



(12) 发明专利申请

(10) 申请公布号 CN 118245763 A

(43) 申请公布日 2024. 06. 25

(21) 申请号 202410382456.2

(22) 申请日 2024.03.29

(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 杨敬轩 张毅 白若瑄

何泓霖 李述 张佐 陆秋婧

(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 栗若木

(51) Int. Cl.

G06F 18/21 (2023.01)

G06F 18/2415 (2023.01)

权利要求书1页 说明书6页 附图2页

(54) 发明名称

一种表格型密集强化学习方法、计算机存储介质及终端

(57) 摘要

本申请公开一种表格型密集强化学习方法、计算机存储介质及终端,包括:从关键状态集合中均匀采样初始状态,使得初始状态均为关键状态;根据学习率、时序差分误差及关键状态集合的示性函数,对未达到最优的兴趣事件的发生概率 $Q(s, a)$ 进行更新学习。本公开实施例从关键状态集合中均匀采样初始状态,基于包含关键状态集合的示性函数实现兴趣事件的发生概率 $Q(s, a)$ 的更新学习,使得训练数据包含的关键状态信息密集化,减少了计算量、节省了计算资源,提升了未达到最优的兴趣事件的发生概率 $Q(s, a)$ 的学习效率。

从关键状态集合中均匀采样初始状态,使得初始状态均为关键状态

根据学习率、时序差分误差及均匀采样后的关键状态集合的示性函数,对未达到最优的兴趣事件的发生概率 $Q(s, a)$ 进行更新学习

1. 一种表格型密集强化学习方法,其特征在于,包括:

从关键状态集合中均匀采样初始状态,使得初始状态均为关键状态;

根据学习率、时序差分误差及均匀采样后的关键状态集合的示性函数,对未达到最优的兴趣事件的发生概率 $Q(s, a)$ 进行更新学习。

2. 根据权利要求1所述的表格型密集强化学习方法,其特征在于,所述对初始化的未达到最优的兴趣事件的发生概率 $Q(s, a)$ 进行更新学习之前,所述表格型密集强化学习方法还包括:

初始化所述未达到最优的兴趣事件的发生概率 $Q(s, a)$,使得 $Q(s, a) = 0, \forall s \in \mathcal{S}, a \in \mathcal{A}$,其中, \mathcal{S} 表示离散状态空间, \mathcal{A} 表示离散动作空间。

3. 根据权利要求1所述的表格型密集强化学习方法,其特征在于,所述根据学习率、时序差分误差及关键状态集合的示性函数,对未达到最优的兴趣事件的发生概率 $Q(s, a)$ 进行更新学习,包括基于以下表达式进行更新学习:

$$Q(s, a) \leftarrow Q(s, a) + \alpha \delta \mathbb{I}_{\mathcal{S}_c}(s);$$

其中, α 为所述学习率, δ 为所述时序差分误差, \mathcal{S}_c 表示所述关键状态集合, $\mathbb{I}_{\mathcal{S}_c}(s)$ 为所述关键状态集合的示性函数。

4. 根据权利要求1所述的表格型密集强化学习方法,其特征在于,所述表格型密集强化学习方法还包括:

所述更新学习的时长 t 小于预先设定的最大时长 T 时,以相同的概率探索离散动作空间中的每个动作,以确定用于更新学习的动作,及搜索每一个动作后对应的观测到的状态及基于奖励函数获得的对应于该动作的奖励;

其中,所述离散动作空间为马尔可夫决策过程中的参数。

5. 根据权利要求4所述的表格型密集强化学习方法,其特征在于,所述马尔可夫决策过程为 $\mathcal{M} = \{\mathcal{S}, \mathcal{A}, R, P, \gamma\}$;

其中, R 表示奖励函数, $\gamma \in (0, 1)$ 表示折扣因子, P 表示状态转移概率。

6. 根据权利要求1至5任一项所述的表格型密集强化学习方法,其特征在于,所述兴趣事件包括:自动驾驶汽车的事事件。

7. 根据权利要求6所述的表格型密集强化学习方法,其特征在于,所述兴趣事件为自动驾驶汽车的事事件时,所述兴趣事件的发生概率 $Q(s, a)$ 为自动驾驶汽车的事率。

8. 一种计算机存储介质,所述计算机存储介质中存储有计算机程序,所述计算机程序被处理器执行时实现如权利要求1至7中任一项所述的表格型密集强化学习方法。

9. 一种终端,包括:存储器和处理器,所述存储器中保存有计算机程序;其中,处理器被配置为执行存储器中的计算机程序;

所述计算机程序被所述处理器执行时实现如权利要求1至7中任一项所述的表格型密集强化学习方法。

一种表格型密集强化学习方法、计算机存储介质及终端

技术领域

[0001] 本申请涉及但不限于自动驾驶技术,其中涉及一种表格型密集强化学习方法、计算机存储介质及终端。

背景技术

[0002] 当前自动驾驶汽车面临严峻的安全问题,一些前沿的汽车车辆运营公司研发的自动驾驶汽车均遭遇了严重的交通事故,这些安全问题阻碍了自动驾驶汽车的规模化应用和商业化落地,因此亟需对自动驾驶汽车进行安全性测试评估。

[0003] 在对自动驾驶汽车进行安全性测试评估的过程中,准确预测安全关键场景的事故率至关重要;然而,自然驾驶环境中安全关键场景的罕见性导致奖励函数(发生事故奖励为1,其他情况奖励为0)极端稀疏,相关技术中自动驾驶安全性指标大多只能粗略估计安全关键场景的事故率不同,安全关键场景事故率属于兴趣事件的发生概率,因此,如何提升未达到最优的兴趣事件的发生概率的学习效率,成为一个有待解决的问题。

发明内容

[0004] 以下是对本申请详细描述的主题的概述。本概述并非是为了限制权利要求的保护范围。

[0005] 本公开实施例提供一种表格型密集强化学习方法、计算机存储介质及终端,能够提升了未达到最优的兴趣事件的发生概率的学习效率。

[0006] 本公开实施例提供了一种表格型密集强化学习方法,包括:

[0007] 从关键状态集合中均匀采样初始状态,使得初始状态均为关键状态;

[0008] 根据学习率、时序差分误差及均匀采样后的关键状态集合的示性函数,对未达到最优的兴趣事件的发生概率 $Q(s, a)$ 进行更新学习。

[0009] 另一方面,本公开实施例还提供一种计算机存储介质,所述计算机存储介质中存储有计算机程序,所述计算机程序被处理器执行时实现上述表格型密集强化学习方法。

[0010] 再一方面,本公开实施例还提供一种终端,包括:存储器和处理器,所述存储器中保存有计算机程序;其中,

[0011] 处理器被配置为执行存储器中的计算机程序;

[0012] 所述计算机程序被所述处理器执行时实现如上述表格型密集强化学习方法。

[0013] 与相关技术相比,本申请包括:从关键状态集合中均匀采样初始状态,使得初始状态均为关键状态;根据学习率、时序差分误差及均匀采样后的关键状态集合的示性函数,对未达到最优的兴趣事件的发生概率 $Q(s, a)$ 进行更新学习。本公开实施例从关键状态集合均匀采样初始状态,基于包含关键状态集合的示性函数实现兴趣事件的发生概率 $Q(s, a)$ 的更新学习,使得训练数据包含的关键状态信息密集化,减少了计算量、节省了计算资源,提升了未达到最优的兴趣事件的发生概率 $Q(s, a)$ 的学习效率。

[0014] 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

[0015] 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。

[0016] 图1为本公开实施例表格型密集强化学习方法的流程图;

[0017] 图2为本公开实施例超车场景的示意图;

[0018] 图3为本公开实施例一自动驾驶汽车的事故率的学习结果对比图;

[0019] 图4为本公开实施例另一自动驾驶汽车的事故率的学习结果对比图。

具体实施方式

[0020] 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。

[0021] 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,以形成由权利要求限定的独特的发明方案。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,以形成另一个由权利要求限定的独特的发明方案。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。

[0022] 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。

[0023] 对自动驾驶汽车进行安全性测试评估的过程中,准确预测安全关键场景的事故率的问题,属于最终输出的兴趣事件的发生概率问题,本公开实施例记最终输出的兴趣事件的发生概率为 $Q^*(s, a) = \mathbb{P}_p(F | s, a)$,其中,F表示兴趣事件,可以是自动驾驶汽车与周围背景车辆发生碰撞事故的事件,p表示测试场景X的状态转移概率,a为动作变量(驾驶环境中背景汽车的加速度等信息),s为状态变量(驾驶环境中全部车辆的位置、速度等信息), $\mathbb{P}_p(F | s, a)$ 表示兴趣事件为自动驾驶汽车与周围背景车辆发生碰撞事故时,最终输出的发生自动驾驶汽车与周围背景车辆发生碰撞事故的概率。

[0024] 本公开实施例将最终输出的兴趣事件的发生概率 $Q^*(s, a)$ 的预测建模为强化学习问题,包括:

[0025] 1、记马尔可夫决策过程为 $\mathcal{M} = \{\mathcal{S}, \mathcal{A}, R, P, \gamma\}$,其中, \mathcal{S} 表示离散状态空间(包含自动驾驶汽车与周围背景车辆的位置、速度等参数), \mathcal{A} 表示离散动作空间(周围背景的加速度与方向盘角度等参数), R 表示奖励函数,奖励函数包含内容为:发生兴趣事件(例如事故)奖励为1,其他情况奖励为0, $\gamma \in (0, 1)$ 表示折扣因子,折扣因子是可调整的超参数,可根据训练效果调整;

[0026] 2、将最终输出的兴趣事件的发生概率 $Q^*(s, a)$ 表示为状态价值函数 $Q^*(s, a) = \mathbb{E}_p \left[\sum_{\tau=t+1}^T \gamma^{\tau-t-1} R_\tau \mid s, a \right]$,进而使用强化学习方法学习最终输出的兴趣事件的发生概率 $Q^*(s, a)$,其中, t 为 (s, a) 的时刻, T 为最大时长,如公式所写 τ 是中间变量,取值为 $t+1, \dots, T$ 。然而,当最终输出的兴趣事件的发生概率,当兴趣事件发生概率较低时(如 10^{-5})时,学习最终输出的兴趣事件的发生概率 $Q^*(s, a)$,成为一个有待解决的问题。

[0027] 图1为本公开实施例表格型密集强化学习方法的流程图,如图1所示,包括:

[0028] 步骤101、从关键状态集合 \mathcal{S}_c 中均匀采样初始状态,使得初始状态均为关键状态;本公开实施例中的关键状态集合 \mathcal{S}_c 可以通过相关技术获取的包含全部关键状态的集合,关键状态集合可通过代理模型进行搜索获得,具体方法可参见Feng, S., Yan, X., Sun, H., Feng, Y. and Liu, H.X. 基于自然对抗驾驶环境的自动驾驶汽车智能性测试,自然·通信(Intelligent driving intelligence test for autonomous vehicles with naturalistic and adversarial environment. Nature Communications), 12, 748 (2021)。初始状态即测试场景的初始状态,包括自动驾驶汽车和周围背景车辆的位置、速度等参数;关键状态一般指容易发生事故的危险状态;

[0029] 步骤102、根据学习率、时序差分误差及均匀采样后的关键状态集合的示性函数,对初始化的未达到最优的兴趣事件的发生概率 $Q(s, a)$ 进行更新学习。

[0030] 本公开实施例均匀采样初始状态获得关键状态集合,基于包含关键状态集合的示性函数实现兴趣事件的发生概率 $Q(s, a)$ 的更新学习,使得训练数据包含的关键状态信息密集化,减少了计算量、节省了计算资源,提升了未达到最优的兴趣事件的发生概率 $Q(s, a)$ 的学习效率。

[0031] 在一种示例性实例中,本公开实施例通过对未达到最优的兴趣事件的发生概率 $Q(s, a)$ 进行更新学习,参照相关技术确定未达到最优的兴趣事件的发生概率的收敛条件后(例如,更新学习过程中最近1000个时序差分误差的绝对值的和小于0.01),可以获得最优的兴趣事件的发生概率 $Q^*(s, a)$,也即最终输出的兴趣事件的发生概率 $Q^*(s, a)$ 。

[0032] 在一种示例性实例中,本公开实施例步骤102之前,还包括:

[0033] 初始化未达到最优的兴趣事件的发生概率 $Q(s, a) = 0, \forall s \in \mathcal{S}, a \in \mathcal{A}$,其中, \mathcal{S} 表示离散状态空间, \mathcal{A} 表示离散动作空间。

[0034] 在一种示例性实例中,本公开实施例根据学习率、时序差分误差及关键状态的示性函数,对未达到最优的兴趣事件的发生概率进行更新学习,包括基于以下表达式进行更新学习:

[0035] $Q(s, a) \leftarrow Q(s, a) + \alpha \delta \mathbb{I}_{S_c}(s)$;

[0036] 其中, α 为学习率, δ 为时序差分误差, $\mathbb{I}_{S_c}(s)$ 为关键状态集合的示性函数。

[0037] 本公开实施例通过上述更新学习的表达式编辑马尔可夫链, 删除非关键状态并连接剩余的关键状态, 将奖励函数 R 回传到编辑后的马尔可夫链上, 通过奖励函数对马尔可夫链上各动作对应的奖励值进行更新, 实现了未达到最优的兴趣事件的发生概率 $Q(s, a)$ 的更新学习; 这里, 本公开实施例将状态空间减去关键状态即为上述非关键状态。

[0038] 需要说明的是, 本公开实施例上述学习率和时序差分误差, 为本领域技术人员公知的兴趣事件的发生概率的已有参数; 其中, 学习率为可调整的超参数, 例如取 0.0001; 时序差分误差可选择相关技术中的 Q-learning、Sarsa、Expected Sarsa 等公知算法; 关键状态集合的示性函数: 当状态属于关键状态时, 示性函数等于 1, 否则示性函数等于 0。

[0039] 在一种示例性实例中, 本公开实施例方法还包括:

[0040] 更新学习的时长 t 小于预先设定的最大时长 T 时, 以相同的概率探索离散动作空间 \mathcal{A} 中的每个动作, 以确定用于更新学习的动作, 及搜索每一个动作后对应的观测到的状态及基于奖励函数获得的对应于该动作的奖励;

[0041] 本公开实施例以相同的概率探索离散动作空间 \mathcal{A} 中的每个动作, 通过使用均匀的行为策略进行搜索, 获得用于更新学习的动作、动作后对应观测到的状态及对应于动作的奖励, 提升了训练数据中关键状态的信息密集化。

[0042] 本公开实施例假设最终输出的兴趣事件的发生概率, 为自动驾驶汽车的面向安全关键场景的事故率, 则表格型密集强化学习方法, 包括:

[0043] 步骤 201、输入状态转移概率 p 、最大时长 T 、离散状态空间 \mathcal{S} 、动作空间 \mathcal{A} 和关键状态集合 \mathcal{S}_c ;

[0044] 步骤 202、初始化未达到最优的事故率 $Q(s, a) = 0, \forall s \in \mathcal{S}, a \in \mathcal{A}$;

[0045] 步骤 203、当参照相关技术判断时序差分误差未收敛时, 执行以下处理:

[0046] 步骤 2031、从集合 \mathcal{S}_c 中均匀采样初始状态 s ;

[0047] 步骤 2032、令 $r \leftarrow 0, t \leftarrow 0$;

[0048] 步骤 2033、当 $r = 0$ 且 $t < T$ 时, 执行步骤 20331 ~ 20335 的处理:

[0049] 步骤 20331、令 $t \leftarrow t + 1$;

[0050] 步骤 20332 从离散动作空间 \mathcal{A} 中均匀采样动作 a ;

[0051] 步骤 20333 执行采样动作 a , 并观测下一个状态 s' 与奖励 r (若发生碰撞事故奖励为 1, 否则奖励为 0);

[0052] 步骤 20334 使用更新学习的表达式 $Q(s, a) \leftarrow Q(s, a) + \alpha \delta \mathbb{I}_{S_c}(s)$ 更新 $Q(s, a)$;

[0053] 步骤 20335 基于观测的下一个状态 s' , 令 $s \leftarrow s'$;

[0054] 步骤 2034、输出 $Q(s, a)$ 。

[0055] 本公开实施例通过 $Q(s, a)$ 的更新学习, 参照相关技术达到预设的收敛条件后, 最终输出的兴趣事件的发生概率 $Q^*(s, a)$ 。

[0056] 本公开实施例表格型密集强化学习方法, 可以应用于高维测试环境中, 并针对多种类型的被测自动驾驶汽车生成定制化的测试策略, 从而提高测试评估的效率, 减少测评

所需测试成本。

[0057] 本公开实施例还提供一种计算机存储介质,计算机存储介质中存储有计算机程序,计算机程序被处理器执行时实现上述表格型密集强化学习方法。

[0058] 本公开实施例还提供一种终端,包括:存储器和处理器,存储器中保存有计算机程序;

[0059] 其中,

[0060] 处理器被配置为执行存储器中的计算机程序;

[0061] 计算机程序被处理器执行时实现如上述表格型密集强化学习方法。

[0062] 以下通过应用示例对本公开实施例进行简要说明,应用示例仅用于陈述本公开实施例,并不用于限定本公开实施例的保护范围。

[0063] 应用示例

[0064] 本公开实施例当兴趣事件的发生概率为自动驾驶汽车发生事故的的概率,即自动驾驶汽车发生事故的的概率(本文后续简称为事故率)时, F 表示自动驾驶汽车与周围背景车辆发生碰撞事故的事件, p 表示测试场景 X 的状态转移概率, a 为驾驶环境中背景汽车的加速度等动作变量, s 为驾驶环境中全部车辆的位置、速度等状态变量。

[0065] 以自动驾驶汽车超车场景为例,图2为本公开实施例超车场景的示意图,如图2所示,将被测自动驾驶汽车记为 AV ,背景车辆记为 BV , BV 的前车记为 LV ;在 AV 超车 BV 与 LV 的过程中,若 BV 也换道超车 LV ,则 BV 可能与 AV 发生碰撞。

[0066] 超车场景的状态定义为 $s = [v_{BV}, R_1, \dot{R}_1, R_2, \dot{R}_2]^T$,其中, v_{BV} 表示 BV 的速度, R_1 表示 LV 与 BV 的相对距离, \dot{R}_1 表示 LV 与 BV 的相对速度, R_2 表示 BV 与 AV 的相对距离, \dot{R}_2 表示 BV 与 AV 的相对速度;超车场景的动作定义为 $a = [a_{LV}, a_{BV}]^T$,其中, a_{LV} 表示 LV 的加速度, a_{BV} 表示 BV 的加速度。

[0067] 为了验证本公开实施例表格型密集强化学习方法的有效性,选择文献(J.W.Ro, P.S.Roop,A.Malik,and P.Ranjitkar在2017年发表的文章标题为“一种建模和模拟人类跟车行为的形式化方法”发表在《IEEE智能交通系统汇刊》第19卷第2期639-648页(J.W.Ro, P.S.Roop,A.Malik,and P.Ranjitkar,“A formal approach for modeling and simulation of human car-following behavior,”IEEE Transactions on Intelligent Transportation Systems,vol.19,no.2,pp.639-648,2017)中的IDM模型作为自动驾驶汽车 AV 的模型,周围车辆 BV 与 LV 遵循文献Feng,S.,Yan,X.,Sun,H.,Feng,Y.and Liu,H.X.基于自然对抗驾驶环境的自动驾驶汽车智能性测试,自然·通信(Intelligent driving intelligence test for autonomous vehicles with naturalistic and adversarial environment.Nature Communications),12,748(2021)的自然驾驶数据的概率分布。自动驾驶汽车 AV 的事故率的学习结果如图3和图4所示;图3和图4的图例中,图3中,曲线3-2表示:初始状态从关键状态集合中采样,动作从自然分布中采样且仅用关键状态进行学习;曲线3-1为本公开实施例方法对应的曲线,表示:初始状态从关键状态集合中采样,动作从动作空间中均匀采样且仅用关键状态进行学习;曲线3-3表示:初始状态从关键状态集合中采样、使用全部状态进行学习且动作从自然分布中采样;曲线3-4表示:初始状态从自然分布中采样、使用全部状态进行学习且动作从动作空间中均匀采样;曲线3-5表示:初始状态从

自然分布中采样、动作从动作空间中均匀采样且仅用关键状态进行学习；曲线3-6表示：初始状态从关键状态集合中采样、使用全部状态进行学习且动作从动作空间中均匀采样；曲线3-7表示：初始状态从自然分布中采样、动作从自然分布中采样且仅用关键状态进行学习；曲线3-8表示：初始状态从自然分布中采样、使用全部状态进行学习且动作从自然分布中采样；图3中纵坐标表示 $Q(s, a)$ 与 $Q^*(s, a)$ 的均方根误差(RMSE, Root Mean Square Error)，横坐标表示训练迭代次数；图4中纵坐标表示平均时序差分误差，横坐标表示训练时间，图4中，曲线4-1表示初始状态从自然分布中采样、动作从自然分布中采样且使用全部状态进行学习；曲线4-2表示，初始状态从关键状态集合中采样、使用全部状态进行学习且动作从自然分布中采样；曲线4-3表示，初始状态从关键状态集合中采样，动作从动作空间中均匀采样且仅用关键状态进行学习。由图3可知，本公开实施例方法可以收敛到 $Q^*(s, a)$ (RMSE趋近于0)，而相关技术中的其他方法收敛速度非常慢或者无法收敛到 $Q^*(s, a)$ ；由图4可知，本公开实施例方法的时序差分误差收敛速度非常快，而相关技术中的其他方法收敛速度非常慢或者不断震荡且无法正确收敛。

[0068] 本公开实施例表格型密集强化学习方法，通过仅对事故率的关键状态的价值函数进行学习，使得训练数据包含的安全关键信息密集化，实现了安全关键场景事故率的有效学习。

[0069] 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

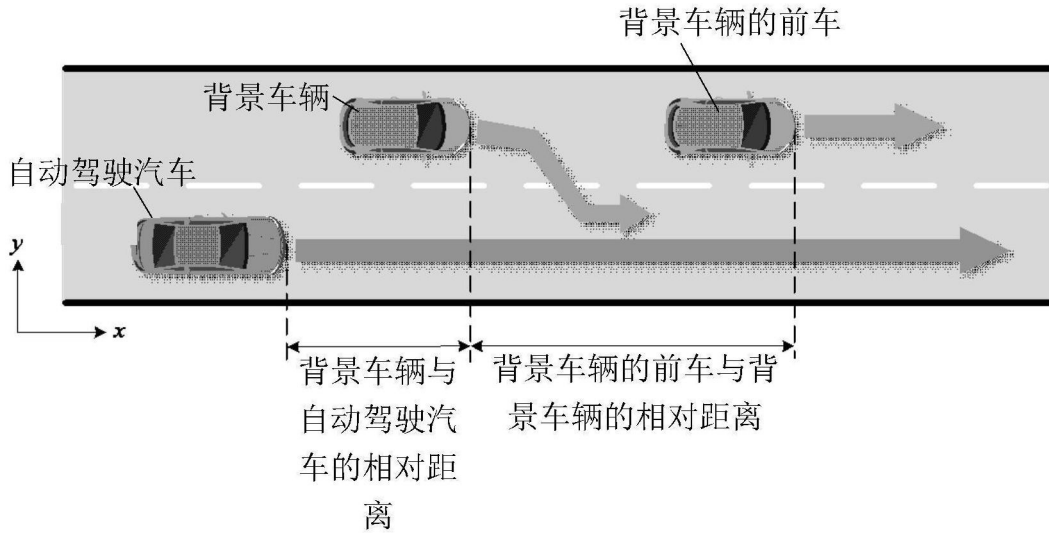


图2




图3




图4