



(12) 发明专利

(10) 授权公告号 CN 116304863 B

(45) 授权公告日 2024.06.11

(21) 申请号 202310141592.8

G06N 3/0442 (2023.01)

(22) 申请日 2023.02.08

G06N 3/08 (2023.01)

(65) 同一申请的已公布的文献号

G06F 16/215 (2019.01)

申请公布号 CN 116304863 A

G10L 25/03 (2013.01)

G10L 25/27 (2013.01)

(43) 申请公布日 2023.06.23

G10L 25/51 (2013.01)

(73) 专利权人 北京北明数科信息技术有限公司

(56) 对比文件

地址 100144 北京市石景山区永引渠南路

CN 109785460 A, 2019.05.21

18号院1号楼1层A116

CN 114022726 A, 2022.02.08

(72) 发明人 王宏军 李磊 陈东升 汪滔滔

CN 114693945 A, 2022.07.01

李刚

CN 114839960 A, 2022.08.02

(74) 专利代理机构 广州嘉权专利商标事务所有

CN 115031994 A, 2022.09.09

限公司 44205

CN 115452392 A, 2022.12.09

专利代理师 孙浩

KR 102389553 B1, 2022.04.27

KR 20190018798 A, 2019.02.26

(51) Int. Cl.

审查员 邱悦

G06F 18/241 (2023.01)

G06F 18/25 (2023.01)

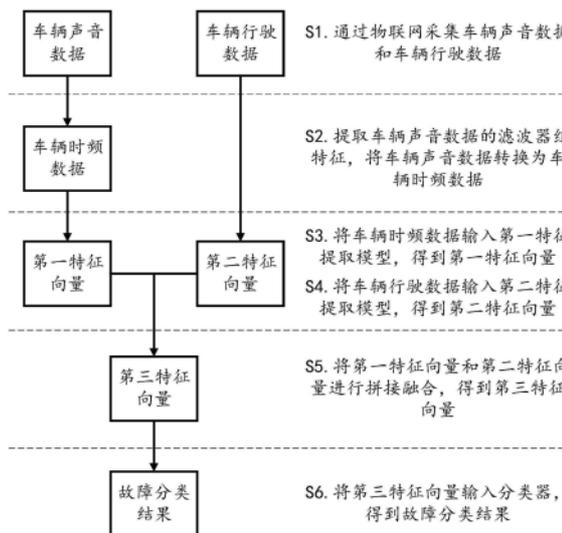
权利要求书2页 说明书8页 附图4页

(54) 发明名称

一种多数据融合的车辆故障监测预警方法、设备及介质

(57) 摘要

本发明公开了一种多数据融合的车辆故障监测预警方法、设备及介质。方法包括以下步骤：通过物联网采集车辆声音数据和车辆行驶数据；提取车辆声音数据的滤波器组特征，将车辆声音数据转换为车辆时频数据；将车辆时频数据输入第一特征提取模型，得到第一特征向量；将车辆行驶数据输入第二特征提取模型，得到第二特征向量；将第一特征向量和第二特征向量进行拼接融合，得到第三特征向量；将第三特征向量输入分类器，得到故障分类结果。本发明有助于进一步建立车辆声音与故障的关系，构建声音、行驶数据与故障的知识图谱，为驾驶人员或维修人员提供高效的故障判别方案。



1. 一种多数据融合的车辆故障监测预警方法,其特征在于,包括以下步骤:

通过物联网采集车辆声音数据和车辆行驶数据;所述车辆行驶数据,具体包括车辆时速、引擎转速、轮胎胎压和车辆耗油量;

提取车辆声音数据的滤波器组特征,将车辆声音数据转换为车辆时频数据;

将车辆时频数据输入第一特征提取模型,得到第一特征向量;所述第一特征提取模型为时延神经网络,由一维卷积层、压缩激励残差网络层和注意力统计池化层构成;

将车辆行驶数据输入第二特征提取模型,得到第二特征向量;所述第二特征提取模型为卷积神经网络和双向长短期记忆网络相结合的深度学习模型;

将第一特征向量和第二特征向量进行拼接融合,得到第三特征向量;

将第三特征向量输入分类器,得到故障分类结果;

所述将车辆声音数据转换为车辆时频数据,具体包括以下步骤:

通过以下公式对车辆声音数据进行预加重处理,得到第一中间声音数据 $y_n$ ;

$$y_n = x_n - ax_{n-1}$$

式中, $x_n$ 是当前时刻的车辆声音数据, $x_{n-1}$ 是上一时刻的车辆声音数据, $a$ 是预设滤波系数;

通过以下公式对第一中间声音数据进行频谱估计,得到第二中间声音数据 $F_x(f)$ ;

$$F_x(f) = \sum_{m=0}^{K-1} \frac{\cos(\frac{m}{K}\pi) + 1}{\sum_{m=0}^{K-1} \cos(\frac{m}{K}\pi) + 1} \times \left( \sum_{n=0}^{N-1} y_n \sqrt{\frac{2}{N+1}} \sin \frac{mn}{N+1} \pi \times e^{-j2fn\pi} \right)^2$$

式中, $K$ 多正弦窗函数的个数, $m=1,2,\dots,N$ ;  $N$ 为采样点数;

对第二声音中间数据进行平滑,得到第三声音中间数据;

将第三声音中间数据输入由以下公式构成的梅尔频率滤波器,得到车辆时频数据;

$$\text{MEL}(f) = 2595 * \lg\left(1 + \frac{f}{700}\right)$$

所述对第二声音中间数据进行平滑,得到第三声音中间数据,具体包括以下步骤:

将第二声音中间数据输入滑动平均滤波器,得到声音平滑数据;

逐帧比较第二声音中间数据和声音平滑数据,取第二声音中间数据和声音平滑数据中的极大值作为新的第二声音中间数据;

返回将第二声音中间数据输入滑动平均滤波器这一步骤,直至返回次数达到预设迭代次数;

将最终得到的第二声音中间数据作为第三声音中间数据输出;

所述将第三特征向量输入分类器,得到故障分类结果,具体包括以下步骤:

通过以下公式计算第三特征向量属于目标故障类别的概率:

$$P_{ic} = \frac{e^{s(\cos(\theta_{c,i}+m))}}{e^{s(\cos(\theta_{c,i}+m))} + \sum_{j=1, j \neq c}^{CN} e^{s \cos \theta_{j,i}}}$$

式中, $c$ 表示目标故障类别; $i$ 表示输入向量; $\theta_{c,i}$ 为权值矩阵中类别 $c$ 对应的列向量 $W_c$ 与输入向量 $i$ 之间的夹角; $CN$ 为类别个数, $m$ 为边缘角度, $s$ 为缩放因子;

选择概率最高的目标故障类别作为第三特征向量的故障分类结果输出。

2. 根据权利要求1所述的一种多数据融合的车辆故障监测预警方法,其特征在于,所述第一特征提取模型,具体包括一维卷积层、压缩激励残差网络层和注意力统计池化层;所述将车辆时频数据输入第一特征提取模型,得到第一特征向量,具体包括以下步骤:

通过一维卷积层对所述车辆时频数据进行卷积操作,得到车辆声音特征;

通过压缩激励残差网络层将所述车辆声音特征进行多层特征融合,提取出车辆声音特征的第一整体信息;

通过一维卷积层对所述车辆声音特征的第一整体信息进行卷积运算,得到第二整体信息;

通过注意力统计池化层压缩所述第二整体信息,得到关于车辆时频数据的第一特征向量。

3. 根据权利要求1所述的一种多数据融合的车辆故障监测预警方法,其特征在于,在所述将车辆行驶数据输入第二特征提取模型之前,还包括以下步骤:

对车辆行驶数据进行数据清洗,去除车辆行驶数据中的噪声;

当所述车辆行驶数据中存在异常值时,通过线性插值法修订车辆行驶数据中的异常值;

将车辆行驶数据作归一化处理。

4. 根据权利要求1所述的一种多数据融合的车辆故障监测预警方法,其特征在于,所述第二特征提取模型,具体包括卷积池化层和双向长短期记忆网络层;所述将车辆行驶数据输入第二特征提取模型,得到第二特征向量,具体包括以下步骤:

通过卷积池化层对所述车辆行驶数据进行卷积池化处理,得到车辆行驶特征;

通过双向长短期记忆网络层对所述车辆行驶特征进行突出特征提取,得到车辆行驶突出特征;

通过卷积池化层对所述车辆行驶数据进行池化处理,得到关于车辆行驶数据的第二特征向量。

5. 一种电子设备,其特征在于,包括处理器以及存储器;

所述存储器用于存储程序;

所述处理器执行所述程序实现如权利要求1-4中任一项所述的方法。

6. 一种计算机可读存储介质,其特征在于,所述存储介质存储有程序,所述程序被处理器执行实现如权利要求1-4中任一项所述的方法。

## 一种多数据融合的车辆故障监测预警方法、设备及介质

### 技术领域

[0001] 本发明涉及车辆状态监控领域,尤其是一种多数据融合的车辆故障监测预警方法、设备及介质。

### 背景技术

[0002] 车辆在使用过程中,存在诸多的安全风险,不仅容易导致车辆在使用过程中不能正常行驶,还会导致交通事故,造成经济的损失和人员的伤亡。

[0003] 当前对车辆的监控,大多通过视频并结合AI技术对驾驶员的驾驶行为进行监控,提示驾驶员安全驾驶;利用物联网技术采集车辆的速度、转速、胎压、油耗、位置等车辆行驶数据,实时同步到物联网中台,监控车辆的运行状态。但是这些监控方法忽视了车辆运行时所发出的声音,没有利用车辆的声音并结合车辆的其他行驶数据,对车辆故障进行监测预警。

### 发明内容

[0004] 有鉴于此,本发明实施例提供一种多数据融合的车辆故障监测预警方法、设备及介质。

[0005] 本发明的第一方面提供了一种多数据融合的车辆故障监测预警方法,包括以下步骤:

[0006] 通过物联网采集车辆声音数据和车辆行驶数据;

[0007] 提取车辆声音数据的滤波器组特征,将车辆声音数据转换为车辆时频数据;

[0008] 将车辆时频数据输入第一特征提取模型,得到第一特征向量;

[0009] 将车辆行驶数据输入第二特征提取模型,得到第二特征向量;

[0010] 将第一特征向量和第二特征向量进行拼接融合,得到第三特征向量;

[0011] 将第三特征向量输入分类器,得到故障分类结果。

[0012] 进一步地,所述将车辆声音数据转换为车辆时频数据,具体包括以下步骤:

[0013] 通过以下公式对车辆声音数据进行预加重处理,得到第一中间声音数据 $y_n$ ;

[0014]  $y_n = x_n - ax_{n-1}$

[0015] 式中, $x_n$ 是当前时刻的车辆声音数据, $x_{n-1}$ 是上一时刻的车辆声音数据, $a$ 是预设滤波系数;

[0016] 通过以下公式对第一中间声音数据进行频谱估计,得到第二中间声音数据 $F_x(f)$ ;

[0017] 
$$F_x(f) = \sum_{m=0}^{K-1} \frac{\cos(\frac{m}{K}\pi) + 1}{\sum_{m=0}^{K-1} \cos(\frac{m}{K}\pi) + 1} \times \left( \sum_{n=0}^{N-1} y_n \sqrt{\frac{2}{N+1}} \sin \frac{mn}{N+1} \pi \times e^{-j2fn\pi} \right)^2$$

[0018] 式中, $K$ 多正弦窗函数的个数, $m=1,2,\dots,N$ ;  $N$ 为采样点数;

[0019] 对第二声音中间数据进行平滑,得到第三声音中间数据;

[0020] 将第三声音中间数据输入由以下公式构成的梅尔频率滤波器,得到车辆时频数

据;

[0021]  $MEL(f) = 2595 * \lg(1 + \frac{f}{700})$

[0022] 式中f表示第三声音中间数据的实际频率。

[0023] 进一步地,所述对第二声音中间数据进行平滑,得到第三声音中间数据,具体包括以下步骤:

[0024] 将第二声音中间数据输入滑动平均滤波器,得到声音平滑数据;

[0025] 逐帧比较第二声音中间数据和声音平滑数据,取第二声音中间数据和声音平滑数据中的极大值作为新的第二声音中间数据;

[0026] 返回将第二声音中间数据输入滑动平均滤波器这一步骤,直至返回次数达到预设迭代次数;

[0027] 将最终得到的第二声音中间数据作为第三声音中间数据输出。

[0028] 进一步地,所述第一特征提取模型,具体包括一维卷积层、压缩激励残差网络层和注意力统计池化层;所述将车辆时频数据输入第一特征提取模型,得到第一特征向量,具体包括以下步骤:

[0029] 通过一维卷积层对所述车辆时频数据进行卷积操作,得到车辆声音特征;

[0030] 通过压缩激励残差网络层将所述车辆声音特征进行多层特征融合,提取出车辆声音特征的第一整体信息;

[0031] 通过一维卷积层对所述车辆声音特征的第一整体信息进行卷积运算,得到第二整体信息;

[0032] 通过注意力统计池化层压缩所述第二整体信息,得到关于车辆时频数据的第一特征向量。

[0033] 进一步地,所述车辆行驶数据,具体包括车辆时速、引擎转速、轮胎胎压和车辆耗油量。

[0034] 进一步地,在所述将车辆行驶数据输入第二特征提取模型之前,还包括以下步骤:

[0035] 对车辆行驶数据进行数据清洗,去除车辆行驶数据中的噪声;

[0036] 当所述车辆行驶数据中存在异常值时,通过线性插值法修订车辆行驶数据中的异常值;

[0037] 将车辆行驶数据作归一化处理。

[0038] 进一步地,所述第二特征提取模型,具体包括卷积池化层和双向长短期记忆网络层;所述将车辆行驶数据输入第二特征提取模型,得到第二特征向量,具体包括以下步骤:

[0039] 通过卷积池化层对所述车辆行驶数据进行卷积池化处理,得到车辆行驶特征;

[0040] 通过双向长短期记忆网络层对所述车辆行驶特征进行突出特征提取,得到车辆行驶突出特征;

[0041] 通过卷积池化层对所述车辆行驶数据进行池化处理,得到关于车辆行驶数据的第二特征向量。

[0042] 进一步地,所述将第三特征向量输入分类器,得到故障分类结果,具体包括以下步骤:

[0043] 通过以下公式计算第三特征向量属于目标故障类别的概率:

$$[0044] \quad P_{ic} = \frac{e^{s(\cos(\theta_{c,i}+m))}}{e^{s(\cos(\theta_{c,i}+m))} + \sum_{j=1, j \neq c}^{CN} e^{s \cos \theta_{j,i}}}$$

[0045] 式中,  $c$  表示目标故障类别;  $i$  表示输入向量;  $\theta_{c,i}$  为权值矩阵中类别  $c$  对应的列向量  $W_c$  与输入向量  $i$  之间的夹角;  $CN$  为类别个数,  $m$  为边缘角度,  $s$  为缩放因子;

[0046] 选择概率最高的目标故障类别作为第三特征向量的故障分类结果输出。

[0047] 本发明第二方面提供了一种电子设备, 包括处理器以及存储器;

[0048] 所述存储器用于存储程序;

[0049] 所述处理器执行所述程序实现一种多数据融合的车辆故障监测预警方法。

[0050] 本发明第三方面提供了一种计算机可读存储介质, 所述存储介质存储有程序, 所述程序被处理器执行实现一种多数据融合的车辆故障监测预警方法。

[0051] 本发明的实施例具有如下方面有益效果: 本发明通过物联网技术采集车辆声音、时速、引擎转速、轮胎胎压和耗油量等数据; 提取声音的滤波器组特征, 利用多个特征提取模型对上述多模态数据进行融合, 实现了通过车辆声音数据和行驶数据判断车辆故障类别。有助于进一步建立车辆声音与故障的关系, 构建声音、行驶数据与故障的知识图谱, 为驾驶人员或维修人员提供高效的故障判别方案。

[0052] 本发明的附加方面和优点将在下面的描述部分中给出, 部分将从下面的描述中变得明显, 或通过本发明的实践了解到。

## 附图说明

[0053] 为了更清楚地说明本申请实施例中的技术方案, 下面将对实施例描述中所需要使用的附图作简单地介绍, 显而易见地, 下面描述中的附图仅仅是本申请的一些实施例, 对于本领域普通技术人员来讲, 在不付出创造性劳动的前提下, 还可以根据这些附图获得其他的附图。

[0054] 图1是本发明一种多数据融合的车辆故障监测预警方法、设备及介质基本流程示意图;

[0055] 图2是本发明一种多数据融合的车辆故障监测预警方法、设备及介质中第一特征提取模型的特征提取流程图;

[0056] 图3是本发明一种多数据融合的车辆故障监测预警方法、设备及介质的第一特征提取模型中压缩激励残差网络的特征提取流程图;

[0057] 图4是本发明一种多数据融合的车辆故障监测预警方法、设备及介质中第二特征提取模型的特征提取流程图。

## 具体实施方式

[0058] 为了使本申请的目的、技术方案及优点更加清楚明白, 以下结合附图及实施例, 对本申请进行进一步详细说明。应当理解, 此处所描述的具体实施例仅仅用以解释本申请, 并不用于限定本申请。

[0059] 车辆行驶时发出的声音中包含了大量的运行状态信息, 当车辆发生故障时, 车辆所发出的声音相较于正常情况会发生一定的变化, 并具有一定的特征。基于此, 本发明实施

例提出一种多数据融合的车辆故障监测预警方法、设备及介质,使用深度学习方法结合车辆行驶速度、引擎转速、轮胎胎压、油耗等数据,识别出汽车可能存在的故障。

[0060] 本发明实施例所提供的一种多数据融合的车辆故障监测预警方法如图1所示,主要包括以下步骤:

[0061] S1.通过物联网采集车辆声音数据和车辆行驶数据;

[0062] S2.提取车辆声音数据的滤波器组特征,将车辆声音数据转换为车辆时频数据;

[0063] S3.将车辆时频数据输入第一特征提取模型,得到第一特征向量;

[0064] S4.将车辆行驶数据输入第二特征提取模型,得到第二特征向量;

[0065] S5.将第一特征向量和第二特征向量进行拼接融合,得到第三特征向量;

[0066] S6.将第三特征向量输入分类器,得到故障分类结果。

[0067] 下面具体论述本发明实施例各步骤实施流程。

[0068] S1.通过物联网采集车辆声音数据和车辆行驶数据。物联网在车辆中的应用又被称为车联网,在目标车辆上安装各类车载终端和传感器,通过车载终端和传感器实现对车辆声音数据和行驶数据的采集。本实施例中车辆行驶数据具体包括车辆时速、引擎转速、轮胎胎压和车辆耗油量;其中,车辆时速和耗油量通过与车辆自带的数据采集系统数据交互得到,引擎转速通过在车辆传动轴上安装转速传感器采集得到,轮胎胎压通过在车辆轮毂上安装压力传感器,测量轮胎气门压力采集得到;车辆声音数据则通过安装在车辆底盘等多个位置的声音传感器采集。采集完成后,通过无线网络通信将车辆声音数据和车辆行驶数据汇总至上位机中,在上位机上通过深度学习模型完成对车辆故障的识别。

[0069] 在一部分实施例中,在通过物联网采集车辆声音数据和车辆行驶数据之后,会根据车辆声音数据和车辆行驶数据构建车辆声音信息库,通过车辆声音信息库中的数据对后续使用的深度学习模型进行训练,进一步优化深度学习模型的故障分类效果。

[0070] S2.提取车辆声音数据的滤波器组特征,将车辆声音数据转换为车辆时频数据。对车辆声音数据而言,由于不同的车辆声音属于会由于车况和路况等原因产生一定的差异,因此本实施例在对车辆声音数据进行特征提取之前,首先将车辆声音数据转换为车辆视频数据,以提高特征提取的效果。

[0071] 将车辆声音数据转换为车辆时频数据,具体包括以下步骤:

[0072] S2-1通过以下公式对车辆声音数据进行预加重处理,得到第一中间声音数据 $y_n$ ;

$$[0073] \quad y_n = x_n - ax_{n-1} \cdots \cdots (1)$$

[0074] 式(1)中, $x_n$ 是当前时刻的车辆声音数据, $x_{n-1}$ 是上一时刻的车辆声音数据, $a$ 是预设滤波系数。由于车辆声音信号在高频部分容易产生损失,因此本实施例通过预加重处理增加车辆声音数据在高频区间的分辨率。本实施例具体采用一阶高通滤波器进行预加重处理,滤波系数 $a$ 的取值介于0.9-1.0之间。

[0075] 预加重完成之后,为了对第一中间声音数据进行频谱估计,本实施例对第一中间声音数据应用多正弦窗函数进行频谱估计。

[0076] S2-2.通过以下公式对第一中间声音数据进行频谱估计,得到第二中间声音数据 $F_x(f)$ ;

$$[0077] \quad F_x(f) = \frac{\sum_{m=0}^{K-1} \cos(\frac{m}{K}\pi) + 1}{\sum_{m=0}^{K-1} \cos(\frac{m}{K}\pi) + 1} \times \left( \sum_{n=0}^{N-1} y_n \sqrt{\frac{2}{N+1}} \sin \frac{mn}{N+1} \pi \times e^{-K^2 f n \pi} \right)^2 \dots\dots (2)$$

[0078] 式(2)中,K多正弦窗函数的个数, $m=1,2,\dots,N$ ;N为采样点数。式(2)为离散傅里叶变换(Discrete Fourier Transform,DFT)的计算公式,其中, $\sqrt{\frac{2}{N+1}} \sin \frac{mn}{N+1}$ 为多正弦

窗函数, $\frac{\cos(\frac{m}{K}\pi) + 1}{\sum_{m=0}^{K-1} \cos(\frac{m}{K}\pi) + 1}$ 为多正弦窗函数的加权值。经实验,本实施例中K值取5-8,具体数值

根据车辆路况和车况确定;通过多个近似的正弦窗函数进行加权处理完成第一中间声音数据的频谱估计,能够得到方差更小,信号特征更稳定的第二中间声音数据。

[0079] 为了进一步提高信号特征的稳定性,本实施例在对第二中间声音数据进行梅尔滤波之前,首先对信号进行平滑处理。

[0080] S2-3.对第二声音中间数据进行平滑,得到第三声音中间数据。

[0081] 步骤S2-3具体包括以下步骤:

[0082] S2-3-1.将第二声音中间数据输入滑动平均滤波器,得到声音平滑数据;

[0083] S2-3-2.逐帧比较第二声音中间数据和声音平滑数据,取第二声音中间数据和声音平滑数据中的极大值作为新的第二声音中间数据;

[0084] S2-3-3.返回将第二声音中间数据输入滑动平均滤波器这一步骤,直至返回次数达到预设迭代次数;

[0085] S2-3-4.将最终得到的第二声音中间数据作为第三声音中间数据输出。

[0086] 本实施例滑动平均滤波器的函数表达式如下所示:

$$[0087] \quad u(i) = \frac{N-|i|}{N^2}$$

[0088] 其中,i取值介于-N-1和N+1之间,本实施例通过滑动平均滤波器对第二声音中间数据进行平滑,得到包络谱的近似表示,能够提高车辆声音数据的时间鲁棒性。

[0089] S2-4.将第三声音中间数据输入由以下公式构成的梅尔频率滤波器,得到车辆时频数据;

$$[0090] \quad \text{MEL}(f) = 2595 * \lg(1 + \frac{f}{700})$$

[0091] 式中f表示第三声音中间数据的实际频率。梅尔频率滤波器是由多个三角形滤波器组成的滤波器组,随着三角形滤波器数量的增多,三角形滤波器的宽度越宽,每个三角形滤波器的中心频率点的幅度为1,向两边线性衰减到0。将第三声音中间数据通过梅尔频率滤波器进行梅尔变换,使得车辆声音数据转换为车辆时频数据。

[0092] S3.将车辆时频数据输入第一特征提取模型,得到第一特征向量。

[0093] 本实施例中第一特征提取模型为时延神经网络(time delay neural network),采用由一维卷积层(Conv1D)、压缩激励残差网络层(Res2Net Block+Squeeze\_Excitation Block)和注意力统计池化层(Attentive Stat Pooling)构成的深度学习模型,特征提取流

程如图2所示。本实施例中压缩激励残差网络层为一层或多层,特征提取流程如图3所示。

[0094] 本实施例中将车辆时频数据输入第一特征提取模型,得到第一特征向量,具体包括以下步骤:

[0095] S3-1.通过一维卷积层对所述车辆时频数据进行卷积操作,得到车辆声音特征;一维卷积层的卷积操作主要是为了提取车辆时频数据中的有效特征。

[0096] S3-2.通过压缩激励残差网络层将所述车辆声音特征进行多层特征融合,提取出车辆声音特征的第一整体信息;本实施例中压缩激励残差网络层主要作用是通过残差连接对特征进行重叠,使得浅层特征可以直接传播到深层特征中,令信息前后传播更加顺畅;再进行密集连接,使得后面的每一层都可以直接得到前面所有层的信息,每一层都可以直接利用梯度信息,加强了特征的传递,更有效的利用特征。

[0097] S3-3.通过一维卷积层对所述车辆声音特征的第一整体信息进行卷积运算,得到第二整体信息;通过本步骤将多个压缩激励残差网络层的输出信息融合,能够加深网络,保留更多的声音浅层特征。

[0098] S3-4.通过注意力统计池化层压缩所述第二整体信息,得到关于车辆时频数据的第一特征向量。

[0099] S4.将车辆行驶数据输入第二特征提取模型,得到第二特征向量。

[0100] 步骤S4所使用第二特征提取模型具体为卷积神经网络(Convolution Neural Network,CNN)和双向长短期记忆网络(Bidirectional Long-Short Term Memory,BLSTM)相结合的深度学习模型,具体包括卷积池化层和双向长短期记忆网络层。第二特征提取模型的特征提取流程如图4所示,具体包括以下步骤:

[0101] S4-1.通过卷积池化层对所述车辆行驶数据进行卷积池化处理,得到车辆行驶特征;

[0102] S4-2.通过双向长短期记忆网络层对所述车辆行驶特征进行突出特征提取,得到车辆行驶突出特征;

[0103] S4-3.通过卷积池化层对所述车辆行驶数据进行池化处理,得到关于车辆行驶数据的第二特征向量。

[0104] 步骤S4中通过对车辆行驶数据进行卷积池化,得到多个车辆行驶特征;进一步使用BLSTM模型对车辆行驶特征进行计算,提取出其中较为突出的特征作为车辆行驶突出特征;将多个车辆行驶突出特征作为全连接层的输入,读取网络模型全连接层的权重,通过比较特征值之间的权重大小来判断是否保留该车辆行驶突出特征,如该特征值权重大于预设的车辆行驶特点特征值权重,则保留该特征值,否则剔除该特征,最终得到表征车辆行驶特点的第二特征向量。

[0105] 在一部分实施例中,步骤S4之前还包括以下步骤:

[0106] S4-0-1.在所述将车辆行驶数据输入第二特征提取模型之前,还包括以下步骤:

[0107] S4-0-2.对车辆行驶数据进行数据清洗,去除车辆行驶数据中的噪声;

[0108] S4-0-3.当所述车辆行驶数据中存在异常值时,通过线性插值法修订车辆行驶数据中的异常值;

[0109] S4-0-4.将车辆行驶数据作归一化处理。

[0110] 由于车辆行驶数据采集时可能由于路况或车况复杂造成部分异常值、缺失值和噪

声出现,因此需要在车辆行驶数据输入第二特征提取模型之前,对车辆行驶数据进行预处理。主要手段包括数据清洗和线性插值法,数据清洗是指对数据进行离散化后,将数据输入多个预设的数据判定区间中,并保留符合要求的一部分数据;线性插值法则具体是通过选取异常值前后的一个或多个行驶数据构造拟合曲线,利用最小二乘法计算异常值点的近似值,使用近似值替代异常值实现。

[0111] 本实施例中通过步骤S4-0对车辆行驶数据进行预处理,能够使得采集到的车辆行驶数据更平滑,反应车辆特征效果更好。

[0112] S5.将第一特征向量和第二特征向量进行拼接融合,得到第三特征向量。

[0113] 执行步骤S3-S4后,能够得到表征车辆行驶过程中声音数据的第一特征向量和行驶数据的第二特征向量。由于车辆的声音数据和行驶数据在时间维度上具有对应关系,因此步骤S5中将第一特征向量和第二特征向量在时间维度上进行拼接,融合为一个同时包含声音数据和行驶数据的第三特征向量,能够减少后续步骤S6故障分类的运算量,提高分类效率。

[0114] S6.将第三特征向量输入分类器,得到故障分类结果。

[0115] 步骤S6中,将第三特征向量输入分类器,得到故障分类结果,具体包括以下步骤:

[0116] S6-1.通过以下公式计算第三特征向量属于目标故障类别的概率:

$$[0117] \quad p_{ic} = \frac{e^{s(\cos(\theta_{c,i}+m))}}{e^{s(\cos(\theta_{c,i}+m))} + \sum_{j=1, j \neq c}^{CN} e^{s \cos \theta_{j,i}}}$$

[0118] 式中,c表示目标故障类别;i表示输入向量; $\theta_{c,i}$ 为权值矩阵中类别c对应的列向量 $W_c$ 与输入向量i之间的夹角;CN为类别个数,m为边缘角度,s为缩放因子;

[0119] S6-2.选择概率最高的目标故障类别作为第三特征向量的故障分类结果输出。

[0120] 步骤S6所使用分类器包括分别用于处理第三特征向量的全连接层和用于判别故障的AAM-Softmax层,通过上述公式计算第三特征向量属于目标故障类别的概率,选择概率最高的一项作为车辆的目标故障类别。

[0121] 在一部分实施例中,在完成车辆故障分类之后,上位机会根据故障所对应的编号,通过实体关系图在预设的数据库中调取与车辆故障相关的注意事项,输出具体的注意事项和维修指导等专业知识给用户。以使用户能根据上位机所提供知识对车辆进行维护和保养。

[0122] 本发明实施例通过车辆声音数据和行驶数据判断车辆故障类别。有助于进一步建立车辆声音与故障的关系,构建声音、行驶数据与故障的知识图谱,为驾驶人员或维修人员提供高效的故障判别方案。

[0123] 本发明实施例还公开了一种计算机程序产品或计算机程序,该计算机程序产品或计算机程序包括计算机指令,该计算机指令存储在计算机可读存储介质中。计算机设备的处理器可以从计算机可读存储介质读取该计算机指令,处理器执行该计算机指令,使得该计算机设备执行图1所示的方法。

[0124] 在一些可选择的实施例中,在方框图中提到的功能/操作可以不按照操作示图提到的顺序发生。例如,取决于所涉及的功能/操作,连续示出的两个方框实际上可以被大体上同时地执行或所述方框有时能以相反顺序被执行。此外,在本发明的流程图中所呈现和描述的实施例以示例的方式被提供,目的在于提供对技术更全面的理解。所公开的方法不

限于本文所呈现的操作和逻辑流程。可选择的实施例是可预期的,其中各种操作的顺序被改变以及其中被描述为较大操作的一部分的子操作被独立地执行。

[0125] 在本说明书的描述中,参考术语“一个实施例”、“一些实施例”、“示例”、“具体示例”、或“一些示例”等的描述意指结合该实施例或示例描述的具体特征、结构、材料或者特点包含于本发明的至少一个实施例或示例中。在本说明书中,对上述术语的示意性表述不一定指的是相同的实施例或示例。而且,描述的具体特征、结构、材料或者特点可以在任何的一个或多个实施例或示例中以合适的方式结合。

[0126] 尽管已经示出和描述了本发明的实施例,本领域的普通技术人员可以理解:在不脱离本发明的原理和宗旨的情况下可以对这些实施例进行多种变化、修改、替换和变型,本发明的范围由权利要求及其等同物限定。

[0127] 以上是对本发明的较佳实施进行了具体说明,但本发明并不限于所述实施例,熟悉本领域的技术人员在不违背本发明精神的前提下还可做出种种的等同变形或替换,这些等同的变形或替换均包含在本申请权利要求所限定的范围内。

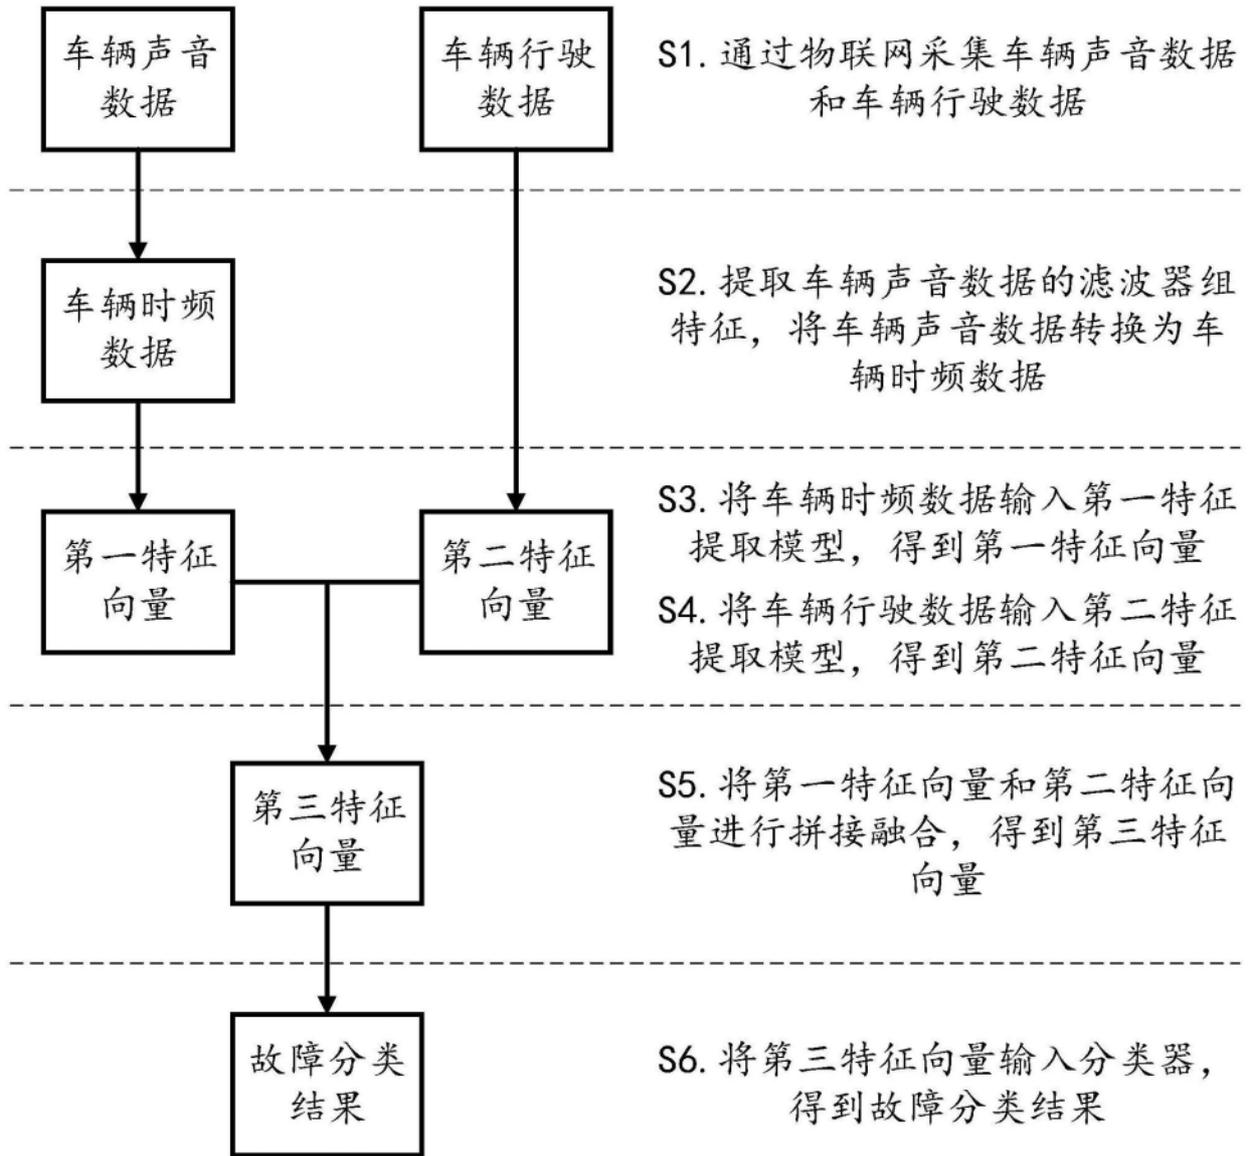


图1

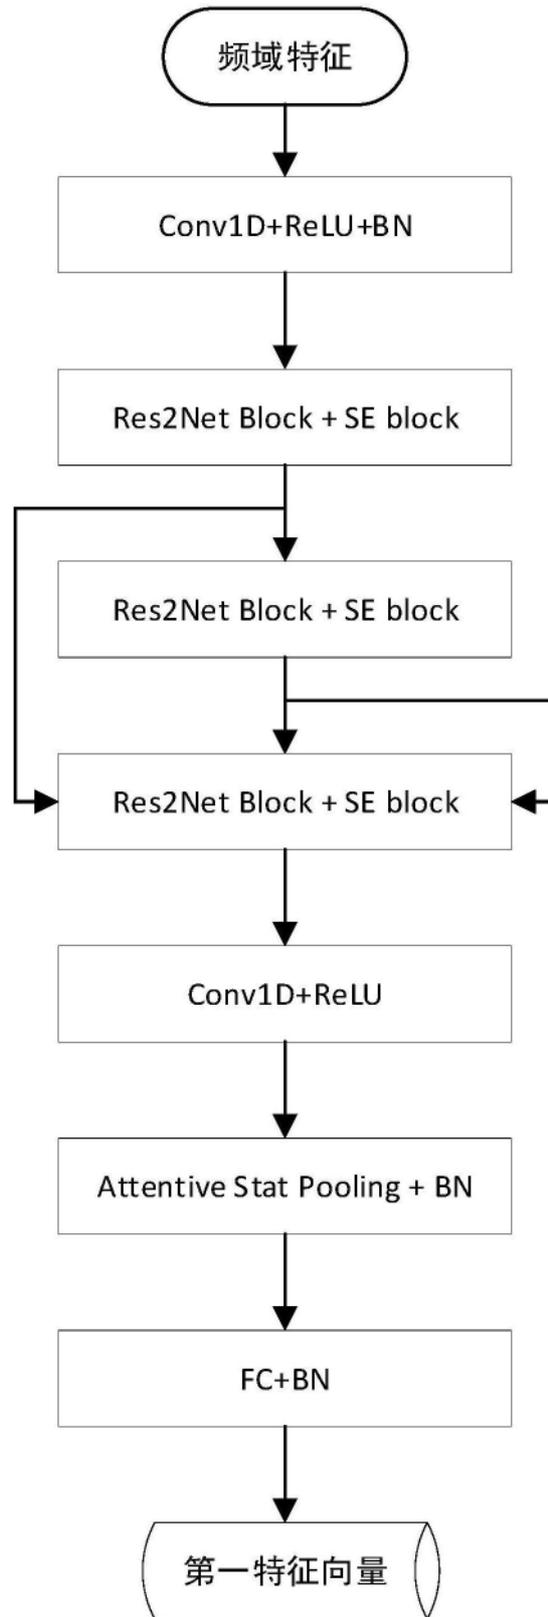


图2

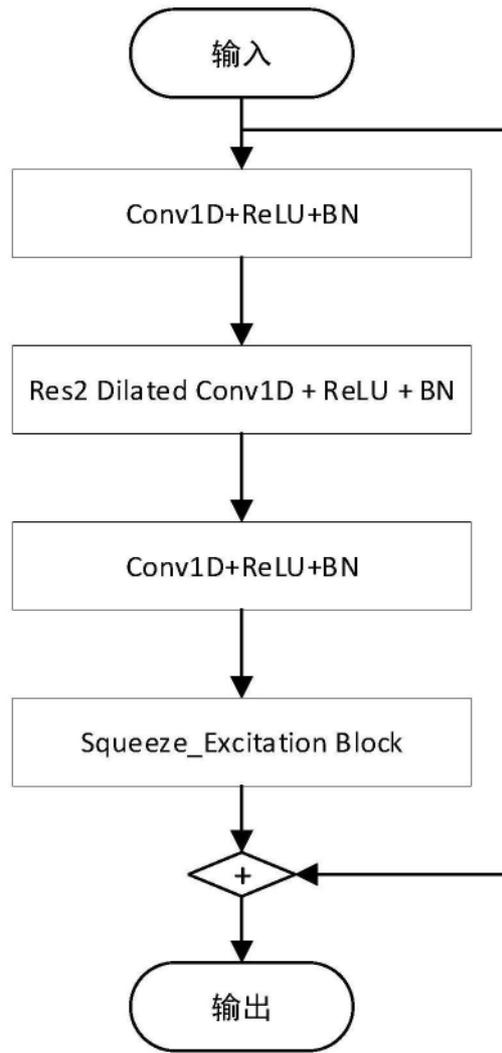


图3

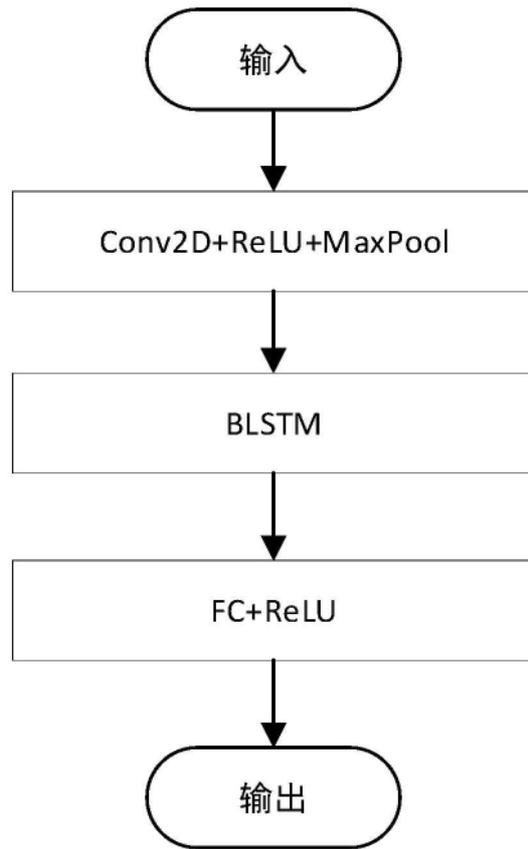


图4