

(19) 国家知识产权局



(12) 发明专利



(10) 授权公告号 CN 116902009 B

(45) 授权公告日 2023. 12. 19

(21) 申请号 202311179915.9

(22) 申请日 2023.09.13

(65) 同一申请的已公布的文献号

申请公布号 CN 116902009 A

(43) 申请公布日 2023.10.20

(73) 专利权人 同济大学

地址 200092 上海市杨浦区四平路1239号

(72) 发明人 黄岩军 杜嘉彤 白玉龙 陈虹

(74) 专利代理机构 北京市诚辉律师事务所

11430

专利代理师 吴敏 耿慧敏

(51) Int.Cl.

B60W 60/00 (2020.01)

B60W 50/00 (2006.01)

G06T 3/00 (2006.01)

G06V 20/56 (2022.01)

G06V 20/64 (2022.01)

G06V 10/82 (2022.01)

G06N 3/045 (2023.01)

G06N 3/044 (2023.01)

G06N 3/0464 (2023.01)

G06N 5/04 (2023.01)

(56) 对比文件

CN 111310574 A, 2020.06.19

CN 112740269 A, 2021.04.30

CN 113420368 A, 2021.09.21

CN 115240150 A, 2022.10.25

CN 116309062 A, 2023.06.23

Mingjun Li 等. Shared Control Driver Assistance System Based on Driving Intention and Situation Assessment. IEEE TRANSACTIONS ON INDUSTRIAL INFORMATICS. 14 (11), 第4982-4994页.

审查员 丁培丽


权利要求书3页 说明书9页 附图2页

(54) 发明名称

基于类脑神经回路的驾驶世界模型

(57) 摘要

本申请涉及车辆控制技术领域,特别涉及一种基于类脑神经回路的驾驶世界模型,包括:感知模块、环境记忆模块、类脑神经网络网络模块以及卷积网络模块;其中,感知模块用于以单目相机图像为输入图像,对输入图像进行图像编码,获取鸟瞰图视角下的图像特征;感知模块包括依次连接的二维特征编码单元、三维特征编码单元以及加和池化单元;环境记忆模块用于获取当前时刻并记忆环境动力学信息;类脑神经网络网络模块用于建立类脑神经网络;卷积网络模块用于生成环境的鸟瞰图图像。本申请利用单目相机图像作为输入图像,应用世界模型提取并记忆环境动力学信息,并模拟线虫神经系统建立类脑神经网络处理环境动力学信息,完成端到端自动驾驶任务。



1. 一种基于类脑神经回路的驾驶世界模型, 其特征在于, 包括: 感知模块、环境记忆模块、类脑神经网络模块以及卷积网络模块; 其中,

所述感知模块用于以单目相机图像为输入图像, 对所述输入图像进行图像编码, 获取鸟瞰图视角下的图像特征; 所述感知模块包括依次连接的二维特征编码单元、三维特征编码单元以及加和池化单元; 所述二维特征编码单元用于从所述图像特征中提取二维特征; 所述三维特征编码单元用于将所述二维特征投影至三维空间, 得到三维特征, 并预测每个三维特征的深度概率分布; 所述加和池化单元用于根据所述深度概率分布, 采用加和池化的方式将所述三维特征映射至鸟瞰图空间中, 得到鸟瞰图视角下的图像特征; 所述环境记忆模块用于根据所述图像特征和隐藏特征, 通过分别生成后验特征、先验特征, 获取当前时刻的环境动力学信息; 并将所述环境动力学信息输出至所述类脑神经网络模块、所述卷积网络模块; 其中, 所述环境动力学信息包括后验特征和先验特征, 所述隐藏特征为包含历史时刻信息的特征; 所述后验特征通过包含历史时刻信息的隐藏特征、前一时刻的动作以及所述图像特征采样生成; 所述先验特征通过包含历史时刻信息的隐藏特征以及前一时刻的动作采样生成;

所述类脑神经网络模块用于模拟线虫神经网络, 建立类脑神经网络; 并将所述环境动力学信息输入至所述类脑神经网络, 得到自动驾驶的控制输出;

所述卷积网络模块用于将所述环境动力学信息输入至卷积网络, 生成环境的鸟瞰图图像。

2. 根据权利要求1所述的基于类脑神经回路的驾驶世界模型, 其特征在于, 所述环境记忆模块包括后验分布拟合单元、先验分布拟合单元以及训练单元; 其中,

所述后验分布拟合单元用于通过所述图像特征拟合环境动力学后验分布;

所述先验分布拟合单元用于通过隐藏特征拟合环境动力学先验分布;

所述训练单元用于以所述环境动力学后验分布和所述环境动力学先验分布相差最小进行训练, 并基于所述环境动力学后验分布和所述隐藏特征, 得到当前时刻的环境动力学信息, 并利用当前时刻的环境动力学信息生成当前时刻的隐藏特征, 作为下一时刻的隐藏特征。

3. 根据权利要求1所述的基于类脑神经回路的驾驶世界模型, 其特征在于, 假设后验特征和先验特征均符合正态分布, 所述后验特征和所述先验特征的生成过程表示为:

$$\begin{cases} x_k = f_e(o_k) \\ q(s_k) \sim N(\mu_\theta(h_k, a_{k-1}, x_k), \sigma_\theta(h_k, a_{k-1}, x_k)) \\ p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1})) \\ h_{k+1} = f_\phi(h_k, s_k) \end{cases} \quad (1)$$

其中, x_k 表示图像特征; o_k 表示输入图像; s_k 表示后验特征; z_k 表示先验特征; h_k 表示隐藏特征; $x_k = f_e(o_k)$ 表示以 k 时刻的单目相机图像作为输入, 得到图像特征的过程; $q(s_k) \sim N(\mu_\theta(h_k, a_{k-1}, x_k), \sigma_\theta(h_k, a_{k-1}, x_k))$ 表示后验特征的生成过程; $p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1}))$ 表示先验特征的生成过程; a_{k-1} 表示前一时刻的动作; $h_{k+1} = f_\phi(h_k, s_k)$ 表示下一时刻的隐藏特征通过循环神经网络编码得到。

4. 根据权利要求1所述的基于类脑神经回路的驾驶世界模型, 其特征在于, 在未来时

刻,先验特征、下一时刻的隐藏特征的生成过程表示为:

$$\begin{cases} p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1})) \\ h_{k+T+1} = f_\phi(h_{k+T}, z_{k+T}) \end{cases} \quad (2)$$

其中, $p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1}))$ 表示在未来时刻先验特征的生成过程; a_{k-1} 表示前一时刻的动作; h_{k+T} 、 z_{k+T} 分别表示未来时刻 $k+T$ 的隐藏特征、先验特征; $h_{k+T+1} = f_\phi(h_{k+T}, z_{k+T})$ 表示在未来时刻 $k+T$, 使用隐藏特征 h_{k+T} 和先验特征 z_{k+T} , 生成下一时刻的隐藏特征的过程。

5. 根据权利要求1所述的基于类脑神经回路的驾驶世界模型, 其特征在于, 所述类脑神经网络网络包括四层神经元; 其中,

所述四层神经元分别为: N_s 个感知神经元、 N_i 个内部神经元, N_c 个指令神经元, N_m 个运动神经元;

在任意两个连续层之间, 对于任意的源神经元, 插入 n_{so-t} 个突触; 其中, n_{so-t} 满足: $n_{so-t} \leq N_t$, 突触极性满足伯努利分布, 其中, N_t 表示目标神经元的个数, n_{so-t} 个目标神经元通过二项分布随机挑选;

在任意两个连续层之间, 任意没有突触的目标神经元 J 插入 m_{so-t} 个突触, m_{so-t} 满足: $m_{so-t} \leq \frac{1}{N_t} \sum_{i=1, i \neq J}^{N_t} L_{ti}$; 其中, L_{ti} 为突触到目标神经元 i 的数量, 突触极性满足伯努利分布, m_{so-t} 个源神经元通过二项分布随机挑选;

指令神经元之间循环连接, 对于任意指令神经元, 插入 l_{so-t} 个突触, 其中, l_{so-t} 满足: $l_{so-t} \leq N_c$, 突触极性满足伯努利分布, 其中, N_c 表示指令神经元的个数, l_{so-t} 个源神经元通过二项分布随机挑选。

6. 根据权利要求5所述的基于类脑神经回路的驾驶世界模型, 其特征在于, 根据神经元突触间传递电流的特征, 建模每个神经元为:

$$\frac{dx(t)}{dt} = -\frac{x(t)}{\tau} + f_I(I(t))(A - x(t)) \quad (3)$$

其中, $x(t)$ 表示神经元突触电流, $I(t)$ 表示突触外界输入, A 为偏差矩阵, f_I 表示神经网络, τ 表示时间常数。

7. 根据权利要求1所述的基于类脑神经回路的驾驶世界模型, 其特征在于, 所述类脑神经网络网络模块包括转换单元;

所述转换单元用于采用类脑神经网络网络将环境动力学信息转换为控制动作信息, 实现感知到控制的转换过程;

使用函数 g 表示类脑神经网络, 所述转换过程通过下式表示:

$$\begin{cases} a_k = g(h_k, s_k), \text{ 历史时刻} \\ a_{k+T} = g(h_{k+T}, z_{k+T}), \text{ 未来时刻} \end{cases} \quad (4)$$

其中, a_k 表示历史时刻的动作; h_k 表示隐藏特征; s_k 表示后验特征; a_{k+T} 表示未来时刻的动作; h_{k+T} 表示未来时刻的隐藏特征; z_{k+T} 表示未来时刻的后验特征。

8. 根据权利要求1所述的基于类脑神经回路的驾驶世界模型, 其特征在于, 采用函数 f_c 表示生成环境的鸟瞰图图像的过程, 如下式所示:

$$\begin{cases} b_k = f_c(h_k, s_k), & \text{历史时刻} \\ b_{k+T} = f_c(h_{k+T}, z_{k+T}), & \text{未来时刻} \end{cases} \quad (5)$$

其中, b_k 表示历史时刻的鸟瞰图图像; h_k 表示历史时刻的隐藏特征; s_k 表示历史时刻的后验特征; b_{k+T} 表示未来时刻的鸟瞰图图像; h_{k+T} 表示未来时刻的隐藏特征; z_{k+T} 表示未来时刻的后验特征。

9. 根据权利要求1所述的基于类脑神经回路的驾驶世界模型, 其特征在于, 所述驾驶世界模型为经过模型训练的世界模型;

所述模型训练的过程, 包括: 将时刻 t_k 至 t_{k+T-1} 的数据作为历史时刻数据, 将时刻 t_{k+T} 至 t_{k+T+F} 的数据作为未来时刻数据, 将 t_k 至 t_{k+T+F} 的数据输入驾驶世界模型进行模型训练, 使得动作序列和鸟瞰图序列出现的联合概率最大, 通过变分推断获得联合概率下限;

通过变分推断获得联合概率下限, 如下式所示:

$$\begin{aligned} & \log(p(a_{k:k+T+F}, b_{k:k+T+F})) \\ & \geq \sum_{t=k}^{t=k+T+F} E[\log p(a_t) + \log p(b_t) - D_{KL}(q(s_k), p(z_k))] \end{aligned} \quad (6)$$

其中, $p(a_{k:k+T+F}, b_{k:k+T+F})$ 表示动作序列和鸟瞰图序列出现的联合概率; D_{KL} 表示两个分布的相对熵; $p(a_t)$ 表示动作序列出现的概率; $p(b_t)$ 表示鸟瞰图序列出现的概率; $q(s_k)$ 表示世界模型中后验概率; $p(z_k)$ 表示世界模型中先验概率。

基于类脑神经回路的驾驶世界模型

技术领域

[0001] 本申请实施例涉及车辆控制技术领域,特别涉及一种基于类脑神经回路的驾驶世界模型。

背景技术

[0002] 如今,人工智能正在从专有人工智能向通用人工智能过渡,以ChatGPT为代表的生成式大模型已经在自然语言处理领域大放异彩,成为了目前主流的自然语言处理通用人工智能模型。自动驾驶是汽车产业与人工智能、自动化控制、大数据等新一代信息技术在交通领域交叉融合的体现,高级别自动驾驶系统需要应对几乎所有的复杂交通环境,并且安全、高效的完成驾驶任务。

[0003] 然而,目前的自动驾驶模型大多使用模块化的方法,该方法需要大量的人工工程,涉及到单个模块的人工标注和跨模块之间的配置,对于新环境新任务需要重新人为设计进行算法升级,迁移性差,不能适应通用人工智能的发展和要求。

发明内容

[0004] 本申请实施例提供一种基于类脑神经回路的驾驶世界模型,该模型利用单目相机图像作为输入,应用世界模型提取并记忆环境动力学信息,并模拟线虫神经系统建立类脑神经回路处理环境动力学信息,完成端到端自动驾驶任务。

[0005] 为解决上述技术问题,本申请实施例提供一种基于类脑神经回路的驾驶世界模型,包括感知模块、环境记忆模块、类脑神经回路网络模块以及卷积网络模块;其中,感知模块用于以单目相机图像为输入图像,对输入图像进行图像编码,获取鸟瞰图视角下的图像特征;感知模块包括依次连接的二维特征编码单元、三维特征编码单元以及加和池化单元;二维特征编码单元用于从图像特征中提取二维特征;三维特征编码单元用于将二维特征投影至三维空间,得到三维特征,并预测每个三维特征的深度概率分布;加和池化单元用于根据深度概率分布,采用加和池化的方式将三维特征映射至鸟瞰图空间中,得到鸟瞰图视角下的图像特征;环境记忆模块用于根据图像特征和隐藏特征,获取当前时刻的环境动力学信息;并将环境动力学信息输出至类脑神经回路网络模块、卷积网络模块;类脑神经回路网络模块用于模拟线虫神经网络,建立类脑神经回路网络;并将环境动力学信息输入至类脑神经回路网络,得到自动驾驶的控制输出;卷积网络模块用于将环境动力学信息输入至卷积网络,生成环境的鸟瞰图图像。

[0006] 在一些示例性实施例中,环境记忆模块包括后验分布拟合单元、先验分布拟合单元以及训练单元;其中,后验分布拟合单元用于通过所述图像特征拟合环境动力学后验分布;先验分布拟合单元用于通过隐藏特征拟合环境动力学先验分布;训练单元用于以所述环境动力学后验分布和所述环境动力学先验分布相差最小进行训练,并基于所述环境动力学后验分布和所述隐藏特征,得到当前时刻的环境动力学信息,并利用当前时刻的环境动力学信息生成当前时刻的隐藏特征,作为下一时刻的隐藏特征。

[0007] 在一些示例性实施例中,环境记忆模块根据图像特征和隐藏特征,通过分别生成后验特征、先验特征,获取当前时刻的环境动力学信息;其中,后验特征通过包含历史时刻信息的隐藏特征、前一时刻的动作以及图像特征采样生成;先验特征通过包含历史时刻信息的隐藏特征以及前一时刻的动作采样生成。

[0008] 在一些示例性实施例中,假设后验特征和先验特征均符合正态分布,其生成过程如下式所示。

$$[0009] \quad \begin{cases} x_k = f_e(o_k) \\ q(s_k) \sim N(\mu_\theta(h_k, a_{k-1}, x_k), \sigma_\theta(h_k, a_{k-1}, x_k)) \\ p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1})) \\ h_{k+1} = f_\phi(h_k, s_k) \end{cases}$$

[0010] 其中, x_k 表示图像特征; o_k 表示输入图像; s_k 表示后验特征; z_k 表示先验特征; h_k 表示隐藏特征; $x_k = f_e(o_k)$ 表示以 k 时刻的图像作为输入,得到图像特征的过程; $q(s_k) \sim N(\mu_\theta(h_k, a_{k-1}, x_k), \sigma_\theta(h_k, a_{k-1}, x_k))$ 表示后验特征的生成过程; $p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1}))$ 表示先验特征的生成过程; a_{k-1} 表示前一时刻的动作; $h_{k+1} = f_\phi(h_k, s_k)$ 表示下一时刻的隐藏特征通过循环神经网络编码得到。

[0011] 在一些示例性实施例中,在未来时刻,先验特征、下一时刻的隐藏特征的生成过程通过下式表示。

$$[0012] \quad \begin{cases} p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1})) \\ h_{k+T+1} = f_\phi(h_{k+T}, z_{k+T}) \end{cases}$$

[0013] 其中, $p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1}))$ 表示在未来时刻先验特征的生成过程; a_{k-1} 表示前一时刻的动作; h_{k+T} 、 z_{k+T} 分别表示未来时刻 $k+T$ 的隐藏特征、先验特征; $h_{k+T+1} = f_\phi(h_{k+T}, z_{k+T})$ 表示在未来时刻 $k+T$, 使用隐藏特征和先验特征,生成下一时刻的隐藏特征的过程。

[0014] 在一些示例性实施例中,类脑神经回路网络包括四层神经元;其中,四层神经元分别为: N_s 个感知神经元、 N_i 个内部神经元, N_c 个指令神经元, N_m 个运动神经元;在任意两个连续层之间,对于任意的源神经元,插入 n_{so-t} 个突触;其中, n_{so-t} 满足: $n_{so-t} \leq N_t$, 突触极性满足伯努利分布,其中, N_t 表示目标神经元的个数, n_{so-t} 个目标神经元通过二项分布随机挑选;在任意两个连续层之间,任意没有突触的目标神经元 j 插入 m_{so-t} 个突触, m_{so-t} 满足: $m_{so-t} \leq \frac{1}{N_t} \sum_{i=1, i \neq j}^{N_t} L_{ti}$; 其中, L_{ti} 为突触到目标神经元 i 的数量, 突触极性满足伯努利分布, m_{so-t} 个源神经元通过二项分布随机挑选;指令神经元之间循环连接,对于任意指令神经元,插入 l_{so-t} 个突触,其中, l_{so-t} 满足: $l_{so-t} \leq N_c$, 突触极性满足伯努利分布,其中, N_c 表示指令神经元的个数, l_{so-t} 个源神经元通过二项分布随机挑选。

[0015] 在一些示例性实施例中,根据神经元突触间传递电流的特征,建模每个神经元,如下式所示。

$$[0016] \quad \frac{dx(t)}{dt} = -\frac{x(t)}{\tau} + f_l(I(t))(A - x(t))$$

[0017] 其中, $x(t)$ 表示神经元突触电流, $I(t)$ 表示突触外界输入, A 为偏差矩阵, f_l 表示神经网络, τ 表示时间常数。

[0018] 在一些示例性实施例中,类脑神经回路网络模块包括转换单元;转换单元用于采用类脑神经回路网络将环境动力学信息转换为控制动作信息,实现感知到控制的转换过程;使用函数 g 表示类脑神经回路网络,所述转换过程通过下式表示。

$$[0019] \quad \begin{cases} a_k = g(h_k, s_k), & \text{历史时刻} \\ a_{k+T} = g(h_{k+T}, z_{k+T}), & \text{未来时刻} \end{cases}$$

[0020] 其中, a_k 表示历史时刻的动作; h_k 表示隐藏特征; s_k 表示后验特征; a_{k+T} 表示未来时刻的动作; h_{k+T} 表示未来时刻的隐藏特征; z_{k+T} 表示未来时刻的后验特征。

[0021] 在一些示例性实施例中,采用函数 f_c 表示生成环境的鸟瞰图图像的过程,如下式所示。

$$[0022] \quad \begin{cases} b_k = f_c(h_k, s_k), & \text{历史时刻} \\ b_{k+T} = f_c(h_{k+T}, z_{k+T}), & \text{未来时刻} \end{cases}$$

[0023] 其中, b_k 表示历史时刻的鸟瞰图图像; h_k 表示历史时刻的隐藏特征; s_k 表示历史时刻的后验特征; b_{k+T} 表示未来时刻的鸟瞰图图像; h_{k+T} 表示未来时刻的隐藏特征; z_{k+T} 表示未来时刻的后验特征。

[0024] 在一些示例性实施例中,上述驾驶世界模型为经过模型训练的世界模型;模型训练的过程,包括:将时刻 t_k 至 t_{k+T-1} 的数据作为历史时刻数据,将时刻 t_{k+T} 至 t_{k+T+F} 的数据作为未来时刻数据,将 t_k 至 t_{k+T+F} 的数据输入驾驶世界模型进行模型训练,使得动作序列和鸟瞰图序列出现的联合概率最大,通过变分推断获得联合概率下限。

[0025] 在一些示例性实施例中,通过变分推断获得联合概率下限,如下式所示。

$$[0026] \quad \begin{aligned} & \log(p(a_{k:k+T+F}, b_{k:k+T+F})) \\ & \geq \sum_{t=k}^{t=k+T+F} E[\log p(a_t) + \log p(b_t) - D_{KL}(q(s_k), p(z_k))] \end{aligned}$$

[0027] 其中, $p(a_{k:k+T+F}, b_{k:k+T+F})$ 表示动作序列和鸟瞰图序列出现的联合概率; D_{KL} 表示两个分布的相对熵; $p(a_t)$ 表示动作序列出现的概率; $p(b_t)$ 表示鸟瞰图序列出现的概率; $q(s_k)$ 表示世界模型中后验概率; $p(z_k)$ 表示世界模型中先验概率。

[0028] 本申请实施例提供的技术方案至少具有以下优点:本申请实施例提供一种基于类脑神经回路的驾驶世界模型,该模型包括:感知模块、环境记忆模块、类脑神经回路网络模块以及卷积网络模块;其中,感知模块用于以单目相机图像为输入图像,对输入图像进行图

像编码,获取鸟瞰图视角下的图像特征;感知模块包括依次连接的二维特征编码单元、三维特征编码单元以及加和池化单元;二维特征编码单元用于从图像特征中提取二维特征;三维特征编码单元用于将二维特征投影至三维空间,得到三维特征,并预测每个三维特征的深度概率分布;加和池化单元用于根据深度概率分布,采用加和池化的方式将三维特征映射至鸟瞰图空间中,得到鸟瞰图视角下的图像特征;环境记忆模块用于根据图像特征和隐藏特征,获取当前时刻的环境动力学信息并记忆当前时刻的环境动力学信息;并将环境动力学信息输出至类脑神经回路网络模块、卷积网络模块;类脑神经回路网络模块用于模拟线虫神经网络,建立类脑神经回路网络;并将环境动力学信息输入至类脑神经回路网络,得到自动驾驶的控制输出;卷积网络模块用于将环境动力学信息输入至卷积网络,生成环境的鸟瞰图图像。

[0029] 本申请提出一种基于类脑神经回路的驾驶世界模型,以单目相机图像作为输入,通过感知模块对输入图像进行编码后得到二维特征;然后将二维特征提升至三维空间,得到三维特征;并预测每个三维特征的深度概率分布,然后采用加和池化的方式将三维特征映射至鸟瞰图空间中,得到鸟瞰图视角下的图像特征。本申请仅使用一个单目相机作为输入图像,即可完成端到端自动驾驶。本申请通过感知模块能够充分提取图像的二维和三维信息,帮助自动驾驶汽车在考虑环境深度信息的鸟瞰图视角下安全运行。此外,本申请还通过模拟线虫神经网络对感知、规划、控制的操作过程,建立类脑神经回路网络,得到自动驾驶的控制输出。同时,基于环境动力学信息生成环境的鸟瞰图图片提高模型的可解释性。该模型利用单目相机图像作为输入,应用世界模型提取并记忆环境动力学信息,并模拟线虫神经系统建立类脑神经回路处理环境动力学信息,完成端到端自动驾驶任务。

附图说明

[0030] 一个或多个实施例通过与之对应的附图中的图片进行示例性说明,这些示例性说明并不构成对实施例的限定,除非有特别申明,附图中的图不构成比例限制。

[0031] 图1为本申请一实施例提供的基于类脑神经回路的驾驶世界模型的结构示意图。

[0032] 图2为本申请一实施例提供的基于类脑神经回路的驾驶世界模型的架构图。

[0033] 图3为本申请一实施例提供的类脑神经回路网络的架构示意图。

[0034] 图4为本申请一实施例提供的鸟瞰图示意图。

具体实施方式

[0035] 由背景技术可知,目前的自动驾驶模型大多使用模块化的方法,该方法需要大量的人工工程,涉及到单个模块的人工标注和跨模块之间的配置,对于新环境新任务需要重新人为设计进行算法升级,迁移性差,不能适应通用人工智能的发展和要求。

[0036] 当前的发展态势表明,生成式人工智能具备为自动驾驶技术带来跃进性转变的潜力。随着几十亿参数量的生成式大模型的涌现能力不断提升,我们可以预见,借助生成式人工智能的强大处理能力和复杂参数结构,能够实现自动驾驶技术路线上的重大突破。

[0037] 为解决上述技术问题,本申请实施例提供一种基于类脑神经回路的驾驶世界模型,该模型包括:感知模块、环境记忆模块、类脑神经回路网络模块以及卷积网络模块;其中,感知模块用于以单目相机图像为输入图像,对输入图像进行图像编码,获取鸟瞰图视角

下的图像特征;感知模块包括依次连接的二维特征编码单元、三维特征编码单元以及加和池化单元;二维特征编码单元用于从图像特征中提取二维特征;三维特征编码单元用于将二维特征投影至三维空间,得到三维特征,并预测每个三维特征的深度概率分布;加和池化单元用于根据深度概率分布,采用加和池化的方式将三维特征映射至鸟瞰图空间中,得到鸟瞰图视角下的图像特征;环境记忆模块用于根据图像特征和隐藏特征,获取当前时刻的环境动力学信息;并将环境动力学信息输出至类脑神经回路网络模块、卷积网络模块;类脑神经回路网络模块用于模拟线虫神经网络,建立类脑神经回路网络;并将环境动力学信息输入至类脑神经回路网络,得到自动驾驶的控制输出;卷积网络模块用于将环境动力学信息输入至卷积网络,生成环境的鸟瞰图图像。本申请利用单目相机图像作为输入,应用世界模型提取并记忆环境动力学信息,通过感知模块能够充分提取图像的二维和三维信息,帮助自动驾驶汽车在考虑环境深度信息的鸟瞰图视角下安全运行;该模型还通过模拟线虫神经系统建立类脑神经回路处理环境动力学信息,完成端到端自动驾驶任务。

[0038] 下面将结合附图对本申请的各实施例进行详细的阐述。然而,本领域的普通技术人员可以理解,在本申请各实施例中,为了使读者更好地理解本申请而提出了许多技术细节。但是,即使没有这些技术细节和基于以下各实施例的种种变化和修改,也可以实现本申请所要求保护的技术方案。

[0039] 参看图1,本申请实施例提供了一种基于类脑神经回路的驾驶世界模型,包括:感知模块101、环境记忆模块102、类脑神经回路网络模块103以及卷积网络模块104;其中,感知模块101用于以单目相机图像为输入图像,对输入图像进行图像编码,获取鸟瞰图视角下的图像特征;感知模块101包括依次连接的二维特征编码单元、三维特征编码单元以及加和池化单元;二维特征编码单元用于从图像特征中提取二维特征;三维特征编码单元用于将二维特征投影至三维空间,得到三维特征,并预测每个三维特征的深度概率分布;加和池化单元用于根据深度概率分布,采用加和池化的方式将三维特征映射至鸟瞰图空间中,得到鸟瞰图视角下的图像特征。

[0040] 本申请使用单目相机图像作为输入,应用世界模型提取并记忆环境动力学信息,通过对世界模型感知部分进行了加强,并模拟线虫神经系统建立类脑神经回路处理环境动力学信息,完成端到端自动驾驶任务;对世界模型感知部分进行加强的过程,包括:以单目相机图像 O_k 作为输入图像,首先通过深度残差网络(Residual Network,简称ResNet)提取周围环境的2D特征并进行图像编码。由于自动驾驶汽车需要感知三维环境,因此,本申请在得到二维特征后,再将二维特征通过相机的内参和外参投影至3D空间中,得到三维特征,并预测每个三维特征的深度概率分布,将采用加和池化的方式对这些三维特征进行加和池化处理,得到鸟瞰图视角下的图像特征。

[0041] 环境记忆模块102用于根据图像特征和隐藏特征,获取当前时刻的环境动力学信息;并将环境动力学信息输出至类脑神经回路网络模块、卷积网络模块。类脑神经回路网络模块103用于模拟线虫神经网络,建立类脑神经回路网络;并将环境动力学信息输入至类脑神经回路网络,得到自动驾驶的控制输出;卷积网络模块104用于将环境动力学信息输入至卷积网络,生成环境的鸟瞰图图像。

[0042] 请继续参看图1,环境记忆模块102包括后验分布拟合单元、先验分布拟合单元以及训练单元;其中,后验分布拟合单元用于通过图像特征拟合环境动力学后验分布;先验分

布拟合单元用于通过隐藏特征拟合环境动力学先验分布；训练单元用于以环境动力学后验分布和环境动力学先验分布相差最小进行训练，并基于环境动力学后验分布和隐藏特征，得到当前时刻的环境动力学信息，并利用当前时刻的环境动力学信息生成当前时刻的隐藏特征，作为下一时刻的隐藏特征。

[0043] 在一些实施例中，环境记忆模块102根据图像特征和隐藏特征，通过分别生成后验特征、先验特征，获取当前时刻的环境动力学信息；其中，后验特征通过包含历史时刻信息的隐藏特征、前一时刻的动作以及图像特征采样生成；先验特征通过包含历史时刻信息的隐藏特征以及前一时刻的动作采样生成。

[0044] 在一些实施例中，假设后验特征和先验特征均符合正态分布，其生成过程如下式所示。

$$[0045] \quad \begin{cases} x_k = f_e(o_k) \\ q(s_k) \sim N(\mu_\theta(h_k, a_{k-1}, x_k), \sigma_\theta(h_k, a_{k-1}, x_k)) \\ p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1})) \\ h_{k+1} = f_\phi(h_k, s_k) \end{cases}$$

[0046] 其中， x_k 表示图像特征； o_k 表示输入图像； s_k 表示后验特征； z_k 表示先验特征； h_k 表示隐藏特征； $x_k = f_e(o_k)$ 表示以k时刻的图像作为输入，得到图像特征的过程； $q(s_k) \sim N(\mu_\theta(h_k, a_{k-1}, x_k), \sigma_\theta(h_k, a_{k-1}, x_k))$ 表示后验特征的生成过程； $p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1}))$ 表示先验特征的生成过程； a_{k-1} 表示前一时刻的动作； $h_{k+1} = f_\phi(h_k, s_k)$ 表示下一时刻的隐藏特征通过循环神经网络编码得到。

[0047] 图2示出了基于类脑神经回路的驾驶世界模型的架构图。

[0048] 如图2所示，以k时刻的图像 o_k 为输入图像，经过感知编码处理，得到图像特征 x_k ，此过程可表示为 $x_k = f_e(o_k)$ 。假设后验特征和先验特征均符合正态分布，通过包含历史时刻信息的隐藏特征，前一时刻的动作 a_{k-1} （横纵向加速度）和图像特征采样生成后验特征 s_k 。通过隐藏特征和前一时刻的动作 a_{k-1} 采样生成先验特征； $p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1}))$ 下一时刻的隐藏特征通过循环神经网络编码得到。具体的，基于隐藏特征和后验特征，通过循环神经网络编码得到下一时刻的隐藏特征。

[0049] 在未来时刻 $k+T$ 驾驶世界模型无法获得图像输入，驾驶世界模型通过想象来获得未来的动作以及鸟瞰图走势。具体的，驾驶世界模型在未来时刻不会生成后验特征，而是直接使用隐藏特征和先验特征生成下一时刻的隐藏特征 h_{k+T+1} 。

[0050] 在一些实施例中，在未来时刻 $k+T$ ，先验特征 z_{k+T} 、下一时刻的隐藏特征 h_{k+T+1} 的生成过程，如下式所示。

$$[0051] \quad \begin{cases} p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1})) \\ h_{k+T+1} = f_\phi(h_{k+T}, z_{k+T}) \end{cases}$$

[0052] 其中, $p(z_k) \sim N(\mu_\varphi(h_k, a_{k-1}), \sigma_\varphi(h_k, a_{k-1}))$ 表示在未来时刻先验特征的生成过程; a_{k-1} 表示前一时刻的动作; h_{k+T} 、 z_{k+T} 分别表示未来时刻 $k+T$ 的隐藏特征、先验特征; $h_{k+T+1} = f_\phi(h_{k+T}, z_{k+T})$ 表示在未来时刻, 使用隐藏特征和先验特征, 生成下一时刻的隐藏特征的过程。

[0053] 本申请通过模仿线虫神经系统, 建立类脑神经回路网络。秀丽隐杆线虫是一种很小的动物, 通过它们近乎完美的神经系统结构完成感知、运动等功能, 而在其神经系统中许多的神经回路都被建模为四层的混合拓扑结构, 本申请模仿其神经回路, 建立类脑神经回路网络架构, 如图3所示。

[0054] 参看图3, 在一些实施例中, 类脑神经回路网络包括四层神经元; 其中, 四层神经元分别为: N_s 个感知神经元、 N_t 个内部神经元、 N_c 个指令神经元、 N_m 个运动神经元; 在任意两个连续层之间, 对于任意的源神经元, 插入 n_{so-t} 个突触; 其中, n_{so-t} 满足: $n_{so-t} \leq N_t$, N_t 表示目标神经元的个数, 突触极性满足伯努利分布, 其中, n_{so-t} 个目标神经元通过二项分布随机挑选; 在任意两个连续层之间, 任意没有突触的目标神经元 j 插入 m_{so-t} 个突触, m_{so-t} 满足: $m_{so-t} \leq \frac{1}{N_t} \sum_{i=1, i \neq j}^{N_t} L_{ti}$; 其中, L_{ti} 为突触到目标神经元 i 的数量, 突触极性满足伯努利分布, m_{so-t} 个源神经元通过二项分布随机挑选; 指令神经元之间循环连接, 对于任意指令神经元, 插入 l_{so-t} 个突触, 其中, l_{so-t} 满足: $l_{so-t} \leq N_c$, 其中, N_c 表示指令神经元的个数, 突触极性满足伯努利分布, l_{so-t} 个源神经元通过二项分布随机挑选。

[0055] 在一些实施例中, 根据神经元突触间传递电流的特征, 建模每个神经元, 如下式所示。

$$[0056] \quad \frac{dx(t)}{dt} = -\frac{x(t)}{\tau} + f_I(I(t))(A - x(t))$$

[0057] 其中, $x(t)$ 表示神经元突触电流, $I(t)$ 表示突触外界输入, A 为偏差矩阵, f_I 表示神经网络, τ 表示时间常数。

[0058] 如上所述, 模拟线虫神经网络, 建立类脑神经回路网络, 将类脑神经回路网络看作是函数 g , 使用类脑神经回路网络将环境动力学信息转换为控制动作信息, 实现感知到控制的转换过程。

[0059] 在一些实施例中, 类脑神经回路网络模块包括转换单元; 转换单元用于采用类脑神经回路网络将环境动力学信息转换为控制动作信息, 实现感知到控制的转换过程; 使用函数 g 表示类脑神经回路网络, 所述转换过程通过下式表示。

$$[0060] \quad \begin{cases} a_k = g(h_k, s_k), & \text{历史时刻} \\ a_{k+T} = g(h_{k+T}, z_{k+T}), & \text{未来时刻} \end{cases}$$

[0061] 其中, a_k 表示历史时刻的动作; h_k 表示隐藏特征; s_k 表示后验特征; a_{k+T} 表示未来时刻的动作; h_{k+T} 表示未来时刻的隐藏特征; z_{k+T} 表示未来时刻的后验特征。

[0062] 通过卷积神经网络使用环境动力学信息生成鸟瞰图图像 b_k , 能够提高端到端方法的可解释性。鸟瞰图示意图如图4所示, 该过程可以看做函数 f_c 。

[0063] 具体的, 在一些实施例中, 采用函数 f_c 表示生成环境的鸟瞰图图像的过程, 如下式所示。

$$[0064] \quad \begin{cases} b_k = f_c(h_k, s_k), & \text{历史时刻} \\ b_{k+T} = f_c(h_{k+T}, z_{k+T}), & \text{未来时刻} \end{cases}$$

[0065] 其中, b_k 表示历史时刻的鸟瞰图图像; h_k 表示历史时刻的隐藏特征; s_k 表示历史时刻的后验特征; b_{k+T} 表示未来时刻的鸟瞰图图像; h_{k+T} 表示未来时刻的隐藏特征; z_{k+T} 表示未来时刻的后验特征。

[0066] 在一些实施例中, 上述驾驶世界模型为经过模型训练的世界模型。

[0067] 模型训练的过程, 包括: 将时刻 t_k 至 t_{k+T-1} 的数据作为历史时刻数据, 将时刻 t_{k+T} 至 t_{k+T+F} 的数据作为未来时刻数据, 将 t_k 至 t_{k+T+F} 的数据输入驾驶世界模型进行模型训练, 使得动作序列和鸟瞰图序列出现的联合概率最大, 通过变分推断获得联合概率下限。

[0068] 在一些实施例中, 通过变分推断获得联合概率下限, 如下式所示。

$$[0069] \quad \begin{aligned} & \log(p(a_{k:k+T+F}, b_{k:k+T+F})) \\ & \geq \sum_{t=k}^{t=k+T+F} E\{\log p(a_t) + \log p(b_t) - D_{KL}(q(s_k), p(z_k))\} \end{aligned}$$

[0070] 其中, $p(a_{k:k+T+F}, b_{k:k+T+F})$ 表示动作序列和鸟瞰图序列出现的联合概率; D_{KL} 表示两个分布的相对熵; $p(a_t)$ 表示动作序列出现的概率; $p(b_t)$ 表示鸟瞰图序列出现的概率; $q(s_k)$ 表示世界模型中后验概率; $p(z_k)$ 表示世界模型中先验概率。

[0071] 由以上技术方案, 本申请实施例提供一种基于类脑神经回路的驾驶世界模型, 该模型包括: 感知模块、环境记忆模块、类脑神经网络模块以及卷积网络模块; 其中, 感知模块用于以单目相机图像为输入图像, 对输入图像进行图像编码, 获取鸟瞰图视角下的图像特征; 感知模块包括依次连接的二维特征编码单元、三维特征编码单元以及加和池化单元; 二维特征编码单元用于从图像特征中提取二维特征; 三维特征编码单元用于将二维特征投影至三维空间, 得到三维特征, 并预测每个三维特征的深度概率分布; 加和池化单元用于根据深度概率分布, 采用加和池化的方式将三维特征映射至鸟瞰图空间中, 得到鸟瞰图视角下的图像特征; 环境记忆模块用于根据图像特征和隐藏特征, 获取当前时刻的环境动力学信息并记忆当前时刻的环境动力学信息; 并将环境动力学信息输出至类脑神经网络模块、卷积网络模块; 类脑神经网络模块用于模拟线虫神经网络, 建立类脑神经网络; 并将环境动力学信息输入至类脑神经网络, 得到自动驾驶的控制输出; 卷积网络模块用于将环境动力学信息输入至卷积网络, 生成环境的鸟瞰图图像。

[0072] 本申请提出一种基于类脑神经回路的驾驶世界模型,以单目相机图像作为输入,通过感知模块对输入图像进行编码后得到二维特征;然后将二维特征提升至三维空间,得到三维特征;并预测每个三维特征的深度概率分布,然后采用加和池化的方式将三维特征映射至鸟瞰图空间中,得到鸟瞰图视角下的图像特征。本申请仅使用一个单目相机作为输入图像,即可完成端到端自动驾驶。本申请通过感知模块能够充分提取图像的二维和三维信息,帮助自动驾驶汽车在考虑环境深度信息的鸟瞰图视角下安全运行。此外,本申请还通过模拟线虫神经网络对感知、规划、控制的操作过程,建立类脑神经回路网络,得到自动驾驶的控制输出。同时,基于环境动力学信息生成环境的鸟瞰图图片提高模型的可解释性。该模型利用单目相机图像作为输入,应用世界模型提取并记忆环境动力学信息,并模拟线虫神经系统建立类脑神经回路处理环境动力学信息,完成端到端自动驾驶任务。

[0073] 本领域的普通技术人员可以理解,上述各实施方式是实现本申请的具体实施例,而在实际应用中,可以在形式上和细节上对其作各种改变,而不偏离本申请的精神和范围。任何本领域技术人员,在不脱离本申请的精神和范围内,均可作各自更动与修改,因此本申请的保护范围应当以权利要求限定的范围为准。




图1




图2




图3




图4