



(21) 申请号 202411426595.7

(22) 申请日 2024.10.12

(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 李述 陆秋婧 杨敬轩

何林轩 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 龙洪 栗若木

(51) Int. Cl.

G06F 18/22 (2023.01)

G06F 30/27 (2020.01)

G06N 3/126 (2023.01)

G06N 3/084 (2023.01)

G06N 3/006 (2023.01)

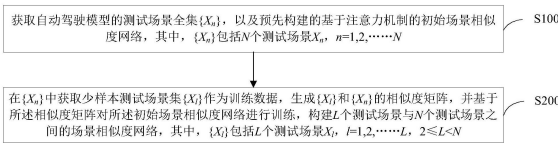
权利要求书3页 说明书10页 附图2页

(54) 发明名称

场景相似度网络训练、典型场景获取、测试方法和平台

(57) 摘要

一种场景相似度网络训练、典型场景获取、测试方法和平台,所述训练方法包括:获取自动驾驶模型的测试场景全集 $\{X_n\}$,以及预先构建的基于注意力机制的初始场景相似度网络,其中, $\{X_n\}$ 包括 N 个测试场景 $X_n, n=1, 2, \dots, N$;在 $\{X_n\}$ 中获取少样本测试场景集 $\{X_1\}$ 作为训练数据,生成 $\{X_1\}$ 和 $\{X_n\}$ 的相似度矩阵,并基于所述相似度矩阵对所述初始场景相似度网络进行训练,构建 L 个测试场景与 N 个测试场景之间的场景相似度网络,其中, $\{X_1\}$ 包括 L 个测试场景 $X_1, 1=1, 2, \dots, L, 2 \leq L < N$,提出了面向少样本测试问题的场景相似度网络,缓解了仿真测试中少样本测试下的显著不确定性问题,提高了少样本测试的可靠性,测试效率高,能够满足测试预算严格限制的情况。



1. 一种场景相似度网络训练方法,其特征在于,包括:

获取自动驾驶模型的测试场景全集 $\{X_n\}$,以及预先构建的基于注意力机制的初始场景相似度网络,其中, $\{X_n\}$ 包括 N 个测试场景 $X_n, n=1, 2, \dots, N$;

在 $\{X_n\}$ 中获取少样本测试场景集 $\{X_1\}$ 作为训练数据,生成 $\{X_1\}$ 和 $\{X_n\}$ 的相似度矩阵,并基于所述相似度矩阵对所述初始场景相似度网络进行训练,构建 L 个测试场景与 N 个测试场景之间的场景相似度网络,其中, $\{X_1\}$ 包括 L 个测试场景 $X_1, 1=1, 2, \dots, L, 2 \leq L < N$ 。

2. 如权利要求1所述的场景相似度网络训练方法,其特征在于,所述对所述初始场景相似度网络进行训练之前,包括:

获取 $\{X_n\}$ 对应的自然概率分布矩阵 $P_{N \times 1} = [p(X_1) p(X_2) \dots p(X_N)]^T$, 其中, $p(X_n)$ 与 X_n 一一对应,代表在所述测试场景 X_n 中的发生兴趣事件的自然概率;

在代理库中获取 K 个自动驾驶的代理模型 m_k , 所述代理库包括与所述代理模型 m_k 一一对应的测试指标真值 μ_{m_k} , 以及每一个所述代理模型 m_k 在每一个所述测试场景 X_n 中发生所述兴趣事件的概率 $p_k(X_n)$, 其中, $k=1, 2, \dots, K$ 。

3. 如权利要求2所述的场景相似度网络训练方法,其特征在于,所述在 $\{X_n\}$ 中获取少样本测试场景集 $\{X_1\}$ 作为训练数据,生成 $\{X_1\}$ 和 $\{X_n\}$ 的相似度矩阵,并基于所述相似度矩阵对所述初始场景相似度网络进行训练,构建 L 个测试场景与 N 个测试场景之间的场景相似度网络,包括:

循环执行以下步骤进行训练,直到达到预先设置的训练结束条件,其中,所述初始场景相似度网络为第一次训练的当前场景相似度网络:

在 $\{X_n\}$ 中采样,获取 L 个测试场景,作为本次训练的少样本测试场景集 $\{X_1\}$;

将 $\{X_n\}$ 和 $\{X_1\}$ 输入所述当前场景相似度网络,生成当前场景相似度矩阵 $S_{L \times N}$;

根据公式 $W_{L \times 1} = S_{L \times N} * P_{N \times 1}$ 计算当前权重矩阵 $W_{L \times 1} = [w(X_1) w(X_2) \dots w(X_L)]^T$, 其中, $w(X_1)$ 与 $\{X_1\}$ 中的测试场景 X_1 一一对应;

对每一个所述代理模型 m_k 执行以下步骤:根据公式 $\tilde{\mu}_{m_k} = \sum_1^L p_k(X_l) w(X_l)$ 计算该代理模型对应的当前测试指标估计值 $\tilde{\mu}_{m_k}$;

根据损失函数 $E = \max_{k=1, \dots, K} |\tilde{\mu}_{m_k} - \mu_{m_k}|$ 计算所述当前损失值 E ;

根据所述当前损失值 E 判断是否达到所述预先设置的训练结束条件,如果是,将所述当前场景相似度网络作为训练好的所述场景相似度网络;如果否,更新所述当前场景相似度网络的参数,进行下一次训练。

4. 如权利要求3所述的场景相似度网络训练方法,其特征在于,所述在 $\{X_n\}$ 中采样,获取 L 个测试场景,包括:

在 $\{X_n\}$ 的所述 N 个测试场景 X_n 中,采用随机采样方法、基于聚类的分类采样方法、或者拟蒙特卡洛采样方法进行采样,获取所述 L 个测试场景。

5. 如权利要求3所述的场景相似度网络训练方法,其特征在于,所述将 $\{X_n\}$ 和 $\{X_1\}$ 输入所述当前场景相似度网络,生成当前场景相似度矩阵 $S_{L \times N}$, 包括:

将 $\{X_n\}$ 中的每一个测试场景 X_n 和 $\{X_1\}$ 中的每一个测试场景 X_1 输入所述当前场景相似度网络进行特征映射,获得与 X_n 一一对应的查询向量 Q_n 和与 X_1 一一对应的键向量 K_1 ;

采用预先设置的相似度函数 d 对 N 个所述查询向量 Q_n 和 L 个所述键向量 K_l 进行相似度计算,获得相似度矩阵 D_{L*N} ,其中,位于 D_{L*N} 中第 l 行第 n 列的元素代表第 l 个键向量和第 n 个的查询向量的相似度 d_{ln} ;

基于预先设置的激活函数softmax对所述相似度矩阵 D_{L*N} 的每一列分别进行归一化处理,获得所述当前场景相似度矩阵 S_{L*N} 。

6. 一种典型场景获取方法,其特征在于,所述获取方法基于如权利要求1-5中任一项所训练好的场景相似度网络执行,包括:

在自动驾驶模型的测试场景全集 $\{X_n\}$ 中进行随机采样,获取 L 个测试场景生成待优化少样本测试场景集 $\{X_l^0\}$,其中, $\{X_n\}$ 包括 N 个测试场景 $X_n, n=1, 2, \dots, N$, $\{X_l^0\}$ 包括 L 个测试场景 $X_l^0, l=1, 2, \dots, L, 2 \leq L < N$;

基于所述场景相似度网络,对所述待优化少样本测试场景集 $\{X_l^0\}$ 采用预定优化策略在自动驾驶模型的测试场景全集 $\{X_n\}$ 中进行多轮迭代优化,获取典型测试场景集 $\{X_l^*\}$,并基于 $\{X_l^*\}$ 获取典型权重矩阵 $W_{L*1}^* = [w(X_1^*) \ w(X_2^*) \ \dots \ w(X_L^*)]^T$,其中, $\{X_l^*\}$ 包括 L 个典型测试场景 $X_l^*, w(X_l^*)$ 与 X_l^* 一一对应,所述预定优化策略包括梯度下降策略、遗传算法策略、粒子群算法策略或深度学习策略。

7. 如权利要求6所述的典型场景获取方法,其特征在于,所述对所述待优化少样本测试场景集 $\{X_l^0\}$ 采用预定优化策略在自动驾驶模型的测试场景全集 $\{X_n\}$ 中进行多轮迭代优化,获取典型测试场景集 $\{X_l^*\}$,包括:

循环执行以下步骤进行所述多轮迭代优化,直到本轮迭代对应的本轮优化后场景集 $\{X_1''\}$ 与本轮优化前场景集 $\{X_1'\}$ 之间的本轮曼哈顿距离 Y 小于第二预设阈值 Y_g ,其中,第一轮迭代的所述本轮优化前场景集 $\{X_1'\}$ 为所述待优化少样本测试场景集 $\{X_l^0\}$:

将所述测试场景全集 $\{X_n\}$ 和所述本轮优化前场景集 $\{X_1'\}$ 输入训练好的所述场景相似度网络,生成本轮场景相似度矩阵 S_{L*N}' ;

根据公式 $W_{L*1}' = S_{L*N}' * P_{N*1}$ 计算本轮权重矩阵 $W_{L*1}' = [w(X_1') \ w(X_2') \ \dots \ w(X_L')]^T$,其中, $w(X_1')$ 与所述本轮优化前场景集 $\{X_1'\}$ 中的测试场景 X_1' 一一对应;其中, P_{N*1} 代表 $\{X_n\}$ 对应的自然概率分布矩阵, $P_{N*1} = [p(X_1) \ p(X_2) \ \dots \ p(X_N)]^T, p(X_n)$ 与 X_n 一一对应,代表在所述测试场景 X_n 中的发生兴趣事件的自然概率;

在代理库中获取 K 个自动驾驶的代理模型 m_k ,对每一个代理模型 m_k 执行以下步骤:获取与 X_1' 一一对应的发生所述兴趣事件的概率 $p(X_1')$,根据公式 $\tilde{\mu}_{m_k}^1 = \sum_1^L p_k(X_l') w(X_l')$ 计算该代理模型对应的本轮测试指标估计值 $\tilde{\mu}_{m_k}^1$;其中, $k=1, 2, \dots, K, p_k(X_1')$ 代表该代理模型 m_k 在 X_1' 中发生所述兴趣事件的概率;

根据优化目标函数 $E' = \max_{k=1, \dots, K} |\tilde{\mu}_{m_k}^1 - \mu_{m_k}|$ 计算本轮最大误差 E' ;其中, μ_{m_k} 与所述代理模型 m_k 一一对应,代表所述代理模型 m_k 对应的测试指标真值;

根据 E' 和 $\{X_1'\}$,采用所述预定优化策略在 $\{X_n\}$ 内对每一个 X_1' 进行优化搜索,获取与 X_1' 一一对应的本轮优化后场景 X_1'' ,基于 L 个 X_1'' 生成所述本轮优化后场景集 $\{X_1''\}$;

根据所述本轮优化后场景集 $\{X_1''\}$ 与所述本轮优化前场景集 $\{X_1'\}$ 计算所述本轮曼哈顿距离 Y ;

对比所述本轮曼哈顿距离 Y 和第二预设阈值 Y_g , 当 $Y < Y_g$, 将所述本轮优化后场景集 $\{X_1''\}$ 作为所述典型测试场景集 $\{X_i^*\}$, 将所述本轮权重矩阵 $W_{L*1}' = [w(X_1') \ w(X_2') \ \dots \ w(X_L')]^T$ 作为典型权重矩阵 $W_{L*1}^* = [w(X_1^*) \ w(X_2^*) \ \dots \ w(X_L^*)]^T$; 当 $Y \geq Y_g$, 将所述本轮优化后场景集 $\{X_1''\}$ 作为下一轮迭代的所述本轮优化前场景集 $\{X_1'\}$ 。

8. 如权利要求7所述的典型场景获取方法, 其特征在于: 所述根据所述本轮优化后场景集 $\{X_1''\}$ 与所述本轮优化前场景集 $\{X_1'\}$ 计算所述本轮曼哈顿距离 Y , 包括:

获取所述本轮优化后场景集 $\{X_1''\}$ 中 L 个 X_1'' 各自对应的 T 个状态分量 a_{1t}'' ;

获取所述本轮优化前场景集 $\{X_1'\}$ 中 L 个 X_1' 各自对应的 T 个状态分量 a_{1t}' ;

根据公式 $Y = \sum_{l=1}^L \sum_{t=1}^T |a_{lt}'' - a_{lt}'|$ 计算所述本轮曼哈顿距离 Y 。

9. 一种典型场景测试方法, 其特征在于, 所述测试方法基于如权利要求6-8中任一项所述的典型测试场景集 $\{X_i^*\}$ 和典型权重矩阵 $W_{L*1}^* = [w(X_1^*) \ w(X_2^*) \ \dots \ w(X_L^*)]^T$ 执行, 包括:

将待测自动驾驶模型与所述典型测试场景集 $\{X_i^*\}$ 中的 L 个典型测试场景 X_i^* 分别进行交互, 获得交互测试结果 $Q_{1*L} = [q(X_1^*) \ q(X_2^*) \ \dots \ q(X_L^*)]$, 其中, $q(X_i^*)$ 代表所述待测自动驾驶模型在所述典型测试场景 X_i^* 中发生兴趣事件的概率;

根据公式 $\mu = Q_{1*L} * W_{L*1}^* = \sum_{i=1}^L q(X_i^*) \ w(X_i^*)$ 获得所述待测自动驾驶模型发生所述兴趣事件的总概率 μ 。

10. 一种典型场景测试平台, 其特征在于, 包括: 处理器和存储器;

所述存储器, 用于保存典型场景测试程序;

所述处理器, 用于读取所述典型场景测试程序, 并进行如权利要求9所述的典型场景测试方法。

场景相似度网络训练、典型场景获取、测试方法和平台

技术领域

[0001] 本文涉及自动驾驶测试领域,尤指一种场景相似度网络训练、典型场景获取、测试方法和平台。

背景技术

[0002] 近年来,自动驾驶技术取得了显著进展,在正式投入使用前需要进行自动驾驶测试,目前可以采用的测试方法有两种,一种是开放道路测试,该方法基于蒙特卡洛测试理论,但由于现实世界中低风险场景极多,难以准确评估自动驾驶在高危情境下的表现,导致测试效率极低,需要数十亿英里的测试才能准确评估自动驾驶算法在致命事故中的表现,难以实现实际应用,与此同时,真实道路上的测试也可能对社会造成安全隐患;另一种是计算机仿真测试,采用自动驾驶测试场景库对自动驾驶模型进行测试,该方法采用的场景库基于专家经验或特定模型的场景生成方法而构建,在测试时通常使用特殊设计的标准进行评估,难以得出具有一般性的测试结果,难以真实量化自动驾驶安全性,且在测试次数极少,而大规模的场景测试导致测试周期长、测试效率低下、成本偏高;另外,目前的自动驾驶研发迭代周期短,算法更新迅速,难以保证每一种自动驾驶算法的大规模测试,在测试预算限制严格的情况下的测试结果完全不可靠。

发明内容

[0003] 本申请实施例提供了一种场景相似度网络训练、典型场景获取、测试方法和平台,提出了面向少样本测试问题的场景相似度网络,缓解了仿真测试中少样本测试下的显著不确定性问题,提高了少样本测试的可靠性,测试效率高,能够满足测试预算严格限制的情况。

[0004] 第一方面,本申请实施例提供了一种场景相似度网络训练方法,包括:

[0005] 获取自动驾驶模型的测试场景全集 $\{X_n\}$,以及预先构建的基于注意力机制的初始场景相似度网络,其中, $\{X_n\}$ 包括 N 个测试场景 $X_n, n=1, 2, \dots, N$;

[0006] 在 $\{X_n\}$ 中获取少样本测试场景集 $\{X_1\}$ 作为训练数据,生成 $\{X_1\}$ 和 $\{X_n\}$ 的相似度矩阵,并基于所述相似度矩阵对所述初始场景相似度网络进行训练,构建 L 个测试场景与 N 个测试场景之间的场景相似度网络,其中, $\{X_1\}$ 包括 L 个测试场景 $X_1, 1=1, 2, \dots, L, 2 \leq L < N$ 。

[0007] 第二方面,本申请实施例提供了一种典型场景获取方法,所述获取方法基于如上述实施例所训练好的场景相似度网络执行,包括:

[0008] 在自动驾驶模型的测试场景全集 $\{X_n\}$ 中进行随机采样,获取 L 个测试场景生成待优化少样本测试场景集 $\{X_l^0\}$,其中, $\{X_n\}$ 包括 N 个测试场景 $X_n, n=1, 2, \dots, N$, $\{X_l^0\}$ 包括 L 个测试场景 $X_l^0, 1=1, 2, \dots, L, 2 \leq L < N$;

[0009] 基于所述场景相似度网络,对所述待优化少样本测试场景集 $\{X_l^0\}$ 采用预定优化策略在自动驾驶模型的测试场景全集 $\{X_n\}$ 中进行多轮迭代优化,获取典型测试场景集 $\{X_l^*\}$,并

基于 $\{X_i^*\}$ 获取典型权重矩阵 $W_{L*1}^* = [w(X_1^*) \ w(X_2^*) \ \dots \ w(X_L^*)]^T$,其中, $\{X_i^*\}$ 包括L个典型测试场景 X_i^* , $w(X_i^*)$ 与 X_i^* 一一对应,所述预定优化策略包括梯度下降策略、遗传算法策略、粒子群算法策略或深度学习策略。

[0010] 第三方面,本申请实施例提供了一种典型场景测试方法,所述测试方法基于如上述实施例所述的典型测试场景集 $\{X_i^*\}$ 和典型权重矩阵 $W_{L*1}^* = [w(X_1^*) \ w(X_2^*) \ \dots \ w(X_L^*)]^T$ 执行,包括:

[0011] 将待测自动驾驶模型与所述典型测试场景集 $\{X_i^*\}$ 中的L个典型测试场景 X_i^* 分别进行交互,获得交互测试结果 $Q_{1*L} = [q(X_1^*) \ q(X_2^*) \ \dots \ q(X_L^*)]$,其中, $q(X_i^*)$ 代表所述待测自动驾驶模型在所述典型测试场景 X_i^* 中发生兴趣事件的概率;

[0012] 根据公式 $\mu = Q_{1*L} * W_{L*1}^* = \sum_1^L q(X_i^*) \ w(X_i^*)$ 获得所述待测自动驾驶模型发生所述兴趣事件的总概率 μ 。

[0013] 第四方面,本申请实施例还提供了一种典型场景测试平台,包括处理器和存储器;

[0014] 所述存储器,用于保存典型场景测试程序;

[0015] 所述处理器,用于读取所述典型场景测试程序,并进行如上述实施例所述的典型场景测试方法。

[0016] 与相关技术相比,本申请实施例的一种场景相似度网络训练、典型场景获取、测试方法和平台,提出了面向少样本测试问题的场景相似度网络,通过基于注意力机制的深度学习方法进行场景相似度学习,构建了自动驾驶仿真测试的少样本测试场景和测试场景全集的相似度网络,最大化利用了少样本测试场景代表的局部信息和测试场景全集代表的全局信息的相似性,缓解了仿真测试中少样本测试下的显著不确定性问题,提高了少样本测试的可靠性,测试效率高,成本低廉,能够满足测试预算严格限制的情况。

[0017] 本申请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,或者通过实施本申请而了解。本申请的其他优点可通过在说明书以及附图中所描述的方案来实现和获得。

附图说明

[0018] 附图用来提供对本申请技术方案的理解,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。

[0019] 图1为本申请实施例的一种场景相似度网络训练方法流程图;

[0020] 图2为本申请实施例的一种典型场景获取方法流程图;

[0021] 图3为本申请实施例的一种典型场景测试方法流程图;

[0022] 图4为本申请实施例的一种典型场景测试平台示意图。

具体实施方式

[0023] 本申请描述了多个实施例,但是该描述是示例性的,而不是限制性的,并且对于本领域的普通技术人员来说显而易见的是,在本申请所描述的实施例包含的范围内可以有更多的实施例和实现方案。尽管在附图中示出了许多可能的特征组合,并在具体实施方式中

进行了讨论,但是所公开的特征的许多其它组合方式也是可能的。除非特意加以限制的情况以外,任何实施例的任何特征或元件可以与任何其它实施例中的任何其他特征或元件结合使用,或可以替代任何其它实施例中的任何其他特征或元件。

[0024] 本申请包括并设想了与本领域普通技术人员已知的特征和元件的组合。本申请已经公开的实施例、特征和元件也可以与任何常规特征或元件组合,以形成独特的发明方案。任何实施例的任何特征或元件也可以与来自其它发明方案的特征或元件组合,以形成另一个独特的发明方案。因此,应当理解,在本申请中示出和/或讨论的任何特征可以单独地或以任何适当的组合来实现。因此,除了根据所附权利要求及其等同替换所做的限制以外,实施例不受其它限制。此外,可以在所附权利要求的保护范围内进行各种修改和改变。

[0025] 此外,在描述具有代表性的实施例时,说明书可能已经将方法和/或过程呈现为特定的步骤序列。然而,在该方法或过程不依赖于本文所述步骤的特定顺序的程度上,该方法或过程不应限于所述的特定顺序的步骤。如本领域普通技术人员将理解的,其它的步骤顺序也是可能的。因此,说明书中阐述的步骤的特定顺序不应被解释为对权利要求的限制。此外,针对该方法和/或过程的权利要求不应限于按照所写顺序执行它们的步骤,本领域技术人员可以容易地理解,这些顺序可以变化,并且仍然保持在本申请实施例的精神和范围内。

[0026] 自动驾驶技术近年来取得了显著进展,特别是在感知、决策和执行等方面,然而,尽管技术进步迅速,安全性仍然是一个亟待解决的关键问题,自动驾驶系统面临的道路环境极为复杂,包括天气变化、道路条件、行人行为等各种不可预测的因素。为了确保自动驾驶汽车在各种情况下的安全运行,系统必须经过大量的测试和验证;现有的开放道路测试方法和计算机仿真测试方法均不能满足目前自动驾驶研发迭代周期短、算法更新迅速、需要进行大量自动驾驶测试的需求。

[0027] 本申请实施例提供了一种场景相似度网络训练方法,包括步骤S1000-S2000,如图1所示:

[0028] S1000:获取自动驾驶模型的测试场景全集 $\{X_n\}$,以及预先构建的基于注意力机制的初始场景相似度网络,其中, $\{X_n\}$ 包括N个测试场景 $X_n, n=1, 2, \dots, N$;

[0029] S2000:在 $\{X_n\}$ 中获取少样本测试场景集 $\{X_1\}$ 作为训练数据,生成 $\{X_1\}$ 和 $\{X_n\}$ 的相似度矩阵,并基于所述相似度矩阵对所述初始场景相似度网络进行训练,构建L个测试场景与N个测试场景之间的场景相似度网络,其中, $\{X_1\}$ 包括L个测试场景 $X_1, 1=1, 2, \dots, L, 2 \leq L < N$ 。

[0030] 本实施例中,测试场景全集 $\{X_n\}$ 可以是某一种场景类型下的N个场景,场景类型比如十字路口、高速公路、学校周边、乡村道路、雨雪天气道路等;比如在十字路口场景类型下包括N个场景 X_n ,每一个场景 X_n 均包括若干个状态分量,状态分量可以用于表示背景车辆的数量、每一个背景车辆对应的起始位置、起始时间、行驶路线、行驶速度,行人的数量,周边建筑物的位置等,上述场景类型和状态分量均为示例性描述,不作为本申请的限制,不再一一赘述。

[0031] 本实施例中,对所述初始场景相似度网络进行深度学习训练可以包括多次迭代,每一次迭代时均从测试场景全集 $\{X_n\}$ 中采样,获取少样本测试场景集 $\{X_1\}$ 作为本次训练的训练数据,并且,每一次获取的训练数据 $\{X_1\}$ 均为测试场景全集 $\{X_n\}$ 的子集。

[0032] 本实施例中,N为测试场景全集 $\{X_n\}$ 中的总测试场景数,L为每一次迭代训练时采

用的测试场景数,通过步骤S2000构建了L个测试场景和N个测试场景之间的场景相似度网络,即少样本测试场景和测试场景全集之间的场景相似度网络,将自动驾驶模型在L个测试场景中的测试结果称为少样本测试结果,将自动驾驶模型在N个测试场景中的测试结果称为全局测试结果,该场景相似度网络能够衡量少样本测试结果对全局测试结果的贡献,从而为高效、准确的少样本测试奠定基础。

[0033] 本实施例的场景相似度网络训练方法,提出了面向少样本测试问题的场景相似度网络,通过基于注意力机制的深度学习方法进行场景相似度学习,实现了场景信息的提取与全局优化,构建了自动驾驶仿真测试的少样本测试场景和测试场景全集的相似度网络,最大化利用了少样本测试场景代表的局部信息和测试场景全集代表的全局信息的相似性,缓解了仿真测试中少样本测试下的显著不确定性问题,提高了少样本测试的可靠性,测试效率高,成本低廉,能够满足测试预算严格限制的情况。

[0034] 一种示例性实施例中,在执行步骤S2000之前,可以包括步骤S1100-S1200:

[0035] S1100:获取 $\{X_n\}$ 对应的自然概率分布矩阵 $P_{N \times 1} = [p(X_1) p(X_2) \cdots p(X_N)]^T$, 其中, $p(X_n)$ 与 X_n 一一对应,代表在所述测试场景 X_n 中的发生兴趣事件的自然概率;

[0036] S1200:在代理库中获取K个自动驾驶的代理模型 m_k ,所述代理库包括与所述代理模型 m_k 一一对应的测试指标真值 μ_{m_k} ,以及每一个所述代理模型 m_k 在每一个所述测试场景 X_n 中发生所述兴趣事件的概率 $p_k(X_n)$, 其中, $k=1, 2, \cdots, K$ 。

[0037] 本实施例中,自然概率分布矩阵 $P_{N \times 1}$ 为预先获取的统计数据,包括N个元素 $p(X_n)$, 分别为 $p(X_1)$ 、 $p(X_2)$ 、 \cdots 、 $p(X_N)$, 依次对应于测试场景全集 $\{X_n\}$ 中的测试场景 X_1 、 X_2 、 \cdots 、 X_N 。

[0038] 本实施例中,发生兴趣事件可以包括发生碰撞事故、两车间距小于预设距离、发生车道偏离、发生交通信号违规事件、发生超速驾驶、发生传感器故障、发生通信故障等,上述兴趣事件均为示例性描述,不作为本申请的限制,不再一一赘述。

[0039] 本实施例中,所述代理模型为代理库中保存的自动驾驶模型,代理库中包括若干个代理模型,且代理库中保存有与每一个代理模型对应的测试指标真值 μ_{m_k} , μ_{m_k} 代表该代理模型在测试场景全集 $\{X_n\}$ 中发生兴趣事件的概率,代理库中还保存有每一个代理模型分别在每一个所述测试场景 X_n 中发生所述兴趣事件的概率 $p_k(X_n)$, 在执行步骤S1200时,获取K个自动驾驶的代理模型 m_k 以及每一个 m_k 对应的 μ_{m_k} 和N个 $p_k(X_n)$ 。

[0040] 一种示例性实施例中,步骤S2000可以包括:循环执行步骤S2100-S2600进行训练,直到达到预先设置的训练结束条件,其中,所述初始场景相似度网络为第一次训练的当前场景相似度网络:

[0041] S2100:在 $\{X_n\}$ 中采样,获取L个测试场景,作为本次训练的少样本测试场景集 $\{X_l\}$;

[0042] S2200:将 $\{X_n\}$ 和 $\{X_l\}$ 输入所述当前场景相似度网络,生成当前场景相似度矩阵 $S_{L \times N}$;

[0043] S2300:根据公式 $W_{L \times 1} = S_{L \times N} * P_{N \times 1}$ 计算当前权重矩阵 $W_{L \times 1} = [w(X_1) w(X_2) \cdots w(X_L)]^T$, 其中, $w(X_l)$ 与 $\{X_l\}$ 中的测试场景 X_l 一一对应;

[0044] S2400:对每一个所述代理模型 m_k 执行以下步骤:根据公式 $\tilde{\mu}_{m_k} = \sum_1^L p_k(X_l) w(X_l)$ 计算该代理模型对应的当前测试指标估计值 $\tilde{\mu}_{m_k}$;

[0045] S2500:根据损失函数 $E = \max_{k=1, \dots, K} |\tilde{\mu}_{m_k} - \mu_{m_k}|$ 计算所述当前损失值E;

[0046] S2600:根据所述当前损失值E判断是否达到所述预先设置的训练结束条件,如果是,将所述当前场景相似度网络作为训练好的所述场景相似度网络;如果否,更新所述当前场景相似度网络的参数,进行下一次训练。

[0047] 本实施例中,每一次训练包括步骤S2100-S2600,所述少样本测试场景集 $\{X_1\}$ 为自动驾驶模型的测试场景全集 $\{X_n\}$ 的子集,每一次训练时,均需执行步骤S2100进行重新采样,获取本次训练的L个测试场景,以提高场景相似度网络的泛化能力,减少过拟合现象,增强场景相似度网络的鲁棒性和可靠性。

[0048] 本实施例中,在步骤S2200中,当前场景相似度矩阵 $S_{L \times N}$ 为L行N列的矩阵,其中, $l=1, 2, \dots, L, n=1, 2, \dots, N$, 位于 $S_{L \times N}$ 中第l行第n列的矩阵代表少样本测试场景集 $\{X_1\}$ 中第l个测试场景和测试场景全集 $\{X_n\}$ 中第n个测试场景的相似度。

[0049] 本实施例中,在步骤S2300中,公式 $W_{L \times 1} = S_{L \times N} * P_{N \times 1}$ 中的 $P_{N \times 1}$ 即在步骤S1100中获取的 $P_{N \times 1}$, $P_{N \times 1}$ 为N行1列的矩阵,通过该公式计算后获得的当前权重矩阵 $W_{L \times 1}$ 为L行1列的矩阵,当前权重矩阵 $W_{L \times 1}$ 包括L个元素 $w(X_1)$, 分别对应于少样本测试场景集 $\{X_1\}$ 中的测试场景 X_1 。

[0050] 本实施例中,在每一个训练中,步骤S2400需执行K次,即对步骤S1200中获取到的K个自动驾驶的代理模型 m_k 分别执行一次步骤S2400,获得与 m_k 一一对应的当前测试指标估计值 $\tilde{\mu}_{m_k}$ 。

[0051] 本实施例的一种实施方式中,所述预先设置的训练结束条件,可以在执行步骤S2600时,对比所述当前损失值E和第一预设阈值 E_g , 当 $E < E_g$, 将所述当前场景相似度网络作为训练好的所述场景相似度网络;当 $E \geq E_g$, 更新所述当前场景相似度网络的参数,进行下一次训练。

[0052] 本实施例的另一种实施方式中,所述预先设置的训练结束条件,可以在执行步骤S2600时,计算本次训练的当前损失值E与上一次训练计算的损失值之差,当该差值在预设范围内时,将所述当前场景相似度网络作为训练好的所述场景相似度网络;当该差值不在预设范围内时,更新所述当前场景相似度网络的参数,进行下一次训练。

[0053] 一种示例性实施例中,步骤S2100中的“在 $\{X_n\}$ 中采样,获取L个测试场景”可以包括步骤S2110:

[0054] S2110:在 $\{X_n\}$ 的所述N个测试场景 X_n 中,采用随机采样方法、基于聚类的分类采样方法、或者拟蒙特卡洛采样方法进行采样,获取所述L个测试场景。

[0055] 一种示例性实施例中,步骤S2200可以包括步骤S2210-S2230:

[0056] S2210:将 $\{X_n\}$ 中的每一个测试场景 X_n 和 $\{X_1\}$ 中的每一个测试场景 X_1 输入所述当前场景相似度网络进行特征映射,获得与 X_n 一一对应的查询向量 Q_n 和与 X_1 一一对应的键向量 K_1 ;

[0057] S2220:采用预先设置的相似度函数d对N个所述查询向量 Q_n 和L个所述键向量 K_1 进行相似度计算,获得相似度矩阵 $D_{L \times N}$, 其中,位于 $D_{L \times N}$ 中第l行第n列的元素代表第l个键向量和第n个的查询向量的相似度 d_{ln} ;

[0058] S2230:基于预先设置的激活函数softmax对所述相似度矩阵 $D_{L \times N}$ 的每一列分别进行归一化处理,获得所述当前场景相似度矩阵 $S_{L \times N}$ 。

[0059] 本实施例中,在执行步骤S2210时获得N个查询向量 Q_n 和L个键向量 K_l ;在步骤S2220中,可以采用欧式距离的倒数、 $d=Q_n K_l^T$ 或者 $d=\cos(Q_n, K_l)$ 作为相似度函数d。

[0060] 本实施例中,在执行步骤S2230时,采用激活函数softmax沿列方向对 $D_{L \times N}$ 进行归一化处理获得当前场景相似度矩阵 $S_{L \times N}$,即在 $S_{L \times N}$ 中,每一列的L个元素之和均为1。

[0061] 本申请实施例还提供了一种典型场景获取方法,所述获取方法基于上述实施例所训练好的场景相似度网络执行,包括步骤S3000-S4000,如图2所示:

[0062] S3000:在自动驾驶模型的测试场景全集 $\{X_n\}$ 中进行随机采样,获取L个测试场景生成待优化少样本测试场景集 $\{X_l^0\}$,其中, $\{X_n\}$ 包括N个测试场景 $X_n, n=1, 2, \dots, N, \{X_l^0\}$ 包括L个测试场景 $X_l^0, l=1, 2, \dots, L, 2 \leq L < N$;

[0063] S4000:基于所述场景相似度网络,对所述待优化少样本测试场景集 $\{X_l^0\}$ 采用预定优化策略在自动驾驶模型的测试场景全集 $\{X_n\}$ 中进行多轮迭代优化,获取典型测试场景集 $\{X_l^*\}$,并基于 $\{X_l^*\}$ 获取典型权重矩阵 $W_{L \times 1} = [w(X_1^*) \ w(X_2^*) \ \dots \ w(X_L^*)]^T$,其中, $\{X_l^*\}$ 包括L个典型测试场景 X_l^* , $w(X_l^*)$ 与 X_l^* 一一对应,所述预定优化策略包括梯度下降策略、遗传算法策略、粒子群算法策略或深度学习策略。

[0064] 本实施例中,在获取到训练好的场景相似度网络之后,基于该场景相似度网络在测试场景全集 $\{X_n\}$ 中获取典型测试场景,即在N个测试场景中获取L个测试场景作为典型测试场景,典型测试场景集 $\{X_l^*\}$ 为测试场景全集 $\{X_n\}$ 的子集,采用预定优化策略进行多轮迭代优化,完成L个测试场景的目标优化搜索问题。

[0065] 本实施例中,步骤S3000是在测试场景全集 $\{X_n\}$ 中获取待优化少样本测试场景集 $\{X_l^0\}$,其中, $\{X_l^0\}$ 是 $\{X_n\}$ 的子集;步骤S4000是对 $\{X_l^0\}$ 中的每一个测试场景 X_l^0 在测试场景全集 $\{X_n\}$ 进行寻优,获取的典型测试场景集 $\{X_l^*\}$ 也是测试场景全集 $\{X_n\}$ 的子集,通过预定优化策略在 $\{X_n\}$ 中进行寻优搜索,将最终获得的L个典型测试场景 X_l^* 作为典型测试场景集 $\{X_l^*\}$,与海量的N个测试场景相比,筛选出了少量的L个典型场景,为进一步的高效典型场景测试奠定了基础。

[0066] 一种示例性实施例中,步骤S4000可以包括:循环执行步骤S4100-S4700进行所述多轮迭代优化,直到本轮迭代对应的本轮优化后场景集 $\{X_1''\}$ 与本轮优化前场景集 $\{X_1'\}$ 之间的本轮曼哈顿距离Y小于第二预设阈值 Y_g ,其中,第一轮迭代的所述本轮优化前场景集 $\{X_1'\}$ 为所述待优化少样本测试场景集 $\{X_l^0\}$:

[0067] S4100:将所述测试场景全集 $\{X_n\}$ 和所述本轮优化前场景集 $\{X_1'\}$ 输入训练好的所述场景相似度网络,生成本轮场景相似度矩阵 $S_L'_{L \times N}$;

[0068] S4200:根据公式 $W_L'_{L \times 1} = S_L'_{L \times N} * P_{N \times 1}$ 计算本轮权重矩阵 $W_L'_{L \times 1} = [w(X_1') \ w(X_2') \ \dots \ w(X_L')]^T$,其中, $w(X_1')$ 与所述本轮优化前场景集 $\{X_1'\}$ 中的测试场景 X_1' 一一对应;其中, $P_{N \times 1}$ 代表 $\{X_n\}$ 对应的自然概率分布矩阵, $P_{N \times 1} = [p(X_1) \ p(X_2) \ \dots \ p(X_N)]^T$, $p(X_n)$ 与 X_n 一一对应,代表在所述测试场景 X_n 中的发生兴趣事件的自然概率;

[0069] S4300:在代理库中获取K个自动驾驶的代理模型 m_k ,对每一个代理模型 m_k 执行以下步骤:获取与 X_1' 一一对应的发生所述兴趣事件的概率 $p(X_1')$,根据公式

$\tilde{\mu}_{m_k}^1 = \sum_{i=1}^L p_k(X_i') w(X_i')$ 计算该代理模型对应的本轮测试指标估计值 $\tilde{\mu}_{m_k}^1$; 其中, $k=1, 2, \dots, K$, $p_k(X_i')$ 代表该代理模型 m_k 在 X_i' 中发生所述兴趣事件的概率;

[0070] S4400: 根据优化目标函数 $E' = \max_{k=1, \dots, K} |\tilde{\mu}_{m_k}^1 - \mu_{m_k}|$ 计算本轮最大误差 E' ; 其中, μ_{m_k} 与
所述代理模型 m_k 一一对应, 代表所述代理模型 m_k 对应的测试指标真值;

[0071] S4500: 根据 E' 和 $\{X_i'\}$, 采用所述预定优化策略在 $\{X_n\}$ 内对每一个 X_i' 进行优化搜索, 获取与 X_i' 一一对应的本轮优化后场景 X_i'' , 基于 L 个 X_i'' 生成所述本轮优化后场景集 $\{X_i''\}$;

[0072] S4600: 根据所述本轮优化后场景集 $\{X_i''\}$ 与所述本轮优化前场景集 $\{X_i'\}$ 计算所述本轮曼哈顿距离 Y ;

[0073] S4700: 对比所述本轮曼哈顿距离 Y 和第二预设阈值 Y_g , 当 $Y < Y_g$, 将所述本轮优化后场景集 $\{X_i''\}$ 作为所述典型测试场景集 $\{X_i^*\}$, 将所述本轮权重矩阵 $W_{L \times 1} = [w(X_1') w(X_2') \dots w(X_L')]^T$ 作为典型权重矩阵 $W_{L \times 1}^* = [w(X_1^*) w(X_2^*) \dots w(X_L^*)]^T$; 当 $Y \geq Y_g$, 将所述本轮优化后场景集 $\{X_i''\}$ 作为下一轮迭代的所述本轮优化前场景集 $\{X_i'\}$ 。

[0074] 本实施例中, 在执行步骤 S4100 时, 可以采用与上述步骤 S2210-S2230 相似的方法生成本轮场景相似度矩阵 $S_{L \times N}$, 将测试场景全集 $\{X_n\}$ 中的每一个测试场景 X_n 和本轮优化前场景集 $\{X_i'\}$ 中的每一个测试场景 X_i' 输入所述训练好的场景相似度网络进行特征映射, 获得与 X_n 一一对应的查询向量 Q_n 和与 X_i' 一一对应的键向量 K_i' ; 采用预先设置的相似度函数 d 对 N 个所述查询向量 Q_n 和 L 个键向量 K_i' 进行相似度计算, 获得相似度矩阵 $D_{L \times N}$, 其中, 位于 $D_{L \times N}$ 中第 l 行第 n 列的元素代表第 l 个键向量 K_l' 和第 n 个的查询向量 Q_n 的相似度 d_{ln} ; 基于预先设置的激活函数 softmax 对所述相似度矩阵 $D_{L \times N}$ 的每一列分别进行归一化处理, 获得本轮场景相似度矩阵 $S_{L \times N}$ 。

[0075] 本实施例中, 步骤 S4200 中的自然概率分布矩阵 $P_{N \times 1}$ 与步骤 S1100 中的自然概率分布矩阵 $P_{N \times 1} = [p(X_1) p(X_2) \dots p(X_N)]^T$ 相同; 步骤 S4300 中的 K 个自动驾驶的代理模型 m_k 与步骤 S1200 中的在代理库中获取 K 个自动驾驶的代理模型 m_k 相同。

[0076] 本实施例中, 在执行步骤 S4400 和 S4500 之后, 所获得的所述本轮优化后场景集 $\{X_i''\}$ 也是测试场景全集 $\{X_n\}$ 的子集, 按照预定优化策略进行优化搜索后获得的本轮优化后场景 X_i'' 与其对应的本轮优化前场景 X_i' 相比, 更具有代表性, 而且在兴趣事件发生概率不同的各区域中, 测试场景分布更加均匀, 从而使最终获取的典型测试场景在兴趣事件发生的不同概率范围内均有分布, 每一个典型测试场景能够代表与其相似的其他场景, 并能够在自动驾驶测试时赋予这些典型测试场景更大的权重, 将典型测试场景应用于自动驾驶测试时能够在提高测试效率的同时使测试误差最小化。

[0077] 本实施例中, 典型权重矩阵 $W_{L \times 1}^*$ 虽然仅包括 L 个元素 $w(X_i^*)$, $w(X_i^*)$ 与典型测试场景集 $\{X_i^*\}$ 中的典型测试场景 X_i^* 一一对应, 但 $W_{L \times 1}^*$ 蕴含着测试场景全集 $\{X_n\}$ 的信息, 可以最大化利用 $\{X_n\}$ 中各个场景的信息, 减少了仅基于典型测试场景进行测试的巨大不确定性。

[0078] 一种示例性实施例中, 步骤 S4600 可以包括步骤 S4610-S4630:

[0079] S4610: 获取所述本轮优化后场景集 $\{X_i''\}$ 中 L 个 X_i'' 各自对应的 T 个状态分量 a_{1t}'' ;

[0080] S4620: 获取所述本轮优化前场景集 $\{X_i'\}$ 中 L 个 X_i' 各自对应的 T 个状态分量 a_{1t}' ;

[0081] S4630:根据公式 $Y = \sum_{l=1}^L \sum_{t=1}^T |a''_{lt} - a'_{lt}|$ 计算所述本轮曼哈顿距离Y。

[0082] 本申请实施例还提供了一种典型场景测试方法,所述测试方法基于如上述实施例所述的典型测试场景集 $\{X_l^*\}$ 和典型权重矩阵 $W_{L*1} = [w(X_1^*) \ w(X_2^*) \ \dots \ w(X_L^*)]^T$ 执行,包括步骤S5000-S6000,如图3所示:

[0083] S5000:将待测自动驾驶模型与所述典型测试场景集 $\{X_l^*\}$ 中的L个典型测试场景 X_l^* 分别进行交互,获得交互测试结果 $Q_{1*L} = [q(X_1^*) \ q(X_2^*) \ \dots \ q(X_L^*)]$,其中, $q(X_l^*)$ 代表所述待测自动驾驶模型在所述典型测试场景 X_l^* 中发生兴趣事件的概率;

[0084] S6000:根据公式 $\mu = Q_{1*L} * W_{L*1} = \sum_{l=1}^L q(X_l^*) \ w(X_l^*)$ 获得所述待测自动驾驶模型发生所述兴趣事件的总概率 μ 。

[0085] 本实施例中,对于一个待测自动驾驶模型,仅需在L个典型测试场景 X_l^* 进行交互测试,即仅需进行步骤S5000的L次测试和步骤S6000的一次矩阵乘法计算,即可获得所述待测自动驾驶模型发生所述兴趣事件的总概率 μ ,无需在测试场景全集 $\{X_n\}$ 执行N次交互测试,极大提高了测试效率,减少了测试成本,同时由于典型权重矩阵 W_{L*1}^* 包含了测试场景全集 $\{X_n\}$ 的信息,获得的所述待测自动驾驶模型发生所述兴趣事件的总概率 μ 能够代表该待测自动驾驶模型在测试场景全集 $\{X_n\}$ 中发生兴趣事件的概率,测试可靠性高。

[0086] 本实施例的典型场景测试方法解决了传统的基于少量测试场景进行测试的不确定性,提高了自动驾驶模型在少量测试场景下进行测试的可靠性,典型权重矩阵包含了测试场景全集的全局信息,测试稳定性强、测试效率大大提升,成本低廉。

[0087] 本申请实施例还提供了一种典型场景测试平台,包括处理器和存储器,如图4所示;

[0088] 所述存储器,用于保存典型场景测试程序;

[0089] 所述处理器,用于读取所述典型场景测试程序,并进行如上述实施例所述的典型场景测试方法。

[0090] 为了说明本申请实施例的场景相似度网络训练方法、典型场景获取方法和典型场景测试方法,下面用具体示例一来详细描述,该具体示例包括步骤S1-S6:

[0091] S1:获取自动驾驶模型的测试场景全集 $\{X_n\}$,以及预先构建的基于注意力机制的初始场景相似度网络,其中, $\{X_n\}$ 包括N个测试场景 X_n , $n=1,2,\dots,N$;

[0092] S2:在 $\{X_n\}$ 中获取少样本测试场景集 $\{X_1\}$ 作为训练数据,生成 $\{X_1\}$ 和 $\{X_n\}$ 的相似度矩阵,并基于所述相似度矩阵对所述初始场景相似度网络进行训练,构建L个测试场景与N个测试场景之间的场景相似度网络,其中, $\{X_1\}$ 包括L个测试场景 X_1 , $1=1,2,\dots,L,2 \leq L < N$;

[0093] S3:在自动驾驶模型的测试场景全集 $\{X_n\}$ 中进行随机采样,获取L个测试场景生成待优化少样本测试场景集 $\{X_l^0\}$,其中, $\{X_l^0\}$ 包括L个测试场景 X_l^0 , $1=1,2,\dots,L,2 \leq L < N$;

[0094] S4:基于步骤S2训练好的场景相似度网络,对所述待优化少样本测试场景集 $\{X_l^0\}$ 采用预定优化策略在自动驾驶模型的测试场景全集 $\{X_n\}$ 中进行多轮迭代优化,获取典型测试场景集 $\{X_l^*\}$,并基于 $\{X_l^*\}$ 获取典型权重矩阵 $W_{L*1}^* = [w(X_1^*) \ w(X_2^*) \ \dots \ w(X_L^*)]^T$,其中, $\{X_l^*\}$ 包括L个典型测试场景 X_l^* , $w(X_l^*)$ 与 X_l^* 一一对应;

[0095] S5:将待测自动驾驶模型与所述典型测试场景集 $\{X_i^*\}$ 中的L个典型测试场景 X_i^* 分别进行交互,获得交互测试结果 $Q_{1*L} = [q(X_1^*) \ q(X_2^*) \ \dots \ q(X_L^*)]$,其中, $q(X_i^*)$ 代表所述待测自动驾驶模型在所述典型测试场景 X_i^* 中发生兴趣事件的概率;

[0096] S6:根据公式 $\mu = Q_{1*L} * W_{L*1} = \sum_1^L q(X_i^*) \ w(X_i^*)$ 获得所述待测自动驾驶模型发生所述兴趣事件的总概率 μ 。

[0097] 具体示例一中S1和S2是训练场景相似度网络的步骤,S3和S4是利用训练好的场景相似度网络获取典型测试场景集 $\{X_i^*\}$ 的步骤,S5和S6是采用典型测试场景集 $\{X_i^*\}$ 对待测自动驾驶模型进行测试的步骤,在获取到典型测试场景集 $\{X_i^*\}$ 之后,对每一个待测自动驾驶模型仅执行步骤S5和S6即可完成测试,在测试时,将待测自动驾驶模型在L个典型测试场景 X_i^* 中分别进行交互即可,与待测自动驾驶模型在测试场景全集 $\{X_n\}$ 中进行N次交互相比,大大提高了测试效率,缩短了测试时间,减少了测试成本。

[0098] 为了说明本申请实施例的典型场景测试方法的效果,下面用具体示例二来详细描述。

[0099] 本具体示例对三个待测自动驾驶测试模型AV1、AV2、AV3分别采用三种方法进行测试,方法一为蒙特卡洛方法,方法二为基于均匀采样的随机拟蒙特卡洛方法,方法三为本申请实施例的典型场景测试方法,在三种方法测试时,均在测试场景全集中取样,选取测试场景子集作为典型测试场景进行测试,包括在 $N = 1000 \sim 10000$ 个测试场景中选取10个典型测试场景(即 $L = 10$)和选取20个典型测试场景(即 $L = 20$)两种方案,对测试效果的评估采用“测试误差”和“99%置信度误差”,如表1所示:

[0100] 表1三种测试方法的效果对比表

待测自动驾驶测试模型	测试方法	测试误差 ($\times 10^{-3}$)		99%置信度误差 ($\times 10^{-3}$)	
		L=10	L=20	L=10	L=20
AV1	方法一	5.77	5.60	97.0	47.0
	方法二	2.88	1.75	14.5	6.19
	方法三	0.61	0.37	1.06	0.93
AV2	方法一	2.80	2.76	98.6	48.6
	方法二	1.42	0.88	6.90	5.66
	方法三	0.38	0.20	0.83	0.74
AV3	方法一	1.32	1.31	0.66	49.3
	方法二	0.77	0.50	4.33	1.83
	方法三	0.20	0.15	0.40	0.28

[0102] 由表1可知,采用本申请实施例的典型场景测试方法,即采用方法三对自动驾驶测

试模型AV1、AV2、AV3进行测试,无论采用10个典型测试场景,还是采用20个典型测试场景进行测试,“测试误差”和“99%置信度误差”均显著低于方法一和方法二,测试可靠性高,效果良好。

[0103] 本领域普通技术人员可以理解,上文中所公开方法中的全部或某些步骤、系统、装置中的功能模块/单元可以被实施为软件、固件、硬件及其适当的组合。在硬件实施方式中,在以上描述中提及的功能模块/单元之间的划分不一定对应于物理组件的划分;例如,一个物理组件可以具有多个功能,或者一个功能或步骤可以由若干物理组件合作执行。某些组件或所有组件可以被实施为由处理器,如数字信号处理器或微处理器执行的软件,或者被实施为硬件,或者被实施为集成电路,如专用集成电路。这样的软件可以分布在计算机可读介质上,计算机可读介质可以包括计算机存储介质(或非暂时性介质)和通信介质(或暂时性介质)。如本领域普通技术人员公知的,术语“计算机存储介质”包括在用于存储信息(诸如计算机可读指令、数据结构、程序模块或其他数据)的任何方法或技术中实施的易失性和非易失性、可移除和不可移除介质。计算机存储介质包括但不限于RAM、ROM、EEPROM、闪存或其他存储器技术、CD-ROM、数字多功能盘(DVD)或其他光盘存储、磁盒、磁带、磁盘存储或其他磁存储装置、或者可以用于存储期望的信息并且可以被计算机访问的任何其他的介质。此外,本领域普通技术人员公知的是,通信介质通常包含计算机可读指令、数据结构、程序模块或者诸如载波或其他传输机制之类的调制数据信号中的其他数据,并且可包括任何信息递送介质。

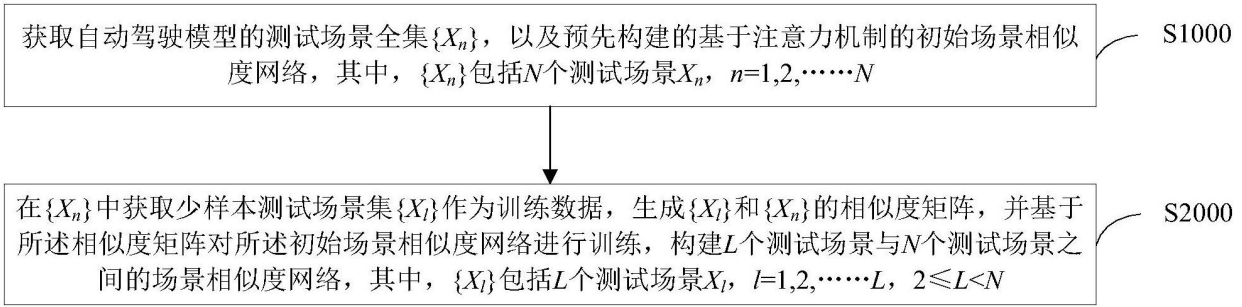


图1

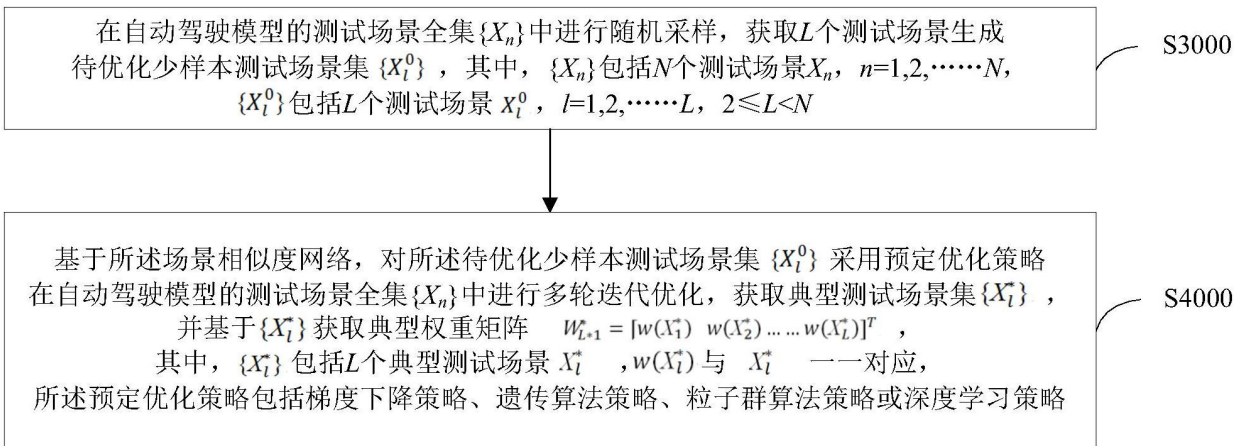


图2

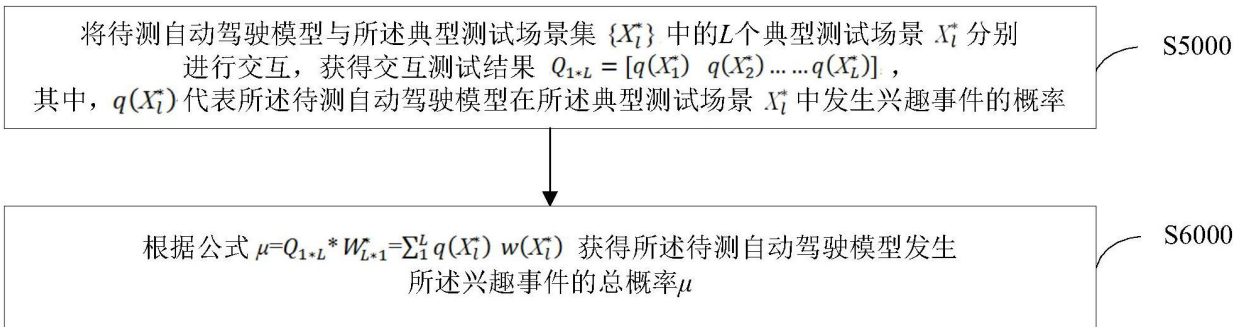


图3




图4