



(12)发明专利申请

(10)申请公布号 CN 106950956 A

(43)申请公布日 2017.07.14

(21)申请号 201710174970.7

(22)申请日 2017.03.22

(71)申请人 合肥工业大学

地址 230009 安徽省合肥市包河区屯溪路193号

(72)发明人 钱立军 谢国涛 王建强 黄彬 吴冰 许庆

(74)专利代理机构 安徽省合肥新安专利代理有限责任公司 34101

代理人 何梅生

(51)Int.Cl.

G05D 1/02(2006.01)

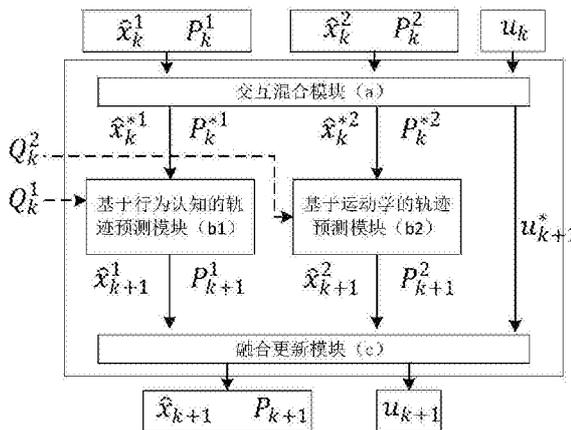
权利要求书5页 说明书10页 附图2页

(54)发明名称

融合运动学模型和行为认知模型的行车轨迹预测系统

(57)摘要

本发明公开了一种融合运动学模型和行为认知模型的行车轨迹预测系统,其特征是以交互混合模块对每个预测模块上一时刻的预测结果进行交互混合输出混合结果,混合结果用于下一时刻的预测;预测模块包括基于行为认知的行为认知轨迹预测模块和基于运动学的运动轨迹预测模块,行为认知轨迹预测模块和运动轨迹预测模块根据交互混合模块输出的混合结果进行预测,输出各预测模块的预测结果,预测结果包括车辆位置和协方差矩阵;融合更新模块根据预测结果对最终预测结果进行融合,并更新权重系数,输出未来某时刻车辆位置以及协方差矩阵。本发明能够在车辆行驶过程中不断估计车辆位置状态以及驾驶行为,预测行车轨迹,为智能驾驶决策提供帮助。



1. 一种融合运动学模型和行为认知模型的行车轨迹预测系统,其特征是包括:

交互混合模块a,其对每个预测模块上一时刻的预测结果进行交互混合输出混合结果,所述混合结果用于下一时刻的预测;

所述预测模块包括基于行为认知的行为认知轨迹预测模块b1和基于运动学的运动轨迹预测模块b2,所述行为认知轨迹预测模块b1和所述运动轨迹预测模块b2根据交互混合模块a输出的混合结果进行预测,输出各预测模块的预测结果,所述预测结果包括车辆位置和协方差矩阵;

融合更新模块c,根据所述预测模块输出的各个预测结果,对最终预测结果进行融合,并更新权重系数,输出未来某时刻车辆位置以及协方差矩阵。

2. 根据权利要求1所述的融合运动学模型和行为认知模型的行车轨迹预测系统,其特征是:所述预测模块的预测结果包括由所述行为认知轨迹预测模块b1预测的k时刻车辆参数预测均值 $\hat{x}_k^1$ 和预测协方差 $P_k^1$ ,以及由所述运动轨迹预测模块b2预测的k时刻车辆参数预测均值 $\hat{x}_k^2$ 和预测协方差 $P_k^2$ ;车辆参数表示为向量X, $X=(x,y,\theta,v,a,\omega)$ ,其中x、y、 $\theta$ 、v、a和 $\omega$ 一一对应表示为纵向位置、横向位置、横摆角、行车速度、行车加速度以及横摆角速度;初始时刻的车辆参数均值和协方差为环境变量观测估计值;

设定所述行为认知轨迹预测模块b1中的预测模型M1和所述运动轨迹预测模块b2中的预测模型M2随时间的转移满足一阶马尔科夫假设,定义转移矩阵p为:

$$p=(0.85,0.15;0.15,0.85)$$

输入所述行为认知轨迹预测模块b1和所述运动轨迹预测模块b2的车辆参数混合均值和混合协方差是:

$$\hat{x}_k^{*1} = \mu_k^{1|1} \hat{x}_k^1 + \mu_k^{2|1} \hat{x}_k^2$$

$$\hat{x}_k^{*2} = \mu_k^{1|2} \hat{x}_k^1 + \mu_k^{2|2} \hat{x}_k^2$$

$$P_k^{*1} = \mu_k^{1|1} (P_k^1 + (\hat{x}_k^1 - \hat{x}_k^{*1})(\hat{x}_k^1 - \hat{x}_k^{*1})^T) + \mu_k^{2|1} (P_k^2 + (\hat{x}_k^2 - \hat{x}_k^{*1})(\hat{x}_k^2 - \hat{x}_k^{*1})^T)$$

$$P_k^{*2} = \mu_k^{1|2} (P_k^1 + (\hat{x}_k^1 - \hat{x}_k^{*2})(\hat{x}_k^1 - \hat{x}_k^{*2})^T) + \mu_k^{2|2} (P_k^2 + (\hat{x}_k^2 - \hat{x}_k^{*2})(\hat{x}_k^2 - \hat{x}_k^{*2})^T)$$

其中:

$\hat{x}_k^{*1}$ 和 $P_k^{*1}$ 分别为预测模块b1在k时刻的车辆参数混合均值和混合协方差;

$\hat{x}_k^{*2}$ 和 $P_k^{*2}$ 分别是预测模块b2在k时刻的车辆参数混合均值和混合协方差;

$$\mu_k^{1|1} = \frac{1}{p_{11}\mu_k^1 + p_{21}\mu_k^2}; \quad \mu_k^{2|1} = \frac{1}{p_{11}\mu_k^1 + p_{21}\mu_k^2} p_{21}\mu_k^2;$$

$$\mu_k^{1|2} = \frac{1}{p_{12}\mu_k^1 + p_{22}\mu_k^2} p_{12}\mu_k^1; \quad \mu_k^{2|2} = \frac{1}{p_{12}\mu_k^1 + p_{22}\mu_k^2} p_{22}\mu_k^2;$$

其中: $p_{11}=0.85, p_{12}=0.15, p_{21}=0.15, p_{22}=0.85$ ;

$\mu_k^1$ 是预测模块b1在k时刻的权重, $\mu_k^2$ 是预测模块b2在k时刻的权重,定义:在k=0的初始时刻下, $\mu_0^1 = 0.1; \mu_0^2 = 0.9$ 。

3. 根据权利要求2所述的融合运动学模型和行为认知模型的行车轨迹预测系统,其特征是:

所述行为认知轨迹预测模块b1包括驾驶行为认知单元(1)和轨迹预测单元(2);所述驾

驶行为认知单元(1)用于估计驾驶行为,输出行为认知概率分布;所述轨迹预测单元(2)基于驾驶行为预测行车轨迹,输出未来一段时间的车辆位置以及协方差矩阵;

所述运动轨迹预测模块b2包括车辆运动学单元(3)和基于UKF的轨迹预测单元(4);利用所述车辆运动学单元(3)根据车辆运动学模型推导各个变量的关系,输出状态转移方程;所述基于UKF的轨迹预测单元(4)根据所述状态转移方程,考虑观测不确定性和模型不确定性,预测车辆轨迹,输出车辆在未来一段时间的车辆参数预测均值和预测协方差。

4.根据权利要求3所述的融合运动学模型和行为认知模型的行车轨迹预测系统,其特征是:

所述行为认知单元(1)包括驾驶行为数据库和驾驶行为认知网络学习;所述驾驶行为数据库是通过采集真实道路信息构建而成,是驾驶行为认知学习的数据基础;所述驾驶行为认知网络学习是基于驾驶行为数据库,应用expectation maximization算法优化网络参数,学习驾驶行为认知知识;

所述轨迹预测单元(2)是基于驾驶行为认知单元(1),对行车轨迹按如下方法进行预测:

首先,根据驾驶行为概率分布 $p(B=B_0|Z_{1:k_0})$ ,将预测轨迹概率 $p(X_{k_0+k_p}|Z_{1:k_0})$ 描述为:

$$p(X_{k_0+k_p}|Z_{1:k_0}) = \sum_{B_0} p(X_{k_0+k_p}|B=B_0)p(B=B_0|Z_{1:k_0})$$

其中, $Z_{1:k_0}$ 是观测的信息序列, $X_{k_0+k_p}$ 表示预测的位置参数, $k_0$ 是开始预测的时间, $k_p$ 是预测时间长度, $B$ 表示驾驶行为, $B_0$ 表示某个驾驶行为如换道行为, $p(X_{k_0+k_p}|B=B_0)$ 表示某个驾驶行为下预测轨迹的概率分布;

其次,考虑不确定参数下,定义不同驾驶行为的轨迹预测模型,包括:

(a1)、车道保持轨迹预测:根据离散维纳过程加速模型预测纵向参数,并根据奥恩斯坦-乌伦贝克过程预测车辆横向位置如式(1):

$$\dot{y}_t^{latR} = \alpha(\mu - y_t^{latR}) + \omega_t, \alpha > 0 \quad (1)$$

式(1)中, $y_t^{latR}$ 为车辆横向位置参数, $\mu$ 为横向位置均值, $\mu$ 的值设定为道路中线位置, $\omega_t$ 为高斯白噪声, $\alpha$ 为车辆回到道路中间的平均速度, $\dot{y}_t^{latR}$ 为车辆横向位置变化即车辆横向速度,将式(1)离散为:

$$y_{k+1}^{latR} - y_k^{latR} = (1 - e^{-\alpha\Delta t})(\mu - y_k^{latR}) + \omega^{latR}$$

其中, $\omega^{latR}$ 为过程噪声的标量, $\omega^{latR}$ 是均值为0、方差为 $(\frac{W_L - W_V}{6})^2 (1 - e^{-\alpha\Delta t})$ 的高斯噪声,其中, $W_L$ 为车道宽度, $W_V$ 为车辆宽度, $\Delta t$ 为离散周期;

(b1)、换道行为轨迹预测:在世界坐标系下,定义换道轨迹为式(2)所示的正弦函数:

$$y^{latR}(\Delta x^{longR}) = -\frac{W_L}{2} \cos\left(\frac{\pi}{l_R} \Delta x^{longR}\right), \forall \Delta x^{longR} \in [0, l_R] \quad (2)$$

式(2)中, $\Delta x^{longR}$ 是换道行为开始点的纵向相对距离, $l_R$ 是换道的长度, $y^{latR}$ 是车辆横向位置;不确定性是通过换道行为开始点来描述如式(3):

$$p(y^{\text{latR}}(\Delta x^{\text{longR}} = 0)) = \mathcal{N}\left(\left(\frac{W_L}{2}\right), \sigma_{y_s^{\text{latR}}}^2\right) \quad (3)$$

式(3)中,  $p(y^{\text{latR}}(\Delta x^{\text{longR}} = 0))$  表示换道车辆横向初始位置  $y^{\text{latR}}(\Delta x^{\text{longR}} = 0)$  时的概率分布,  $\mathcal{N}\left(\left(\frac{W_L}{2}\right), \sigma_{y_s^{\text{latR}}}^2\right)$  是高斯函数,  $\frac{W_L}{2}$  为高斯函数的均值,  $\sigma_{y_s^{\text{latR}}}^2$  为高斯函数的方差; 横摆角  $\theta_k^{\text{LC}}$  的预测为:

$$\theta_k^{\text{LC}} = \arctan\left(\frac{\pi W_L}{2l_R} \sin\left(\frac{\pi}{l_R} \Delta x^{\text{longR}}\right)\right).$$

5. 根据权利要求4所述的融合运动学模型和行为认知模型的行车轨迹预测系统, 其特征是: 所述驾驶行为数据库的建立是按如下步骤进行:

步骤101, 真实道路数据采集: 采集驾驶员在自然驾驶状态下的驾驶数据, 包括方向盘转角和横向加速度;

步骤102, 驾驶行为定义: 定义驾驶行为包括车道保持行为、左换道驾驶行为和右换道驾驶行为;

步骤103, 驾驶行为数据标定: 通过人为标定, 将从真实道路中采集的数据进行标定, 标定出各个驾驶行为的数据序列;

步骤104, 驾驶行为数据存储: 将人为标定的驾驶行为数据序列进行存储起来, 构建驾驶行为数据库。

6. 根据权利要求4所述的融合运动学模型和行为认知模型的行车轨迹预测系统, 其特征是: 所述驾驶行为认知网络学习包括以下步骤:

步骤111, 认知网络结构的确定: 根据动态贝叶斯理论, 构建驾驶行为认知网络结构; 所述认知网络结构包括行为认知层(X)、隐含层(M)以及观测层(Y); 所述观测层(Y)是传感器感知的数据信息, 包括方向盘转角大小、纵横向加速度、速度以及位移; 所述隐含层(M)是连接观测层(Y)和行为认知层(X)的中间层, 其参数是离散型的; 所述行为认知层(X)是抽象层信息, 代表智能驾驶车辆对驾驶行为的认知结果;

所述驾驶行为认知网络是带有时间维度的有向非循环图, 变量用节点表示, 变量之间的相互关系用有向箭头和条件概率表示; 所述驾驶行为认知网络满足一阶马尔科夫假设; 所述驾驶行为认知网络包括先验网络  $B_1$  和转移网络  $B_{\rightarrow}$ ; 所述先验网络  $B_1$  定义初始状态的条件概率分布以及多变量间的关系, 其节点间的连接结构用实线表示; 所述转移网络  $B_{\rightarrow}$  表示  $t-1$  时刻和  $t$  时刻间的关系以条件概率分布, 其节点间的连接用虚线表示; 所述先验网络  $B_1$  中, 节点  $X_t$  对节点  $M_t$  和节点  $Y_t$  都直接相连, 节点  $M_t$  和节点  $Y_t$  也直接相连; 所述转移网络  $B_{\rightarrow}$  中,  $t-1$  时刻的  $X_{t-1}$  节点和  $t$  时刻的  $X_t$  节点直接相连,  $t-1$  时刻的  $M_{t-1}$  节点和  $t$  时刻的  $X_t$  和  $Y_t$  节点直接相连;

步骤112, 认知网络参数学习: 基于所述驾驶行为数据库, 应用EM方法学习认知网络参数;

步骤113, 认知网络性能评估: 对行为认知网络估计性能进行评估; 所述行为认知网络评估包括正确识别, 开始识别时间, 成功识别时间以及综合评估参数;

所述正确识别是指: 根据历史信息, 所述认知网络对某行为估计概率大于或者等于 90%, 且估计的行为是正确的; 相反则为误识别;

所述正确识别时间是指: 根据历史信息, 所述认知网络正确识别该行为的时间, 其正确

识别时间点表示为 $t_{0.9}$ ,表示第一次正确估计某行为概率大于或等于90%的时间点,并有:

$$t_{\text{succeed}} = t_{0.9} - t_{\text{label}}$$

其中, $t_{\text{label}}$ 是行为开始的标定时间,人为进行确定,若 $t_{\text{label}} = 0$ ,则 $t_{\text{succeed}} = t_{0.9}$ ;

所述开始识别时间是指:根据历史信息,模型第一次对正确行为的估计概率达到20%,此时的时间点记为 $t_{0.2}$ ,并有:

$$t_{\text{start}} = t_{0.2} - t_{\text{label}}$$

其中,如果 $t_{\text{label}} = 0$ ,则 $t_{\text{start}} = t_{0.2}$ ;

定义认知网络性能评估的综合评估参数 $f(s)$ 为:

$$f(s) = \lambda_1 \sum_{i=1}^n \delta(i) + \lambda_2 \sum_{i=1}^n \frac{t_{\text{succeed}}}{T} + \lambda_3 \sum_{i=1}^n \frac{t_{\text{start}}}{T}$$

$$\delta(i) = \begin{cases} 1, & \text{the } i\text{th case is incorrectly} \\ 0, & \text{the } i\text{th case is correctly} \end{cases}$$

其中, $i$ 是指第 $i$ 个测试例, $n$ 为测试例的个数; $T$ 是指其测试例的时间长度, $s$ 表示某种认知网络结构, $\lambda_1$ 、 $\lambda_2$ 和 $\lambda_3$ 是各个评价指标的权重因子,定义: $\lambda_1 = \lambda_2 = \lambda_3 = 1$ 。

7. 根据权利要求1所述的融合运动学模型和行为认知模型的行车轨迹预测系统,其特征是:所述融合更新模块 $c$ 按如下方式对最终预测结果进行融合,并更新权重系数:

以 $\hat{x}_{k+1}^1$ 和 $P_{k+1}^1$ 分别表示 $k+1$ 时刻预测模块 $b_1$ 的预测均值和预测协方差;

以 $\hat{x}_{k+1}^2$ 和 $P_{k+1}^2$ 分别表示 $k+1$ 时刻预测模块 $b_2$ 的预测均值和预测协方差;

以 $\text{Pred}_1$ 表征预测模型 $M_1$ ,以 $\text{Pred}_2$ 表征预测模型 $M_2$ ;则有:

$$(\hat{x}_{k+1}^1, P_{k+1}^1) = \text{Pred}_1(\hat{x}_k^1, P_k^1)$$

$$(\hat{x}_{k+1}^2, P_{k+1}^2) = \text{Pred}_2(\hat{x}_k^2, P_k^2)$$

其中:

$P(x_{k+1}^1)$ 为预测模块 $b_1$ 的纵向位置预测方差;

$P(y_{k+1}^1)$ 为预测模块 $b_1$ 的横向位置预测方差;

$P(x_{k+1}^2)$ 为预测模块 $b_2$ 的纵向位置预测方差;

$P(y_{k+1}^2)$ 为预测模块 $b_2$ 的横向位置预测方差;

则有:

预测模块 $b_1$ 在 $k+1$ 时刻的概率 $\Lambda_{k+1}^1$ 为: $\Lambda_{k+1}^1 = 1 / (P(x_{k+1}^1) + P(y_{k+1}^1))$ ,

预测模块 $b_2$ 在 $k+1$ 时刻的概率 $\Lambda_{k+1}^2$ 为: $\Lambda_{k+1}^2 = 1 / (P(x_{k+1}^2) + P(y_{k+1}^2))$ ,

预测模块 $b_1$ 在 $k+1$ 时刻的权重 $\mu_{k+1}^1$ 为: $\mu_{k+1}^1 = \frac{1}{c} \Lambda_{k+1}^1 \bar{c}_1$ ;其中, $c = \Lambda_{k+1}^1 \bar{c}_1 + \Lambda_{k+1}^2 \bar{c}_2$ ,

$$\bar{c}_1 = p_{11} \mu_k^1 + p_{21} \mu_k^2;$$

预测模块 $b_2$ 在 $k+1$ 时刻的权重 $\mu_{k+1}^2$ 为: $\mu_{k+1}^2 = \frac{1}{c} \Lambda_{k+1}^2 \bar{c}_2$ ;其中, $\bar{c}_2 = p_{12} \mu_k^1 + p_{22} \mu_k^2$ ;

$k+1$ 时刻车辆参数的最终预测均值 $\hat{x}_{k+1}$ 为: $\hat{x}_{k+1} = \mu_{k+1}^1 \hat{x}_{k+1}^1 + \mu_{k+1}^2 \hat{x}_{k+1}^2$ ;

$k+1$ 时刻车辆参数的最终预测协方差 $P_{k+1}$ 为:

$$P_{k+1} = \mu_{k+1}^1 (P_{k+1}^1 + (\hat{x}_{k+1}^1 - \hat{x}_{k+1})(\hat{x}_{k+1}^1 - \hat{x}_{k+1})^T) + \mu_{k+1}^2 (P_{k+1}^2 + (\hat{x}_{k+1}^2 - \hat{x}_{k+1})(\hat{x}_{k+1}^2 - \hat{x}_{k+1})^T)。$$

## 融合运动学模型和行为认知模型的行车轨迹预测系统

### 技术领域

[0001] 本发明涉及智能驾驶领域,特别是涉及一种行车轨迹预测系统。

### 背景技术

[0002] 智能驾驶车辆对交通安全,交通效率以及环保节能等有着积极的作用。智能驾驶车辆是通过感知系统,感知驾驶环境参数,识别目标类型;通过认知系统提高对驾驶环境的理解如驾驶行为意图等的理解,对未来环境变化进行估计和预测,判断其它道路使用者如车辆和行人的决策机制,对环境做出正确的理解;通过决策系统以及执行系统完成驾驶行为及路径规划,实现驾驶操作任务。其中,环境认知技术是对环境的深层理解,像人一样,通过分析周围车辆的驾驶行为,考虑其它道路使用者的意图和决策机制,对驾驶环境的变化进行估计、判断和预测,提高智能驾驶车辆在复杂环境下的决策水平和能力。只有实现了智能驾驶车辆对环境的深层次理解和认知,并正确地判断和预测周围环境的变化,才能实现真正的“智能”驾驶,有效应对复杂的驾驶环境。轨迹预测是对未来一段时间内车辆位置进行预测,以判断和预测周围环境的变化,为智能驾驶在复杂交通环境下的决策提供基础。

[0003] 目前,针对行车轨迹预测方法的研究较多。轨迹预测主要包括短时间预测(Short-term Prediction)和长时间预测(Long-term Prediction)。其中,短时间预测主要是基于车辆动力学或者运动学方法,假设某些运动变量比如行车速度、加速度、横摆角速度等保持不变的情况下进行预测。短时间预测虽然预测时间短,但是在较短时间内,其预测结果较准确。长时间预测主要是基于行为认知进行车辆轨迹预测,在考虑运动参数的条件下,对车辆行为进行估计,根据行为概率分布,预测某一段时间内车辆的轨迹变化。基于行为认知的预测方法能够在较长的一段时间内进行轨迹预测。然而,基于行为认知的轨迹预测方法在短时间内预测误差较大。

[0004] 现阶段针对智能驾驶技术,行为认知以及轨迹预测存在以下几个方面的问题:一是不能自主认识以及预测驾驶环境的变化,决策系统智能化水平低,难以应付复杂交通环境下的需求;二是基于运动学的轨迹预测方法只能在较短的时间内进行预测,且较长时间的预测误差较大;三是基于行为认知的轨迹预测方法虽能够长时间预测行车轨迹,但没有考虑车辆动力学,在短时间内的预测误差较大;四是多种轨迹预测模型的融合方法基于固定的参数,不能满足复杂环境下的需求。

### 发明内容

[0005] 本发明是为避免上述现有技术所存在的不足,提供一种融合运动学模型和行为认知模型的行车轨迹预测系统,在车辆行驶过程中不断估计车辆位置状态以及驾驶行为,预测行车轨迹,为智能驾驶决策提供帮助,使其能够适应复杂的交通环境。

[0006] 本发明为解决技术问题采用如下技术方案:

[0007] 本发明融合运动学模型和行为认知模型的行车轨迹预测系统的特点是包括:

[0008] 交互混合模块a,其对每个预测模块上一时刻的预测结果进行交互混合输出混合

结果,所述混合结果用于下一时刻的预测;

[0009] 所述预测模块包括基于行为认知的行为认知轨迹预测模块b1和基于运动学的运动轨迹预测模块b2,所述行为认知轨迹预测模块b1和所述运动轨迹预测模块b2根据交互混合模块a输出的混合结果进行预测,输出各预测模块的预测结果,所述预测结果包括车辆位置和协方差矩阵;

[0010] 融合更新模块c,根据所述预测模块输出的各个预测结果,对最终预测结果进行融合,并更新权重系数,输出未来某时刻车辆位置以及协方差矩阵。

[0011] 本发明融合运动学模型和行为认知模型的行车轨迹预测系统的特点也在于:所述预测模块的预测结果包括由所述行为认知轨迹预测模块b1预测的k时刻车辆参数预测均值 $\hat{x}_k^1$ 和预测协方差 $P_k^1$ ,以及由所述运动轨迹预测模块b2预测的k时刻车辆参数预测均值 $\hat{x}_k^2$ 和预测协方差 $P_k^2$ ;车辆参数表示为向量 $X$ , $X=(x,y,\theta,v,a,\omega)$ ,其中 $x$ 、 $y$ 、 $\theta$ 、 $v$ 、 $a$ 和 $\omega$ 一一对应表示为纵向位置、横向位置、横摆角、行车速度、行车加速度以及横摆角速度;初始时刻的车辆参数均值和协方差为环境变量观测估计值;

[0012] 设定所述行为认知轨迹预测模块b1中的预测模型M1和所述运动轨迹预测模块b2中的预测模型M2随时间的转移满足一阶马尔科夫假设,定义转移矩阵 $p$ 为:

[0013]  $p=(0.85,0.15;0.15,0.85)$

[0014] 输入所述行为认知轨迹预测模块b1和所述运动轨迹预测模块b2的车辆参数混合均值和混合协方差是:

$$[0015] \quad \hat{x}_k^{*1} = \mu_k^{1|1} \hat{x}_k^1 + \mu_k^{2|1} \hat{x}_k^2$$

$$[0016] \quad \hat{x}_k^{*2} = \mu_k^{1|2} \hat{x}_k^1 + \mu_k^{2|2} \hat{x}_k^2$$

$$[0017] \quad P_k^{*1} = \mu_k^{1|1} (P_k^1 + (\hat{x}_k^1 - \hat{x}_k^{*1})(\hat{x}_k^1 - \hat{x}_k^{*1})^T) + \mu_k^{2|1} (P_k^2 + (\hat{x}_k^2 - \hat{x}_k^{*1})(\hat{x}_k^2 - \hat{x}_k^{*1})^T)$$

$$[0018] \quad P_k^{*2} = \mu_k^{1|2} (P_k^1 + (\hat{x}_k^1 - \hat{x}_k^{*2})(\hat{x}_k^1 - \hat{x}_k^{*2})^T) + \mu_k^{2|2} (P_k^2 + (\hat{x}_k^2 - \hat{x}_k^{*2})(\hat{x}_k^2 - \hat{x}_k^{*2})^T)$$

[0019] 其中:

[0020]  $\hat{x}_k^{*1}$ 和 $P_k^{*1}$ 分别为预测模块b1在k时刻的车辆参数混合均值和混合协方差;

[0021]  $\hat{x}_k^{*2}$ 和 $P_k^{*2}$ 分别是预测模块b2在k时刻的车辆参数混合均值和混合协方差;

$$[0022] \quad \mu_k^{1|1} = \frac{1}{p_{11}\mu_k^1 + p_{21}\mu_k^2} p_{11}\mu_k^1; \quad \mu_k^{2|1} = \frac{1}{p_{11}\mu_k^1 + p_{21}\mu_k^2} p_{21}\mu_k^2;$$

$$[0023] \quad \mu_k^{1|2} = \frac{1}{p_{12}\mu_k^1 + p_{22}\mu_k^2} p_{12}\mu_k^1; \quad \mu_k^{2|2} = \frac{1}{p_{12}\mu_k^1 + p_{22}\mu_k^2} p_{22}\mu_k^2;$$

[0024] 其中: $p_{11}=0.85$ , $p_{12}=0.15$ , $p_{21}=0.15$ , $p_{22}=0.85$ ;

[0025]  $\mu_k^1$ 是预测模块b1在k时刻的权重, $\mu_k^2$ 是预测模块b2在k时刻的权重,定义:在 $k=0$ 的初始时刻下, $\mu_0^1=0.1$ ; $\mu_0^2=0.9$ 。

[0026] 本发明融合运动学模型和行为认知模型的行车轨迹预测系统的特点也在于:

[0027] 所述行为认知轨迹预测模块b1包括驾驶行为认知单元和轨迹预测单元;所述驾驶行为认知单元用于估计驾驶行为,输出行为认知概率分布;所述轨迹预测单元基于驾驶行为预测行车轨迹,输出未来一段时间的车辆位置以及协方差矩阵;

[0028] 所述运动轨迹预测模块b2包括车辆运动学单元和基于UKF的轨迹预测单元;利用

所述车辆运动学单元根据车辆运动学模型推导各个变量的关系,输出状态转移方程;所述基于UKF的轨迹预测单元根据所述状态转移方程,考虑观测不确定性和模型不确定性,预测车辆轨迹,输出车辆在未来一段时间的车辆参数预测均值和预测协方差。

[0029] 本发明融合运动学模型和行为认知模型的行车轨迹预测系统的特点也在于:

[0030] 所述行为认知单元包括驾驶行为数据库和驾驶行为认知网络学习;所述驾驶行为数据库是通过采集真实道路信息构建而成,是驾驶行为认知学习的数据基础;所述驾驶行为认知网络学习是基于驾驶行为数据库,应用expectation maximization算法优化网络参数,学习驾驶行为认知知识;

[0031] 所述轨迹预测单元是基于驾驶行为认知单元,对行车轨迹按如下方法进行预测:

[0032] 首先,根据驾驶行为概率分布 $p(B=B_0|Z_{1:k_0})$ ,将预测轨迹概率 $p(X_{k_0+k_p}|Z_{1:k_0})$ 描述为:

$$[0033] \quad p(X_{k_0+k_p}|Z_{1:k_0}) = \sum_{B_0} p(X_{k_0+k_p}|B=B_0)p(B=B_0|Z_{1:k_0})$$

[0034] 其中, $Z_{1:k_0}$ 是观测的信息序列, $X_{k_0+k_p}$ 表示预测的位置参数, $k_0$ 是开始预测的时间, $k_p$ 是预测时间长度, $B$ 表示驾驶行为, $B_0$ 表示某个驾驶行为如换道行为, $p(X_{k_0+k_p}|B=B_0)$ 表示某个驾驶行为下预测轨迹的概率分布;

[0035] 其次,考虑不确定参数下,定义不同驾驶行为的轨迹预测模型,包括:

[0036] (a1)、车道保持轨迹预测:根据离散维纳过程加速模型预测纵向参数,并根据奥恩斯坦-乌伦贝克过程预测车辆横向位置如式(1):

$$[0037] \quad \dot{y}_t^{latR} = \alpha(\mu - y_t^{latR}) + \omega_t, \alpha > 0 \quad (1)$$

[0038] 式(1)中, $y_t^{latR}$ 为车辆横向位置参数, $\mu$ 为横向位置均值, $\mu$ 的值设定为道路中线位置, $\omega_t$ 为高斯白噪声, $\alpha$ 为车辆回到道路中间的平均速度, $y_t^{latR}$ 为车辆横向位置变化即车辆横向速度,将式(1)离散为:

$$[0039] \quad y_{k+1}^{latR} - y_k^{latR} = (1 - e^{-\alpha\Delta t})(\mu - y_k^{latR}) + \omega^{latR}$$

[0040] 其中, $\omega^{latR}$ 为过程噪声的标量, $\omega^{latR}$ 是均值为0、方差为 $(\frac{W_L - W_V}{6})^2 (1 - e^{-\alpha\Delta t})$ 的高斯噪声,其中, $W_L$ 为车道宽度, $W_V$ 为车辆宽度, $\Delta t$ 为离散周期;

[0041] (b1)、换道行为轨迹预测:在世界坐标系下,定义换道轨迹为式(2)所示的正弦函数:

$$[0042] \quad y^{latR}(\Delta x^{longR}) = -\frac{W_L}{2} \cos\left(\frac{\pi}{l_R} \Delta x^{longR}\right), \forall \Delta x^{longR} \in [0, l_R] \quad (2)$$

[0043] 式(2)中, $\Delta x^{longR}$ 是换道行为开始点的纵向相对距离, $l_R$ 是换道的长度, $y^{latR}$ 是车辆横向位置;不确定性是通过换道行为开始点来描述如式(3):

$$[0044] \quad p(y^{latR}(\Delta x^{longR} = 0)) = \mathcal{N}\left(\left(\frac{W_L}{2}\right), \sigma_{y_s^{latR}}^2\right) \quad (3)$$

[0045] 式(3)中, $p(y^{latR}(\Delta x^{longR} = 0))$ 表示换道车辆横向初始位置 $y^{latR}(\Delta x^{longR} = 0)$ 时的

概率分布,  $\mathcal{N}\left(\left(\frac{W_L}{2}\right), \sigma_{y_s^{latR}}^2\right)$  是高斯函数,  $\frac{W_L}{2}$  为高斯函数的均值,  $\sigma_{y_s^{latR}}^2$  为高斯函数的方差;

[0046] 横摆角  $\theta_k^{LC}$  的预测为:

$$[0047] \quad \theta_k^{LC} = \arctan\left(\frac{\pi W_L}{2l_R} \sin\left(\frac{\pi}{l_R} \Delta x^{longR}\right)\right).$$

[0048] 本发明融合运动学模型和行为认知模型的行车轨迹预测系统的特点也在于:所述驾驶行为数据库的建立是按如下步骤进行:

[0049] 步骤101, 真实道路数据采集:采集驾驶员在自然驾驶状态下的驾驶数据,包括方向盘转角和横向加速度;

[0050] 步骤102, 驾驶行为定义:定义驾驶行为包括车道保持行为、左换道驾驶行为和右换道驾驶行为;

[0051] 步骤103, 驾驶行为数据标定:通过人为标定,将从真实道路中采集的数据进行标定,标定出各个驾驶行为的数据序列;

[0052] 步骤104, 驾驶行为数据存储:将人为标定的驾驶行为数据序列进行存储起来,构建驾驶行为数据库。

[0053] 本发明融合运动学模型和行为认知模型的行车轨迹预测系统的特点也在于:所述驾驶行为认知网络学习包括以下步骤:

[0054] 步骤111, 认知网络结构的确定:根据动态贝叶斯理论,构建驾驶行为认知网络结构;所述认知网络结构包括行为认知层、隐含层以及观测层;所述观测层是传感器感知的数据信息,包括方向盘转角大小、纵横向加速度、速度以及位移;所述隐含层是连接观测层和行为认知层的中间层,其参数是离散型的;所述行为认知层是抽象层信息,代表智能驾驶车辆对驾驶行为的认知结果;

[0055] 所述驾驶行为认知网络是带有时间维度的有向非循环图,变量用节点表示,变量之间的相互关系用有向箭头和条件概率表示;所述驾驶行为认知网络满足一阶马尔科夫假设;所述驾驶行为认知网络包括先验网络  $B_1$  和转移网络  $B_{\rightarrow}$ ;所述先验网络  $B_1$  定义初始状态的条件概率分布以及多变量间的关系,其节点间的连接结构用实线表示;所述转移网络  $B_{\rightarrow}$  表示  $t-1$  时刻和  $t$  时刻间的关系以条件概率分布,其节点间的连接用虚线表示;所述先验网络  $B_1$  中,节点  $X_t$  对节点  $M_t$  和节点  $Y_t$  都直接相连,节点  $M_t$  和节点  $Y_t$  也直接相连;所述转移网络  $B_{\rightarrow}$  中,  $t-1$  时刻的  $X_{t-1}$  节点和  $t$  时刻的  $X_t$  节点直接相连,  $t-1$  时刻的  $M_{t-1}$  节点和  $t$  时刻的  $X_t$  和  $Y_t$  节点直接相连;

[0056] 步骤112, 认知网络参数学习:基于所述驾驶行为数据库,应用EM方法学习认知网络参数;

[0057] 步骤113, 认知网络性能评估:对行为认知网络估计性能进行评估;所述行为认知网络评估包括正确识别,开始识别时间,成功识别时间以及综合评估参数;

[0058] 所述正确识别是指:根据历史信息,所述认知网络对某行为估计概率大于或者等于90%,且估计的行为是正确的;相反则为误识别;

[0059] 所述正确识别时间是指:根据历史信息,所述认知网络正确识别该行为的时间,其正确识别时间点表示为  $t_{0.9}$ ,表示第一次正确估计某行为概率大于或等于90%的时间点,并有:

[0060]  $t_{\text{succeed}} = t_{0.9} - t_{\text{label}}$

[0061] 其中,  $t_{\text{label}}$  是行为开始的标定时间, 人为进行确定, 若  $t_{\text{label}} = 0$ , 则  $t_{\text{succeed}} = t_{0.9}$ ;

[0062] 所述开始识别时间是指: 根据历史信息, 模型第一次对正确行为的估计概率达到 20%, 此时的时间点记为  $t_{0.2}$ , 并有:

[0063]  $t_{\text{start}} = t_{0.2} - t_{\text{label}}$

[0064] 其中, 如果  $t_{\text{label}} = 0$ , 则  $t_{\text{start}} = t_{0.2}$ ;

[0065] 定义认知网络性能评估的综合评估参数  $f(s)$  为:

$$[0066] \quad f(s) = \lambda_1 \sum_{i=1}^n \delta(i) + \lambda_2 \sum_{i=1}^n \frac{t_{\text{succeed}}}{T} + \lambda_3 \sum_{i=1}^n \frac{t_{\text{start}}}{T}$$

$$[0067] \quad \delta(i) = \begin{cases} 1, & \text{the } i\text{th case is incorrectly} \\ 0, & \text{the } i\text{th case is correctly} \end{cases}$$

[0068] 其中,  $i$  是指第  $i$  个测试例,  $n$  为测试例的个数;  $T$  是指其测试例的时间长度,  $s$  表示某种认知网络结构,  $\lambda_1$ 、 $\lambda_2$  和  $\lambda_3$  是各个评价指标的权重因子, 定义:  $\lambda_1 = \lambda_2 = \lambda_3 = 1$ 。

[0069] 本发明融合运动学模型和行为认知模型的行车轨迹预测系统的特点也在于: 所述融合更新模块  $c$  按如下方式对最终预测结果进行融合, 并更新权重系数:

[0070] 以  $\hat{x}_{k+1}^1$  和  $P_{k+1}^1$  分别表示  $k+1$  时刻预测模块  $b1$  的预测均值和预测协方差;

[0071] 以  $\hat{x}_{k+1}^2$  和  $P_{k+1}^2$  分别表示  $k+1$  时刻预测模块  $b2$  的预测均值和预测协方差;

[0072] 以  $\text{Pred}_1$  表征预测模型  $M1$ , 以  $\text{Pred}_2$  表征预测模型  $M2$ ; 则有:

$$[0073] \quad (\hat{x}_{k+1}^1, P_{k+1}^1) = \text{Pred}_1(\hat{x}_k^1, P_k^1)$$

$$[0074] \quad (\hat{x}_{k+1}^2, P_{k+1}^2) = \text{Pred}_2(\hat{x}_k^2, P_k^2)$$

[0075] 其中:

[0076]  $P(x_{k+1}^1)$  为预测模块  $b1$  的纵向位置预测方差;

[0077]  $P(y_{k+1}^1)$  为预测模块  $b1$  的横向位置预测方差;

[0078]  $P(x_{k+1}^2)$  为预测模块  $b2$  的纵向位置预测方差;

[0079]  $P(y_{k+1}^2)$  为预测模块  $b2$  的横向位置预测方差;

[0080] 则有:

$$[0081] \quad \text{预测模块 } b1 \text{ 在 } k+1 \text{ 时刻的概率 } A_{k+1}^1 \text{ 为: } A_{k+1}^1 = 1 / (P(x_{k+1}^1) + P(y_{k+1}^1)),$$

$$[0082] \quad \text{预测模块 } b2 \text{ 在 } k+1 \text{ 时刻的概率 } A_{k+1}^2 \text{ 为: } A_{k+1}^2 = 1 / (P(x_{k+1}^2) + P(y_{k+1}^2)),$$

$$[0083] \quad \text{预测模块 } b1 \text{ 在 } k+1 \text{ 时刻的权重 } \mu_{k+1}^1 \text{ 为: } \mu_{k+1}^1 = \frac{1}{c} A_{k+1}^1 \bar{c}_1; \text{ 其中, } c = A_{k+1}^1 \bar{c}_1 + A_{k+1}^2 \bar{c}_2,$$

$$\bar{c}_1 = p_{11} \mu_k^1 + p_{21} \mu_k^2;$$

$$[0084] \quad \text{预测模块 } b2 \text{ 在 } k+1 \text{ 时刻的权重 } \mu_{k+1}^2 \text{ 为: } \mu_{k+1}^2 = \frac{1}{c} A_{k+1}^2 \bar{c}_2; \text{ 其中, } \bar{c}_2 = p_{12} \mu_k^1 + p_{22} \mu_k^2;$$

$$[0085] \quad k+1 \text{ 时刻车辆参数的最终预测均值 } \hat{x}_{k+1} \text{ 为: } \hat{x}_{k+1} = \mu_{k+1}^1 \hat{x}_{k+1}^1 + \mu_{k+1}^2 \hat{x}_{k+1}^2$$

[0086]  $k+1$  时刻车辆参数的最终预测协方差  $P_{k+1}$  为:

[0087]

$$P_{k+1} = \mu_{k+1}^1 (P_{k+1}^1 + (\hat{x}_{k+1}^1 - \hat{x}_{k+1})(\hat{x}_{k+1}^1 - \hat{x}_{k+1})^T) + \mu_{k+1}^2 (P_{k+1}^2 + (\hat{x}_{k+1}^2 - \hat{x}_{k+1})(\hat{x}_{k+1}^2 - \hat{x}_{k+1})^T)。$$

[0088] 与已有技术相比,本发明有益效果体现在:

[0089] 1、本发明能够在车辆行驶过程中不断估计车辆位置状态以及驾驶行为,预测行车轨迹,为智能驾驶决策提供帮助,使其能够适应复杂的交通环境;

[0090] 2、本发明融合了运动学模型和行为认知模型进行行车轨迹预测,既能保证短时间内预测结果精确性,同时也保证了长时间预测中趋势的正确性;

[0091] 3、本发明能够根据各个模型的预测精度,不断调整各个模型的预测权重,使其能够适应复杂的交通环境,使行车轨迹预测结果更准确。

## 附图说明

[0092] 图1为本发明系统构成示意图;

[0093] 图2为本发明中预测模块结构图;

[0094] 图3为本发明中驾驶行为认知模块原理框图;

[0095] 图4为本发明驾驶行为认知网络结构图;

[0096] 图5为本发明中换道场景示意图;

## 具体实施方式

[0097] 本实施例中融合运动学模型和行为认知模型的行车轨迹预测系统是针对智能驾驶车辆设计的。参见图1,其包括:

[0098] 交互混合模块a,其对每个预测模块上一时刻的预测结果进行交互混合输出混合结果,混合结果用于下一时刻的预测;

[0099] 预测模块包括基于行为认知的行为认知轨迹预测模块b1和基于运动学的运动轨迹预测模块b2,行为认知轨迹预测模块b1和运动轨迹预测模块b2根据交互混合模块a输出的混合结果进行预测,输出各预测模块的预测结果,预测结果包括车辆位置和协方差矩阵;

[0100] 融合更新模块c,根据预测模块输出的各个预测结果,对最终预测结果进行融合,并更新权重系数,输出未来某时刻车辆位置以及协方差矩阵。

[0101] 具体实施中,预测模块的预测结果包括由行为认知轨迹预测模块b1预测的k时刻车辆参数预测均值 $\hat{x}_k^1$ 和预测协方差 $P_k^1$ ,以及由运动轨迹预测模块b2预测的k时刻车辆参数预测均值 $\hat{x}_k^2$ 和预测协方差 $P_k^2$ ;车辆参数表示为向量 $X$ , $X = (x, y, \theta, v, a, \omega)$ ,其中 $x$ 、 $y$ 、 $\theta$ 、 $v$ 、 $a$ 和 $\omega$ 一一对应表示为纵向位置、横向位置、横摆角、行车速度、行车加速度以及横摆角速度;初始时刻的车辆参数均值和协方差为环境变量观测估计值;

[0102] 设定行为认知轨迹预测模块b1中的预测模型M1和运动轨迹预测模块b2中的预测模型M2随时间的转移满足一阶马尔科夫假设,定义转移矩阵 $p$ 为: $p = (0.85, 0.15; 0.15, 0.85)$ ;

[0103] 输入行为认知轨迹预测模块b1和运动轨迹预测模块b2的车辆参数混合均值和混合协方差是:

$$[0104] \quad \hat{x}_k^{*1} = \mu_k^{1|1} \hat{x}_k^1 + \mu_k^{2|1} \hat{x}_k^2$$

$$[0105] \quad \hat{x}_k^{*2} = \mu_k^{1|2} \hat{x}_k^1 + \mu_k^{2|2} \hat{x}_k^2$$

$$[0106] \quad P_k^{*1} = \mu_k^{1|1} (P_k^1 + (\hat{x}_k^1 - \hat{x}_k^{*1})(\hat{x}_k^1 - \hat{x}_k^{*1})^T) + \mu_k^{2|1} (P_k^2 + (\hat{x}_k^2 - \hat{x}_k^{*1})(\hat{x}_k^2 - \hat{x}_k^{*1})^T)$$

$$[0107] \quad P_k^{*2} = \mu_k^{1|2} (P_k^1 + (\hat{x}_k^1 - \hat{x}_k^{*2})(\hat{x}_k^1 - \hat{x}_k^{*2})^T) + \mu_k^{2|2} (P_k^2 + (\hat{x}_k^2 - \hat{x}_k^{*2})(\hat{x}_k^2 - \hat{x}_k^{*2})^T)$$

[0108] 其中:

[0109]  $\hat{x}_k^{*1}$ 和 $P_k^{*1}$ 分别为预测模块b1在k时刻的车辆参数混合均值和混合协方差;

[0110]  $\hat{x}_k^{*2}$ 和 $P_k^{*2}$ 分别是预测模块b2在k时刻的车辆参数混合均值和混合协方差;

$$[0111] \quad \mu_k^{1|1} = \frac{1}{p_{11}\mu_k^1 + p_{21}\mu_k^2} p_{11}\mu_k^1; \quad \mu_k^{2|1} = \frac{1}{p_{11}\mu_k^1 + p_{21}\mu_k^2} p_{21}\mu_k^2;$$

$$[0112] \quad \mu_k^{1|2} = \frac{1}{p_{12}\mu_k^1 + p_{22}\mu_k^2} p_{12}\mu_k^1; \quad \mu_k^{2|2} = \frac{1}{p_{12}\mu_k^1 + p_{22}\mu_k^2} p_{22}\mu_k^2;$$

[0113] 其中: $p_{11}=0.85, p_{12}=0.15, p_{21}=0.15, p_{22}=0.85$ ;

[0114]  $\mu_k^1$ 是预测模块b1在k时刻的权重,  $\mu_k^2$ 是预测模块b2在k时刻的权重, 定义: 在 $k=0$ 的初始时刻下,  $\mu_0^1 = 0.1; \mu_0^2 = 0.9$ 。

[0115] 具体实施中, 参见图1和图2, 行为认知轨迹预测模块b1包括驾驶行为认知单元1和轨迹预测单元2; 驾驶行为认知单元1用于估计驾驶行为, 输出行为认知概率分布; 轨迹预测单元2基于驾驶行为预测行车轨迹, 输出未来一段时间的车辆位置以及协方差矩阵。

[0116] 参见图2, 运动轨迹预测模块b2包括车辆运动学单元3和基于UKF的轨迹预测单元4; 利用车辆运动学单元3根据车辆运动学模型推导各个变量的关系, 输出状态转移方程; 基于UKF的轨迹预测单元4根据状态转移方程, 考虑观测不确定性和模型不确定性, 预测车辆轨迹, 输出车辆在未来一段时间的车辆参数预测均值和预测协方差。

[0117] 假设状态转移方程S表示为:  $S(t+\Delta t) = \Delta f(t) + S(t)$ ;

[0118] 其中 $\Delta f(t)$ 表示为:

$$[0119] \quad \Delta f(t) = \begin{pmatrix} \frac{v+a\Delta t}{\omega} \sin(\theta+\omega\Delta t) + \frac{a}{\omega^2} \cos(\theta+\omega\Delta t) - \frac{v}{\omega} \sin(\theta) - \frac{a}{\omega^2} \cos(\theta) \\ -\frac{v+a\Delta t}{\omega} \cos(\theta+\omega\Delta t) + \frac{a}{\omega^2} \sin(\theta+\omega\Delta t) + \frac{v}{\omega} \cos(\theta) - \frac{a}{\omega^2} \sin(\theta) \\ \omega\Delta t \\ a\Delta t \\ 0 \\ 0 \end{pmatrix}$$

[0120] 其中,  $t$ 表示系统运行时间,  $\Delta t$ 表示系统运行周期, 本模型中, 系统周期为100ms。

[0121] 根据状态转移方程, 其车辆参数预测均值和预测协方差通过Unscented Transform (UT) 进行估算, 完成基于UKF的轨迹预测单元4。

[0122] 具体实施中, 参见图3, 行为认知单元1包括驾驶行为数据库和驾驶行为认知网络学习, 用于估计驾驶行为, 输出行为认知概率分布; 驾驶行为数据库是通过采集真实道路信息构建而成, 是驾驶行为认知学习的数据基础; 驾驶行为认知网络学习是基于驾驶行为数据库, 应用expectation maximization算法优化网络参数, 学习驾驶行为认知知识。

[0123] 参见图2, 轨迹预测单元2是基于驾驶行为认知单元1, 对行车轨迹按如下方法进行预测:

[0124] 首先,根据驾驶行为概率分布 $p(B=B_0|Z_{1:k_0})$ ,将预测轨迹概率 $p(X_{k_0+k_p}|Z_{1:k_0})$ 描述为:

$$[0125] \quad p(X_{k_0+k_p}|Z_{1:k_0}) = \sum_{B_0} p(X_{k_0+k_p}|B=B_0)p(B=B_0|Z_{1:k_0})$$

[0126] 其中, $Z_{1:k_0}$ 是观测的信息序列, $X_{k_0+k_p}$ 表示预测的位置参数, $k_0$ 是开始预测的时间, $k_p$ 是预测时间长度, $B$ 表示驾驶行为, $B_0$ 表示某个驾驶行为如换道行为, $p(X_{k_0+k_p}|B=B_0)$ 表示某个驾驶行为下预测轨迹的概率分布;

[0127] 其次,考虑不确定参数下,定义不同驾驶行为的轨迹预测模型,包括:

[0128] (a1)、车道保持轨迹预测:根据离散维纳过程加速模型预测纵向参数,并根据奥恩斯坦-乌伦贝克过程预测车辆横向位置如式(1):

$$[0129] \quad \dot{y}_t^{latR} = \alpha(\mu - y_t^{latR}) + \omega_t, \alpha > 0 \quad (1)$$

[0130] 式(1)中, $y_t^{latR}$ 为车辆横向位置参数, $\mu$ 为横向位置均值, $\mu$ 的值设定为道路中线位置, $\omega_t$ 为高斯白噪声, $\alpha$ 为车辆回到道路中间的平均速度, $y_t^{latR}$ 为车辆横向位置变化即车辆横向速度,将式(1)离散为:

$$[0131] \quad y_{k+1}^{latR} - y_k^{latR} = (1 - e^{-\alpha\Delta t})(\mu - y_k^{latR}) + \omega^{latR}$$

[0132] 其中, $\omega^{latR}$ 为过程噪声的标量, $\omega^{latR}$ 是均值为0、方差为 $(\frac{W_L - W_V}{6})^2 (1 - e^{-\alpha\Delta t})$ 的高斯噪声,其中, $W_L$ 为车道宽度, $W_V$ 为车辆宽度, $\Delta t$ 为离散周期;

[0133] (b1)、换道行为轨迹预测:在世界坐标系下,定义换道轨迹为式(2)所示的正弦函数:

$$[0134] \quad y^{latR}(\Delta x^{longR}) = -\frac{W_L}{2} \cos\left(\frac{\pi}{l_R} \Delta x^{longR}\right), \forall \Delta x^{longR} \in [0, l_R] \quad (2)$$

[0135] 式(2)中, $\Delta x^{longR}$ 是换道行为开始点的纵向相对距离, $l_R$ 是换道的长度, $y^{latR}$ 是车辆横向位置;不确定性是通过换道行为开始点来描述如式(3):

$$[0136] \quad p(y^{latR}(\Delta x^{longR} = 0)) = \mathcal{N}\left(\left(\frac{W_L}{2}\right), \sigma_{y_s^{latR}}^2\right) \quad (3)$$

[0137] 式(3)中, $p(y^{latR}(\Delta x^{longR} = 0))$ 表示换道车辆横向初始位置 $y^{latR}(\Delta x^{longR} = 0)$ 时的概率分布, $\mathcal{N}\left(\left(\frac{W_L}{2}\right), \sigma_{y_s^{latR}}^2\right)$ 是高斯函数, $\frac{W_L}{2}$ 为高斯函数的均值, $\sigma_{y_s^{latR}}^2$ 为高斯函数的方差;

横摆角 $\theta_k^{LC}$ 的预测为: $\theta_k^{LC} = \arctan\left(\frac{\pi W_L}{2 l_R} \sin\left(\frac{\pi}{l_R} \Delta x^{longR}\right)\right)$ 。

[0138] 具体实施中,参见图3,驾驶行为数据库的建立是按如下步骤进行:

[0139] 步骤101,真实道路数据采集:采集驾驶员在自然驾驶状态下的驾驶数据,包括方向盘转角和横向加速度。

[0140] 步骤102,驾驶行为定义如图5所示,定义驾驶行为包括车道保持行为、左换道驾驶行为和右换道驾驶行为。

[0141] 步骤103,驾驶行为数据标定:通过人为标定,将从真实道路中采集的数据进行标定,标定出各个驾驶行为的数据序列。

[0142] 步骤104, 驾驶行为数据存储: 将人为标定的驾驶行为数据序列进行存储起来, 构建驾驶行为数据库。

[0143] 具体实施中, 如图3所示, 驾驶行为认知网络学习包括以下步骤:

[0144] 步骤111, 认知网络结构的确定: 根据动态贝叶斯理论, 构建驾驶行为认知网络结构; 认知网络结构包括行为认知层X、隐含层M以及观测层Y; 观测层Y是传感器感知的数据信息, 包括方向盘转角大小、纵横向加速度、速度以及位移; 隐含层M是连接观测层Y和行为认知层X的中间层, 其参数是离散型的; 行为认知层X是抽象层信息, 代表智能驾驶车辆对驾驶行为的认知结果。

[0145] 驾驶行为认知网络是带有时间维度的有向非循环图, 变量用节点表示, 变量之间的相互关系用有向箭头和条件概率表示; 驾驶行为认知网络满足一阶马尔科夫假设; 驾驶行为认知网络包括先验网络 $B_1$ 和转移网络 $B_{\rightarrow}$ ; 先验网络 $B_1$ 定义初始状态的条件概率分布以及多变量间的关系, 其节点间的连接结构用实线表示; 转移网络 $B_{\rightarrow}$ 表示 $t-1$ 时刻和 $t$ 时刻间的关系以条件概率分布, 其节点间的连接用虚线表示; 先验网络 $B_1$ 中, 节点 $X_t$ 对节点 $M_t$ 和节点 $Y_t$ 都直接相连, 节点 $M_t$ 和节点 $Y_t$ 也直接相连; 转移网络 $B_{\rightarrow}$ 中,  $t-1$ 时刻的 $X_{t-1}$ 节点和 $t$ 时刻的 $X_t$ 节点直接相连,  $t-1$ 时刻的 $M_{t-1}$ 节点和 $t$ 时刻的 $X_t$ 和 $Y_t$ 节点直接相连; 其驾驶行为认知网络结构如图4所示。

[0146] 步骤112, 认知网络参数学习: 基于驾驶行为数据库, 应用EM方法学习认知网络参数;

[0147] 基于动态贝叶斯网络, 其参数描述如下,

[0148] 如果节点Z和其父节点 $Pa(Z)$ 都是离散变量 $i, j$ , 则条件概率 $P(Z=i | Pa(Z)=j)$ 表示如下:

$$[0149] \quad P(Z=i | Pa(Z)=j) = P(i, j)$$

[0150] 其中表示,  $P(i, j)$  表示概率值大小;

[0151] 如果节点Z是离散变量 $i$ , 其父节点是连续变量 $y$ , 则条件概率 $P(Z=i | Pa(Z)=y)$ 表达为:

$$[0152] \quad P(Z=i | Pa(Z)=y) = \mathcal{N}(y; u_i, \Sigma_i)$$

[0153] 其中,  $\mathcal{N}$  表示高斯分布,  $u_i$  是分布的均值,  $\Sigma_i$  是协方差;

[0154] 如果节点Z是连续变量 $z$ , 其父节点也是连续变量, 则条件概率为:

$$[0155] \quad P(Z=z | Pa(Z)=y) = \mathcal{N}(z; W * y + u, \Sigma)$$

[0156] 其中,  $W$  是权重系数,  $u, \Sigma$  分别是高斯分布的均值和方差;

[0157] 步骤113, 认知网络性能评估: 对行为认知网络估计性能进行评估; 行为认知网络评估包括正确识别, 开始识别时间, 成功识别时间以及综合评估参数。

[0158] 正确识别是指: 根据历史信息, 认知网络对某行为估计概率大于或者等于90%, 且估计的行为是正确的; 相反则为误识别。

[0159] 正确识别时间是指: 根据历史信息, 认知网络正确识别该行为的时间, 其正确识别时间点表示为 $t_{0.9}$ , 表示第一次正确估计某行为概率大于或等于90%的时间点, 并有:

$$[0160] \quad t_{\text{succed}} = t_{0.9} - t_{\text{label}}$$

[0161] 其中,  $t_{\text{label}}$  是行为开始的标定时间, 人为进行确定, 若 $t_{\text{label}} = 0$ , 则 $t_{\text{succed}} = t_{0.9}$ ;

[0162] 开始识别时间是指: 根据历史信息, 模型第一次对正确行为的估计概率达到20%,

此时的时间点记为 $t_{0.2}$ ,并有:

$$[0163] \quad t_{\text{start}} = t_{0.2} - t_{\text{label}}$$

[0164] 其中,如果 $t_{\text{label}}=0$ ,则 $t_{\text{start}}=t_{0.2}$ ;

[0165] 定义认知网络性能评估的综合评估参数 $f(s)$ 为:

$$[0166] \quad f(s) = \lambda_1 \sum_{i=1}^n \delta(i) + \lambda_2 \sum_{i=1}^n \frac{t_{\text{succeed}}}{T} + \lambda_3 \sum_{i=1}^n \frac{t_{\text{start}}}{T}$$

$$[0167] \quad \delta(i) = \begin{cases} 1, & \text{the } i\text{th case is incorrectly} \\ 0, & \text{the } i\text{th case is correctly} \end{cases}$$

[0168] 其中, $i$ 是指第 $i$ 个测试例, $n$ 为测试例的个数; $T$ 是指其测试例的时间长度, $s$ 表示某种认知网络结构, $\lambda_1$ 、 $\lambda_2$ 和 $\lambda_3$ 是各个评价指标的权重因子,定义: $\lambda_1=\lambda_2=\lambda_3=1$ 。

[0169] 如图1所示,本实施例中融合更新模块 $c$ 按如下方式对最终预测结果进行融合,并更新权重系数:

[0170] 以 $\hat{x}_{k+1}^1$ 和 $P_{k+1}^1$ 分别表示 $k+1$ 时刻预测模块 $b_1$ 的预测均值和预测协方差;

[0171] 以 $\hat{x}_{k+1}^2$ 和 $P_{k+1}^2$ 分别表示 $k+1$ 时刻预测模块 $b_2$ 的预测均值和预测协方差;

[0172] 以 $\text{Pred}_1$ 表征预测模型 $M_1$ ,以 $\text{Pred}_2$ 表征预测模型 $M_2$ ;则有:

$$[0173] \quad (\hat{x}_{k+1}^1, P_{k+1}^1) = \text{Pred}_1(\hat{x}_k^1, P_k^1)$$

$$[0174] \quad (\hat{x}_{k+1}^2, P_{k+1}^2) = \text{Pred}_2(\hat{x}_k^2, P_k^2)$$

[0175] 其中:

[0176]  $P(x_{k+1}^1)$ 为预测模块 $b_1$ 的纵向位置预测方差;

[0177]  $P(y_{k+1}^1)$ 为预测模块 $b_1$ 的横向位置预测方差;

[0178]  $P(x_{k+1}^2)$ 为预测模块 $b_2$ 的纵向位置预测方差;

[0179]  $P(y_{k+1}^2)$ 为预测模块 $b_2$ 的横向位置预测方差;

[0180] 则有:

$$[0181] \quad \text{预测模块 } b_1 \text{ 在 } k+1 \text{ 时刻的概率 } A_{k+1}^1 \text{ 为: } A_{k+1}^1 = 1 / (P(x_{k+1}^1) + P(y_{k+1}^1)),$$

$$[0182] \quad \text{预测模块 } b_2 \text{ 在 } k+1 \text{ 时刻的概率 } A_{k+1}^2 \text{ 为: } A_{k+1}^2 = 1 / (P(x_{k+1}^2) + P(y_{k+1}^2)),$$

$$[0183] \quad \text{预测模块 } b_1 \text{ 在 } k+1 \text{ 时刻的权重 } \mu_{k+1}^1 \text{ 为: } \mu_{k+1}^1 = \frac{1}{c} A_{k+1}^1 \bar{c}_1; \text{ 其中, } c = A_{k+1}^1 \bar{c}_1 + A_{k+1}^2 \bar{c}_2, \\ \bar{c}_1 = p_{11} \mu_k^1 + p_{21} \mu_k^2;$$

$$[0184] \quad \text{预测模块 } b_2 \text{ 在 } k+1 \text{ 时刻的权重 } \mu_{k+1}^2 \text{ 为: } \mu_{k+1}^2 = \frac{1}{c} A_{k+1}^2 \bar{c}_2; \text{ 其中, } \bar{c}_2 = p_{12} \mu_k^1 + p_{22} \mu_k^2;$$

$$[0185] \quad k+1 \text{ 时刻车辆参数的最终预测均值 } \hat{x}_{k+1} \text{ 为: } \hat{x}_{k+1} = \mu_{k+1}^1 \hat{x}_{k+1}^1 + \mu_{k+1}^2 \hat{x}_{k+1}^2$$

[0186]  $k+1$ 时刻车辆参数的最终预测协方差 $P_{k+1}$ 为:

[0187]

$$P_{k+1} = \mu_{k+1}^1 (P_{k+1}^1 + (\hat{x}_{k+1}^1 - \hat{x}_{k+1}) (\hat{x}_{k+1}^1 - \hat{x}_{k+1})^T) + \mu_{k+1}^2 (P_{k+1}^2 + (\hat{x}_{k+1}^2 - \hat{x}_{k+1}) (\hat{x}_{k+1}^2 - \hat{x}_{k+1})^T)。$$

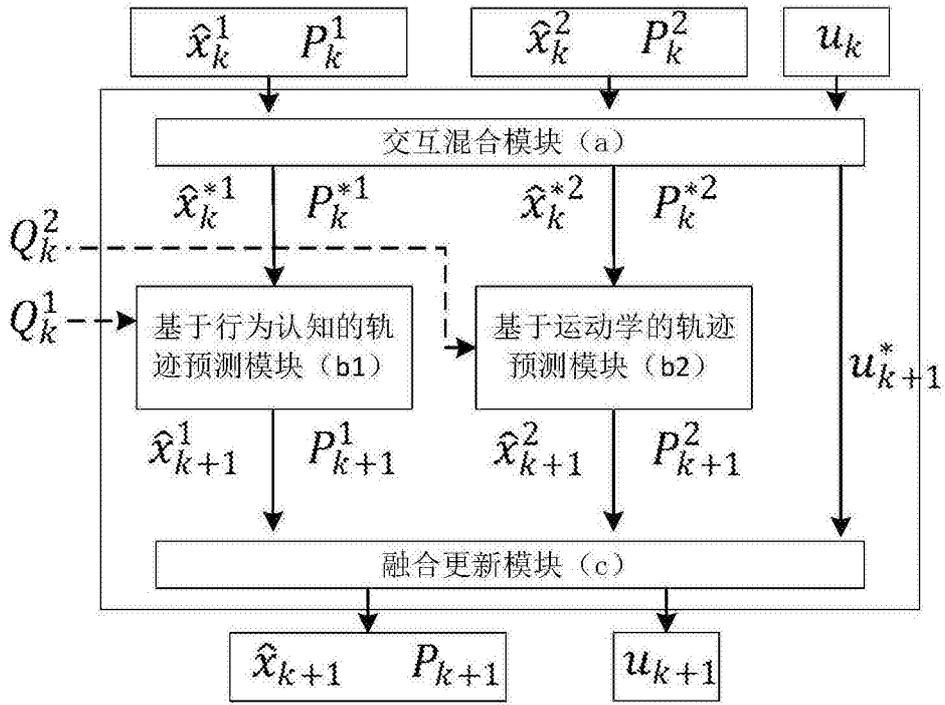


图1

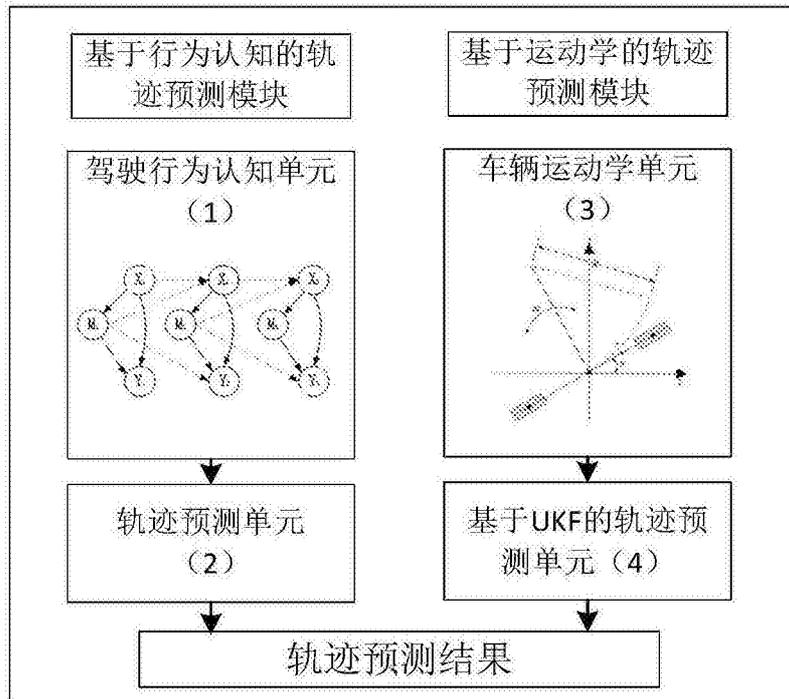


图2

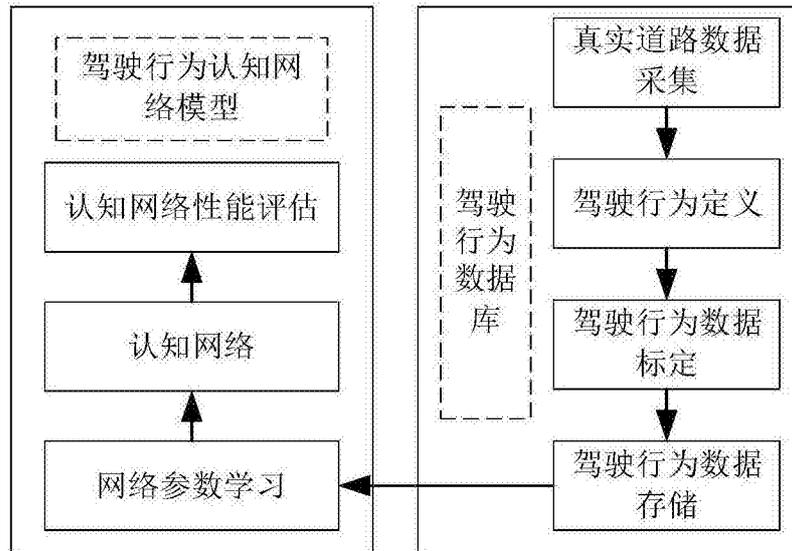


图3

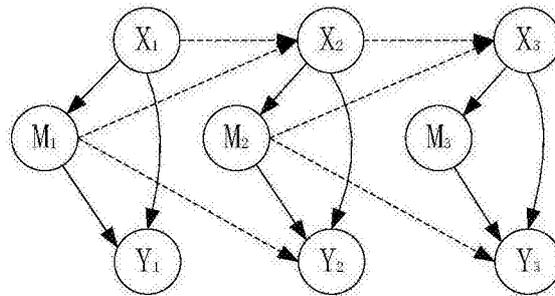


图4

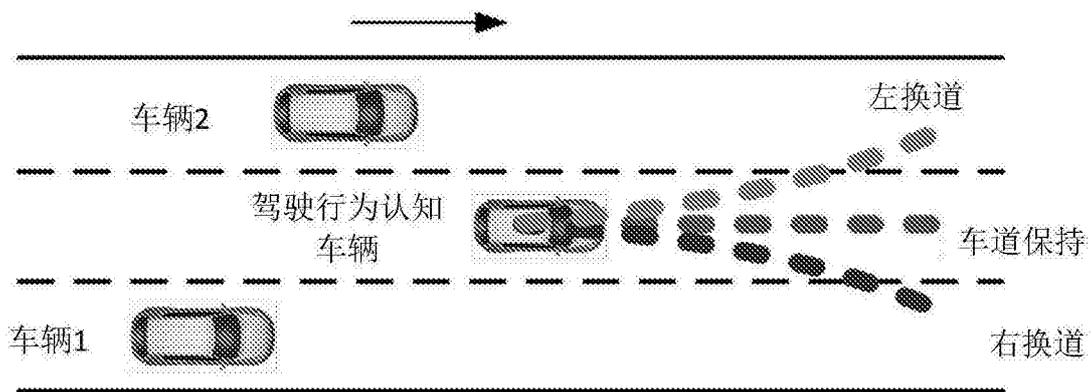


图5