



(21) 申请号 202511204185.2

G06N 3/0464 (2023.01)

(22) 申请日 2025.08.26

B60W 60/00 (2020.01)

(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 王子航

姬浩元 程诗景

(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 张建秀 解婷婷

(51) Int.Cl.

G06F 18/214 (2023.01)

G06F 18/241 (2023.01)

G06V 20/56 (2022.01)

G06V 10/774 (2022.01)

G06N 3/0455 (2023.01)

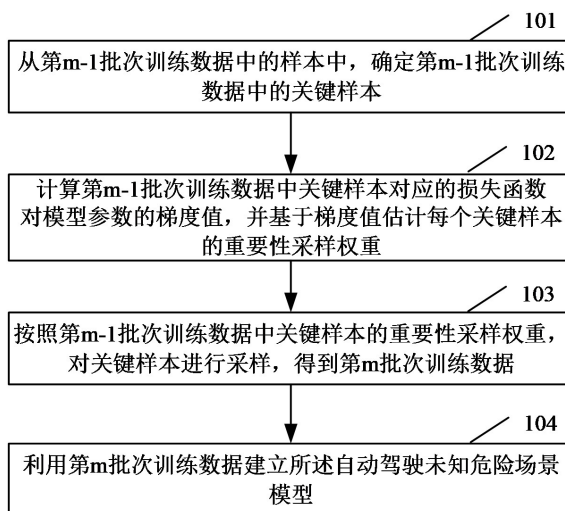
权利要求书2页 说明书11页 附图2页

(54) 发明名称

一种自动驾驶未知危险场景模型的建立和管理方法

(57) 摘要

一种自动驾驶未知危险场景模型的建立和管理方法,其中所述自动驾驶未知危险场景模型用于识别输入数据中汽车在给定的运行状态下的控制动作是否为未知危险场景,所述方法包括:从第 $m-1$ 批次训练数据中的样本中,确定第 $m-1$ 批次训练数据中的关键样本,其中 m 为正整数;计算第 $m-1$ 批次训练数据中关键样本对应的损失函数对模型参数的梯度值,并基于梯度值估计每个关键样本的重要性采样权重;按照第 $m-1$ 批次训练数据中关键样本的重要性采样权重,对关键样本进行采样,得到第 m 批次训练数据;利用第 m 批次训练数据建立所述自动驾驶未知危险场景模型。



1. 一种自动驾驶未知危险场景模型的建立方法, 其中所述自动驾驶未知危险场景模型用于识别输入数据中汽车在给定的运行状态下的控制动作是否为未知危险场景, 所述方法包括:

从第 $m-1$ 批次训练数据中的样本中, 确定第 $m-1$ 批次训练数据中的关键样本, 其中 m 为正整数;

计算第 $m-1$ 批次训练数据中关键样本对应的损失函数对模型参数的梯度值, 并基于梯度值估计每个关键样本的重要性采样权重;

按照第 $m-1$ 批次训练数据中关键样本的重要性采样权重, 对关键样本进行采样, 得到第 m 批次训练数据;

利用第 m 批次训练数据建立所述自动驾驶未知危险场景模型。

2. 根据权利要求1所述的方法, 其特征在于, 所述第 $m-1$ 批次训练数据中的关键样本的确定方式, 包括:

对第 $m-1$ 批次训练数据中的样本, 获取计算损失函数对模型参数的梯度, 得到第 $m-1$ 批次训练数据中每个样本的梯度值;

从第 $m-1$ 批次训练数据中每个样本的梯度值, 确定第 $m-1$ 批次中关键样本的重要性采样权重;

其中, 样本的梯度幅值越大, 样本的重要性越高。

3. 根据权利要求1所述的方法, 其特征在于, 所述第 $m-1$ 批次中每个关键样本的重要性采样权重的计算表达式如下:

$$\hat{q}(x) = \frac{|\nabla_{\theta} L(y, \hat{y})| |I_{x_c}(x) p(x)|}{\sum_{i=1}^n |\nabla_{\theta} L(y_i, \hat{y}_i)| |I_{x_c}(x_i)|}, \quad \forall x \in \{x_1, \dots, x_n\};$$

其中, n 为第 $m-1$ 批次中样本的总数,

$\nabla_{\theta} L(y, \hat{y})$ 表示模型参数 θ 对样本的损失函数 L 的梯度, 其中, $y \in \{0, 1\}$ 为真实类别, $\hat{y} \in [0, 1]$ 为自动驾驶未知危险场景模型输出的概率;

\mathcal{X}_c 为关键样本集合;

$p(x)$ 为原始概率分布;

I_{x_c} 为指示函数, 用于判断样本是否属于关键样本集合。

4. 根据权利要求1所述的方法, 其特征在于, 所述利用第 m 批次训练数据建立所述自动驾驶未知危险场景模型, 包括:

在采用平衡训练模式时, 从正负样本索引集合中分别采样 $N/2$ 个样本;

在采用不平衡训练模式时, 从第 m 批次训练集随机采样 N 个采样; 其中, N 为单次迭代训练中使用的样本数量。

5. 根据权利要求1所述的方法, 其特征在于, 第 m 批次训练数据中每个样本的损失函数为根据每个样本的交叉熵与各自的加权值确定的, 其中:

对于第 m 批次训练数据中当前样本, 交叉熵是自动驾驶未知危险场景模型对当前样本输出的概率与当前样本的真实类别之间的交叉熵; 加权值为原始概率分布与重要性采样的

概率分布之间的比值。

6. 根据权利要求1所述的方法, 其特征在于:

所述自动驾驶未知危险场景模型的表达式为

$$\hat{y} = \sigma(W_4 \cdot \text{ReLU}(W_3 \cdot \text{ReLU}(W_2 \cdot \text{ReLU}(W_1 \cdot X + b_1) + b_2) + b_3) + b_4);$$

其中, \hat{y} 为自动驾驶未知危险场景模型输出的概率, W_1 至 W_4 以及 b_1 至 b_4 均为模型参数, ReLU 为激活函数, σ 为Sigmoid函数, X 表示样本。

7. 根据权利要求1所述的方法, 其特征在于, 所述方法还包括:

在建立自动驾驶未知危险场景模型过程中, 如果 m 的取值小于预设的批次最大值, 则获取第 m 批次中非关键样本的梯度贡献;

如果第 m 批次中非关键样本的梯度贡献小于预设的阈值 ϵ , 更新 m 的取值为 $m+1$, 并继续训练自动驾驶未知危险场景模型; 否则, 停止训练操作, 其中阈值 ϵ 为非关键样本梯度贡献的容忍值。

8. 一种自动驾驶未知危险场景模型的管理方法, 包括:

获取控制数据, 其中所述控制数据包括汽车的运行状态以及在所述运行状态下的控制动作;

利用自动驾驶未知危险场景模型对所述控制数据进行处理, 得到识别结果, 其中所述自动驾驶未知危险场景模型是基于如权利要求1至7任一项所述的方法建立的。

9. 一种存储介质, 其特征在于, 所述存储介质中存储有计算机程序, 其中, 所述计算机程序被设置为运行时执行所述权利要求1至8任一项中所述的方法。

10. 一种电子装置, 包括存储器和处理器, 其特征在于, 所述存储器中存储有计算机程序, 所述处理器被设置为运行所述计算机程序以执行所述权利要求1至8任一项中所述的方法。

一种自动驾驶未知危险场景模型的建立和管理方法

技术领域

[0001] 本文涉及自动驾驶技术,尤指一种自动驾驶未知危险场景模型的建立和管理方法。

背景技术

[0002] 在自动驾驶领域,未知危险场景的识别是一个关键挑战。由于危险场景的发生极为稀少,数据集中通常存在极端的正负样本不平衡现象。正样本(未知危险场景)数量极少,而负样本(非未知危险场景)数量庞大。这种不平衡现象对传统深度学习方法的训练过程产生了显著影响,主要体现在以下几个方面:

模型训练困难:由于正样本数量稀少,模型在训练过程中难以有效学习正样本的特征,导致对正样本的识别能力不足。

[0003] 预测偏差:数据不平衡会导致模型对负样本的预测过于敏感,而对正样本的预测过于保守,容易出现漏检和误检。

[0004] 模型泛化能力差:训练出的模型在面对新的数据时泛化能力较差,容易出现过拟合现象,无法准确识别未知危险场景。

[0005] 因此,在自动驾驶场景中,如何高效地识别和处理未知危险场景,是一个亟待解决的技术难题。

发明内容

[0006] 本申请实施例提供了一种自动驾驶未知危险场景模型的建立和管理方法。

[0007] 一种自动驾驶未知危险场景模型的建立方法,其中所述自动驾驶未知危险场景模型用于识别输入数据中汽车在给定的运行状态下的控制动作是否为未知危险场景,所述方法包括:

从第 $m-1$ 批次训练数据中的样本中,确定第 $m-1$ 批次训练数据中的关键样本,其中 m 为正整数;

计算第 $m-1$ 批次训练数据中关键样本对应的损失函数对模型参数的梯度值,并基于梯度值估计每个关键样本的重要性采样权重;

按照第 $m-1$ 批次训练数据中关键样本的重要性采样权重,对关键样本进行采样,得到第 m 批次训练数据;

利用第 m 批次训练数据建立所述自动驾驶未知危险场景模型。

[0008] 一种自动驾驶未知危险场景模型的管理方法,包括:

获取控制数据,其中所述控制数据包括汽车的运行状态以及在所述运行状态下的控制动作;

利用自动驾驶未知危险场景模型对所述控制数据进行处理,得到识别结果,其中所述自动驾驶未知危险场景模型是基于上文所述的方法建立的。

[0009] 一种存储介质,所述存储介质中存储有计算机程序,其中,所述计算机程序被设置

为运行时执行上文所述的方法。

[0010] 一种电子装置,包括存储器和处理器,所述存储器中存储有计算机程序,所述处理器被设置为运行所述计算机程序以执行上文所述的方法。

[0011] 本申请实施例,通过筛选关键样本并进行重要性采样,提高模型对稀有样本的学习能力,提高模型对未知危险场景的识别能力,增强召回率和泛化能力。

[0012] 另外,通过获取控制数据,利用自动驾驶未知危险场景模型实时识别控制数据是否存在未知危险动作,为自动驾驶提供可靠的安全保障。

[0013] 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

[0014] 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。

[0015] 图1为本申请实施例提供的自动驾驶未知危险场景模型的建立方法的流程示意图;

图2为本申请实施例提供的自动驾驶未知危险场景模型的管理方法的流程示意图;

图3为本申请实施例提供的自动驾驶未知危险场景模型的建立装置的结构示意图;

图4为本申请实施例提供的自动驾驶未知危险场景模型的管理方法的结构示意图。

具体实施方式

[0016] 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。

[0017] 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。

[0018] 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。

[0019] 在自动驾驶领域中, s (State, 状态) 表示自动驾驶汽车当前所处的环境状态,通常包括但不限于以下参数:车辆自身的状态(如速度、加速度、转向角、位置等);周围环境信息(如其他车辆的位置、行人动态、道路拓扑、交通信号状态等);传感器数据(如摄像头、雷达、激光雷达的实时输入)。 a (Action, 动作) 表示自动驾驶汽车在状态 s 下可能采取的控制动作,例如:加速或减速(油门/刹车控制);转向(方向盘角度调整);车道保持或变道决策;紧急制动或避障策略。

[0020] 其中, $Q(s,a)$ 表示预测的事故概率,具体来说,基于先验信息(如历史数据、仿真模型或规则库),在给定状态 s 下执行动作 a 时,自动驾驶汽车发生事故的预测概率。

[0021] $Q^*(s,a)$ 表示真实事故概率,具体来说,在状态 s 下执行动作 a 时,通过真实测试或高保真仿真得出的实际事故概率,用于验证和校准自动驾驶未知危险场景模型确定的 $Q(s,a)$ 的准确性。

[0022] 根据 $Q(s,a)$ 和 $Q^*(s,a)$ 可将状态动作空间划分为四个区域,分别为已知危险状态动作区域、已知安全状态动作区域、未知危险状态动作区域以及未知安全状态动作区域,如表1所示。

[0023]	危险状态动作		安全状态动作	
	已知	$Q(s,a) > 0, Q^*(s,a) > 0$	$Q(s,a) = 0, Q^*(s,a) = 0$	
	未知	$Q(s,a) = 0, Q^*(s,a) > 0$	$Q(s,a) > 0, Q^*(s,a) = 0$	

[0024] 表1

从表1可知,在 $Q(s,a)=0$ 且 $Q^*(s,a)>0$ 时,未知危险状态动作构成未知危险场景空间,表示为 $\Omega_{UU} = (s,a) \in S \times A: Q(s,a) = 0, Q^*(s,a) > 0$ 。

[0025] 在自动驾驶安全性测试过程中,未知危险场景起着重要的作用。

[0026] 设未知危险场景分类问题中的数据集由正样本(未知危险场景)与负样本(非未知危险场景)组成,由于数据集极端不平衡,直接训练神经网络模型会导致模型难以学习到正样本的特征,从而影响其在未知危险场景识别任务中的召回率和泛化能力。

[0027] 神经网络模型是一类模拟人脑神经元结构的机器学习模型,能够自动从数据中学习复杂的映射关系。例如,典型的多层感知机(Multilayer Perceptron, MLP)由多个全连接层组成,适用于结构化数据建模;Transformer是一种基于自注意力机制的神经网络架构,能够捕捉序列中不同位置之间的依赖关系,广泛应用于自然语言处理、图像理解等任务。神经网络通过前向传播计算预测输出,通过反向传播调整参数,从而不断优化模型性能。目前,已有的神经网络模型方法在数据分类中已有显著成果,然而,在自动驾驶安全性领域,尤其是在识别和分类未知危险场景时,现有方法难以有效应对数据极端不平衡的问题。

[0028] 基于上述分析,本申请实施例提供如下解决方案,包括:

图1为本申请实施例提供的自动驾驶未知危险场景模型的建立方法的流程示意

图。如图1所示,所述自动驾驶未知危险场景模型用于识别输入数据中汽车在给定的运行状态下的控制动作是否为未知危险场景,所述方法包括:

步骤101:从第 $m-1$ 批次训练数据中的样本中,确定第 $m-1$ 批次训练数据中的关键样本,其中 m 为正整数。

[0029] 上述步骤101旨在识别对模型训练有重要影响的样本,以便在后续训练中重点关注。

[0030] 其中,关键样本可以是那些对模型性能有显著影响的样本,例如梯度幅值较大的样本、类别不平衡中的少数类样本、或具有极端特征的样本。

[0031] 其中,关键样本的筛选方法可以有如下多种实现方式:

基于梯度幅值:计算每个样本的梯度幅值(损失函数对模型参数的梯度绝对值),选择梯度幅值较大的样本作为关键样本;

基于类别平衡:在类别不平衡的数据集中,选择少数类样本作为关键样本;

基于特征稀疏度:选择那些在某些特征上具有稀疏或极端值的样本;

基于先验知识:根据领域专家的知识或先前的研究结果选择关键样本。

[0032] 步骤102:计算第 $m-1$ 批次训练数据中关键样本对应的损失函数对模型参数的梯度值,并基于梯度值估计每个关键样本的重要性采样权重。

[0033] 上述步骤102的目的是为每个关键样本分配一个权重,表示其在训练中的重要性。

[0034] 其中,重要性度值可以是梯度幅值、样本的稀疏度、或类别不平衡程度等。

[0035] 其中,重要性度值计算方法可以有如下多种实现方式:

梯度幅值:计算每个样本的梯度幅值,梯度幅值较大的样本分配更高的重要性度值。

[0036] 类别权重:在类别不平衡的情况下,少数类样本分配更高的重要性度值。

[0037] 特征稀疏度:计算样本在某些特征上的稀疏度,稀疏度较高的样本分配更高的重要性度值。

[0038] 综合指标:结合多个指标(如梯度幅值、类别权重、特征稀疏度等)计算重要性度值。

[0039] 步骤103:按照第 $m-1$ 批次训练数据中关键样本的重要性采样权重,对关键样本进行采样,得到第 m 批次训练数据。

[0040] 上述步骤103的目的是通过重要性采样,确保关键样本在训练中得到更多的关注。

[0041] 其中,采样策略可以有如下多种方式,包括:

重要性采样:根据关键样本的重要性度值,按概率分布进行采样。重要性度值较高的样本被采样的概率更高。

[0042] 重采样策略:在每个训练批次中,从正样本和负样本集合中均匀随机采样相等数量的数据点,确保类别平衡。

[0043] 动态调整:根据训练过程中的性能指标(如损失值、准确率等),动态调整采样策略。

[0044] 具体实现方式包括:

计算采样概率:根据关键样本的重要性度值,计算每个样本的采样概率。

[0045] 采样过程:按照计算的采样概率,从关键样本中采样,构建新的训练批次。

- [0046] 步骤104:利用第m批次训练数据建立所述自动驾驶未知危险场景模型。
- [0047] 上述步骤104的目的是通过优化后的训练数据,提高模型的性能和泛化能力。
- [0048] 对构建的模型进行训练,其中:
构建的模型的网络结构为神经网络架构,如多层全连接神经网络、卷积神经网络(CNN)、或Transformer架构;优化器可以为Adam、SGD等;损失函数可以为如交叉熵损失、均方误差等。
- [0049] 在训练过程中,对第m批次训练数据执行如下操作,包括:
加载数据:加载第m批次训练数据。
- [0050] 设定参数:设定训练参数,如批量大小、学习率、训练轮数等。
- [0051] 训练循环:对于前向传播,计算模型的输出;对于计算损失:计算损失函数值;对于反向传播:计算梯度并更新模型参数。
- [0052] 评估模型:在验证集上评估模型性能,如准确率、召回率、F1值等。
- [0053] 保存模型:保存训练好的模型参数。
- [0054] 此外,还可以针对模型进行优化,包括:
动态调整:根据训练过程中的性能指标,动态调整训练参数(如学习率、批量大小等)。
- [0055] 正负样本平衡:在每个训练批次中,确保正负样本的比例平衡,以提高模型对稀有正样本的学习能力。
- [0056] 通过上述步骤,通过筛选关键样本并进行重要性采样,从而提高模型对稀有样本的学习能力,提高模型对未知危险场景的识别能力,增强召回率和泛化能力。
- [0057] 下面对本申请实施例提供的方法进行说明:
在一个示例性实施例中,所述第m-1批次训练数据中的关键样本的确定方式,包括:
对第m-1批次训练数据中的样本,获取计算损失函数对模型参数的梯度,得到第m-1批次训练数据中每个样本的梯度值;
从第m-1批次训练数据中每个样本的梯度值,确定第m-1批次中关键样本的重要性采样权重;
其中,样本的梯度幅值越大,样本的重要性采样权重越高。
- [0058] 在本申请实施例中,采用梯度幅值确定关键样本的方式具有以下技术优势:
1. 直接反映样本对模型优化的贡献
梯度幅值大的样本对模型参数的更新有更大的影响,意味着这些样本在模型训练过程中起到了更关键的作用。通过选择这些样本,可以确保模型在训练过程中更多地关注那些对优化方向有显著影响的样本,从而提高模型的优化效率。
- [0059] 2. 动态适应模型训练过程
梯度幅值会随着模型的训练而变化,这使得关键样本的确定能够动态适应模型的训练状态。与基于静态特征(如类别标签或样本的稀疏度)的方法相比,基于梯度幅值的方法能够更好地反映模型在不同训练阶段的需求,确保模型在每个阶段都能关注到最重要的样本。
- [0060] 3. 简单易实现

计算梯度幅值是深度学习训练过程中的一个标准步骤,因此这种方法易于实现,不需要额外的复杂计算或数据预处理。相比之下,其他一些方法可能需要额外的计算步骤或复杂的特征工程。

[0061] 4. 提高模型的泛化能力

通过关注梯度幅值大的样本,模型能够更好地学习到数据中的复杂模式和细微差别,从而提高其泛化能力。这有助于模型在面对新的、未见过的数据时表现得更好。

[0062] 5. 有效处理类别不平衡问题

在类别不平衡的数据集中,少数类样本可能具有较大的梯度幅值,因为模型在这些样本上更容易出错。通过选择这些梯度幅值大的样本,可以增强模型对少数类样本的学习能力,从而缓解类别不平衡带来的问题。

[0063] 在一个示例性实施例中,第 $m-1$ 批次中每个关键样本的重要性采样权重的计算表达式如下:

$$\hat{q}(x) = \frac{|\nabla_{\theta} L(y, \hat{y})| |I_{x_c}(x) p(x)|}{\sum_{i=1}^n |\nabla_{\theta} L(y_i, \hat{y}_i)| |I_{x_c}(x_i)|}, \quad \forall x \in \{x_1, \dots, x_n\};$$

其中, n 为第 $m-1$ 批次中样本的总数,

$\nabla_{\theta} L(y, \hat{y})$ 表示模型参数 θ 对样本的损失函数 L 的梯度,其中, $y \in \{0, 1\}$ 为真实类别, $\hat{y} \in [0, 1]$ 为自动驾驶未知危险场景模型输出的概率;

\mathcal{X}_c 为关键样本集合;

$p(x)$ 为原始概率分布,即每个样本被选中的概率;

I_{x_c} 为指示函数,用于判断样本是否属于关键样本集合。

[0064] 在实际应用中,原始概率分布通常为均匀分布,即 $p(x) = \frac{1}{n}$ 。

[0065] 上述表达式的推导过程如下:

重要性函数 q 被定义为一个概率分布,满足 $q(x) > 0$, 对于所有 $x \in \{x \in X: \nabla_{\theta} L(Y, \hat{Y}) p(x) \neq 0\}$ 。其中 X 表示样本空间, $\nabla_{\theta} L(Y, \hat{Y})$ 表示损失函数 L 对模型参数 θ 的梯度。

[0066] 设 Q 为包含所有重要性函数的函数空间,则梯度的期望值 μ 的表达式如下:

$$\mu = E_p[\nabla_{\theta} L(Y, \hat{Y})] = E_q\left[\frac{\nabla_{\theta} L(Y, \hat{Y}) p(X)}{q(X)}\right].$$

[0067] 其中, $\hat{Y} = g_{\theta}(X)$, \hat{Y} 表示模型对输入 X 的预测输出, Y 表示输入 X 对应的真实结果。

[0068] 基于重要性采样的梯度期望估计 $\hat{\mu}_q$ 的表达式如下:

$$\hat{\mu}_q = \frac{1}{n} \sum_{i=1}^n \frac{\nabla_{\theta} L(Y_i, \hat{Y}_i) p(X_i)}{q(X_i)}, X_i \sim q.$$

[0069] 设 $(\mathcal{X}_{-c}, \mathcal{X}_c)$ 是空间 \mathcal{X} 的一个划分,其中 \mathcal{X}_c 是关键样本集合, \mathcal{X}_{-c} 是非关键样本集合,且满足 $E_p[\nabla_{\theta} L(Y, \hat{Y}) I_{\mathcal{X}_{-c}}(X)] < \varepsilon$,其中, ε 表示非关键样本梯度贡献的容忍值。

[0070] 在密集重要性采样中,只使用属于 \mathcal{X}_c 的样本来估计重要性采样的梯度期望估计 $\hat{\mu}_q$ 的表达式如下:

$$\hat{\mu}_q := \frac{1}{n} \sum_{i=1}^n \frac{\nabla_{\theta} L(Y_i, \hat{Y}_i) p(X_i)}{q(X_i)} I_{\mathcal{X}_c}(X_i), X_i \sim q$$

[0071] 其中, $I_{\mathcal{X}_c}(X_i)$ 为指示函数,当 $X_i \in \mathcal{X}_c$ 时为1,否则为0。

[0072] 基于上述推导,对于 n 个训练样本 $\{x_1, \dots, x_n\}$,且 p 是均匀分布,那么 \hat{q} 可以通过以下方式进行确定:

$$\hat{q}(x) = \frac{|\nabla_{\theta} L(y, \hat{y})| |I_{\mathcal{X}_c}(x) p(x)|}{\sum_{i=1}^n |\nabla_{\theta} L(y_i, \hat{y}_i)| |I_{\mathcal{X}_c}(x_i)|}, \quad \forall x \in \{x_1, \dots, x_n\}.$$

[0073] 通过上述推导,重要性函数被设计为能够突出关键样本的影响,同时减少非关键样本的干扰。这种采样策略不仅提高了模型训练的效率,还增强了模型对关键样本的学习能力,从而提升了模型的性能和泛化能力。

[0074] 在步骤104中,在第 m 批次训练数据中正样本和负样本的数据相等时,按照第 $m-1$ 批次中关键样本的重要性采样权重,分别从正样本数据集和负样本数据集获取训练数据;

具体的,按照计算出的重要性采样权重,分别从正样本数据集和负样本数据集中进行采样。重要性采样权重较高的样本被采样的概率更高,确保从正样本和负样本数据集中采样的样本数量相等,从而构建一个类别平衡的训练批次。

[0075] 在步骤104中,在采用平衡训练模式时,从正负样本索引集合中分别采样 $N/2$ 个样本;在采用不平衡训练模式时,从第 m 批次训练集随机采样 N 个采样;其中, N 为单次迭代训练中使用的样本数量。

[0076] 具体的,结合过采样和欠采样技术,确保最终的训练批次中正负样本的比例相对平衡。其中:

过采样:对于样本数量较少的类别(通常是正样本),可以采用过采样技术,如SMOTE(合成少数过采样技术),增加少数类样本的数量。

[0077] 欠采样:对于样本数量较多的类别(通常是负样本),可以采用欠采样技术,减少多数类样本的数量。

[0078] 通过上述方式,可以有效地处理正负样本不平衡的问题,确保模型在训练过程中能够充分学习到关键样本的特征,从而提高模型的识别精度和召回率。

[0079] 在一个示例性实施例中,第 m 批次训练数据中每个样本的损失函数为根据每个样本的交叉熵与各自的加权值确定的,其中:

对于第 m 批次训练数据中当前样本,交叉熵是自动驾驶未知危险场景模型对当前样本输出的概率与当前样本的真实类别之间的交叉熵;加权值为原始概率分布与重要性采样的概率分布之间的比值。

[0080] 采用上述方式确定损失函数具有以下优势：

1. 突出关键样本的影响

通过结合交叉熵和加权值,该损失函数能够突出关键样本在训练中的影响。关键样本(如梯度幅值较大的样本)对模型优化的贡献更大,因此在损失计算中给予更高的权重,有助于模型更快地学习到这些样本的特征,从而提高模型的识别精度和召回率。

[0081] 2. 动态适应训练过程

加权值基于样本在前一批次中的重要性采样权重动态调整,使得损失函数能够动态适应模型的训练状态。这种动态调整有助于模型在不同训练阶段关注不同的关键样本,从而提高模型的优化效率和最终性能。

[0082] 3. 有效处理类别不平衡

通过为不同类别样本分配不同的权重,该损失函数能够有效处理类别不平衡问题。在自动驾驶场景中,危险场景(正样本)通常较少,通过加权可以增强模型对正样本的学习能力,从而提高模型在稀有场景下的识别能力。

[0083] 4. 提高模型的泛化能力

通过关注关键样本并动态调整权重,模型能够更好地学习到数据中的复杂模式和细微差别,从而提高其泛化能力。这有助于模型在面对新的、未见过的数据时表现得更好。

[0084] 5. 快速收敛

与某些其他损失函数相比,交叉熵损失函数在反向传播过程中能够更快地收敛到最优解。这是因为其梯度与预测值和真实值之间的差异成正比,从而避免了梯度消失或爆炸的问题。

[0085] 综上所述,这种结合交叉熵和加权值的损失函数确定方式,不仅能够提高模型的识别精度和召回率,还能有效处理类别不平衡问题,提高模型的泛化能力和优化效率。

[0086] 在本申请实施例中,所述自动驾驶未知危险场景模型的表达式为

$$\hat{y} = \sigma(W_4 \cdot \text{ReLU}(W_3 \cdot \text{ReLU}(W_2 \cdot \text{ReLU}(W_1 \cdot X + b_1) + b_2) + b_3) + b_4);$$

其中, \hat{y} 为自动驾驶未知危险场景模型输出的概率, W_1 至 W_4 以及 b_1 至 b_4 均为模型参数, ReLU 为激活函数, σ 为Sigmoid函数, X 表示样本。

[0087] 采用上述模型具有以下优势：

1. 深度特征学习:多层神经网络结构能够自动从数据中学习复杂的映射关系,通过逐层特征提取,模型可以捕捉到输入数据中的深层次特征,这对于自动驾驶场景中的复杂模式识别尤为重要。

[0088] 2. 非线性表达能力:ReLU激活函数的引入增强了模型的非线性表达能力,使得模型能够更好地拟合复杂的非线性关系,提高了模型的预测精度。

[0089] 3. 输出概率值:Sigmoid函数将模型的输出限制在(0,1)范围内,提供了对未知危险场景的预测概率,这不仅便于理解和决策,还为后续的风险评估提供了直接依据。

[0090] 4. 模型参数的可训练性:模型参数(权重 W 和偏置 b)可以通过训练数据进行优化,使得模型能够适应不同的自动驾驶场景和数据分布,具有较高的灵活性和适应性。

[0091] 5. 计算效率:ReLU激活函数的计算效率高,且模型结构相对简单,这使得模型在训练和推理过程中具有较低的计算成本,适合实时性要求较高的自动驾驶应用。

[0092] 6. 可解释性:虽然深度神经网络通常被认为是“黑箱”模型,但该模型的结构相对简单,通过分析各层的权重和激活值,可以在一定程度上理解模型的决策过程,为模型的可解释性提供了可能性。

[0093] 7. 广泛适用性:该模型结构适用于多种类型的输入数据,如图像、传感器数据等,为自动驾驶系统中不同数据源的融合提供了可能性。

[0094] 综上所述,该自动驾驶未知危险场景模型通过其深度结构和激活函数的选择,在特征学习、非线性拟合、计算效率和可解释性等方面展现出明显优势,为自动驾驶场景中的未知危险识别提供了高效可靠的解决方案。

[0095] 可选的,在建立自动驾驶未知危险场景模型过程中,如果 m 的取值小于预设的批次最大值,则获取第 m 批次中非关键样本的平均梯度贡献;

如果第 m 批次中非关键样本的平均梯度贡献小于预设的阈值 ϵ ,更新 m 的取值为 $m+1$,并继续训练自动驾驶未知危险场景模型;否则,停止训练操作,其中阈值 ϵ 为非关键样本梯度贡献的容忍值。

[0096] 其中,非关键样本的平均梯度贡献的表达式为 $E_p[\nabla_{\theta}L(Y,\hat{Y})I_{X_c}(X)]$ 。

[0097] 通过监测非关键样本的平均梯度贡献,可以动态判断模型是否已经充分学习了这些样本的特征。如果非关键样本的平均梯度贡献低于预设的阈值 ϵ ,说明模型对这些样本的学习已经趋于稳定,此时可以停止训练,避免不必要的计算资源浪费。另外,通过关注非关键样本的梯度贡献,可以确保模型在面对各种场景时具有更好的鲁棒性,避免模型过于依赖某些特定的样本,从而提高模型的泛化能力。

[0098] 下面以某一应用场景的模型建立过程进行说明:

某一应用场景中,训练数据集包含1000个样本,其中正样本(未知危险场景)仅20个(占比2%),负样本(非未知危险场景)980个(占比98%),其中模型的训练目标是高精度识别未知危险场景的分类模型。

[0099] 例如,从1000个样本中随机抽取一个批次(如32个样本)时,可能仅选中0-1个正样本,概率极低。基于该批次计算损失并更新参数,但由于正样本参与不足,易偏向负样本,导致正样本召回率低,模型无法有效学习危险场景特征。

[0100] 在按照本申请实施例提供的方法后,执行如下操作,包括:

确定关键样本:计算每个样本的梯度幅值,选择梯度幅值较大的样本作为关键样本。梯度幅值大的样本对模型参数的更新影响更大,这些样本通常是模型在训练过程中需要重点关注的。

[0101] 计算重要性度值:为每个关键样本分配一个重要性采样权重,重要性采样权重高的样本在训练中会被给予更高的权重。

[0102] 重要性采样:根据重要性采样权重进行采样,确保关键样本在训练批次中得到更多的关注。具体来说,从正样本和负样本中分别采样,确保每个批次中正负样本的数量相等,从而平衡类别分布。

[0103] 动态调整训练过程:在训练过程中,监测非关键样本的平均梯度贡献。如果非关键样本的平均梯度贡献低于预设的阈值 ϵ ,说明模型对这些样本的学习已经趋于稳定,此时可以停止训练,避免资源浪费。

[0104] 通过上述方法,模型在训练过程中能够更多地关注正样本,从而提高对未知危险

场景的识别能力。具体来说：

1. 提高正样本的参与度:通过确保每个批次中正负样本数量相等,模型能够充分学习到正样本的特征。

[0105] 2. 增强模型的召回率:通过关注关键样本,模型能够更好地识别未知危险场景,提高召回率。

[0106] 3. 优化训练效率:通过动态调整训练过程,避免资源浪费,提高训练效率。

[0107] 综上所述,本申请实施例提供的方法在模型训练过程中能够有效克服由于正样本参与不足导致的模型偏向负样本的问题,提高模型对未知危险场景的识别能力,增强模型的召回率和泛化能力。

[0108] 图2为本申请实施例提供的自动驾驶未知危险场景模型的管理方法的流程示意图。如图2所示,所述方法包括:

步骤201、获取控制数据,其中所述控制数据包括汽车的运行状态以及在所述运行状态下的控制动作;

其中,控制数据是根据如下数据得到的,包括:

传感器数据:从汽车的传感器(如摄像头、雷达、激光雷达等)获取实时数据,包括车速、加速度、转向角度、刹车状态等。

[0109] 控制动作数据:从汽车的控制系统获取控制动作数据,如方向盘的转动角度、油门和刹车的使用情况等。

[0110] 环境数据:从外部环境传感器获取数据,如天气条件、道路状况等。

[0111] 步骤202、利用自动驾驶未知危险场景模型对所述控制数据进行处理,得到识别结果,其中所述自动驾驶未知危险场景模型是基于上文所述的方法建立的。

[0112] 通过自动驾驶未知危险场景模型对控制数据进行处理,识别出潜在的未知危险场景,实现方式如下:

步骤2-1、模型输入:

数据加载:将预处理后的控制数据加载到自动驾驶未知危险场景模型中;

特征映射:将输入数据映射到模型的输入层,确保数据格式与模型要求一致;

步骤2-2、模型处理:

前向传播:通过模型的多层神经网络进行前向传播,计算输出结果;

激活函数:使用ReLU激活函数进行非线性变换,增强模型的表达能力;

输出层:通过Sigmoid函数输出对未知危险场景的预测概率;

步骤2-3、结果解读:

概率阈值:设定一个概率阈值(如0.5),当预测概率超过该阈值时,判断为未知危险场景。

[0113] 此外,还可以执行决策制定:根据模型的输出结果,制定相应的驾驶决策,如发出警告、自动刹车等。

[0114] 本申请实施例提供的方法,通过获取控制数据,利用自动驾驶未知危险场景模型实时识别控制数据是否存在未知危险动作,为自动驾驶提供可靠的安全保障。

[0115] 图3为本申请实施例提供的自动驾驶未知危险场景模型的建立装置的结构示意图。如图3所示,所述自动驾驶未知危险场景模型用于识别输入数据中汽车在给定的运行状

态下的控制动作是否为未知危险场景,所述方法包括:

确定模块301,设置为从第 $m-1$ 批次训练数据中的样本中,确定第 $m-1$ 批次训练数据中的关键样本,其中 m 为正整数;

计算模块302,设置为计算第 $m-1$ 批次训练数据中关键样本对应的损失函数对模型参数的梯度值,并基于梯度值估计每个关键样本的重要性采样权重;

采样模块303,设置为按照第 $m-1$ 批次训练数据中关键样本的重要性采样权重,对关键样本进行采样,得到第 m 批次训练数据;

建立模块304,设置为利用第 m 批次训练数据建立所述自动驾驶未知危险场景模型。

[0116] 本申请实施例提供的装置,通过筛选关键样本并进行重要性采样,从而提高模型对稀有样本的学习能力,提高模型对未知危险场景的识别能力,增强召回率和泛化能力。

[0117] 图4为本申请实施例提供的自动驾驶未知危险场景模型的管理方法的结构示意图。如图4所示,所述装置包括:

获取模块401,设置为获取控制数据,其中所述控制数据包括汽车的运行状态以及在所述运行状态下的控制动作;

识别模块402,设置为利用自动驾驶未知危险场景模型对所述控制数据进行处理,得到识别结果,其中所述自动驾驶未知危险场景模型是基于上文所述的方法建立的。

[0118] 本申请实施例提供的装置,通过获取控制数据,利用自动驾驶未知危险场景模型实时识别控制数据是否存在未知危险动作,为自动驾驶提供可靠的安全保障。

[0119] 此外,本申请还提供一种存储介质,所述存储介质中存储有计算机程序,其中,所述计算机程序被设置为运行时执行上文所述的方法。

[0120] 一种电子装置,包括存储器和处理器,所述存储器中存储有计算机程序,所述处理器被设置为运行所述计算机程序以执行上文所述的方法。

[0121] 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。

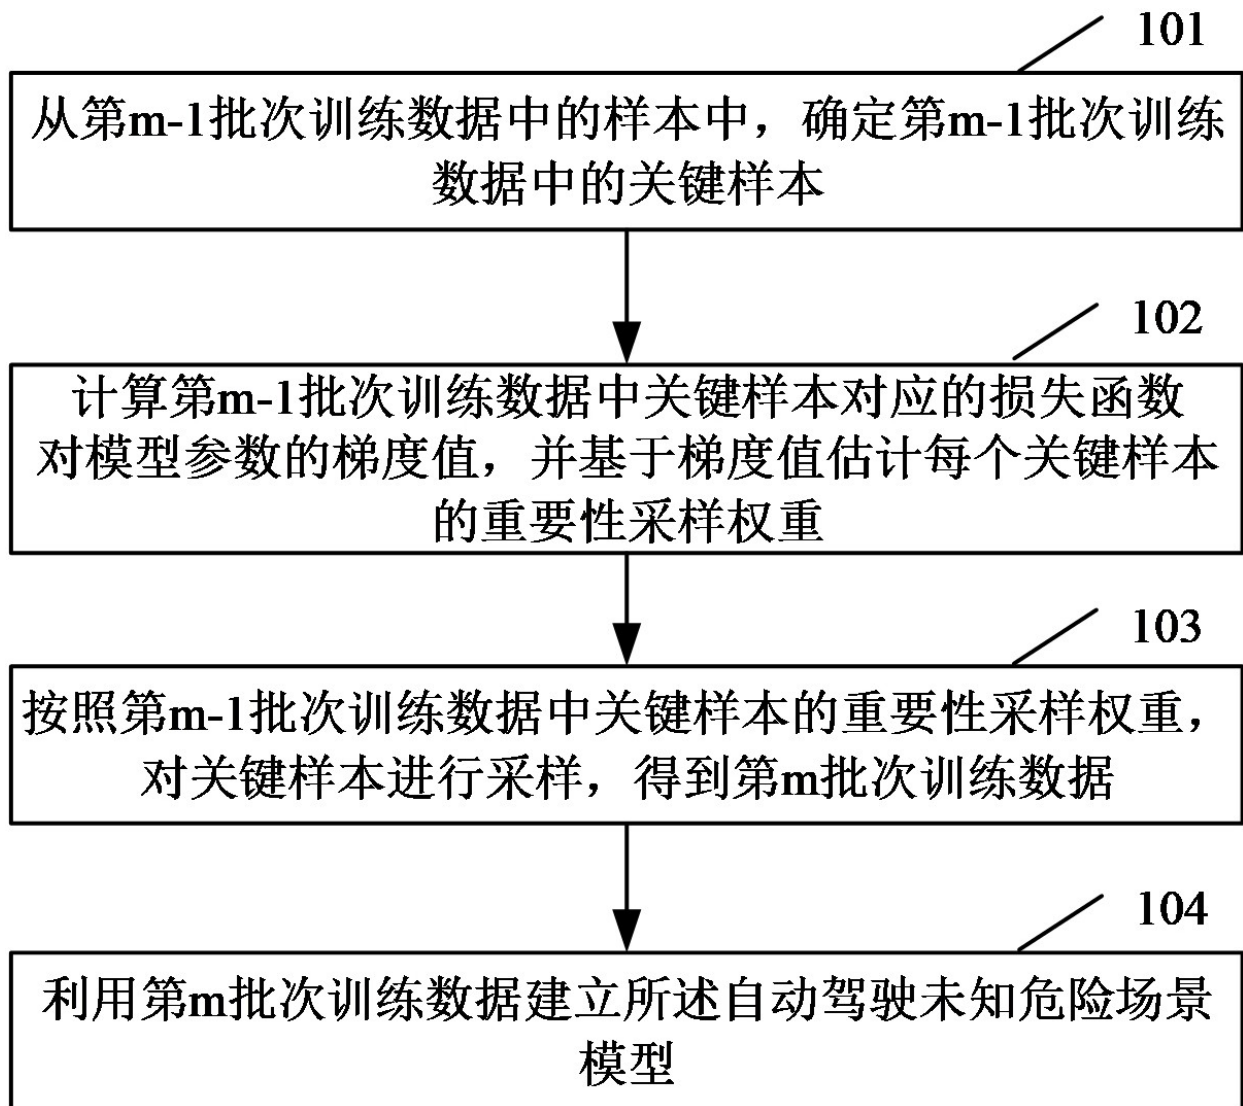


图1

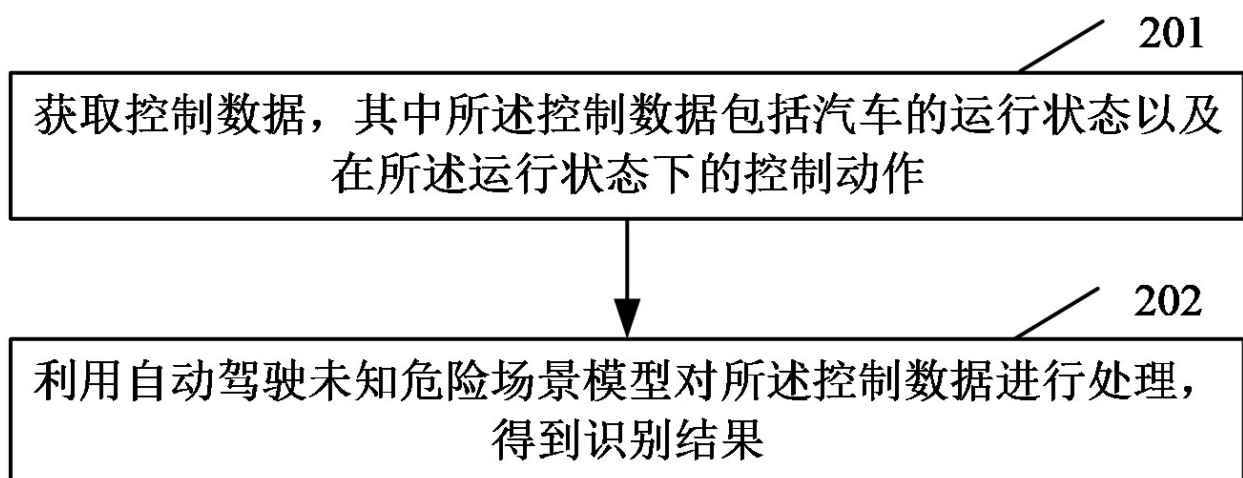


图2




图3




图4