



(10) 授权公告号 CN 116756881 B

(45) 授权公告日 2024. 01. 05

(21) 申请号 202311047801.9

(22) 申请日 2023.08.21

(65) 同一申请的已公布的文献号

申请公布号 CN 116756881 A

(43) 申请公布日 2023.09.15

(73) 专利权人 人工智能与数字经济广东省实验室(广州)

地址 510330 广东省广州市海珠区新港东路2429号首层自编051房

(72) 发明人 李巍华 陈佳鲜 黄如意 陈祝云 何国林

(74) 专利代理机构 广州科粤专利商标代理有限公司 44001

专利代理师 邓潮彬

(51) Int.Cl.

G06F 30/17 (2020.01)

G01M 13/04 (2019.01)

G06N 3/0442 (2023.01)

G06F 30/27 (2020.01)

G06F 119/04 (2020.01)

(56) 对比文件

CN 116090353 A, 2023.05.09

CN 112632466 A, 2021.04.09

CN 113962253 A, 2022.01.21

CN 109726524 A, 2019.05.07

CN 110197288 A, 2019.09.03

CN 114580705 A, 2022.06.03

WO 2023065220 A1, 2023.04.27

US 2019273509 A1, 2019.09.05

审查员 王雪琴


权利要求书3页 说明书9页 附图4页

(54) 发明名称

一种轴承剩余使用寿命预测方法、装置及存储介质

(57) 摘要

本发明公开了一种轴承剩余使用寿命预测方法、装置及存储介质。该方法结合了故障知识驱动和数据驱动的优势,利用多参数Wiener过程生成多条退化数据,充分考虑了退化模式的多样性;利用数据驱动的双向长短时记忆网络处理退化数据,提高剩余使用寿命的预测结果。在双向长短时记忆网络的隐藏层,使用最大均值差异计算新故障和已知故障的深度空间特征差异,并作为正则项输入到双向长短时记忆网络中,进行深度时序特征的提取和不同故障特征空间的适配,有利于深度挖掘通用的时序退化特征,更有利于剩余寿命的预测。相比于单一的数据驱动方法,本发明融合故障知识的剩余寿命预测方法可提供退化过程中的时序知识,其预测结果具有鲁棒性和工程实用性。



1. 一种故障知识联合数据驱动的轴承剩余使用寿命预测方法,其特征在于,所述方法包括:

将轴承新故障的测试数据输入到训练好的剩余寿命预测模型中,得到预测值;

所述训练好的剩余寿命预测模型通过如下方式得到:

获取轴承新故障数据,并设置多组Wiener过程的参数,以生成多条新故障退化数据;

将所述多条新故障退化数据和已知故障退化数据输入到收缩自编码网络中,得到新故障的深度空间特征和已知故障的深度空间特征;

将所述新故障的深度空间特征和已知故障的深度空间特征输入到双向长短时记忆网络中;

在所述双向长短时记忆网络的隐藏层,使用最大均值差异计算新故障和已知故障的深度空间特征差异,并作为正则项输入到所述双向长短时记忆网络中,进行深度时序特征的提取和不同故障特征空间的适配,构建得到剩余寿命预测模型

利用优化器对所述构建得到的剩余寿命预测模型进行训练,得到训练好的剩余寿命预测模型。

2. 如权利要求1所述的故障知识联合数据驱动的轴承剩余使用寿命预测方法,其特征在于,所述方法还包括:

对所得到的预测值采用平均绝对误差和均方根误差进行预测结果评估。

3. 如权利要求1所述的故障知识联合数据驱动的轴承剩余使用寿命预测方法,其特征在于,所述Wiener过程的参数包括漂移系数和扩散系数,通过系数的组合生成多条新故障退化数据;所述Wiener过程表达式为:

$$dS_t = \mu S_t dt + \eta S_t dB_t \quad (1)$$

其中, S_t 表示在 t 时刻的退化值; μ 表示反映退化率的漂移系数; η 是反映退化过程随机不确定性的扩散系数; B_t 是标准布朗运动;

对公式 (1) 进行欧拉离散化得到离散时间模型:

$$S_t = S_{t-\Delta t} e^{(\mu - \frac{1}{2}\sigma^2)\Delta t + \sigma \varepsilon_t \sqrt{\Delta t}} \quad (2)$$

其中, $S_{t-\Delta t}$ 表示在 $t - \Delta t$ 时刻的退化值; ε_t 服从正态分布。

4. 如权利要求1所述的故障知识联合数据驱动的轴承剩余使用寿命预测方法,其特征在于,所述收缩自编码网络其目标是学习退化数据的流形表示,提取深度空间特征,具体表达形式为:

$$J_{CAE}(\theta) = \sum_{x \in D_n} L(x, g(f(x))) + \lambda \|J_f(x)\|^2 \quad (3)$$

其中, x 是原始退化数据, $f(x) = s(Wx + b_h)$ 是编码函数, s 是激活函数, W 是权重矩阵, b_h 是偏置矩阵, h 表示隐藏层; $g(f(x))$ 是解码网络, L 是重构误差, λ 是控制正则

化强度的超参数; $\|J_f(x)\|^2$ 是关于输入 x 的 Jacobian 矩阵的 Frobenius 范数;

$$\|J_f(x)\|^2 = \sum_{j=1}^{d_h} \|h_j(1-h_j)W_j\|^2 \quad (4)$$

其中, d_h 表示隐藏层维度。

5. 如权利要求1所述的故障知识联合数据驱动的轴承剩余使用寿命预测方法, 其特征在于, 所述双向长短时记忆网络包括正序和逆序两个独立的长短时记忆网络单元, 每一个长短时记忆网络均包括输入门 $\mathbf{i}_t$, 输出门 $\mathbf{o}_t$, 遗忘门 $\mathbf{f}_t$, 记忆单元 $\mathbf{c}_t$, 和隐层状态 $\mathbf{h}_t$ 。

6. 如权利要求5所述的故障知识联合数据驱动的轴承剩余使用寿命预测方法, 其特征在于, 所述双向长短时记忆网络的表达形式为:

$$\begin{cases} \bar{\mathbf{i}}_t = \sigma(\bar{\mathbf{W}}_i \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_i \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_i) \\ \bar{\mathbf{f}}_t = \sigma(\bar{\mathbf{W}}_f \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_f \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_f) \\ \bar{\mathbf{o}}_t = \sigma(\bar{\mathbf{W}}_o \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_o \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_o) \\ \bar{\mathbf{c}}_t = \bar{\mathbf{f}}_t \odot \bar{\mathbf{c}}_{t-1} + \bar{\mathbf{i}}_t \odot \tanh(\bar{\mathbf{W}}_c \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_c \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_c) \\ \bar{\mathbf{h}}_t = \bar{\mathbf{o}}_t \odot \tanh(\bar{\mathbf{c}}_t) \end{cases} \quad (5)$$

$$\begin{cases} \bar{\mathbf{i}}_t = \sigma(\bar{\mathbf{W}}_i \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_i \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_i) \\ \bar{\mathbf{f}}_t = \sigma(\bar{\mathbf{W}}_f \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_f \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_f) \\ \bar{\mathbf{o}}_t = \sigma(\bar{\mathbf{W}}_o \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_o \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_o) \\ \bar{\mathbf{c}}_t = \bar{\mathbf{f}}_t \odot \bar{\mathbf{c}}_{t-1} + \bar{\mathbf{i}}_t \odot \tanh(\bar{\mathbf{W}}_c \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_c \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_c) \\ \bar{\mathbf{h}}_t = \bar{\mathbf{o}}_t \odot \tanh(\bar{\mathbf{c}}_t) \end{cases} \quad (6)$$

其中, $\mathbf{x}_t$ 表示 t 时刻的输入, $\mathbf{h}_{t-1}$ 表示 $t-1$ 时刻的隐层状态值; $\mathbf{W}_i$ 、 $\mathbf{W}_f$ 、 $\mathbf{W}_o$ 和 $\mathbf{W}_c$ 分别表示输入门、遗忘门、输出门和特征提取过程中 $\mathbf{x}_t$ 的权重系数; $\mathbf{V}_i$ 、 $\mathbf{V}_f$ 、 $\mathbf{V}_o$ 和 $\mathbf{V}_c$ 分别表示输入门、遗忘门、输出门和特征提取过程中 $\mathbf{h}_{t-1}$ 的权重系数; $\mathbf{b}_i$ 、 $\mathbf{b}_f$ 、 $\mathbf{b}_o$ 和 $\mathbf{b}_c$ 分别表示输入门、遗忘门、输出门和特征提取过程中的偏置项; $\tanh$ 表示正切双曲函数, σ 表示激活函数 Sigmoid; $\rightarrow$ 和 $\leftarrow$ 表示正向和逆向过程。

7. 如权利要求1所述的故障知识联合数据驱动的轴承剩余使用寿命预测方法, 其特征在于, 所述最大均值差异的具体表达式为:

$$MMD(X, Y) = \left\| \frac{1}{n} \sum_{i=1}^n \phi(x_i) - \frac{1}{m} \sum_{j=1}^m \phi(y_j) \right\|_H^2 \quad (7)$$

其中, X 和 Y 分别表示新故障和已知故障的特征分布, n 和 m 表示新故障和已知故障的样本数, H 表示希尔伯特空间。

8.如权利要求1所述的故障知识联合数据驱动的轴承剩余使用寿命预测方法,其特征在于,所述双向长短时记忆网络设置包括时间步长为5,输入维度为10,输出维度为1;

所述优化器为Adam优化器,Adam优化器的学习率为0.001,迭代次数为500。

9.一种故障知识联合数据驱动的轴承剩余使用寿命预测装置,包括存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序,其特征在于,所述处理器执行所述计算机程序时实现如权利要求1至8中任一所述方法的步骤。

10.一种计算机可读存储介质,所述计算机可读存储介质存储有计算机程序,其特征在于,所述计算机程序被处理器执行时实现如权利要求1至8中任一所述方法的步骤。

一种轴承剩余使用寿命预测方法、装置及存储介质

技术领域

[0001] 本发明涉及故障预测技术,具体涉及一种故障知识联合数据驱动的轴承剩余使用寿命预测方法、装置及存储介质。

背景技术

[0002] 专利文献CN 115828737 A提出了一种利用核函数把故障物理模型和数据驱动各自预测得到的电路板剩余寿命进行融合,得到融合后的剩余寿命,该方案主要包括两部分:

[0003] 故障物理模型方法:确定故障物理模型形式;利用维纳过程生成未来具有不确定性的退化数据;将故障物理模型获得的参数带入数据驱动模型进行寿命融合预测,并将预测的参数值转化为电路板剩余寿命值。

[0004] 数据驱动方法:利用全部监测到的退化参数和监测应力输入到神经网络算法中进行训练,利用生成的未来退化参数进行预测。

[0005] 上述方法主要存在如下的不足:

[0006] 1.上述通过核函数将物理模型和数据驱动方法得到的预测结果进行融合,属于决策层融合,在预测过程中为充分结合故障物理知识。

[0007] 2.上述利用神经网络的方法需要用到大量的数据,虽然上述方法利用维纳过程生成了具有不确定性的退化数据,但是未充分借助已有故障模式的退化知识,仅仅利用维纳过程生成的数据进行预测,数据的质量无法充分保证,需进一步融合已有知识,进行高质量的预测。

发明内容

[0008] 为了解决当轴承出现新故障时,由于没有历史积累数据,难以准确进行剩余寿命预测的问题,本发明提出一种故障知识联合数据驱动的剩余寿命预测方法、装置及存储介质,结合深度学习和迁移学习等人工智能技术,挖掘并迁移已有故障模式的退化知识解决新故障的剩余寿命预测问题

[0009] 为实现上述目的,本发明的技术方案是:

[0010] 第一方面,本发明提供一种故障知识联合数据驱动的轴承剩余使用寿命预测方法,所述方法包括:

[0011] 将轴承新故障的测试数据输入到训练好的剩余寿命预测模型中,得到预测值;

[0012] 所述训练好的剩余寿命预测模型通过如下方式得到:

[0013] 获取轴承新故障数据,并设置多组Wiener过程的参数,以生成多条新故障退化数据;

[0014] 将所述多条新故障退化数据和已知故障退化数据输入到收缩自编码网络中,得到新故障的深度空间特征和已知故障的深度空间特征;

[0015] 将所述新故障的深度空间特征和已知故障的深度空间特征输入到双向长短时记忆网络中;

[0016] 在所述双向长短时记忆网络的隐藏层,使用最大均值差异计算新故障和已知故障的深度空间特征差异,并作为正则项输入到所述双向长短时记忆网络中,进行深度时序特征的提取和不同故障特征空间的适配,构建得到剩余寿命预测模型

[0017] 利用优化器对所述构建得到的剩余寿命预测模型进行训练,得到训练好的剩余寿命预测模型。

[0018] 进一步地,所述方法还包括:

[0019] 对所得到的预测值采用平均绝对误差和均方根误差进行预测结果评估

[0020] 一步地,所述Wiener过程表达式为:

$$[0021] \quad dS_t = \mu S_t dt + \eta S_t dB_t \quad (1)$$

[0022] 其中, S_t 表示在 t 时刻的退化值; μ 表示反映退化率的漂移系数; η 是反映退化过程随机不确定性的扩散系数; B_t 是标准布朗运动。

[0023] 进一步地,对公式 (1) 进行欧拉离散化得到离散时间模型:

$$[0024] \quad S_t = S_{t-\Delta t} e^{(\mu - \frac{1}{2}\sigma^2)\Delta t + \sigma \varepsilon_t \sqrt{\Delta t}} \quad (2)$$

[0025] 其中, $S_{t-\Delta t}$ 表示在 $t - \Delta t$ 时刻的退化值; ε_t 服从正态分布。

[0026] 进一步地,所述收缩自编码网络其目标是学习退化数据的流形表示,提取深度空间特征,具体表达形式为:

$$[0027] \quad J_{CAE}(\theta) = \sum_{x \in D_n} L(x, g(f(x))) + \lambda \|J_f(x)\|^2 \quad (3)$$

[0028] 其中, x 是原始退化数据, $f(x) = s(Wx + b_h)$ 是编码函数, s 是激活函数, W 是权重矩阵, b_h 是偏置矩阵, h 表示隐藏层; $g(f(x))$ 是解码网络, L 是重构误差, λ 是控制正则化强度的超参数; $\|J_f(x)\|^2$ 是关于输入 x 的Jacobian矩阵的Frobenius范数。

$$[0029] \quad \|J_f(x)\|^2 = \sum_{j=1}^{d_h} \|h_j(1-h_j)W_j\|^2 \quad (4)$$

[0030] 其中, d_h 表示隐藏层维度。

[0031] 进一步地,所述双向长短时记忆网络包括正序和逆序两个独立的长短时记忆网络单元,每一个长短时记忆网络均包括输入门 i_t , 输出门 o_t , 遗忘门 f_t , 记忆单元 c_t , 和隐层状态 h_t 。

[0032] 进一步地,所述双向长短时记忆网络的表达形式为:

$$[0033] \quad \begin{cases} \bar{\mathbf{i}}_t = \sigma(\bar{\mathbf{W}}_i \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_i \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_i) \\ \bar{\mathbf{f}}_t = \sigma(\bar{\mathbf{W}}_f \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_f \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_f) \\ \bar{\mathbf{o}}_t = \sigma(\bar{\mathbf{W}}_o \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_o \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_o) \\ \bar{\mathbf{c}}_t = \bar{\mathbf{f}}_t \odot \bar{\mathbf{c}}_{t-1} + \bar{\mathbf{i}}_t \odot \tanh(\bar{\mathbf{W}}_c \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_c \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_c) \\ \bar{\mathbf{h}}_t = \bar{\mathbf{o}}_t \odot \tanh(\bar{\mathbf{c}}_t) \end{cases} \quad (5)$$

$$[0034] \quad \begin{cases} \bar{\mathbf{i}}_t = \sigma(\bar{\mathbf{W}}_i \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_i \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_i) \\ \bar{\mathbf{f}}_t = \sigma(\bar{\mathbf{W}}_f \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_f \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_f) \\ \bar{\mathbf{o}}_t = \sigma(\bar{\mathbf{W}}_o \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_o \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_o) \\ \bar{\mathbf{c}}_t = \bar{\mathbf{f}}_t \odot \bar{\mathbf{c}}_{t-1} + \bar{\mathbf{i}}_t \odot \tanh(\bar{\mathbf{W}}_c \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_c \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_c) \\ \bar{\mathbf{h}}_t = \bar{\mathbf{o}}_t \odot \tanh(\bar{\mathbf{c}}_t) \end{cases} \quad (6)$$

[0035] 其中, $\mathbf{x}_t$ 表示 t 时刻的输入, $\mathbf{h}_{t-1}$ 表示 $t-1$ 时刻的隐层状态值; $\mathbf{W}_i$ 、 $\mathbf{W}_f$ 、 $\mathbf{W}_o$ 和 $\mathbf{W}_c$ 分别表示输入门、遗忘门、输出门和特征提取过程中 $\mathbf{x}_t$ 的权重系数; $\mathbf{V}_i$ 、 $\mathbf{V}_f$ 、 $\mathbf{V}_o$ 和 $\mathbf{V}_c$ 分别表示输入门、遗忘门、输出门和特征提取过程中 $\mathbf{h}_{t-1}$ 的权重系数; $\mathbf{b}_i$ 、 $\mathbf{b}_f$ 、 $\mathbf{b}_o$ 和 $\mathbf{b}_c$ 分别表示输入门、遗忘门、输出门和特征提取过程中的偏置项; $\tanh$ 表示正切双曲函数, σ 表示激活函数 Sigmoid; $\rightarrow$ 和 $\leftarrow$ 表示正向和逆向过程。

[0036] 进一步地, 所述最大均值差异的具体表达式为:

$$[0037] \quad MMD(X, Y) = \left\| \frac{1}{n} \sum_{i=1}^n \phi(x_i) - \frac{1}{m} \sum_{j=1}^m \phi(y_j) \right\|_H^2 \quad (7)$$

[0038] 其中, X 和 Y 分别表示新故障和已知故障的特征分布, n 和 m 表示新故障和已知故障的样本数, H 表示希尔伯特空间。

[0039] 进一步地, 所述双向长短时记忆网络设置包括时间步长为 5, 输入维度为 10, 输出维度为 1;

[0040] 所述优化器为 Adam 优化器, Adam 优化器的学习率为 0.001, 迭代次数为 500。

[0041] 进一步地, 所述 Wiener 过程的参数包括漂移系数和扩散系数, 通过系数的组合生成多条新故障退化数据。

[0042] 第二方面, 本发明提供一种故障知识联合数据驱动的轴承剩余使用寿命预测装置, 包括存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序, 所述处理器执行所述计算机程序时实现如上任一所述方法的步骤。

[0043] 第三方面, 本发明提供一种计算机可读存储介质, 所述计算机可读存储介质存储有计算机程序, 所述计算机程序被处理器执行时实现如上任一所述方法的步骤。

[0044] 本发明与现有技术相比,其有益效果在于:

[0045] 本发明结合了故障知识驱动和数据驱动的优势,利用多参数Wiener过程生成多条退化数据,充分考虑了退化模式的多样性;利用数据驱动的双向长短时记忆网络处理退化数据,提高剩余使用寿命的预测结果。

[0046] 本发明在双向长短时记忆网络的隐藏层,使用最大均值差异计算新故障和已知故障的深度空间特征差异,并作为正则项输入到双向长短时记忆网络中,进行深度时序特征的提取和不同故障特征空间的适配,通过对新故障和已知故障的特征空间进行领域适配,有利于深度挖掘通用的时序退化特征,更有利于剩余寿命的预测。

附图说明

[0047] 图1是本发明实施例1提供的故障知识联合数据驱动的轴承新故障剩余寿命预测方法的算法流程图;

[0048] 图2是统计模型Wiener过程生成的退化数据示意图;

[0049] 图3是本发明实施例1提供的故障知识联合数据驱动的轴承新故障剩余寿命预测方法的网络结构示意图。

[0050] 图4是采用本发明实施例1提供的故障知识联合数据驱动的轴承新故障剩余寿命预测方法的网络的预测结果示意图;

[0051] 图5是采用本发明实施例1提供的故障知识联合数据驱动的轴承新故障剩余寿命预测方法的预测值误差示意图;

[0052] 图6为本发明实施例2提供的故障知识联合数据驱动的轴承新故障剩余寿命预测装置的组成示意图。

具体实施方式

[0053] 下面结合附图和实施例对本发明的技术方案做进一步的说明。

[0054] 实施例1:

[0055] 本实施例提供的故障知识联合数据驱动的轴承新故障剩余寿命预测方法,该方法通过结合故障知识驱动和数据驱动的优势,生成新故障的退化数据,并进一步学习深度特征表示,使得所构建的网络模型在只有已知故障的历史退化数据的情况下,也能够实现对新故障的剩余寿命预测。

[0056] 具体地,如图1所示,该方法包括如下步骤:

[0057] 步骤一:获取轴承新故障的少量数据,并设置多组Wiener(维纳)过程的参数,包括漂移系数和扩散系数,通过系数的组合生成多条新故障退化数据,尽可能涵盖新故障退化过程的多样性。

[0058] 步骤二:将多条新故障退化数据和已知故障退化数据输入到收缩自编码网络中,得到新故障的深度空间特征和已知故障的深度空间特征。其中,新故障退化数据和已知故障退化数据所输入的收缩自编码网络结构是一致的

[0059] 步骤三:将新故障的深度空间特征和已知故障的深度空间特征继续输入到双向长短时记忆网络中。其中,双向长短时记忆网络结构设置包括时间步长为5,输入维度为10,输出维度为1。

[0060] 步骤四：在双向长短时记忆网络的隐藏层，使用最大均值差异计算新故障和已知故障的深度空间特征差异，并作为正则项输入到双向长短时记忆网络中，进行深度时序特征的提取和不同故障特征空间的适配，构建得到剩余寿命预测模型。

[0061] 步骤五：利用优化器对上述构建的剩余寿命预测模型进行训练，得到训练好的剩余寿命预测模型。

[0062] 步骤六：将新故障的测试数据输入到训练好的剩余寿命预测模型中，得到预测值。

[0063] 由此可见，本发明结合了故障知识驱动和数据驱动的优势，利用多参数Wiener过程生成多条退化数据，充分考虑了退化模式的多样性；利用数据驱动的双向长短时记忆网络处理退化数据，提高剩余使用寿命的预测结果，可以提取故障的深度空间特征和时序特征，这些特征可以充分表达故障特性，通过对新故障和已知故障的特征空间进行领域适配，有利于深度挖掘通用的时序退化特征，更有利于剩余寿命的预测。

[0064] 在一具体实施例中，步骤一中，该Wiener过程的参数包括漂移系数和扩散系数，通过系数的组合生成多条新故障退化数据；利用统计模型Wiener过程生成退化数据，描述新故障多样的退化过程；其中Wiener过程表达式为：

$$[0065] \quad dS_t = \mu S_t dt + \eta S_t dB_t \quad (1)$$

[0066] 其中， S_t 表示在 t 时刻的退化值； μ 表示反映退化率的漂移系数； η 是反映退化过程随机不确定性的扩散系数； B_t 是标准布朗运动。进一步地，对公式(1)进行欧拉离散化可以得到离散时间模型：

$$[0067] \quad S_t = S_{t-\Delta t} e^{(\mu - \frac{1}{2}\sigma^2)\Delta t + \sigma \varepsilon_t \sqrt{\Delta t}} \quad (2)$$

[0068] 其中， $S_{t-\Delta t}$ 表示在 $t - \Delta t$ 时刻的退化值； ε_t 服从正态分布(期望为0，方差为1)；

[0069] 在一具体实施例中，步骤二构建的收缩自编码模型，其目标是学习退化数据的流形表示，提取深度故障特征，具体表达形式为：

$$[0070] \quad J_{CAE}(\theta) = \sum_{x \in D_n} L(x, g(f(x))) + \lambda \|J_f(x)\|^2 \quad (3)$$

[0071] 其中， x 是原始退化数据， $f(x) = s(Wx + b_h)$ 是编码函数， s 是激活函数， W 是权重矩阵， b_h 是偏置矩阵， h 表示隐藏层； $g(f(x))$ 是解码网络， L 是重构误差， λ 是控制正则化强度的超参数。

$$[0072] \quad \|J_f(x)\|^2 = \sum_{j=1}^{d_h} \|h_j(1-h_j)W_j\|^2 \quad (4)$$

[0073] 其中， $\|J_f(x)\|^2$ 是关于输入 x 的Jacobian矩阵的Frobenius范数，目的是学习具有强收缩作用的特征表示， d_h 表示隐藏层维度。

[0074] 在一具体实施例中,步骤三构建的双向长短时记忆网络,其网络构设置包括时间步长为5,输入维度为10,输出维度为1,其目标是学习退化数据的深度时序特征表示,具体得说,双向长短时记忆网络包括正序和逆序两个独立的长短时记忆网络单元,每一个长短时记忆网络均包括输入门 $\mathbf{i}_t$,输出门 $\mathbf{o}_t$,遗忘门 $\mathbf{f}_t$,记忆单元 $\mathbf{c}_t$,和隐层状态 $\mathbf{h}_t$ 。其表达形式为:

$$[0075] \quad \begin{cases} \bar{\mathbf{i}}_t = \sigma(\bar{\mathbf{W}}_i \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_i \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_i) \\ \bar{\mathbf{f}}_t = \sigma(\bar{\mathbf{W}}_f \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_f \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_f) \\ \bar{\mathbf{o}}_t = \sigma(\bar{\mathbf{W}}_o \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_o \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_o) \\ \bar{\mathbf{c}}_t = \bar{\mathbf{f}}_t \odot \bar{\mathbf{c}}_{t-1} + \bar{\mathbf{i}}_t \odot \tanh(\bar{\mathbf{W}}_c \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_c \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_c) \\ \bar{\mathbf{h}}_t = \bar{\mathbf{o}}_t \odot \tanh(\bar{\mathbf{c}}_t) \end{cases} \quad (5)$$

$$[0076] \quad \begin{cases} \bar{\mathbf{i}}_t = \sigma(\bar{\mathbf{W}}_i \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_i \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_i) \\ \bar{\mathbf{f}}_t = \sigma(\bar{\mathbf{W}}_f \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_f \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_f) \\ \bar{\mathbf{o}}_t = \sigma(\bar{\mathbf{W}}_o \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_o \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_o) \\ \bar{\mathbf{c}}_t = \bar{\mathbf{f}}_t \odot \bar{\mathbf{c}}_{t-1} + \bar{\mathbf{i}}_t \odot \tanh(\bar{\mathbf{W}}_c \bar{\mathbf{x}}_t + \bar{\mathbf{V}}_c \bar{\mathbf{h}}_{t-1} + \bar{\mathbf{b}}_c) \\ \bar{\mathbf{h}}_t = \bar{\mathbf{o}}_t \odot \tanh(\bar{\mathbf{c}}_t) \end{cases} \quad (6)$$

[0077] 其中, $\mathbf{x}_t$ 表示 t 时刻的输入, $\mathbf{h}_{t-1}$ 表示 $t-1$ 时刻的隐层状态值; $\mathbf{W}_i$ 、 $\mathbf{W}_f$ 、 $\mathbf{W}_o$ 和 $\mathbf{W}_c$ 分别表示输入门、遗忘门、输出门和特征提取过程中 $\mathbf{x}_t$ 的权重系数; $\mathbf{V}_i$ 、 $\mathbf{V}_f$ 、 $\mathbf{V}_o$ 和 $\mathbf{V}_c$ 分别表示输入门、遗忘门、输出门和特征提取过程中 $\mathbf{h}_{t-1}$ 的权重系数; $\mathbf{b}_i$ 、 $\mathbf{b}_f$ 、 $\mathbf{b}_o$ 和 $\mathbf{b}_c$ 分别表示输入门、遗忘门、输出门和特征提取过程中的偏置项; $\tanh$ 表示正切双曲函数, σ 表示激活函数Sigmoid; $\rightarrow$ 和 $\leftarrow$ 表示正向和逆向过程。

[0078] 在一具体实施例中,步骤四构建的最大均值差异适配项,其目标是减小新故障和已知故障的特征空间分布差异,学习域无关的退化时序特征,最大均值差异的具体表达式为:

$$[0079] \quad MMD(X, Y) = \left\| \frac{1}{n} \sum_{i=1}^n \phi(x_i) - \frac{1}{m} \sum_{j=1}^m \phi(y_j) \right\|_H^2 \quad (7)$$

[0080] 其中, X 和 Y 分别表示新故障和已知故障的特征分布, n 和 m 表示新故障和已知故障的样本数, H 表示希尔伯特空间。

[0081] 在一具体实施例中,步骤五构建基于故障知识联合数据驱动的轴承新故障剩余寿命预测模型,并利用Adam优化器进行模型的训练与优化,Adam优化器的学习率为0.001,迭

代次数为500。在训练过程中,仅仅需要新故障的生成退化数据和已知故障的历史退化数据,就可实现对新故障的剩余寿命预测。

[0082] 在一具体实施例中,在步骤六中,针对新故障监测数据,输入到训练好的剩余寿命模型中,即可得到剩余寿命预测值;最后,还可以利用平均绝对误差和均方根误差进行预测

结果量化评价,均方根误差计算公式为 $RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2}$;平均绝对误差计算

公式为 $MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i|$,其中 N 为样本个数; $\hat{y}_i$ 为真实值; y_i 为预测值。

[0083] 轴承是旋转机械的重要部件之一,为了验证本发明所提方法的有效性,以XJTU-SY的轴承数据集为例,开展轴承新故障的剩余寿命预测实验。

[0084] 1、XJTU-SY数据集的实验对象是LDK UER204滚动轴承,共设计了三种实验工况,并在每种工作条件下开展了5组实验。工况一的转速为2100rpm,负载为12kN;工况二的转速为2250rpm,负载为11kN;工况三的转速为2400rpm,负载为11kN。本发明所用到的实验设置如表1所示。

表 1 XJTU-SY 数据集信息

	轴承	故障模式
[0085] 训练集	Bearing1_1	1
	Bearing1_2	1
测试集	Bearing2_1	3

[0086] 其中Bearing1_1中第一个1表示工况1,第二个1表示第一个轴承,以此类推。

[0087] 2、新故障退化数据的生成。如图2所示,将测试集少量的新故障数据输入到构建的Wiener过程模型中,通过设置6组参数,可以生成6条不同的退化数据。

[0088] 3、同时将生成的新故障退化数据和已知故障的历史数据输入到构建的剩余寿命预测模型中,其中收缩自编码模块负责提取深度空间特征,双向长短时记忆网络模块负责提取深度时序特征,最大均值差异模块负责减少新故障和已知故障的特征空间分布差异。通过Adam优化器对上述网络进行模型训练,其中Adam的学习率为0.001,迭代次数为500。所构建的基于故障知识联合数据驱动的轴承剩余寿命预测模型网络结构如图3所示。

[0089] 4、将监测到的新故障测试数据输入到上述训练好的故障知识联合数据驱动的轴承剩余寿命预测模型中,其预测结果如图4所示。

[0090] 5、本发明所提出的方法和仅使用Wiener过程生成的数据直接进行预测的对比结果如图5所示。同时,利用评价指标平均绝对误差和均方根误差验证本发明所提方法的有效性,其结果如表2所示。

表 2 预测结果量化对比

	RMSE	MAE
[0091] 本发明所提方法	0.10	0.08
仅使用 Wiener 过程	0.37	0.62

[0092] 由此可见,本发明提供的基于故障知识联合数据驱动的轴承新故障剩余寿命预测方法,结合具体故障知识和数据驱动模型强大的特征学习能力,可提高剩余寿命预测的准确度。

[0093] 实施例2:

[0094] 参阅图6所示,本实施例提供的故障知识联合数据驱动的轴承剩余使用寿命预测装置包括处理器61、存储器62以及存储在该存储器62中并可在所述处理器61上运行的计算机程序63,例如故障知识联合数据驱动的轴承剩余使用寿命预测程序。该处理器61执行所述计算机程序63时实现上述实施例1步骤。

[0095] 示例性的,所述计算机程序63可以被分割成一个或多个模块/单元,所述一个或者多个模块/单元被存储在所述存储器62中,并由所述处理器61执行,以完成本发明。所述一个或多个模块/单元可以是能够完成特定功能的一系列计算机程序指令段,该指令段用于描述所述计算机程序63在所述故障知识联合数据驱动的轴承剩余使用寿命预测装置中的执行过程。

[0096] 所述故障知识联合数据驱动的轴承剩余使用寿命预测装置可以是桌上型计算机、笔记本、掌上电脑及云端服务器等计算设备。所述故障知识联合数据驱动的轴承剩余使用寿命预测装置可包括,但不仅限于,处理器61、存储器62。本领域技术人员可以理解,图6仅仅是故障知识联合数据驱动的轴承剩余使用寿命预测装置的示例,并不构成故障知识联合数据驱动的轴承剩余使用寿命预测装置的限定,可以包括比图示更多或更少的部件,或者组合某些部件,或者不同的部件,例如所述故障知识联合数据驱动的轴承剩余使用寿命预测装置还可以包括输入输出设备、网络接入设备、总线等。

[0097] 所称处理器61可以是中央处理单元(Central Processing Unit,CPU),还可以是其他通用处理器、数字信号处理器(Digital Signal Processor,DSP)、专用集成电路(Application Specific Integrated Circuit,ASIC)、现成可编程门阵列(FieldProgrammable Gate Array,FPGA)或者其他可编程逻辑器件、分立门或者晶体管逻辑器件、分立硬件组件等。通用处理器可以是微处理器或者该处理器也可以是任何常规的处理器等。

[0098] 所述存储器62可以是所述故障知识联合数据驱动的轴承剩余使用寿命预测装置的内部存储单元,例如故障知识联合数据驱动的轴承剩余使用寿命预测装置的硬盘或内存。所述存储器62也可以是所述故障知识联合数据驱动的轴承剩余使用寿命预测装置的外部存储设备,例如所述故障知识联合数据驱动的轴承剩余使用寿命预测装置上配备的插接式硬盘,智能存储卡(SmartMedia Card,SMC),安全数字(Secure Digital,SD)卡,闪存卡(Flash Card)等。进一步地,所述存储器62还可以既包括所述故障知识联合数据驱动的轴承剩余使用寿命预测装置的内部存储单元也包括外部存储设备。所述存储器62用于存储所

述计算机程序以及所述故障知识联合数据驱动的轴承剩余使用寿命预测装置所需的其他程序和数据。所述存储器62还可以用于暂时地存储已经输出或者将要输出的数据。

[0099] 实施例3:

[0100] 本实施例提供了一种计算机可读存储介质,所述计算机可读存储介质存储有计算机程序,所述计算机程序被处理器执行时实现实施例1所述方法的步骤。

[0101] 所示计算机可读介质可以是任何可以包含、存储、通信、传播或传输程序以供指令执行系统、装置或设备或结合这些指令执行系统、装置或设备而使用的装置。计算机可读介质的更具体的示例(非穷尽性列表)包括以下:具有一个或多个布线的电连接部(电子装置),便携式计算机盘盒(磁装置),随机存取存储器(RAM),只读存储器(ROM),可擦除可编程只读存储器(EPROM或闪速存储器),光纤装置,以及便携式光盘只读存储器(CDROM)。另外,计算机可读介质甚至可以是可在其上打印所述程序的纸或其他合适的介质,例如通过对纸或其他介质进行光学扫描,接着进行编辑、解译或必要时以其他合适方式进行处理再以电子方式获得所述程序,然后将其存储在计算机存储器中。

[0102] 上述实施例只是为了说明本发明的技术构思及特点,其目的是在于让本领域内的普通技术人员能够了解本发明的内容并据以实施,并不能以此限制本发明的保护范围。凡是根据本发明内容的实质所做出的等效的变化或修饰,都应涵盖在本发明的保护范围内。




图 1




图 2




图 3




图 4




图 5




图 6