



(12) 发明专利申请

(10) 申请公布号 CN 119442627 A

(43) 申请公布日 2025. 02. 14

(21) 申请号 202411479527.7

(22) 申请日 2024.10.22

(71) 申请人 清华大学

地址 100084 北京市海淀区清华园

(72) 发明人 封硕 任坤 杨敬轩 陆秋婧

张毅 胡坚明

(74) 专利代理机构 北京安信方达知识产权代理

有限公司 11262

专利代理师 李丹 龙洪

(51) Int. Cl.

G06F 30/20 (2020.01)

G06F 17/18 (2006.01)

G06F 111/08 (2020.01)

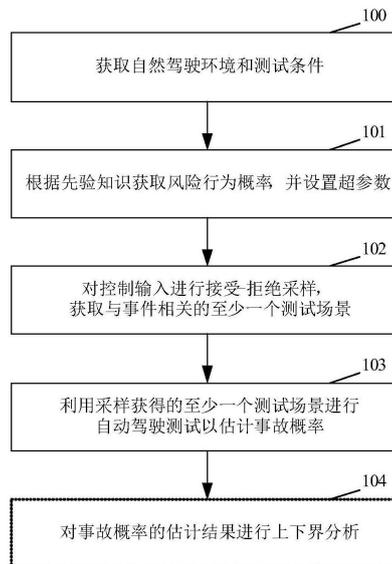
权利要求书2页 说明书14页 附图3页

(54) 发明名称

一种自动驾驶测试方法及自动驾驶测试装置

(57) 摘要

本申请公开了一种自动驾驶测试方法及自动驾驶测试装置,通过接受-拒绝采样方法,不依赖显式的交通概率分布即可得到风险性较高的提议分布并进行采样,同时得到未归一化的采样权重,用于估计测试结果。解决了相关技术中的局限性,提高了测试效率,尤其适用于对高维复杂的自然加速环境模型进行加速测试。



1. 一种自动驾驶测试方法,其特征在于,包括:

获取自然驾驶环境和测试条件;

根据先验知识获取风险行为概率,并设置超参数;

对控制输入进行接受-拒绝采样,获取与预先设置的事件相关的至少一个测试场景;

利用采样获得的至少一个测试场景进行自动驾驶测试以估计事故概率。

2. 根据权利要求1所述的自动驾驶测试方法,还包括:对所述事故概率的估计结果进行上下界分析。

3. 根据权利要求1或2所述的自动驾驶测试方法,其中,所述测试环境的隐式采样概率为 $P(x)$ ;  $P(x)$ 描述车辆在真实交通环境中的状态分布。

4. 根据权利要求1或2所述的自动驾驶测试方法,其中,通过设置测试参数获取所述测试条件;

所述测试参数包括:最大测试时长 $T$ 或最大测试距离 $D$ ,测试次数 $n$ 。

5. 根据权利要求1或2所述的自动驾驶测试方法,其中,所述获取自然驾驶环境包括:

基于自动驾驶环境信息构建的环境变量分布 $P(x)$ ,并通过隐式重要性采样法获取采样分布 $q(x)$ ;其中, $P(x)$ 为测试环境的隐式采样概率 $P(x)$ ,用于描述自动驾驶车辆在测试场景中的表现。

6. 根据权利要求5所述的自动驾驶测试方法,其中,所述通过隐式重要性采样法获取采样分布 $q(x)$ ,包括:

设置一采样分布 $q(x)$ ,并通过隐式重要性采样法调整采样分布 $q(x)$ 使其更接近目标分布;根据调整后的采样分布 $q(x)$ 估计在自动驾驶测试中预先设置的所述事件发生的概率。

7. 根据权利要求1或2所述的自动驾驶测试方法,其中,按照下式获取所述风险行为概率 $H_1$ :

$$H_1(s(k)) = \int_{u_c} P(u|s(k))du;$$

其中, $u_c$ 是基于经验或分析确定的风险动作集合,表示哪些控制输入属于风险动作; $P(u|s(k))$ 是给定状态 $s(k)$ 时,控制输入 $u$ 的概率分布,积分是对控制输入 $u$ 在危险动作集合 $u_c$ 上进行的; $H_1(s(k))$ 表示在状态 $s(k)$ 下,所有可能控制输入 $u$ 的概率总和。

8. 根据权利要求1或2所述的自动驾驶测试方法,其中,按照下式设置所述超参数;所述超参数包括第一超参数 $K_1$ 和第二超参数 $K_2$ :

$$\min c_{ik} = (K_1 - 1) \cdot \min H_1 + K_2;$$

$$\max c_{ik} = (K_1 - 1) \cdot \max H_1 + K_2;$$

其中,第一超参数 $K_1$ 和第二超参数 $K_2$ 为用于调整 $c_{ik}$ 的超参数; $H_1$ 为所述风险行为概率,表示在状态 $s(k)$ 下,危险动作的概率; $\min c_{ik}$ 和 $\max c_{ik}$ 分别为 $c_{ik}$ 的上下界。

9. 根据权利要求8所述的自动驾驶测试方法,其中,按照下式计算所述 $c(x_i)$ 的上下界:

$$c(x_i) = \prod_{k \in T_{i,c}} c_{ik} \geq \prod_{k \in T_{i,c}} \min c_{ik} = (\min c_{ik})^{T_{i,c}};$$

$$c(x_i) = \prod_{k \in T_{i,c}} c_{ik} \leq \prod_{k \in T_{i,c}} \max c_{ik} = (\max c_{ik})^{T_{i,c}};$$

其中, $T_{i,c}$ 表示与场景 $x_i$ 相关的状态和时刻的集合,表示在场景 $x_i$ 下,与所述事件A相关的所有时刻的集合。

10. 根据权利要求1或2所述的自动驾驶测试方法,其中,所述获取与预先设置的事件相关的至少一个测试场景,包括:

通过所述控制输入 $u(k)$ 的采样分布 $q(u(k) | s(k))$ 生成候选控制输入;

计算候选控制输入的接受概率 $P_{acc}(u(k) | s(k))$ 并进行接受-拒绝采样;

通过在每个时间点 $k$ 上执行所述接受-拒绝采样过程,以生成一个由场景序列组成的测试场景,重复所述接受-拒绝采样以生成多个测试场景。

11. 根据权利要求10所述的自动驾驶测试方法,其中,所述采样分布 $q(u(k) | s(k))$ 经过重要性采样的调整和归一化处理。

12. 根据权利要求1或2所述的自动驾驶测试方法,其中,采用下式对所述事故概率进行估计,包括:

$$\hat{\mu}_{q_u} = \frac{1}{n} \sum_{i=1}^n P(A|x_i) w_u(x_i), x_i \sim q(x);$$

$$\text{其中, } \mu_{q_u} = E_q(P(A|x)w_u(x_i)) \approx \hat{\mu}_{q_u};$$

其中, $\hat{\mu}_{q_u}$ 为所述事故概率的估计结果; $E_q$ 表示在采样分布 $q(x)$ 下的期望; $w_u(x_i)$ 为所述接受-拒绝采样方法中的样本权重; $x_i \sim q(x)$ 表示从采样分布 $q(x)$ 中抽取的样本; $P(A|x_i)$ 表示给定环境变量 $x_i$ 的条件下事件A发生的概率。

13. 根据权利要求9所述的自动驾驶测试方法,其中,所述对事故概率的估计结果进行上下界分析,包括:

通过对所述采样权重 $c(x)$ 的上下界分析,调整所述第一超参数 $K_1$ 和所述第二超参数 $K_2$ ;

通过结合置信水平 $\lambda$ 和标准差函数 $\text{std}(\cdot)$ 计算所述事件A发生的概率 $P(A)$ 的上下界。

14. 根据权利要求13所述的自动驾驶测试方法,其中,所述事件A发生的概率 $P(A)$ 的上下界如下式所示:

$$P(A) \geq E_P \left[ \frac{P(A|x)}{c(x)} c_{\min}(x) \right] \geq \hat{\mu}_{q_u, \min} - \lambda \cdot \text{std}(\hat{\mu}_{q_u, \min}) = \inf P(A);$$

$$P(A) \leq E_P \left[ \frac{P(A|x)}{c(x)} c_{\max}(x) \right] \geq \hat{\mu}_{q_u, \max} - \lambda \cdot \text{std}(\hat{\mu}_{q_u, \max}) = \sup P(A);$$

其中, $\hat{\mu}_{q_u, \min}$ 表示所述事故概率的估计结果的最小值, $c_{\max}(x)$ 和 $c_{\min}(x)$ 表示 $c(x)$ 的上下界, $\hat{\mu}_{q_u, \max}$ 表示所述事故概率的估计结果的最大值。

15. 一种计算机可读存储介质,存储有计算机可执行指令,所述计算机可执行指令用于执行权利要求1-14任一项所述的自动驾驶测试方法。

16. 一种自动驾驶测试装置,包括存储器和处理器,其中,存储器中存储有以下可被处理器执行的指令:用于执行权利要求1-14任一项所述的自动驾驶测试方法的步骤。

## 一种自动驾驶测试方法及自动驾驶测试装置

### 技术领域

[0001] 本申请涉及但不限于自动驾驶技术领域,具体涉及一种自动驾驶测试方法及自动驾驶测试装置。

### 背景技术

[0002] 随着自动驾驶技术的快速发展,如何有效评估其安全性已成为一项关键挑战。自动驾驶汽车需要在复杂多变的交通环境中运行,而潜在的安全风险(如交通事故等)的发生率极低。这使得通过传统方法测试其在各种环境下的安全性十分困难,难以全面评估系统在应对极端或危险场景的表现。

[0003] 目前,自动驾驶的测试大多依赖自然驾驶环境(NDE)或仿真生成的测试场景。NDE方法基于真实世界中的车辆行为数据来构建场景,虽然能够模拟自然驾驶场景,但难以覆盖罕见的安全关键事件。仿真方法则通过人为设计特定的驾驶场景,如对抗性驾驶行为等,以评估自动驾驶系统在极端环境下的表现。然而,这些方法在实现场景的对抗性与真实性之间的平衡上存在挑战,难以得到与真实环境下等效或无偏的估计结果。

[0004] 由于自动驾驶场景的高维复杂性和安全关键事件的稀缺性,传统的自动驾驶测试方法需要大量的真实道路测试数据才能覆盖可能发生的各类场景。这种大规模测试不仅耗时长且成本高昂,难以实现。此外,许多极端的驾驶场景无法通过常规测试方法有效覆盖的,因此,如何提高测试效率已成为自动驾驶安全性验证的核心问题之一。

### 发明内容

[0005] 本申请提供一种自动驾驶测试方法及自动驾驶测试装置,能够提高测试效率。

[0006] 本发明实施例提供了一种自动驾驶测试方法,包括:

[0007] 获取自然驾驶环境和测试条件;

[0008] 根据先验知识获取风险行为概率,并设置超参数;

[0009] 对控制输入进行接受-拒绝采样,获取与预先设置的事件相关的至少一个测试场景;

[0010] 利用采样获得的至少一个测试场景进行自动驾驶测试以估计事故概率。

[0011] 在一种示例性实例中,还包括:对所述事故概率的估计结果进行上下界分析。

[0012] 在一种示例性实例中,所述测试环境的隐式采样概率为 $P(x)$ ;  $P(x)$ 描述车辆在真实交通环境中的状态分布。

[0013] 在一种示例性实例中,通过设置测试参数获取所述测试条件;

[0014] 所述测试参数包括:最大测试时长 $T$ 或最大测试距离 $D$ ,测试次数 $n$ 。

[0015] 在一种示例性实例中,所述获取自然驾驶环境包括:

[0016] 基于自动驾驶环境信息构建的环境变量分布 $P(x)$ ,并通过隐式重要性采样法获取采样分布 $q(x)$ ;其中, $P(x)$ 为测试环境的隐式采样概率 $P(x)$ ,用于描述自动驾驶车辆在测试场景中的表现。

[0017] 在一种示例性实例中,所述通过隐式重要性采样法获取采样分布 $q(x)$ ,包括:

[0018] 设置一采样分布 $q(x)$ ,并通过隐式重要性采样法调整采样分布 $q(x)$ 使其更接近目标分布;根据调整后的采样分布 $q(x)$ 估计在自动驾驶测试中预先设置的所述事件发生的概率。

[0019] 在一种示例性实例中,按照下式获取所述风险行为概率 $H_1$ :

$$[0020] \quad H_1(s(k)) = \int_{u_c} P(u|s(k))du;$$

[0021] 其中, $u_c$ 是基于经验或分析确定的风险动作集合,表示哪些控制输入属于风险动作; $P(u|s(k))$ 是给定状态 $s(k)$ 时,控制输入 $u$ 的概率分布,积分是对控制输入 $u$ 在危险动作集合 $u_c$ 上进行的; $H_1(s(k))$ 表示在状态 $s(k)$ 下,所有可能控制输入 $u$ 的概率总和。

[0022] 在一种示例性实例中,按照下式设置所述超参数;所述超参数包括第一超参数 $K_1$ 和第二超参数 $K_2$ :

$$[0023] \quad \text{min}c_{ik} = (K_1 - 1) \cdot \text{min}H_1 + K_2;$$

$$[0024] \quad \text{max}c_{ik} = (K_1 - 1) \cdot \text{max}H_1 + K_2;$$

[0025] 其中,第一超参数 $K_1$ 和第二超参数 $K_2$ 为用于调整 $c_{ik}$ 的超参数; $H_1$ 为所述风险行为概率,表示在状态 $s(k)$ 下,危险动作的概率; $\text{min}c_{ik}$ 和 $\text{max}c_{ik}$ 分别为 $c_{ik}$ 的上下界。

[0026] 在一种示例性实例中,按照下式计算所述 $c(x_i)$ 的上下界:

$$[0027] \quad c(x_i) = \prod_{k \in T_{i,c}} c_{ik} \geq \prod_{k \in T_{i,c}} \text{min}c_{ik} = (\text{min}c_{ik})^{T_{i,c}};$$

$$c(x_i) = \prod_{k \in T_{i,c}} c_{ik} \leq \prod_{k \in T_{i,c}} \text{max}c_{ik} = (\text{max}c_{ik})^{T_{i,c}};$$

[0028] 其中, $T_{i,c}$ 表示与场景 $x_i$ 相关的状态和时刻的集合,表示在场景 $x_i$ 下,与所述事件A相关的所有时刻的集合。

[0029] 在一种示例性实例中,所述获取与预先设置的事件相关的至少一个测试场景,包括:

[0030] 通过所述控制输入 $u(k)$ 的采样分布 $q(u(k)|s(k))$ 生成候选控制输入;

[0031] 计算候选控制输入的接受概率 $P_{\text{acc}}(u(k)|s(k))$ 并进行接受-拒绝采样;

[0032] 通过在每个时间点 $k$ 上执行所述接受-拒绝采样过程,以生成一个由场景序列组成的测试场景,重复所述接受-拒绝采样以生成多个测试场景。

[0033] 在一种示例性实例中,所述采样分布 $q(u(k)|s(k))$ 经过重要性采样的调整和归一化处理。

[0034] 在一种示例性实例中,采用下式对所述事故概率进行估计,包括:

$$[0035] \quad \hat{\mu}_{q_u} = \frac{1}{n} \sum_{i=1}^n P(A|x_i) w_u(x_i), x_i \sim q(x);$$

$$[0036] \quad \text{其中}, \mu_{q_u} = E_q(P(A|x)w_u(x_i)) \approx \hat{\mu}_{q_u};$$

[0037] 其中, $\hat{\mu}_{q_u}$ 为所述事故概率的估计结果; $E_q$ 表示在采样分布 $q(x)$ 下的期望; $w_u(x_i)$ 为所述接受-拒绝采样方法中的样本权重; $x_i \sim q(x)$ 表示从采样分布 $q(x)$ 中抽取的样本; $P(A|x_i)$ 表示给定环境变量 $x_i$ 的条件下事件A发生的概率。

[0038] 在一种示例性实例中,所述对事故概率的估计结果进行上下界分析,包括:

[0039] 通过对所述采样权重 $c(x)$ 的上下界分析,调整所述第一超参数 $K_1$ 和所述第二超参

数 $K_2$ ;

[0040] 通过结合置信水平 $\lambda$ 和标准差函数 $\text{std}(\cdot)$ 计算所述事件A发生的概率 $P(A)$ 的上下界。

[0041] 在一种示例性实例中,所述事件A发生的概率 $P(A)$ 的上下界如下式所示:

$$P(A) \geq E_P \left[ \frac{P(A|x)}{c(x)} c_{\min}(x) \right] \geq \hat{\mu}_{q_{u,\min}} - \lambda \cdot \text{std}(\hat{\mu}_{q_{u,\min}}) = \inf P(A);$$

$$P(A) \leq E_P \left[ \frac{P(A|x)}{c(x)} c_{\max}(x) \right] \geq \hat{\mu}_{q_{u,\max}} - \lambda \cdot \text{std}(\hat{\mu}_{q_{u,\max}}) = \sup P(A);$$

[0043] 其中, $\hat{\mu}_{q_{u,\min}}$ 表示所述事故概率的估计结果的最小值, $c_{\max}(x)$ 和 $c_{\min}(x)$ 表示 $c(x)$ 的上下界, $\hat{\mu}_{q_{u,\max}}$ 表示所述事故概率的估计结果的最大值。

[0044] 本申请实施例还提供一种计算机可读存储介质,存储有计算机可执行指令,所述计算机可执行指令用于执行上述任一项所述的自动驾驶测试方法。

[0045] 本申请实施例再提供一种自动驾驶测试装置,包括存储器和处理器,其中,存储器中存储有以下可被处理器执行的指令:用于执行上述任一项所述的自动驾驶测试方法的步骤。

[0046] 本申请实施例提出的自动驾驶测试方法,通过接受-拒绝采样方法,不依赖显式的交通概率分布即可得到风险性较高的提议分布并进行采样,同时得到未归一化的采样权重,用于估计测试结果。解决了相关技术中的局限性,提高了测试效率,尤其适用于对高维复杂的自然加速环境模型进行加速测试。

[0047] 本发明的其它特征和优点将在随后的说明书中阐述,并且,部分地从说明书中变得显而易见,或者通过实施本发明而了解。本发明的目的和其他优点可通过在说明书、权利要求书以及附图中所特别指出的结构来实现和获得。

## 附图说明

[0048] 附图用来提供对本申请技术方案的进一步理解,并且构成说明书的一部分,与本申请的实施例一起用于解释本申请的技术方案,并不构成对本申请技术方案的限制。

[0049] 图1为本申请实施例中自动驾驶测试方法的流程示意图;

[0050] 图2为本申请实施例中NDE-I下,本申请自动驾驶测试方法中的IIS与NDE测试结果的对比实验示意图;

[0051] 图3为本申请实施例中NDE-I下,本申请自动驾驶测试方法中的IIS的误差分析结果实验示意图;

[0052] 图4为本申请实施例中NDE-II下,本申请自动驾驶测试方法中的IIS与NDE测试结果的对比实验示意图;

[0053] 图5为本申请实施例中NDE-II下,本申请自动驾驶测试方法中的IIS的误差分析结果实验示意图;

[0054] 图6为本申请实施例中自动驾驶的测试装置的组成结构示意图。

## 具体实施方式

[0055] 为使本申请的目的、技术方案和优点更加清楚明白,下文中将结合附图对本申请的实施例进行详细说明。需要说明的是,在不冲突的情况下,本申请中的实施例及实施例中的特征可以相互任意组合。

[0056] 为了便于理解本申请,下面将参照相关附图对本申请进行更全面的描述。附图中给出了本申请的实施例。但是,本申请可以以许多不同的形式来实现,并不限于本文所描述的实施例。相反地,提供这些实施例的目的是使本申请的公开内容更加透彻全面。

[0057] 除非另有定义,本文所使用的所有的技术和科学术语与属于本申请的技术领域的技术人员通常理解的含义相同。本文中在本申请的说明书中所使用的术语只是为了描述具体的实施例的目的,不是旨在于限制本申请。

[0058] 可以理解,本申请所使用的术语“第一”、“第二”仅用于描述目的,而不能理解为指示或暗示相对重要性或者隐含指明所指示的技术特征的数量。由此,限定有“第一”、“第二”的特征可以明示或隐含地包括至少一个该特征。在本申请的描述中,“多个”的含义是至少两个,例如两个、三个等,除非另有明确具体的限定。

[0059] 可以理解,以下实施例中的“连接”,如果被连接的电路、模块、单元等相互之间具有电信号或数据的传递,则应理解为“电连接”、“通信连接”等。

[0060] 在此使用时,单数形式的“一”、“一个”和“所述/该”也可以包括复数形式,除非上下文清楚指出另外的方式。还应当理解的是,术语“包括/包含”或“具有”等指定所陈述的特征、整体、步骤、操作、组件、部分或它们的组合的存在,但是不排除存在或添加一个或多个其他特征、整体、步骤、操作、组件、部分或它们的组合的可能性。同时,在本说明书中使用的术语“和/或”包括相关所列项目的任何及所有组合。

[0061] 以使用 $x$ 表示测试环境, $A$ 表示与自动驾驶汽车性能相关的事件为例,事件 $A$ 可以是在自动驾驶测试中预先设置的感兴趣的事件如交通事故的发生等。在自动驾驶测试中,希望估计事件 $A$ 发生的概率,以评估自动驾驶汽车的性能。事件 $A$ 发生的概率可以表示为 $P(A) = \sum_{x \in X} P(A|x)P(x)$ ,测试环境 $x$ 基于概率分布 $P(x)$ 进行采样。基于相关技术中的蒙特卡洛采样方法,可以得到 $P(A)$ 的估计值如公式(1)所示:

$$[0062] \quad P(A) = E_P(P(A|x)) \approx \frac{1}{n} \sum_{i=1}^n P(A|x_i) \approx \frac{m}{n}, \quad x_i \sim P(x) \quad (1)$$

[0063] 公式(1)是相关技术中用于描述自动驾驶测试中预先设置的事件 $A$ 发生的概率,是对事件 $A$ 发生的概率的期望估计,其中 $x$ 表示自动驾驶环境下的状态变量(如位置、速度等),通过构建 $P(x)$ 的分布,描述测试场景中的各类状态。公式(1)中, $x_i$ 表示由概率分布 $P(x)$ 采样得到的测试场景, $n$ 表示采样次数也即样本数量, $m$ 表示事件 $A$ 发生的次数; $E_P$ 表示对分布 $P(x)$ 下的期望, $P(A|x)$ 表示在给定环境变量 $x$ 的情况下事件 $A$ 发生的条件概率, $x_i \sim P(x)$ 表示从分布 $P(x)$ 中抽取的样本。

[0064] 由于在真实的自动驾驶环境中,发生交通事故的概率是极低的,因此,采用公式(1)的基于蒙特卡洛采样的估计需要大量的采样样本才可得到对事故率的准确估计,其所依赖的时间成本和经济成本是极高的。也就是说,对于自动驾驶这样的场景,即当事件 $A$ 是一个低概率事件时(如交通事故),绝大多数从 $P(x)$ 中采样的状态 $x$ 都不会发生事件 $A$ ,导致大量样本的权重很低,从而需要生成大量样本来获得稳定和准确的估计,导致了时间成本

和计算资源的浪费。

[0065] 为了提高测试效率,一系列加速测试方法被提出。例如,基于重要性采样的方法通过改变场景被采样的概率,增加交通事故等事件的可能性,从而减少所需的测试次数。然而,这些方法通常依赖于显式的交通概率分布,由于交通环境的复杂性、高维性,这在实际情况往往是难以实现的。也就是说,当前的自动驾驶测试方法通常依赖于显式的、往往不易获取的交通行为分布,无法有效应对复杂的高维交通环境。

[0066] 为了解决上述任一问题,本申请实施例提出一种自动驾驶测试方法,图1为本申请实施例中自动驾驶测试方法的流程示意图,如图1所示,可以包括:

[0067] 步骤100:获取自然驾驶环境和测试条件。

[0068] 在一种示例性实例中,可以从现实或模拟的自动驾驶场景中获取自然驾驶环境。这些环境的隐式采样概率可以采用 $P(x)$ 来表示, $P(x)$ 描述了车辆在真实交通环境中的状态分布,自然驾驶环境的隐式采样概率为 $P(x)$ ,也就是环境变量分布 $P(x)$ 。

[0069] 在一种示例性实例中,可以通过设置测试参数获取测试条件。获取的测试条件可以包括但不限于如:最大测试时长 $T$ 或最大测试距离 $D$ ,测试次数 $n$ 等。其中,最大测试时长 $T$ 或最大测试距离 $D$ ,定义了测试过程中车辆能够经历的时间或开出的距离的上限。测试次数 $n$ 指计划执行的独立测试次数,即模拟或真实测试的总量。

[0070] 通过步骤100,确定了测试的总规模,并通过隐式采样概率 $P(x)$ 描述了自然驾驶环境中的状态。

[0071] 在一种示例性实例中,步骤100中的获取自然驾驶环境可以包括:

[0072] 基于自动驾驶环境信息构建的环境变量分布 $P(x)$ ,通过隐式重要性采样法获取采样分布 $q(x)$ 。

[0073] 步骤100中的根据自动驾驶环境信息构建的环境变量分布 $P(x)$ ,是通过收集自动驾驶测试中的各项环境信息,构建环境变量分布 $P(x)$ ,用于描述自动驾驶车辆在特定测试场景中的表现。

[0074] 环境信息可以包括但不限于如速度、位置、传感器数据等。在一种实施例中, $x$ 表示测试环境, $x$ 是一个多维向量,表示自动驾驶过程中涉及的所有环境变量和车辆状态信息。比如可以包括但不限于如:位置(Position)如车辆在测试区域内的具体坐标,速度(Speed)即车辆的当前行驶速度,加速度(Acceleration)即车辆的加速度信息,环境特征(Environmental Factors)如天气条件、道路类型(湿滑、干燥等)、交通密度等,传感器数据(Sensor Data)如激光雷达、摄像头等传感器在不同时间点收集到的周围环境信息,等等。

[0075] 由于交通环境的高维性和复杂性,对自然驾驶环境的建模往往基于十分复杂的模型结构,例如神经网络。模型的复杂性和黑箱性导致我们难以显式地获取概率分布 $P(x)$ ,仅能够得到基于隐式概率分布的采样结果,这使得传统的基于显式分布的测试方法受到限制。因此,为了解决这一问题,本申请实施例提出隐式重要性采样方法(IIS, Implicit Importance Sampling)。

[0076] 在一种示例性实例中,步骤100中的通过隐式重要性采样法获取采样分布 $q(x)$ ,可以包括:

[0077] 设置一采样分布 $q(x)$ ,并通过隐式重要性采样法调整采样分布 $q(x)$ 使其更接近目标分布;根据调整后的采样分布 $q(x)$ 估计在自动驾驶测试中预先设置的事件发生的概率。

本申请实施例中,采样分布 $q(x)$ 被设计得更接近于那些会发生事件A的状态,使得采样时能够更频繁地遇到与事件A相关的样本。

[0078] 在一种示例性实例中,使用重要性采样时, $P(A)$ 的估计值如公式(2)所示:

$$[0079] \quad P(A) = E_q \left( P(A|x) \frac{P(x)}{q(x)} \right) \approx \frac{1}{n} \sum_{i=1}^n P(A|x_i) \frac{P(x_i)}{q(x_i)}, \quad x_i \sim q(x_i) \quad (2)$$

[0080] 公式(2)中, $q(x)$ 为重要性采样分布,用于生成样本; $E_q$ 表示在采样分布 $q(x)$ 下的期望; $\frac{P(x)}{q(x)}$ 表示重要性权重,用于调整样本权重。 $x_i \sim q(x)$ 表示根据采样分布 $q(x)$ 采样的测试场景即从采样分布 $q(x)$ 中抽取的样本。

[0081] 公式(2)中,权重 $\frac{P(x_i)}{q(x_i)}$ 是用于调整从采样分布 $q(x)$ 中生成的样本,使得这些样本在期望计算时更能代表目标分布 $P(x)$ 。通过设计一个更有效的采样分布 $q(x)$ ,大大减少了所需的样本数,从而提高了采样效率,降低了时间和计算成本。

[0082] 本申请实施例中,通过选择一个适当的采样分布 $q(x)$ ,在采样分布 $q(x)$ 下,可能导致事件A出现的测试环境,其出现的概率更高,从而提高对风险场景的采样效率。重要性采样方法的关键在于对生成的样本进行加权,使得这些样本在期望计算时更能代表原始分布 $P(x)$ 。以减少实际采样时稀有事件被低估的风险。

[0083] 本申请实施例中,通过使用重要性采样(Importance Sampling),不直接从分布 $P(x)$ 中采样,而是从一个新的采样分布 $q(x)$ 中采样,而采样分布 $q(x)$ 是更接近于那些会发生事件A的状态,因此,使得采样时能够更频繁地遇到与事件相关的样本,大大提高了对事件A概率估计的效率,降低了样本数需求和计算成本。

[0084] 在一种示例性实例中,交通场景是随时间动态变化的,交通场景的动态变化可以通过引入马尔可夫性简化了环境变量分布 $P(x)$ 和采样分布 $q(x)$ 的建模。这种简化基于马尔可夫过程的假设,即未来状态只依赖于当前状态,而与之前的状态无关。因此,步骤100还可以包括:

[0085] 首先,通过马尔可夫性对环境变量分布 $P(x)$ 和采样分布 $q(x)$ 进行简化建模,分别如公式(3)、公式(4)所示:

$$[0086] \quad P(x) = P(s(0)) \prod_{k=0}^T P(u(k)|s(k)) \mathcal{T}(s(k+1)|s(k), u(k)) \quad (3)$$

$$q(x) = q(s(0)) \prod_{k=0}^T q(u(k)|s(k)) \mathcal{T}(s(k+1)|s(k), u(k)) \quad (4)$$

[0087] 公式(3)中, $P(s(0))$ 表示初始状态 $s(0)$ 的概率分布; $u(k)$ 为在第 $k$ 时刻的控制输入,表示自动驾驶系统或驾驶员在该时刻施加的操作(如加速、刹车或转向); $s(k)$ 为第 $k$ 时刻的状态,表示车辆在该时刻的状态(如速度、位置、方向等); $\mathcal{T}(s(k+1)|s(k), u(k))$ 表示给定控制输入 $u(k)$ 下,从状态 $s(k)$ 到 $s(k+1)$ 的状态转移概率,状态转移概率 $\mathcal{T}$ 描述了自动驾驶系统的动态行为,比如车辆在当前速度和加速度下的状态如何转移到下一个时刻。

[0088] 公式(4)中, $q(s(0))$ 为初始状态 $s(0)$ 的采样分布,表示在马尔可夫链中的初始状态; $q(u(k)|s(k))$ 为给定状态 $s(k)$ 时,第 $k$ 时刻控制输入 $u(k)$ 的采样分布,这是针对控制输入的采样设计,根据具体的优化目标设计 $q(u(k)|s(k))$ ,使得采样过程更集中于重要区域;

$\mathcal{T}(s(k+1)|s(k), u(k))$  表示给定控制输入  $u(k)$  下, 从状态  $s(k)$  到  $s(k+1)$  的状态转移概率。

[0089] 然后, 根据简化后的环境变量分布  $P(x)$  和采样分布  $q(x)$  估计在自动驾驶测试中预先设置的事件发生的概率, 可以入公式 (5) 所示:

$$[0090] \quad P(A) \approx \frac{1}{n} \sum_{i=1}^n P(A|x_i) \prod_{k=1}^{T_i} \frac{P(u(k)|s(k))}{q(u(k)|s(k))}, x_i \sim q(x_i) \quad (5)$$

[0091] 本申请实施例中, 一方面, 通过马尔可夫性假设, 未来状态仅依赖于当前状态, 而不依赖之前的历史状态。这使得环境变量分布  $P(x)$  和采样分布  $q(x)$  的计算更加简洁。无需跟踪完整的状态历史, 系统的计算复杂度明显降低。另一方面, 由于交通事故是低概率事件, 重要性采样通过构建一个优化的采样分布  $q(x)$ , 集中采样在更可能与事件相关的状态区域。马尔可夫模型通过时间演化捕捉这些重要的动态变化, 使得生成样本的过程更加合理, 并减少对样本数量的需求。再一方面, 交通场景是动态变化的, 状态随时间变化。通过公式 (3) 和公式 (4), 这种动态变化得以捕捉, 状态  $s(k)$  在时间维度上的变化通过控制输入和状态转移概率进行建模。这种模型更真实地模拟了实际的自动驾驶系统运行环境。

[0092] 步骤101: 根据先验知识获取风险行为概率  $H_1$ , 并设置超参数。

[0093] 在一种示例性实例中, 可以按照公式 (6) 获取风险行为概率  $H_1$ :

$$[0094] \quad H_1(s(k)) = \int_{u_c} P(u|s(k)) du \quad (6)$$

[0095] 公式 (6) 中,  $u_c$  是基于经验或分析确定的风险动作集合, 表示哪些控制输入  $u$  属于风险动作。 $P(u|s(k))$  是给定状态  $s(k)$  时, 控制输入  $u$  的概率分布, 积分是对控制输入  $u$  在危险动作集合  $u_c$  上进行的;  $H_1(s(k))$  表示在状态  $s(k)$  下, 所有可能控制输入  $u$  的概率总和。 $H_1$  的作用是为每个状态  $s(k)$  计算所有可能的控制输入的加权和, 为超参数的计算提供基础。公式 (2) 表示了对于每个状态  $s(k)$ , 通过对  $P(u|s(k))$  进行积分, 得到  $H_1(s(k))$ 。

[0096] 在一种示例性实例中, 可以根据先验知识计算  $P(A|x)$ 。先验知识基于历史数据或仿真结果, 用来估计事件  $A$  在不同状态下发生的条件概率  $P(A|x)$ 。这里的事件  $A$  通常代表自动驾驶系统中的特定事件 (如碰撞、失控等)。

[0097] 在一种实施例中, 计算  $P(u|s(k))$  的先验知识可以包括如: 自动驾驶车辆在特定状态  $s(k)$  (如特定的速度、位置或环境条件) 下, 通常会采取哪些控制输入  $u$  (如转向角度、加速度、刹车力度等)。这些控制输入  $u$  的概率分布  $P(u|s(k))$  可能来源于历史数据、仿真模型或先前测试的统计结果。先验知识还可以定义风险动作集合  $u_c$ , 风险动作集合  $u_c$  是一组控制输入  $u$ , 其被认为会增加事故或失控等风险, 比如过度转向、紧急刹车或过快加速等行为在某些状态  $s(k)$  下可能会被归入风险动作集合  $u_c$ , 先验知识可能来源于专家判断、事故分析报告或安全标准, 用于识别哪些控制输入会增加风险。

[0098] 在一种实施例中, 可以通过大量的自动驾驶数据, 了解在不同状态  $s(k)$  (比如特定的速度、位置或环境条件) 下, 控制输入  $u$  的典型分布情况, 可以通过数据分析生成  $P(u|s(k))$ 。或者, 通过安全专家或系统设计者根据对系统的理解, 定义哪些控制输入会在特定状态下增加风险, 从而确定风险动作集合  $u_c$ 。或者, 可以使用仿真工具来模拟自动驾驶场景, 为不同状态  $s(k)$  下的控制输入分布提供参考, 并可以确定可能引发事故的控制输入集合。

[0099] 在一种示例性实例中, 可以基于公式 (7a)、公式 (7b) 设置超参数, 使得下式中  $c_{ik}$  的

上下界均尽可能接近于1,公式(7a)、公式(7b)中涉及的第一超参数 $K_1$ 和第二超参数 $K_2$ 用于优化采样过程,确保采样分布更加集中在重要区域,减少不相关样本的生成。由于 $c_{ik}$ 与 $H_1$ 成线性关系,因此, $c_{ik}$ 的最小值即 $\min c_{ik}$ 和最大值 $\max c_{ik}$ 与第一超参数 $K_1$ 和第二超参数 $K_2$ 的关系分别如公式(7a)、公式(7b)所示:

$$[0100] \quad \min c_{ik} = (K_1 - 1) \cdot \min H_1 + K_2 \quad (7a)$$

$$[0101] \quad \max c_{ik} = (K_1 - 1) \cdot \max H_1 + K_2 \quad (7b)$$

[0102] 在公式(7a)、公式(7b)中,第一超参数 $K_1$ 和第二超参数 $K_2$ 用于调整采样权重的超参数。 $H_1$ 即是 $H_1(s(k))$ ,表示在状态 $s(k)$ 下,危险动作的概率。

[0103] 公式(7a)、公式(7b)通过将 $H_1$ 的最小值(对应最危险的状态)和最大值(对应最安全的状态)与第一超参数 $K_1$ 和第二超参数 $K_2$ 结合,来计算 $c_{ik}$ 的上下界。

[0104] 在一种实施例中,可以根据公式(8a)、公式(8b)计算 $c(x_i)$ 的上下界:

$$c(x_i) = \prod_{k \in T_{i,c}} c_{ik} \geq \prod_{k \in T_{i,c}} \min c_{ik} = (\min c_{ik})^{T_{i,c}} \quad (8a)$$

$$[0105] \quad c(x_i) = \prod_{k \in T_{i,c}} c_{ik} \leq \prod_{k \in T_{i,c}} \max c_{ik} = (\max c_{ik})^{T_{i,c}} \quad (8b)$$

[0106] 公式(8a)、公式(8b)用于计算 $c(x_i)$ 的上下界,描述了如何使用各个状态 $k$ 的最小 $c_{ik}$ 和最大 $c_{ik}$ 来计算整个测试场景 $x_i$ 的 $c(x_i)$ 。

[0107] 公式(8a)、公式(8b)中, $T_{i,c}$ 表示与场景 $x_i$ 相关的状态和时刻的集合,表示在场景 $x_i$ 下,与事件A(例事故或其他相关事件)相关的所有时刻的集合。换句话说, $T_{i,c}$ 是场景 $x_i$ 在时间维度上的集合,用来累积该场景下多个时刻的最小或最大采样权重。对 $T_{i,c}$ 中每个时刻 $k$ 进行累乘表示场景的时间维度上,不同时间点对采样权重的累积影响。通过最小或最大权重的累乘,可以估算出在整个测试场景下,最坏或最好的情况下事故发生的概率权重,从而计算出整个测试场景 $x_i$ 的采样权重上下界。

[0108] 本申请实施例中,通过引入第一超参数 $K_1$ 和第二超参数 $K_2$ 对控制输入和状态分布进行优化,确保了采样过程更有效。也就是说,通过引入第一超参数 $K_1$ 和第二超参数 $K_2$ ,针对不同的风险状态对采样分布进行调整,确保了在异常情况或低概率事件中也能保持样本的有效性,这样可以避免稀有事件在采样中的低权重问题,从而获得更加稳定的概率估计。

[0109] 步骤102:对控制输入 $u(k)$ 进行接受-拒绝采样,获取与预先设置的事件相关的至少一个测试场景。

[0110] 在一种示例性实例中,步骤102可以包括:

[0111] 通过控制输入 $u(k)$ 的采样分布 $q(u(k) | s(k))$ 生成候选控制输入;

[0112] 计算候选控制输入的接受概率 $P_{acc}(u(k) | s(k))$ 并进行接受-拒绝采样;

[0113] 通过在每个时间点 $k$ 上执行上述采样过程,以生成一个由场景序列组成的测试场景,重复采样以生成多个测试场景。

[0114] 在一种示例性实例中,通过控制输入 $u(k)$ 的采样分布 $q(u(k) | s(k))$ 生成候选控制输入,可以包括:

[0115] 在每个时刻 $k$ ,根据状态 $s(k)$ 使用采样分布 $q(u(k) | s(k))$ 生成一个候选控制输入 $u(k)$ 。其中,采样分布 $q(u(k) | s(k))$ 是通过重要性采样的调整和归一化处理的。

[0116] 这里,采样分布 $q(u(k) | s(k))$ 是经过优化的,可以集中在那些更容易引发事故的控制输入上(即如步骤100中所述的通过重要性采样的调整)。比如,如果系统检测到当前状

态 $s(k)$ 是危险的,采样分布可能会生成更激进的控制输入,如急转弯、突然刹车等。

[0117] 在一种示例性实例中,可以根据公式(9)计算候选控制输入的接受概率 $P_{acc}(u(k)|s(k))$ :

$$[0118] \quad P_{acc}(u|s) = \frac{q_u(u|s)}{K_1 P(u|s)} = \frac{K(u|s)}{K_1} = \begin{cases} 1, & \text{if } C(s) \neq 0 \text{ and } P(A|u, s) > 0 \\ \frac{K_2}{K_1}, & \text{if } C(s) \neq 0 \text{ and } P(A|u, s) = 0 \end{cases} \quad (9)$$

[0119] 公式(9)中, $q_u(u|s)$ 表示未归一化的采样分布, $C(s)$ 表示状态 $s$ 下场景的风险性, $C(s) \neq 0$ 意味着发生事故的可能性。为了在 $C(s) \neq 0$ 时从 $q(u|s)$ 中进行采样,采用接受-拒绝采样方法,对概率 $P(u|s)$ 进行采样,并以公式(9)的接受概率选择接受或拒绝采样的样本,从而保证采样结果符合概率分布。

[0120] 在一种实施例中,采样过程可以包括:如果根据 $P_{acc}$ 的计算结果决定接受控制输入 $u(k)$ ,该输入会用于生成测试场景;如果根据 $P_{acc}$ 的计算结果决定拒绝控制输入 $u(k)$ ,丢弃该输入并重新采样,直到找到合适的控制输入。

[0121] 在一种示例性实例中,通过在每个时间步 $k$ 上执行上述采样过程,以生成一个由场景序列组成的测试场景,可以包括:

[0122] 通过在每个时间步 $k$ 上执行上述采样过程,可以逐步生成一个完整的场景序列: $x = \{(s(0), u(0)), (s(1), u(1)), \dots, (s(T), u(T))\}$ ,其中,每一对 $(s(k), u(k))$ 表示车辆在时刻 $k$ 的状态和相应的控制输入。每个测试场景由多个时间步的状态和控制输入构成。这些测试场景是根据接受-拒绝采样过程生成的,确保了每个测试场景都具有高事故相关性。

[0123] 通过重复上述采样过程,生成 $N$ 个测试场景,每个测试场景都是一个独立的序列 $x_i: \{x_{i1}, x_{i2}, \dots, x_{iN}\}$ 。这些测试场景经过采样分布和接受-拒绝筛选,重点集中在那些可能引发事故或异常行为的状态和控制输入上,本申请实施例中生成的测试场景有效提高了自动驾驶系统的测试效率。

[0124] 本申请实施例中,对概率分布 $P(x)$ 进行调整,从而构造采样分布 $q(x)$ ,以提高生成对抗性测试场景的概率。由于 $P(u|s)$ 是无法计算概率的隐式分布,因此本申请实施例中借助接受-拒绝采样方法设计概率分布 $q(u|s)$ 并进行采样。分布 $q(u|s)$ 设计如公式(10)所示:

$$q(u|s) = \frac{q_u(u|s)}{\int q_u(u|s) du},$$

$$[0125] \quad q_u(u|s) = K(u, s)P(u|s), \quad (10)$$

$$K(u, s) = \begin{cases} K_0 = 1, & \text{if } C(s) = 0 \\ K_1 > 1, & \text{if } C(s) \neq 0 \text{ and } P(A|u, s) > 0 \\ K_2 < 1, & \text{if } C(s) \neq 0 \text{ and } P(A|u, s) = 0 \end{cases}$$

[0126] 基于公式(10),公式(9)中,当 $C(s) \neq 0$ 时,即当前状态可能发生事故时, $K_1 > 1$ 将作用于 $P(A|u, s) > 0$ 的动作 $u$ ,提高这部分动作被采样的概率,从而提高了事故发生的概率。

[0127] 基于接受-拒绝采样方法,可以得到未归一化的样本权重 $w_u(x_i)$ 如公式(11)所示:

$$[0128] \quad w_u(x_i) = \frac{P(x_i)}{q(x_i)} = \prod_{k=1}^{T_i} \frac{P(u(k)|s(k))}{q_u(u(k)|s(k))} = \prod_{k=1}^{T_i} w_{u,ik} \quad (11)$$

[0129] 其中,  $w_{u,ik} = \frac{P(u(k)|s(k))}{q_u(u(k)|s(k))} = \frac{1}{K(u(k),s(k))}$ ;

[0130] 公式(11)中,  $T_i$ 表示第*i*次测试的时间步,  $w_{i,k}$ 表示第*i*次测试 $x_i$ 中第*k*个时间步的权重。在风险程度 $C(s)$ 为0的状态下,有 $P(u|s) = q(u|s)$ ,则对应的权重为1。因此,在计算权重时只需考虑部分有风险性的关键状态。使用 $T_i, c$ 表示第*i*次测试中的关键时间步集合,那么,

$$[0131] \quad w_u(x_i) = \prod_{k \in T_i, c} w_{u,ik} \quad (12)$$

[0132] 则对事件A概率的估计结果可以表示为公式(13)所示:

$$[0133] \quad \hat{\mu}_{q_u} = \frac{1}{n} \sum_{i=1}^n P(A|x_i) w_u(x_i), x_i \sim q(x) \quad (13)$$

[0134] 其中,  $\mu_{q_u} = E_q(P(A|x)w_u(x_i)) \approx \hat{\mu}_{q_u}$ ;

[0135] 通过步骤102生成了重点集中于可能引发事故的测试场景,这些测试场景更集中于风险较高的驾驶行为,从而可以有效评估自动驾驶系统在危险环境下的性能,从而提高了自动驾驶系统测试的效率,并为更准确地估计事故发生的概率提供了保障。

[0136] 步骤103:利用采样获得的至少一个测试场景进行自动驾驶测试以估计事故概率。

[0137] 在一种示例性实例中,可以根据公式(13)计算事故率的估计结果。

[0138] 与相关技术中基于重要性采样的加速测试方法不同,本申请实施例提出的自动驾驶测试方法,通过接受-拒绝采样方法,不依赖显式的交通概率分布即可得到风险性较高的提议分布并进行采样,同时得到未归一化的采样权重,用于估计测试结果。解决了相关技术中的局限性,提高了测试效率,尤其适用于对高维复杂的自然加速环境模型进行加速测试。

[0139] 在一种示例性实例中,为了确保测试结果 $\mu_{q_u}$ 与目标值 $P(A)$ 近似无偏,本申请实施例提供的自动驾驶测试方法,还可以包括步骤104。

[0140] 步骤104:对事故概率的估计结果进行上下界分析。

[0141] 在一种示例性实例中,步骤104可以包括:

[0142] 通过对归一化系数 $c(x)$ 的上下界分析,调整第一超参数 $K_1$ 和第二超参数 $K_2$ ,以确保最终的估计结果尽可能接近实际事故概率 $P(A)$ ;

[0143] 通过结合置信水平 $\lambda$ 和标准差函数 $\text{std}(\cdot)$ 计算事件A发生的概率 $P(A)$ 的上下界,以有效地估计事故概率的范围,确保测试结果的可靠性。

[0144] 通过步骤103的处理能够得到高于自然驾驶环境的采样和测试效率,但是,受到未归一化的影响,得到的测试结果 $\mu_{q_u}$ 并不等于 $P(A)$ 。对此,本申请发明人发现,通过选择合适的第一超参数 $K_1$ 和第二超参数 $K_2$ ,测试结果 $\mu_{q_u}$ 与目标值 $P(A)$ 是近似无偏的。

[0145] 因此,本申请实施例中针对估计结果 $\mu_{q_u}$ 提供了一种上下界分析方法。 $P(A)$ 和 $\mu_{q_u}$ 之间的偏差是由 $q_u(x)$ 的未归一化造成的,因此,首先,可以如公式(14)所示对系数 $c(x)$ 进行归一化处理,定义系数 $c(x)$ 为 $q_u(x)$ 的归一化系数:

$$[0146] \quad c(x) = \frac{q_u(x)}{q(x)} \quad (14)$$

[0147] 通过公式(14)的归一化系数处理,可以调整采样分布 $q_u(x)$ 与 $P(x)$ 之间的差异,使

得 $\hat{\mu}_{q_u}$ 更接近 $P(A)$ 。结合公式(2),可以得到公式(15):

$$\begin{aligned}
 [0148] \quad E_q(\hat{\mu}_{q_u}) &= E_q\left(\frac{1}{n}\sum_{i=1}^n P(A|x_i) w_u(x_i)\right) = E_q(P(A|x)w_u(x)) \\
 &= E_q\left(\frac{P(A|x)P(x)}{c(x)q(x)}\right) = E_q\left(\frac{P(A|x)}{c(x)}\right) \quad (15)
 \end{aligned}$$

[0149] 公式(15)中, $\hat{\mu}_{q_u}$ 提供了对 $E_q\left(\frac{P(A|x)}{c(x)}\right)$ 的无偏估计,而不是 $P(A)$ 的无偏估计。为了最小化与目标结果 $P(A) = E_q(P(A|x))$ 的偏差,系数 $c(x)$ 应尽可能接近1,从而确保 $\hat{\mu}_{q_u}$ 提供更接近 $P(A)$ 的估计。

[0150] 因此,本申请实施例中,通过对 $c(x)$ 上下界的近似分析,对第一超参数 $K_1$ 和第二超参数 $K_2$ 的选择提供指导,以确保得到的估计结果尽可能准确,同时实现了对 $P(A)$ 进行上下界的近似分析。对于一次测试 $x_i$ ,使用 $c_{ik}$ 表示在第 $k$ 个时间步分布 $q_u(u_k|s_k)$ 的归一化系数如公式(16)所示:

$$[0151] \quad c_{ik} = \int q_u(u_k|s_k) du_k \quad (16)$$

[0152] 对于整个序列即一个完整的测试场景 $x_i$ , $c(x_i)$ 可以表示为乘积 $\prod_{k \in T_i, c} c_{ik}$ 。也就是说,其归一化系数 $c(x_i)$ 可以表示为所有时间步的归一化系数的乘积即 $c(x_i) = \prod_{k \in T_i, c} c_{ik}$ 。那么,计算 $c_{ik}$ 可以如公式(17)所示:

$$[0153] \quad c_{ik} = K_1 \cdot H_1(s(k)) + K_2 \cdot H_2(s(k))$$

$$[0154] \quad = (K_1 - 1) \cdot H_1(s(k)) + K_2 \quad (17)$$

[0155] 公式(17)中的 $H_1(s(k))$ 如公式(6)所示, $H_2(s(k)) = 1 - H_1(s(k))$ , $H_2(s(k))$ 是 $H_1(s(k))$ 的互补概率。由于 $c_{ik}$ 与 $H_1$ 成线性关系,因此, $c_{ik}$ 的最小值和最大值分别如公式(7a)、公式(7b)所示。 $T_i, c$ 表示集合中元素的数量。对 $c(x)$ 的最小值和最大值可以分别如公式(18a)、公式(18b)所示:

$$[0156] \quad c_{min}(x_i) = (\min c_{ik})^{T_i, c} \quad (18a)$$

$$[0156] \quad c_{max}(x_i) = (\max c_{ik})^{T_i, c} \quad (18b)$$

[0157] 进而,得到通过归一化系数调整后,事故概率 $P(A)$ 的一个上下界估计方法如下:

$$[0158] \quad E_q\left(\frac{P(A|x)}{c(x)} c_{min}(x)\right) \leq P(A) = E_q\left(\frac{P(A|x)}{c(x)} c(x)\right) \leq E_q\left(\frac{P(A|x)}{c(x)} c_{max}(x)\right) \quad (19)$$

[0159] 在实际计算中,上述的上下界可以通过采样方法进行估计,分别如公式(20a)、公式(20b)所示:

$$E_q \left( \frac{P(A|x)}{c(x)} c_{max}(x) \right) = E_q \left( \frac{P(A|x) P(x)}{c(x) q(x)} c_{max}(x) \right) = E_q (P(A|x) w_u(x) c_{max}(x))$$

$$\approx \frac{1}{n} \sum_{i=1}^n P(A|x_i) w_u(x_i) c_{max}(x_i) = \hat{\mu}_{q_u, max}, x_i \sim q(x) \quad (20a)$$

$$E_q \left( \frac{P(A|x)}{c(x)} c_{min}(x) \right) \approx \frac{1}{n} \sum_{i=1}^n P(A|x_i) w_u(x_i) c_{min}(x_i) = \hat{\mu}_{q_u, min}, x_i \sim q(x) \quad (20b)$$

[0161] 引入置信水平 $\lambda$ 和标准差函数 $std(\cdot)$ ,则P(A)的上下界计算如公式(21a)、公式(21b)所示:

$$P(A) \geq E_P \left[ \frac{P(A|x)}{c(x)} c_{min}(x) \right] \geq \hat{\mu}_{q_u, min} - \lambda \cdot std(\hat{\mu}_{q_u, min}) = \inf P(A) \quad (21a)$$

$$P(A) \leq E_P \left[ \frac{P(A|x)}{c(x)} c_{max}(x) \right] \geq \hat{\mu}_{q_u, max} - \lambda \cdot std(\hat{\mu}_{q_u, max}) = \sup P(A) \quad (21b)$$

[0163] 公式(21a)、公式(21b)分别给出了事故概率的最小值和最大值,通过调整归一化系数 $c(x)$ 来确保估计尽可能准确。 $\inf P(A)$ 指P(A)的下确界,即所有可能的P(A)值中最小的界限; $\sup P(A)$ 指P(A)的上确界,即所有可能的P(A)值中最大的界限。

[0164] 在一种实施例中,一方面,本申请实施例通过马尔可夫性假设,未来状态仅依赖于当前状态,而不依赖之前的历史状态。这使得环境变量分布 $P(x)$ 和采样分布 $q(x)$ 的计算更加简洁。无需跟踪完整的状态历史,系统的计算复杂度明显降低。另一方面,由于交通事故是低概率事件,重要性采样通过构建一个优化的采样分布 $q(x)$ ,集中采样在更可能与事件相关的状态区域。马尔可夫模型通过时间演化捕捉这些重要的动态变化,使得生成样本的过程更加合理,并减少对样本数量的需求。再一方面,交通场景是动态变化的,状态随时间变化。通过公式(3)和公式(4),这种动态变化得以捕捉,状态 $s(k)$ 在时间维度上的变化通过控制输入和状态转移概率进行建模。这种模型更真实地模拟了实际的自动驾驶系统运行环境。

[0165] 本申请还提供一种计算机可读存储介质,存储有计算机可执行指令,所述计算机可执行指令用于执行上述任一项所述的自动驾驶测试方法。

[0166] 本公开实施例再提供了一种计算机装置,包括存储器;和连接至存储器的处理器,所述处理器执行基于存储在所述存储器中的指令,执行如前一项所述的自动驾驶测试方法的步骤。

[0167] 为了验证本申请实施例提出的自动驾驶测试方法的有效性,下面选择两种不同类型的自然驾驶环境模型进行测试:(1)第一种自然驾驶环境模型记为NDE-I,为文献(Feng S, Sun H, Yan X, et al. Dense reinforcement learning for safety validation of autonomous vehicles[J]. Nature, 2023, 615(7953): 620-627.)中构建的自然驾驶环境模型;(2)第二种自然驾驶环境模型记为NDE-II,为文献(Yan X, Zou Z, Feng S, et al. Learning naturalistic driving environment with statistical realism[J]. Nature communications, 2023, 14(1): 2037.)中构建的自然驾驶环境模型。

[0168] NDE-I基于显式的离散概率分布进行建模,因此,基于测试过程中得到的概率分布进行数据分析,将风险行为概率 $H_1$ 的范围确定为 $(1 \times 10^{-7}, 5 \times 10^{-5})$ 。分别设置第一超参数 $K_1 = 100$ ,第二超参数 $K_2 = 0.99$ 和第一超参数 $K_1 = 500$ ,第二超参数 $K_2 = 0.99$ ,以确保 $c_{ik}$ 接近1。以两车道平直高速公路驾驶场景为例,基于提出的隐式重要性采样IIS方法进行测试环境

生成,得到事故率估计结果,并与自然驾驶环境下得到的事故率估计结果进行比较。图2展示了两组参数下的事故率估计结果及直接估计(NDE,Naive Direct Estimation)与重要性采样(IIS,Importance Sampling)技术在自动驾驶测试中估计事故率的对比结果,图中的IIS技术使用了两种不同的设置,分别是 $K_1=100$ 和 $K_1=500$ 。这些图表的目的是,在NDE-I基于显式的离散概率分布进行建模下,对比两种方法在事故率估计、置信区间相对半宽度以及所需测试次数上的表现。图2中的(a)和(d)展示了事故率随测试次数的变化情况,图2中的(b)和(e)展示了相对半宽度(衡量估计的置信度)随测试次数的变化,图2中的(c)和(f)展示了在置信区间下,所需测试次数的分布。其中,第一列图片展示了随着测试数量的增加,事故率估计结果的变化情况,阴影部分表示置信水平 $\lambda=0.95$ 时估计结果的置信区间;第二列图片展示了相对半宽(RHW,Relative half-width)指标,并计算了达到精度阈值(RHW=0.3)所需的最少测试次数;第三列图片展示了多次重复实验下,需要的最少测试次数出现的频率。

[0169] 实验结果表明,在自然驾驶环境下需要大约 $2.03 \times 10^8$ 次测试;当 $K_1=100$ 时,在IIS生成的环境中所需的测试次数减少至 $2.34 \times 10^6$ ,将测试过程加速了87倍,且实验结果与自然驾驶环境下的结果近似无偏;当 $K_1=500$ 时,仅需要 $4.32 \times 10^5$ 次测试,将测试过程加速了470倍,但是,同时导致了事故率估计结果的偏差略有增大。进一步,对IIS方法得到的估计结果进行了误差分析,在置信水平 $\lambda=0.95$ 下得到了P(A)的上下界估计结果,如图3所示,图3中阴影部分表示使用本申请实施例提出的自动驾驶测试方法得到的上下界估计范围。基于以上实验结果可以看出,对于NDE-I,通过本申请实施例提出的自动驾驶测试方法,将未归一化导致的偏差控制在了较小的范围内,得到了可靠的、偏差较小的测试结果,并大幅提高了测试效率。

[0170] 从图2、图3的对比可见,相比于NDE,IIS显著减少了为获得可靠事故率估计所需的测试次数。随着IIS中第一超参数 $K_1$ 的增大,性能进一步提升,尽管会稍微增加所需的测试次数,但是IIS依旧在稳定性、置信度和效率上优于NDE。

[0171] NDE-II基于神经网络进行建模,驾驶行为概率分布 $P(u|s)$ 为隐式分布,无法获得准确的分布值,只能得到采样结果。基于文献(2)中的已有工作,得到了对驾驶行为风险性的分析结果,并将风险行为概率 $H_1$ 的范围估计为 $(4.5 \times 10^{-5}, 3 \times 10^{-3})$ 。分别设置参数第一超参数 $K_1=50$ ,第二超参数 $K_2=0.99$ 和第一超参数 $K_1=100$ ,第二超参数 $K_2=0.99$ ,以确保 $c_{ik}$ 接近1。本实施例中以环岛驾驶场景为例,基于本申请实施例提出的IIS方法进行测试环境生成,得到事故率估计结果,并与自然驾驶环境下得到的事故率估计结果进行比较。与NDE-I的结果类似,得到如图4所示的事故率估计结果,以及图5所示的误差估计结果。

[0172] 实验结果表明,在自然驾驶环境下需要大约 $5.87 \times 10^6$ 次测试;当第一超参数 $K_1=50$ 时,在IIS生成的环境中所需的测试次数减少至 $1.24 \times 10^5$ ,将测试过程加速了47倍,且实验结果与自然驾驶环境下的结果近似无偏;当第一超参数 $K_1=100$ 时,仅需要 $8.05 \times 10^4$ 次测试,将测试过程加速了73倍,但是,同时导致了事故率估计结果的偏差略有增大。基于实验结果可以看出,本本申请实施例提出的自动驾驶测试方法对于NDE-II依然有效,同样实现了对测试过程进行加速。

[0173] 图6为本申请实施例中自动驾驶的测试装置的组成结构示意图,如图6所示,可以包括:预处理模块、获取模块、估计模块;其中,

[0174] 预处理模块,用于获取自然驾驶环境和测试条件;根据先验知识获取风险行为概率,并设置超参数;

[0175] 获取模块,用于对控制输入进行接受-拒绝采样,获取与预先设置的事件相关的至少一个测试场景;

[0176] 估计模块,用于利用采样获得的至少一个测试场景进行自动驾驶测试以估计事故概率。

[0177] 在一种示例性实例中,还包括分析模块,用于对事故概率的估计结果进行上下界分析。

[0178] 本申请实施例提出的自动驾驶的测试装置,通过接受-拒绝采样方法,不依赖显式的交通概率分布即可得到风险性较高的提议分布并进行采样,同时得到未归一化的采样权重,用于估计测试结果。解决了相关技术中的局限性,提高了测试效率,尤其适用于对高维复杂的自然加速环境模型进行加速测试。

[0179] 虽然本申请所揭露的实施方式如上,但所述的内容仅为便于理解本申请而采用的实施方式,并非用以限定本申请。任何本申请所属领域内的技术人员,在不脱离本申请所揭露的精神和范围的前提下,可以在实施的形式及细节上进行任何的修改与变化,但本申请的专利保护范围,仍须以所附的权利要求书所界定的范围为准。

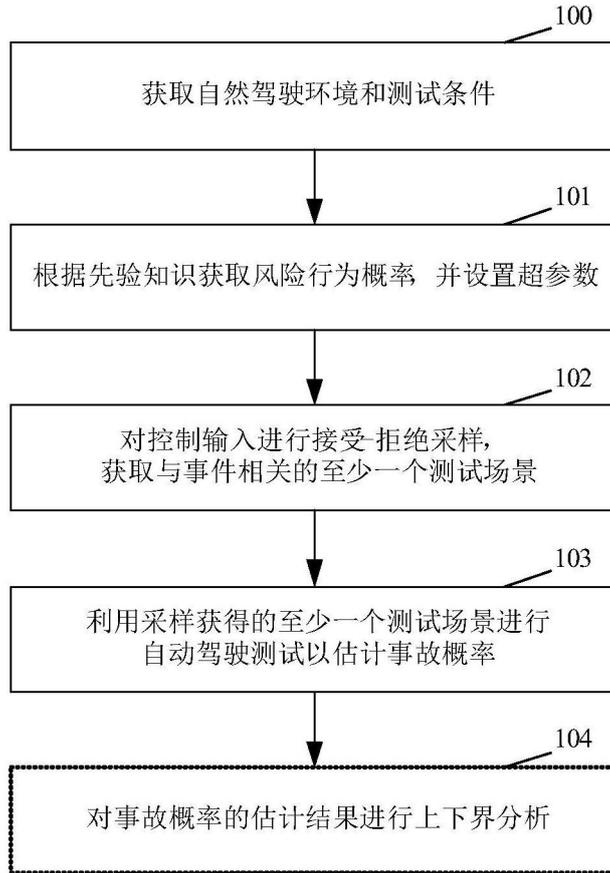


图1

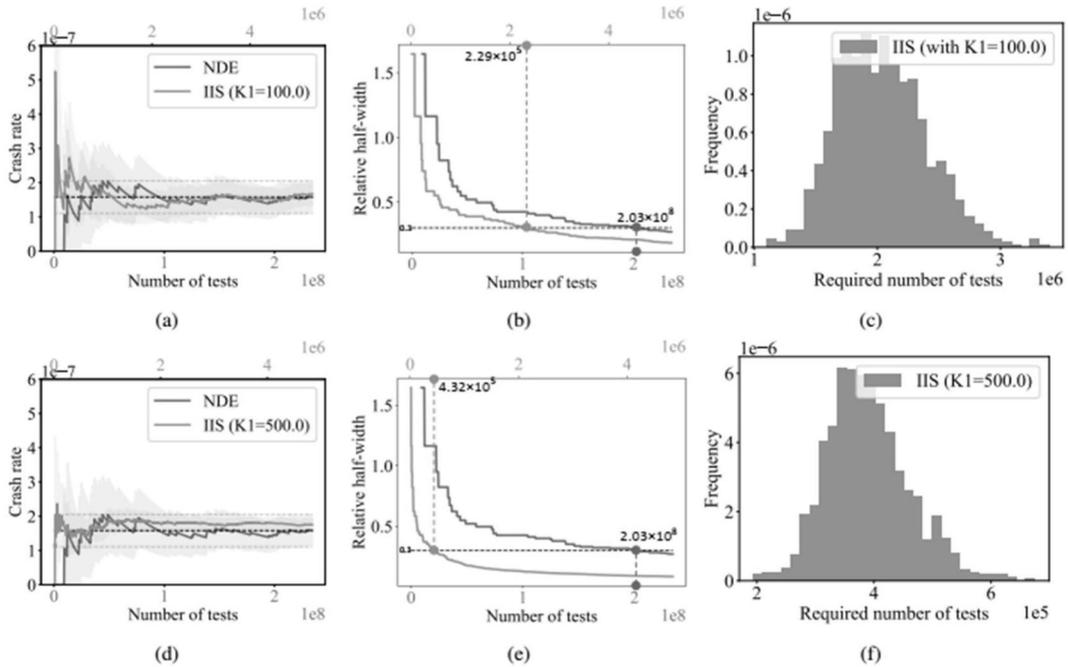


图2

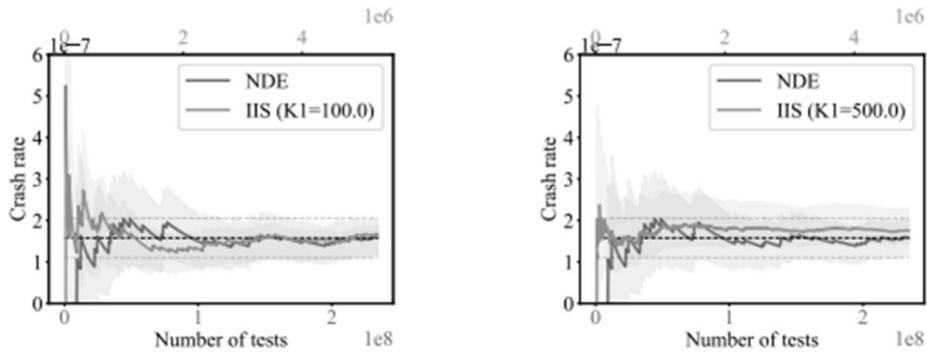


图3

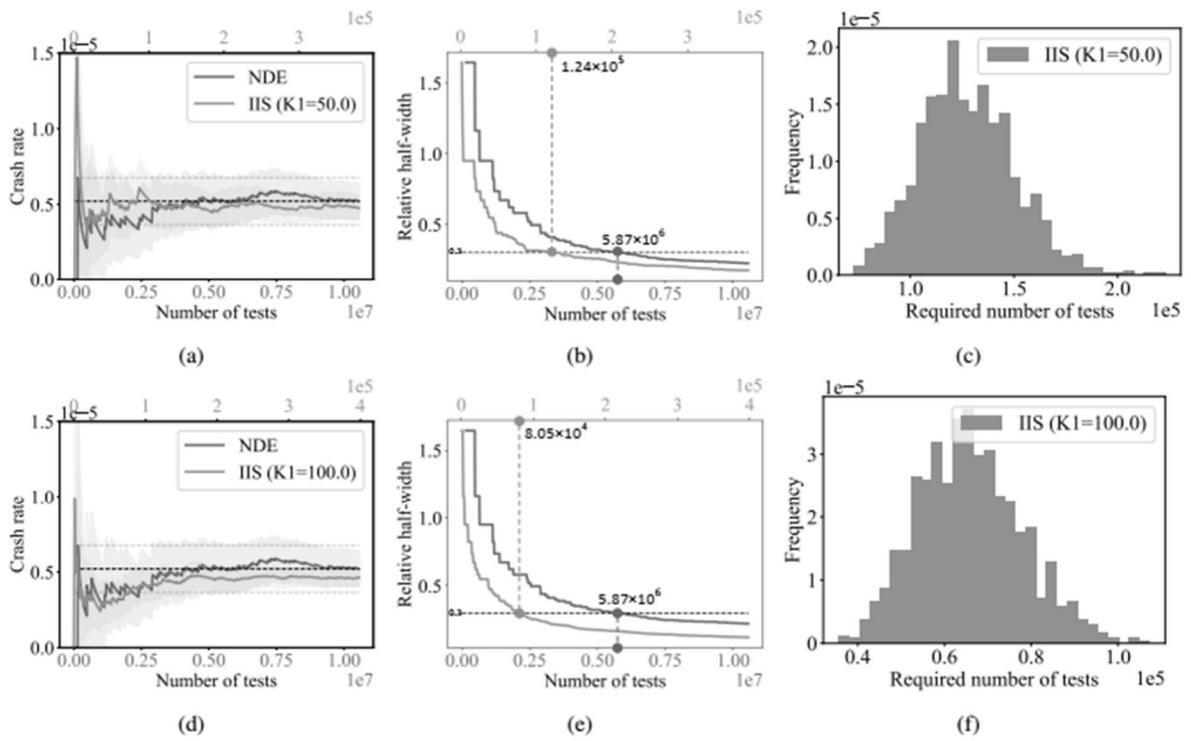


图4

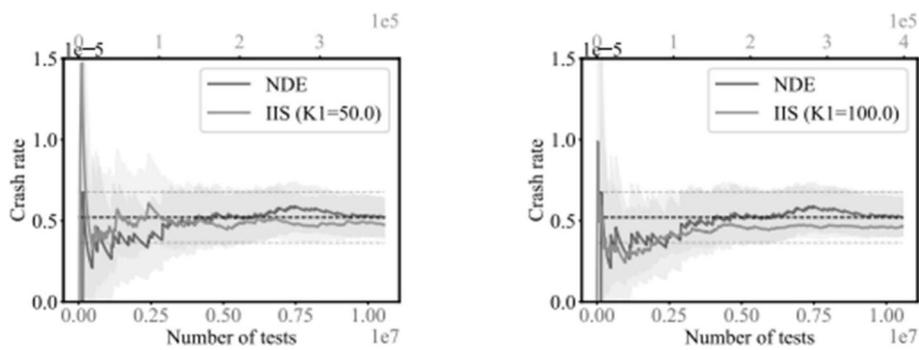


图5

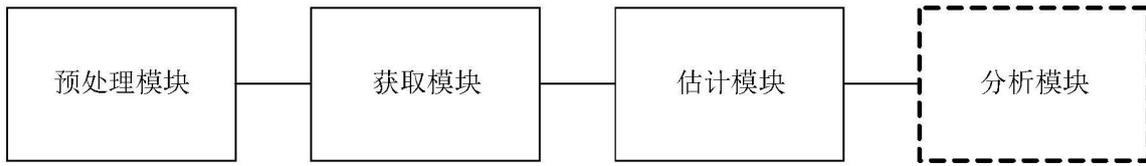


图6