t-1}, x_t])$$

$$[0017] \quad r_t = \text{sigmoid}(W_r \cdot [h_{t-1}, x_t])$$

$$[0018] \quad \tilde{h}_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t])$$

$$[0019] \quad h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t$$

[0020] 式中, r_t 表示GRU网络模型的重置门, z_t 表示GRU网络模型的更新门, x_t 表示当前节点的输入, \tilde{h}_t 表示当前节点输出的候选隐藏状态, h_t 表示当前节点输出的隐藏状态。

[0021] 步骤3-1)中确定各GRU网络模型的权重参数和偏置向量的步骤如下：

[0022] 首先初始化GRU网络的权重参数和偏置向量,使用初始学习率将步骤3)得到的训练集的数据送入GRU网络模型进行训练处理,取t时刻前n个时间段的数据作为样本数据,取t+1时刻的数据作为标签数据,采用梯度下降法(Gradient Descent Optimization)最小化GRU网络模型的损失函数,多次迭代后,完成GRU网络模型的训练,得到GRU网络模型的权重参数和偏置向量。

[0023] 步骤5)中所述的满足约束条件的代价函数如下：

$$[0024] \quad \text{cost} = f(x_f, j)$$

[0025] 式中, x_f 为车辆最小化换道的纵向距离, j 为车辆加速度的变化值。

[0026] 所述代价函数中 x_f 满足以下公式作为约束条件：

$$[0027] \quad x_f > \frac{6y_f u}{\sqrt{6y_f a_{rl\max}}}$$

[0028] 式中,

[0029] y_f 为换道纵向距离, u 为车辆速度, $a_{rl\max}$ 为换道车辆侧翻的最大侧向加速度。

[0030] 步骤5)中所述的计算出换道车辆的换道轨迹的方法采用的是内点法。

[0031] 本发明通过优秀驾驶员(即拥有C1驾照超过3年,且未发生过交通违章及事故的驾驶员)在实际道路环境中进行换道试验,利用5G网络的大带宽、低时延的特点通过全球定位系统使车对车通信系统(V2V)实时、准确获取换道车辆周围的车辆的状态信息,即换道车辆实时获取对周围交通流的运动轨迹和状态信息,坐标统一化换道车辆和周围车辆的轨迹

坐标,得到连续的周围车辆的行驶轨迹点作为原始数据集,并利用原始数据集的数据构建出多个GRU网络模型,组成用于预测周围车辆的行驶轨迹的GRU网络结构图。

[0032] GRU网络模型是循环神经网络 (Recurrent Neural Network, RNN) 的一种,解决了长期记忆和反向传播中的梯度等问题,对计算机内存的要求低,更容易训练,所以本发明通过构建GRU网络模型,解决了标准RNN的梯度消失问题,在保证快速学习的基础上对周围车辆的轨迹进行预测,为换道车辆的换道轨迹规划提供了安全可靠的保障,最大程度的避免了换道车辆在换道过程中存在的危险。

[0033] 本发明中的GRU网络模型是根据原始数据集中 t 时刻前 n 个时间段($t-n+1, t-n+2, \dots, t$)的周围车辆的行驶轨迹数据(全局坐标和速度)来预测 $t+1$ 时刻的周围车辆的行驶轨迹,步骤1)中所述的行驶轨迹数据为 t 时刻车辆的状态信息,包括位置信息和速度信息,即 (x_t, y_t, v_t) ,最大程度反应换道车辆周围交通流的实际情况,为建立GRU网络模型提供准确的数据支持。

[0034] 由于换道过程至少涉及两个相邻车道,从而在换道过程中会影响道路的通行效率,车辆最小化换道的纵向距离 x_f 会降低换道所带来对交通效率的影响,所以选择车辆最小化换道的纵向距离 x_f 来描述换道效率;由于换道过程中存在速度和加速度的变化,这会带来舒适性的影响,一般来说,当车辆匀速行驶时,乘客不会有感觉,当车辆以恒定加速度行驶时,乘客可以通过调整自身来进行适应,而当车辆的加速度在变化时,乘客就会失去调节的平衡,从而感受到不舒服,因此选择车辆加速度的变化值 j 作为衡量乘客舒适性的参数。

[0035] 故步骤5)中所述的满足约束条件的代价函数如下:

[0036] $\text{cost} = f(x_f, j)$

[0037] 式中, x_f 为车辆最小化换道的纵向距离, j 为车辆加速度的变化值。

[0038] 所述代价函数中 x_f 满足以下公式作为约束条件:

[0039]
$$x_f > \frac{6y_f u}{\sqrt{6y_f a_{rl\max}}}$$

[0040] 式中,

[0041] y_f 为换道纵向距离, u 为车辆速度, $a_{rl\max}$ 为换道车辆侧翻的最大侧向加速度。

[0042] 步骤5)中所述的内点法是一种求解线性规划或非线性凸优化问题的算法。

[0043] 本发明中所述的GRU网络模型、轨迹预测模型、换道场景模型、换道车辆的动态换道轨迹规划模型均是在计算机中建立。

附图说明

[0044] 图1为用于预测周围车辆的行驶轨迹的GRU网络结构图;

[0045] 图2为GRU网络模型的结构图;

[0046] 图3为换道场景示意图;

[0047] 图4为换道车辆的动态换道轨迹规划图;

[0048] 图5为换道模型示意图;

[0049] 图6为本发明的流程图;

[0050] 图7为换道车辆在第1时间步长内的实时换道规划轨迹图;

- [0051] 图8为换道车辆在第2时间步长内的实时换道规划轨迹图；
 [0052] 图9为换道车辆在第3时间步长内的实时换道规划轨迹图；
 [0053] 图10为换道车辆在第4时间步长内的实时换道规划轨迹图；
 [0054] 图11为换道车辆在第5时间步长内的实时换道规划轨迹图；
 [0055] 图12为换道车辆各时间步长的实时换道规划轨迹组合图；
 [0056] 图13为实时响应周围交通流变化的换道车辆的动态换道轨迹图。

具体实施方式

[0057] 如图1至图13所示,一种基于5G网络的车辆动态换道轨迹的规划方法,包括以下步骤:

[0058] 1)通过优秀驾驶员在实际道路环境中进行换道试验,利用5G网络通过全球定位系统和车对车通信系统(V2V)采集换道车辆周围的车辆的行驶轨迹数据,对换道车辆和周围车辆的轨迹坐标进行坐标统一化,得到连续的周围车辆的行驶轨迹点作为原始数据集;

[0059] 步骤1)中所述的行驶轨迹数据为 t 时刻车辆的状态信息,包括位置信息和速度信息,即 (x_t, y_t, v_t) 。

[0060] 例如,选择男性、女性优秀驾驶员共6名在实际道路环境中进行换道试验,分别采用20km/h,40km/h,60km/h的车速在如图3所示的换道场景下进行换道操作,通过差分全球定位系统(Differential Global Positioning System,简称DGPS或差分GPS)采集换道车辆周围的车辆的行驶轨迹数据,选择全局坐标原点,对周围车辆的轨迹坐标进行坐标统一化,采集6名优秀驾驶员驾驶的周围车辆 t 时刻前 n 个时间段的行驶轨迹点作为原始数据,采集到的原始数据通常是有很多的噪点的,很多时候都会不稳定,有明显波动,需要对采集的原始数据进行降噪处理,去除异常数据后汇总,形成原始数据集。

[0061] 2)在步骤1)得到的原始数据集的数据中,将 t 时刻前 n 个时间段($t-n+1, t-n+2, \dots, t$)的数据作为GRU网络模型的输入, $t+1$ 时刻的数据作为GRU网络模型的输出,构建出多个GRU网络模型,组成用于预测周围车辆的行驶轨迹的GRU网络结构图;

[0062] 步骤2)中所述的GRU网络模型由以下公式表示:

$$[0063] \quad z_t = \text{sigmoid}(W_z \cdot [h_{t-1}, x_t])$$

$$[0064] \quad r_t = \text{sigmoid}(W_r \cdot [h_{t-1}, x_t])$$

$$[0065] \quad \tilde{h}_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t])$$

$$[0066] \quad h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t$$

[0067] 式中, r_t 表示GRU网络模型的重置门, z_t 表示GRU网络模型的更新门, x_t 表示当前节点的输入, \tilde{h}_t 表示当前节点输出的候选隐藏状态, h_t 表示当前节点输出的隐藏状态。

[0068] 如图1所示,用于预测周围车辆的行驶轨迹的GRU网络结构图由多个GRU网络模型组成,根据某时刻前 n 个时间段的行驶轨迹预测下一时刻的行驶轨迹,相比于其他RNN网络模型(比如LSTM),GRU网络模型最具优势的一点是使用了同一个更新门控 z_t 就可以进行选择遗忘和记忆,从而遗忘和选择的信息是可以联动的,也就是说对于传递进来的维度信息,我们会进行选择遗忘,遗忘的权重可以使用包含当前输入的对应权重进行弥补,从而可

以保持以一种恒定状态。

[0069] 3) 将步骤1) 得到的原始数据集分为训练集和测试集, 例如, 80% 作为训练集, 20% 作为测试集。

[0070] 3-1) 通过训练集的数据训练步骤2) 得到的GRU网络结构图中的各GRU网络模型, 确定各GRU网络模型的权重参数和偏置向量, 得到基于GRU网络模型的轨迹预测模型;

[0071] 步骤3-1) 中确定各GRU网络模型的权重参数和偏置向量的步骤如下:

[0072] 首先初始化GRU网络的权重参数和偏置向量, 使用初始学习率将步骤3) 得到的训练集的数据送入GRU网络模型进行训练处理, 取t时刻前n个时间段的数据作为样本数据, 取t+1时刻的数据作为标签数据, 采用梯度下降法 (Gradient Descent Optimization) 最小化GRU网络模型的损失函数, 多次迭代后, 完成GRU网络模型的训练, 得到GRU网络模型的权重参数和偏置向量。

[0073] 3-2) 利用测试集的数据对步骤3-1) 得到的基于GRU网络模型的轨迹预测模型进行预测结果的可靠性验证测试;

[0074] 4) 将步骤3-1) 中通过预测结果的可靠性验证测试的基于GRU网络模型的轨迹预测模型作为换道车辆的换道决策和轨迹规划的约束条件, 并建立换道场景模型;

[0075] 如图3所示, 本实施例为三车道, 前后六车的换道场景, 各车辆行驶速度都不超过本车道最大限速, 左侧车道为快车道; 假设在换道过程中, 当前车道后方车辆完全注意到换道车辆的换道操作, 配合换道车辆调整自己速度;

[0076] 其中, 换道车辆也称为自车, 用E表示; 周围车辆 (左前、正前、右前、左后、正后、右后) 分别用FL, FM, FR, RL, RM, RR表示;

[0077] 5) 利用步骤4) 建立的换道场景模型中满足约束条件的代价函数构建换道车辆的动态换道轨迹规划模型, 计算出换道车辆的换道规划轨迹;

[0078] 步骤5) 中所述的满足约束条件的代价函数如下:

[0079] $\text{cost} = f(x_f, j)$

[0080] 式中, x_f 为车辆最小化换道的纵向距离, j 为车辆加速度的变化值。

[0081] 所述代价函数中 x_f 满足以下公式作为约束条件:

$$[0082] \quad x_f > \frac{6y_f u}{\sqrt{6y_f a_{rl\max}}}$$

[0083] 式中,

[0084] y_f 为换道纵向距离, u 为车辆速度, $a_{rl\max}$ 为换道车辆侧翻的最大侧向加速度。

[0085] 步骤5) 中所述的计算出换道车辆的换道轨迹的方法采用的是内点法。

[0086] 6) 将换道车辆的换道规划轨迹的用时分成若干时间步长, 本实施例中, 将换道车辆的换道规划轨迹的用时分成五个时间步长, 每一个时间步长中换道车辆根据实时交通流情况采集周围车辆的行驶轨迹数据, 重复步骤2) 到步骤5) 进行滚动计算, 得到每一个时间步长内的实时换道规划轨迹, 并将各时间步长的实时换道规划轨迹进行组合, 得到实时响应周围交通流变化的换道车辆的动态换道轨迹, 如图7至图13所示。

[0087] 以上所述仅为本发明的优选实施例, 并不用于限制本发明, 本领域的技术人员在不脱离本发明的精神的前提下, 对本发明进行的改动均落入本发明的保护范围。

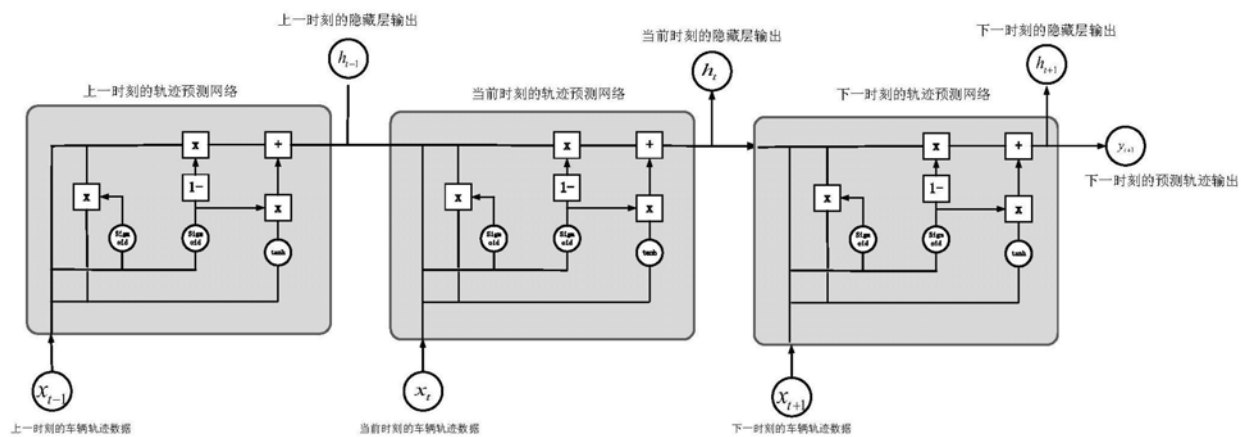


图1

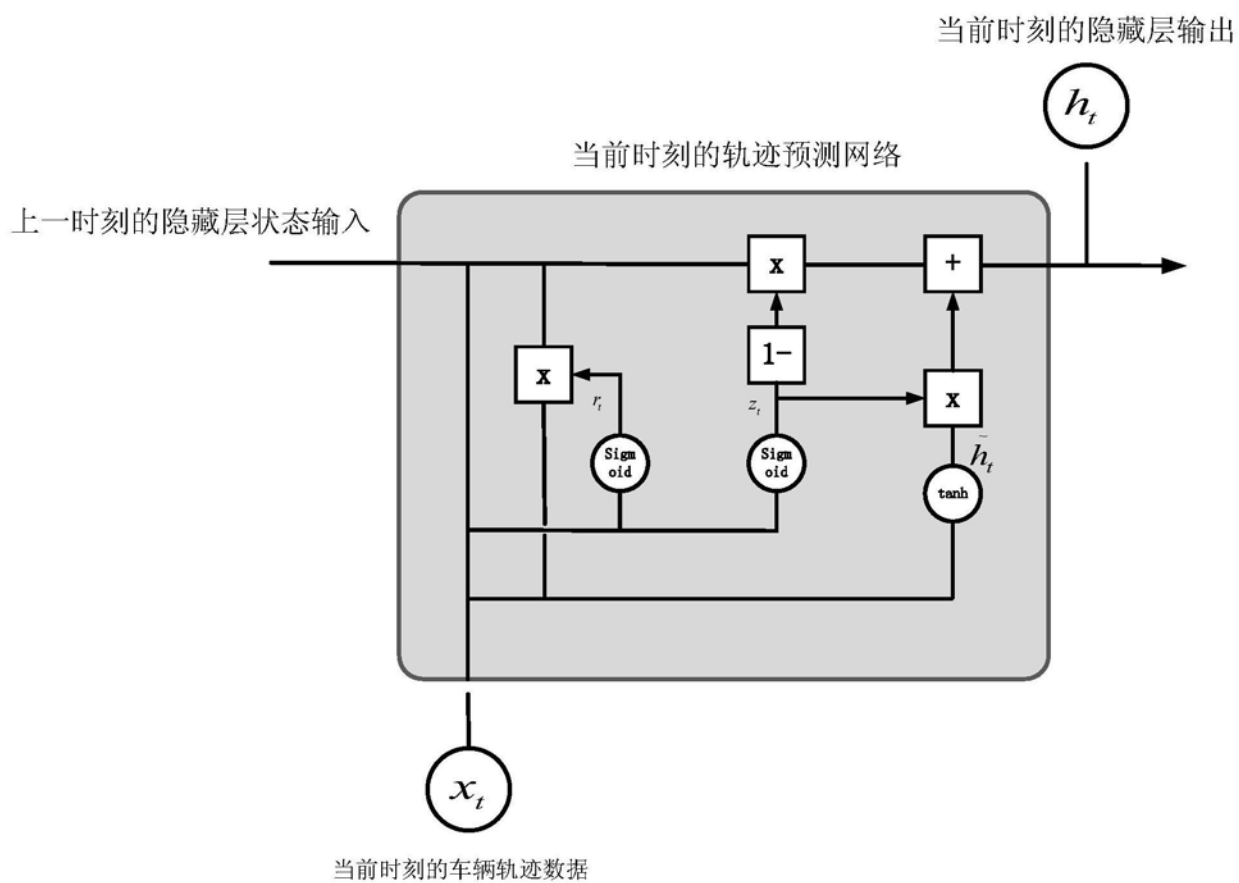


图2




图3

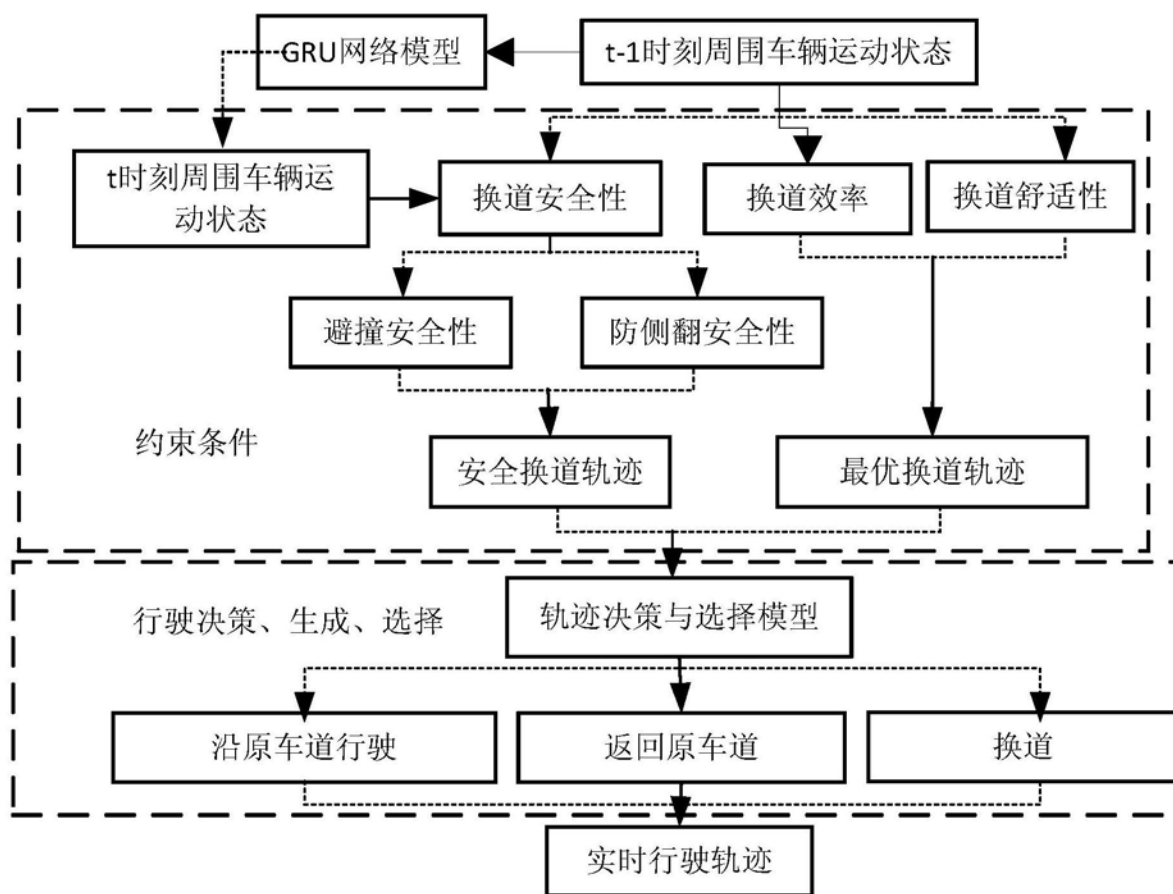


图4




图5

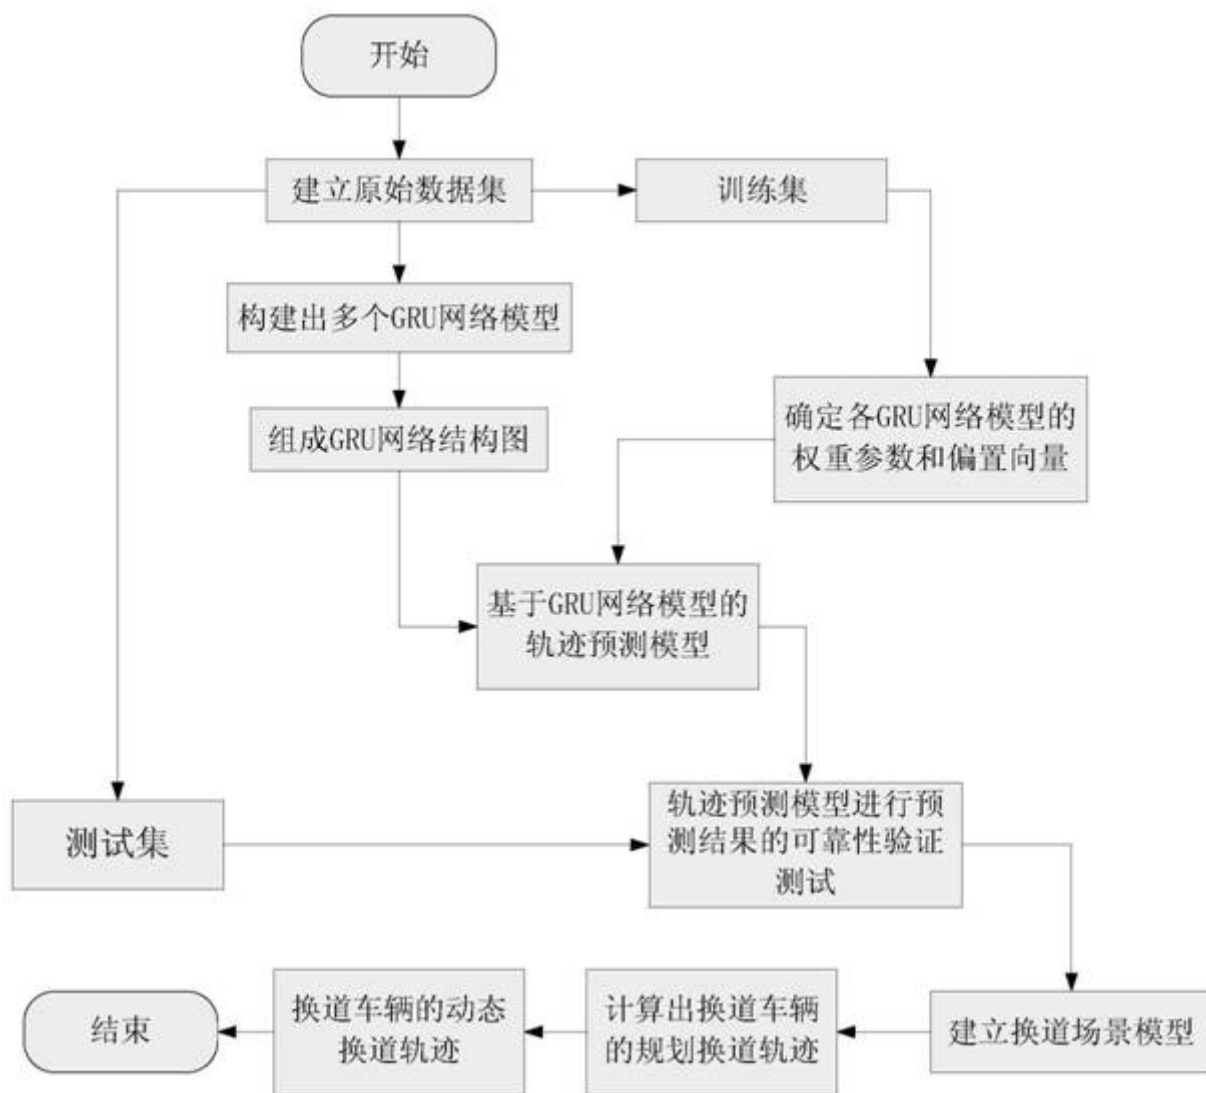


图6




图7




图8




图9




图10




图11




图12




图13