



(12) 发明专利申请

(10) 申请公布号 CN 115964676 A

(43) 申请公布日 2023.04.14

(21) 申请号 202211738905.X

G06N 20/10 (2019.01)

(22) 申请日 2022.12.30

G06N 3/0455 (2023.01)

(71) 申请人 长安大学

地址 710064 陕西省西安市雁塔区南二环路中段

(72) 发明人 闵海根 雷小平 赵祥模 吴霞

杨澜 王润民 宋瑞 孟强

尚旭明 王振 李尧 陈仕祥

(74) 专利代理机构 西安通大专利代理有限责任

公司 61200

专利代理师 朱海临

(51) Int. Cl.

G06F 18/25 (2023.01)

G06F 18/214 (2023.01)

G06N 3/088 (2023.01)

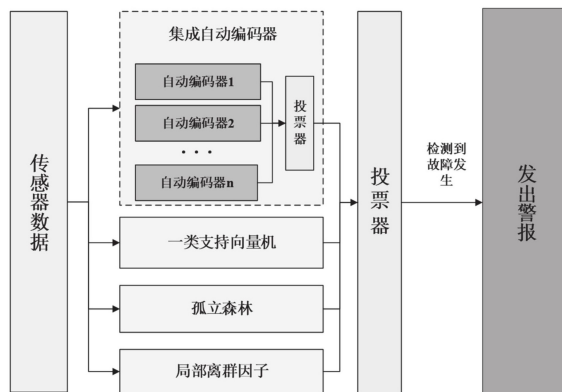
权利要求书2页 说明书7页 附图3页

(54) 发明名称

一种无监督自动驾驶汽车故障检测方法及系统

(57) 摘要

本发明公开了一种无监督自动驾驶汽车故障检测方法及系统,通过实时采集自动驾驶汽车的行驶状态数据,利用不同结构的自动编码器对获取的行驶状态数据进行检测,对不同结构的自动编码器检测结果进行融合得到编码器融合检测结果;同时采用一类支持向量机模型、局部离群因子模型和孤立森林模型分别对自动驾驶汽车的行驶状态数据进行检测得到各自的检测结果,将一类支持向量机模型、局部离群因子模型和孤立森林模型的检测结果与编码器融合检测结果进一步融合得到最终的检测结果,从数据驱动的角度设计了融合多个针对解决故障检测问题的方法的集成框架,可以有效地检测传感器数据异常和自动驾驶汽车运行状态的故障。



1. 一种无监督自动驾驶汽车故障检测方法,其特征在於,包括以下步骤:

S1,实时采集自动驾驶汽车的行驶状态数据,利用不同结构的自动编码器对获取的行驶状态数据进行检测,对不同结构的自动编码器检测结果进行融合得到编码器融合检测结果;

S2,同时采用一类支持向量机模型、局部离群因子模型和孤立森林模型分别对自动驾驶汽车的行驶状态数据进行检测得到各自的检测结果,将一类支持向量机模型、局部离群因子模型和孤立森林模型的检测结果与编码器融合检测结果进一步融合得到最终的检测结果。

2. 根据权利要求1所述的一种无监督自动驾驶汽车故障检测方法,其特征在於,以自动驾驶汽车正常行驶状态下的车辆行驶状态数据作为训练集,训练多个不同结构的自动编码器。

3. 根据权利要求2所述的一种无监督自动驾驶汽车故障检测方法,其特征在於,从自动驾驶汽车正常行驶状态下的车辆行驶状态数据中提取有用字段并进行数据清洗和数据变换;

提取的有用字段包括协议头、采样时刻、航向角、东向速度和北向速度。

4. 根据权利要求3所述的一种无监督自动驾驶汽车故障检测方法,其特征在於,根据东向速度和北向速度变换得到速度信息,记东向速度为 v_e ,北向速度为 v_n ,则速度值的大小为:

$$v = \sqrt{v_e^2 + v_n^2} \quad (1)$$

通过计算两个连续采样时刻偏航角的差商得到角速度信息:

$$\omega = \sqrt{\left(\frac{\psi_{i+1} - \psi_i}{\Delta t}\right)^2} \quad (2)。$$

5. 根据权利要求4所述的一种无监督自动驾驶汽车故障检测方法,其特征在於,自动编码器包括编码器结构和解码器结构,编码器结构由式(3)描述, W 和 b 分别是编码器的权重矩阵和偏置向量;

输入向量 $X = [x_1, x_2, \dots, x_n]^T$,经编码器结构编码为 $X' = [x'_1, x'_2, \dots, x'_n]^T$;解码器结构操作如式(4), W' 和 b' 分别代表解码器的权重矩阵和偏置向量,解码器将编码向量 $X' = [x'_1, x'_2, \dots, x'_n]^T$ 解码为 $\hat{X} = [\hat{x}_1, \hat{x}_2, \dots, \hat{x}_n]^T$;

$$X' = f(WX + b) \quad (3)$$

$$\hat{X} = g(W'X' + b') \quad (4)$$

$$\arg \min_{\theta} J_{AE}(\theta) = \frac{1}{N} \sum_{i=1}^N \|X - \hat{X}\|^2 \quad (5)$$

自动编码器的目标是重构输入数据,目标如式(5),通过反向传播算法优化权重矩阵和偏置向量参数。

6. 根据权利要求5所述的一种无监督自动驾驶汽车故障检测方法,其特征在於,上述构建的自动编码器为非全连接自动编码器。

7. 根据权利要求6所述的一种无监督自动驾驶汽车故障检测方法,其特征在于,多个非全连接自动编码器分别对输入样本进行评估,分别得到样本的重构误差,记第*i*个非全连接自动编码器对当前样本的重构误差为 e_i ,则多个非全连接自动编码器对当前样本的重构误差为 $E=[e_1, e_2, \dots, e_n]^T$ 。

8. 根据权利要求1所述的一种无监督自动驾驶汽车故障检测方法,其特征在于,利用一类支持向量机(One-Class Support Vector Machine, OCSVM)算法在正常数据点和原点之间构造具有最大间隔分离的超平面的方式进行故障检测,数据点位于边界之内,则认为使正常样本。

9. 根据权利要求1所述的一种无监督自动驾驶汽车故障检测方法,其特征在于,将经过融合后的故障分数经sigmoid函数映射到区间(0,1),根据映射后的数值大小判断是否发生故障,在区间(0,0.5)上的为故障,(0.5,1)区间上的为正常。

10. 一种无监督自动驾驶汽车故障检测系统,其特征在于,数据采集模块和检测模块;
数据采集模块用于实时采集自动驾驶汽车的行驶状态数据,并将采集的数据传输至检测模块;

检测模块内存储不同结构的自动编码器、一类支持向量机模型、局部离群因子模型和孤立森林模型,利用不同结构的自动编码器对获取的行驶状态数据进行检测,对不同结构的自动编码器检测结果进行融合得到编码器融合检测结果;同时采用一类支持向量机模型、局部离群因子模型和孤立森林模型分别对自动驾驶汽车的行驶状态数据进行检测得到各自的检测结果,将一类支持向量机模型、局部离群因子模型和孤立森林模型的检测结果与编码器融合检测结果进一步融合得到最终的检测结果。

一种无监督自动驾驶汽车故障检测方法及系统

技术领域

[0001] 本发明属于汽车系统故障诊断领域,具体涉及一种无监督自动驾驶汽车故障检测方法及系统。

背景技术

[0002] 自动驾驶汽车技术融合了传感器技术、计算机技术、通信技术、信息处理技术、控制技术等诸多领域的高科技技术,有着巨大的发展潜力。自动驾驶汽车的安全问题广受关注,现有针对自动驾驶汽车的故障检测方法主要包含:基于模型的方法、基于信号的方法和基于数据驱动的方法,单一的故障检测方法基于特定的假设,难以全面的学习到自动驾驶汽车传感器数据模式,难以对自动驾驶车辆运行中出现的故障做出有效检测。

发明内容

[0003] 本发明的目的在于提供一种无监督自动驾驶汽车故障检测方法及系统,以克服现有无监督自动驾驶汽车故障检测精度低的问题。

[0004] 一种无监督自动驾驶汽车故障检测方法,包括以下步骤:

[0005] S1,实时采集自动驾驶汽车的行驶状态数据,利用不同结构的自动编码器对获取的行驶状态数据进行检测,对不同结构的自动编码器检测结果进行融合得到编码器融合检测结果;

[0006] S2,同时采用一类支持向量机模型、局部离群因子模型和孤立森林模型分别对自动驾驶汽车的行驶状态数据进行检测得到各自的检测结果,将一类支持向量机模型、局部离群因子模型和孤立森林模型的检测结果与编码器融合检测结果进一步融合得到最终的检测结果。

[0007] 优选的,以自动驾驶汽车正常行驶状态下的车辆行驶状态数据作为训练集,训练多个不同结构的自动编码器。

[0008] 优选的,从自动驾驶汽车正常行驶状态下的车辆行驶状态数据中提取有用字段并进行数据清洗和数据变换;

[0009] 提取的有用字段包括协议头、采样时刻、航向角、东向速度和北向速度。

[0010] 优选的,根据东向速度和北向速度变换得到速度信息,记东向速度为 v_e ,北向速度为 v_n ,则速度值的大小为:

$$[0011] \quad v = \sqrt{v_e^2 + v_n^2} \quad (6)$$

[0012] 通过计算两个连续采样时刻偏航角的差商得到角速度信息:

$$[0013] \quad \omega = \sqrt{\left(\frac{\psi_{i+1} - \psi_i}{\Delta t}\right)^2} \quad (7)$$

[0014] 优选的,自动编码器包括编码器结构和解码器结构,编码器结构由式(3)描述, W 和 b 分别是编码器的权重矩阵和偏置向量;

[0015] 输入向量 $X=[x_1, x_2, \dots, x_n]^T$,经编码器结构编码为 $X'=[x'_1, x'_2, \dots, x'_n]^T$;解码器结构操作如式(4), W' 和 b' 分别代表解码器的权重矩阵和偏置向量,解码器将编码向量 $X'=[x'_1, x'_2, \dots, x'_n]^T$ 解码为 $\hat{X}=[\hat{x}_1, \hat{x}_2, \dots, \hat{x}_n]^T$;

$$[0016] \quad X' = f(WX + b) \quad (8)$$

$$[0017] \quad \hat{X} = g(W'X' + b') \quad (9)$$

$$[0018] \quad \arg \min_{\theta} J_{AE}(\theta) = \frac{1}{N} \sum_{i=1}^N \|X - \hat{X}\|^2 \quad (10)$$

[0019] 自动编码器的目标是重构输入数据,目标如式(5),通过反向传播算法优化权重矩阵和偏置向量参数。

[0020] 优选的,上述构建的自动编码器为非全连接自动编码器。

[0021] 优选的,多个非全连接自动编码器分别对输入样本进行评估,分别得到样本的重构误差,记第 i 个非全连接自动编码器对当前样本的重构误差为 e_i ,则多个非全连接自动编码器对当前样本的重构误差为 $E=[e_1, e_2, \dots, e_n]^T$ 。

[0022] 优选的,利用一类支持向量机(One-Class Support Vector Machine, OCSVM)算法在正常数据点和原点之间构造具有最大间隔分离的超平面的方式进行故障检测,数据点位于边界之内,则认为使正常样本。

[0023] 优选的,将经过融合后的故障分数经sigmoid函数映射到区间(0,1),根据映射后的数值大小判断是否发生故障,在区间(0,0.5)上的为故障,(0.5,1)区间上的为正常。

[0024] 一种无监督自动驾驶汽车故障检测系统,数据采集模块和检测模块;

[0025] 数据采集模块用于实时采集自动驾驶汽车的行驶状态数据,并将采集的数据传输至检测模块;

[0026] 检测模块内存储不同结构的自动编码器、一类支持向量机模型、局部离群因子模型和孤立森林模型,利用不同结构的自动编码器对获取的行驶状态数据进行检测,对不同结构的自动编码器检测结果进行融合得到编码器融合检测结果;同时采用一类支持向量机模型、局部离群因子模型和孤立森林模型分别对自动驾驶汽车的行驶状态数据进行检测得到各自的检测结果,将一类支持向量机模型、局部离群因子模型和孤立森林模型的检测结果与编码器融合检测结果进一步融合得到最终的检测结果。

[0027] 与现有技术相比,本发明具有以下有益的技术效果:

[0028] 本发明一种无监督自动驾驶汽车故障检测方法,通过实时采集自动驾驶汽车的行驶状态数据,利用不同结构的自动编码器对获取的行驶状态数据进行检测,对不同结构的自动编码器检测结果进行融合得到编码器融合检测结果;同时采用一类支持向量机模型、局部离群因子模型和孤立森林模型分别对自动驾驶汽车的行驶状态数据进行检测得到各自的检测结果,将一类支持向量机模型、局部离群因子模型和孤立森林模型的检测结果与编码器融合检测结果进一步融合得到最终的检测结果,从数据驱动的角度设计了融合多个针对解决故障检测问题的方法的集成框架,可以有效地检测传感器数据异常和自动驾驶汽车运行状态的故障。

[0029] 本申请采用集成自动编码器、OCSVM、LOF和IF同时对车辆的运动状态进行监测,能

够有效避免单个模型对数据处理的单一性,本申请将对车辆运动状态的检测结果投票构建集成故障检测框架,能够从多角度对最终检验结果进行验证考虑,提高了车辆故障检测的精准度。

附图说明

- [0030] 图1是本发明实施例中无监督故障检测方法及系统整体框架图。
- [0031] 图2是本发明实施例中GNSS天线及有关设备安装示意图。
- [0032] 图3是本发明实施例中自动编码器的网络结构。
- [0033] 图4是本发明实施例中非全连接自动编码器网络结构示意图。
- [0034] 图5是本发明实施例中基于自动编码器的投票器网络结构图。

具体实施方式

[0035] 为了使本技术领域的人员更好地理解本发明方案,下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、完整地描述,显然,所描述的实施例仅仅是本发明一部分的实施例,而不是全部的实施例。基于本发明中的实施例,本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其他实施例,都应当属于本发明保护的范围。

[0036] 需要说明的是,本发明的说明书和权利要求书及上述附图中的术语“第一”、“第二”等是用于区别类似的对象,而不必用于描述特定的顺序或先后次序。应该理解这样使用的数据在适当情况下可以互换,以便这里描述的本发明的实施例能够以除了在这里图示或描述的那些以外的顺序实施。此外,术语“包括”和“具有”以及他们的任何变形,意图在于覆盖不排他的包含,例如,包含了一系列步骤或单元的过程、方法、系统、产品或设备不必限于清楚地列出的那些步骤或单元,而是可包括没有清楚地列出的或对于这些过程、方法、产品或设备固有的其它步骤或单元。

[0037] 一种无监督自动驾驶汽车故障检测方法,包括以下步骤:

[0038] S1,实时采集自动驾驶汽车的行驶状态数据,利用不同结构的自动编码器对获取的行驶状态数据进行检测,对不同结构的自动编码器检测结果进行融合得到编码器融合检测结果;

[0039] 以自动驾驶汽车正常行驶状态下的车辆行驶状态数据作为训练集,训练多个不同结构的自动编码器。

[0040] S2,同时采用一类支持向量机模型、局部离群因子模型和孤立森林模型分别对自动驾驶汽车的行驶状态数据进行检测得到各自的检测结果,将一类支持向量机模型、局部离群因子模型和孤立森林模型的检测结果与编码器融合检测结果进一步融合得到最终的检测结果。

[0041] 本申请的车辆行驶状态数据获取采用传感器信息,具体选择以组合导航(GNSS+惯性导航)信息为例,对于组合导航信息,所采用的数据采集的传感器包括安装于车内的高精度MEMS(微机电系统)组合导航系统和一套接收卫星信号的GNSS天线,一台记录组合导航系统GNSS日志的工控计算机及上述装置配套的供电设备。具体安装如图1所示,将标定好的组合导航系统以及工控计算机放置于车厢后部固定,通过馈线与GNSS天线相连接。GNSS天线

分别旋拧到两个强磁吸盘上并分别固定摆放在自动驾驶汽车的前进方向和后退方向上,将其安置于自动驾驶汽车的最高处以保证能够接收到良好的GNSS信号,同时要保证两个GNSS天线相位中心形成的连线与测试载体中心轴线方向一致或平行。

[0042] 数据的提取及预处理:对上述传感器采集到的数据,提取有用字段并进行数据清洗和数据变换,为后续模型的训练做准备。

[0043] 对于传感器采集到的数据信息,提取的有用字段包括协议头、采样时刻、航向角、东向速度和北向速度。

[0044] 有用字段提取后的文件仍然存在记录的不完整、缺失、以及重复等许多问题,不能直接作为输入送给模型进行训练。本发明中针对踢提取的有用字段中重复记录只保留其中一条,对于提取的有用字段不完整字段或错误字段的样本,使用该样本前后相邻的两个样本对应字段的线性插值补全不完整字段或错误字段。

[0045] 模型训练或验证需要用到的输入数据包括:车辆无人驾驶状态下的速度和角速度。对于直接从提取的有用字段中无法得到的数据,需利用提取的有效字段进行变换后得到。具体变换方法包括以下步骤:

[0046] (1) 速度信息由东向速度和北向速度变换得到。记东向速度为 v_e ,北向速度为 v_n ,则速度值的大小为:

$$[0047] \quad v = \sqrt{v_e^2 + v_n^2} \quad (11)$$

[0048] (2) 角速度信息通过计算两个连续采样时刻偏航角的差商得到。

$$[0049] \quad \omega = \sqrt{\left(\frac{\psi_{i+1} - \psi_i}{\Delta t}\right)^2} \quad (12)$$

[0050] 利用上述方法得到的自动驾驶汽车正常运行时的速度数据、角速度数据,训练多个不同结构的自动编码器,训练完成的多个自动编码器对新样本进行对比,检测出与正常运行状态有较大偏差的数据。具体包括以下步骤:

[0051] S21,自动编码器的训练:自动编码器本质上是包含编码器结构和解码器结构的前馈神经网络,如图2所示,自动编码器的编码器结构操作由式(3)描述,这里W和b分别是编码器的权重矩阵和偏置向量。

[0052] 输入向量 $X = [x_1, x_2, \dots, x_n]^T$,经编码器结构编码为 $X' = [x'_1, x'_2, \dots, x'_n]^T$ 。自动编码器的解码器结构操作如式(4),式中:W'和b'分别代表解码器的权重矩阵和偏置向量,解码器将编码向量 $X' = [x'_1, x'_2, \dots, x'_n]^T$ 解码为 $\hat{X} = [\hat{x}_1, \hat{x}_2, \dots, \hat{x}_n]^T$ 。

$$[0053] \quad X' = f(WX + b) \quad (13)$$

$$[0054] \quad \hat{X} = g(W'X' + b') \quad (14)$$

[0055] 自动编码器的目标是重构输入数据,目标可由式(5)定义,通过反向传播算法优化权重矩阵和偏置向量参数。

[0056] 训练自动编码器模型使用的数据是自动驾驶汽车正常运行状态下的健康数据。训练完成后,自动编码器能够重构与训练数据模式相似的数据。对于故障数据,自动编码器对该数据的重构误差会明显大于正常数据的重构误差。根据输入数据的重构误差的大小,可

以对样本是否发生故障进行判决。

$$[0057] \quad \arg \min_{\theta} J_{AE}(\theta) = \frac{1}{N} \sum_{i=1}^N \|X - \hat{X}\|^2 \quad (15)$$

[0058] S22,集成自动编码器构建:网络层数和每层神经元个数对自动编码器故障检测效果影响很大,难以确定合适的网络规模以达到最优故障检测效果。针对此问题,使用多个不同网络结构的自动编码器构建集成自动编码器,利用集成自动编码器对不同结构的自动编码器检测结果进行融合。考虑到典型自动编码器是全连接层组成的,即使改变网络层数,由于网络结构相同,多个自动编码器之间差异很小。因此,本申请使用非全连接自动编码器作为学习器构建集成自动编码器。在全连接自动编码器的基础上,随机断开部分连接,形成非全连接自动编码器,如图3所示。

[0059] 多个非全连接自动编码器分别对输入样本进行评估,分别得到样本的重构误差,记第*i*个非全连接自动编码器对当前样本的重构误差为 e_i ,则多个(一组)非全连接自动编码器对当前样本的重构误差为 $E = [e_1, e_2, \dots, e_n]^T$ 。

[0060] 集成自动编码器检测结果融合:一组非全连接自动编码器组成的集成自动编码器,集成自动编码器针对输入样本给出一组重构误差。将一组非全连接自动编码器对输入样本的重构误差进行投票,最终融合为一个重构误差。投票器由自动编码器的编码器部分组成,对于上述得到的重构误差向量 $E = [e_1, e_2, \dots, e_n]^T$,将其作为输入向量输入到瓶颈处为一个神经元的自动编码器,如图4所示。经过投票,一组重构误差融合为一个重构误差,具体操作由式(6)描述,式中 $f_{encoder}$ 是编码器操作, E' 是融合之后的重构误差。根据融合后重构误差的大小判断输入样本是否发生故障。

$$[0061] \quad E' = f_{encoder}(E) = f_{encoder}(W_{E1}^T E + b_{E1}) \quad (16)$$

[0062] 构建异构集成故障检测:

[0063] 故障检测算法通常基于特定的假设,不同故障检测算法检测结果之间差异性较大,为了进一步提高故障检测准确率,在上述构建的集成自动编码器的基础上构建异构集成故障检测。选取一类支持向量机、局部离群因子、孤立森林、集成自动编码器作为学习器,使用学习器并行检测,再将学习器检测结果融合。

[0064] 具体细节包括:

[0065] 利用一类支持向量机(One-Class Support Vector Machine, OCSVM)算法在正常数据点和原点之间构造具有最大间隔分离的超平面的方式进行故障检测,数据点位于边界之内,则认为使正常样本。算法的目标函数定义为:

$$[0066] \quad \min_{\omega, \xi_i, \rho} \frac{1}{2} \|\omega\|^2 + \frac{1}{\mu n} \sum_{i=1}^n \xi_i - \rho \quad (17)$$

$$[0067] \quad \begin{aligned} s.t. & (w \cdot \phi(x_i)) \geq \rho - \xi_i \quad i = 1, \dots, n \\ & \xi_i \geq 0 \quad i = 1, \dots, n \end{aligned} \quad (18)$$

[0068] 其中 w 是高维特征空间的特征向量, ξ_i 是允许一些数据点位于边缘内的松弛变量, ρ 是偏移量, $\mu \in (0, 1)$ 是控制边界的权衡参数, n 是样本数, x_i 是第*i*个输入训练数据, $\phi(x_i)$

是将低维原始数据点映射到高维的非线性映射函数。 μ 设置了异常值的分数的上界和支持向量的分数的下界。对于样本 x ,其判定样本是否为故障的函数 s_{OCSVM} 由式(9)定义。

$$[0069] \quad s_{OCSVM} = \sum_{i=1}^n \alpha_i \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) - \rho \quad (19)$$

[0070] 其中, x 是待检测的样本, x_i 为第 i 个输入的训练数据, $\sigma \in \mathbb{R}$ 是决定函数径向范围的参数, α_i 是式(7)利用拉格朗日技术得到的一系列支持向量。如果待检测样本的结果为负,则为异常样本。

[0071] 利用孤立森林(Isolation Forest)算法故障检测的过程是:递归随机分割数据集,直到所有样本都是孤立的或者达到限制的树高。由于故障数据点分布稀疏并且离密度较高的群体较远的特征,故障数据点具有较正常点更短的路径。给定的包含 n 个样本的数据集,树的平均路径长度为:

$$[0072] \quad c(n) = 2H(n-1) - \left(\frac{2(n-1)}{n}\right) \quad (20)$$

[0073] 其中 $H(i)$ 为调和数,可以用 $\ln(i) + \gamma$ (欧拉常数)进行计算, $c(n)$ 为给定样本数 n 时,路径长度的平均值。样本的故障分数为:

$$[0074] \quad s_{IF}(x, n) = 2^{-\frac{E(h(x))}{c(n)}} \quad (21)$$

[0075] 其中 $h(x)$ 为通过 x 从树的根节点到叶子节点的边数, $E(h(x))$ 为样本 x 在一批树中的路径长度的期望。

[0076] 局部离群因子(Local Outlier Factor, LOF)算法通过计算每个点的局部可达密度,进而计算每个点的局部离群因子,选取离群程度最高的 n 个样本点。

[0077] 第 k 距离 $d_k(x_i)$ 为距点 x_i 最近的第 k 个点 x_j 与点 x_i 的距离, $d_k(x_i) = d(x_i, x_j)$, x_j 满足:在集合中至少有不包括 x_i 在内的 k 个点 x'_j ,使得 $d(x_i, x'_j) \leq d(x_i, x_j)$;在集合中至多有不包括 x_i 在内的 $k-1$ 个点 x'_j ,使得 $d(x_i, o') < d(x_i, x_j)$ 。

[0078] 第 k 距离邻域:点 x_i 的第 k 距离邻域 $N_k(x_i)$,点 x_i 的第 k 距离及第 k 距离内的所有点的集合。

[0079] 第 k 可达距离: $rd_k(x_i, x_j) = \max\{d_k(x_i), d(x_i, x_j)\}$,即样本点 x_i 和 x_j 的第 k 可达距离为点 x_i 的第 k 距离和点 x_i 和 x_j 的距离的较大者。

[0080] 第 k 局部可达密度:

$$[0081] \quad lrd_k(x_i) = 1 / \left(\frac{\sum_{x_j \in N_k(x_i)} rd_k(x_j, x_i)}{|N_k(x_i)|} \right) \quad (22)$$

$$[0082] \quad S_{LOF}(x_i) = \frac{\sum_{x_j \in N_k(x_i)} lrd_k(x_j)}{|N_k(x_i)|} \quad (23)$$

[0083] LOF算法故障分数 s^{LOF} 由式(13)描述,故障分数越大,该样本点为故障点的可能性越大。

[0084] 结合上述方法构建的集成自动编码器,将输入数据的故障分数作为基于自动编码器投票器的输入,输入向量 $s = [s_1, s_2, \dots, s_n]^T$ 其中 s_i 为第 i 个学习器给出的故障分数。多个学习器的故障分数组成了一个向量,将此向量作为输入数据输入瓶颈处为一个神经元的自动编码器。该自动编码器需要经过预训练,其预训练阶段输入为多个用于故障检测的自动编码器的异常分数,输入 $s = [s_1, s_2, \dots, s_n]^T$

$$[0085] \quad s' = f_{encoder}(s) = f_{encoder}(W_s^T s + b_s) \quad (24)$$

$$[0086] \quad Sigmoid(S) = \sigma(S) = \frac{1}{1 + e^{-S}} \quad (25)$$

[0087] s' 是输入 s 经过自动编码器编码后的一维数据,我们为了将输入的多个自动编码器的重构误差组合为一个异常分数,将用于组合重构误差的自动编码器的瓶颈处设置为一个神经元,即 $s' \in s^1$ 。 W_s^T 是编码器部分的权重矩阵。自动编码器网络中使用的非线性激活函数为ReLU(Rectified Linear Unit)。

[0088] 将经过融合后的故障分数经sigmoid函数映射到区间 $(0, 1)$,sigmoid函数如式(15)描述。根据映射后的数值大小判断是否发生故障,在区间 $(0, 0.5)$ 上的为故障, $(0.5, 1)$ 区间上的为正常。检测到自动驾驶汽车发生故障时,系统将记录故障数据到日志,并发出警报提示。

[0089] 本发明一种无监督自动驾驶汽车故障检测系统,基于一类支持向量机(OCSVM)、局部离群因子(LOF)、孤立森林(IF)和集成自动编码器。其中,集成自动编码器故障检测模块包括多个自动编码器。采集车辆正常行驶状态下的数据作为训练数据,构建多个自动编码器,用来检测车辆运动状态,将多个自动编码器的检测结果投票构建集成自动编码器。同时,利用正常行驶状态的数据构建OCSVM、LOF、IF故障检测模块。集成自动编码器、OCSVM、LOF和IF同时对车辆的运动状态进行监测,并将对车辆运动状态的检测结果投票构建集成故障检测框架。该框架主要针对自动驾驶汽车的运动状态,从数据驱动的角度设计了融合多个针对解决故障检测问题的方法的集成框架,可以有效地检测传感器数据异常和自动驾驶汽车运行状态的故障。

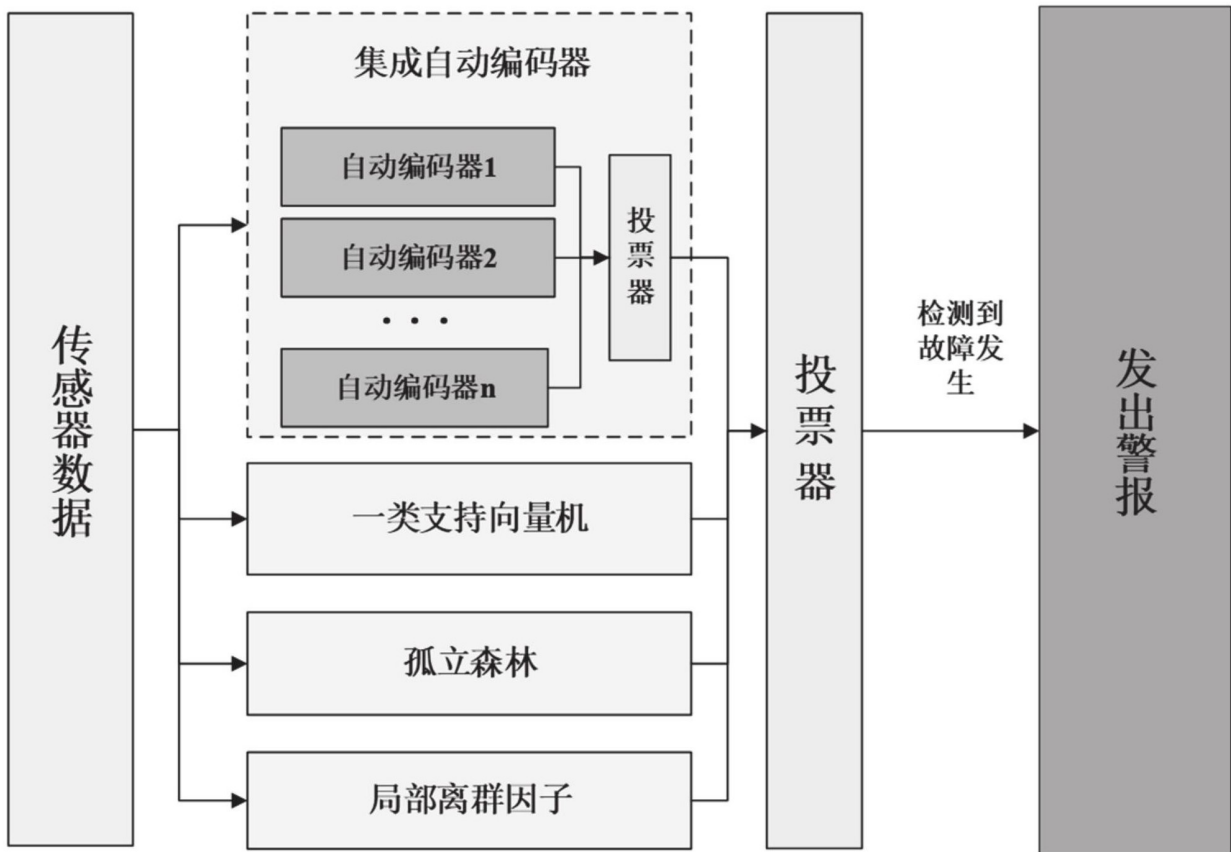


图1




图2




图3




图4




图5