

(19) 中华人民共和国国家知识产权局



(12) 发明专利说明书

(10) 申请公布号 CN 109376892 A

(43) 申请公布日 2019.02.22

(21) 申请号 CN201810600330.2

(22) 申请日 2018.06.12

(71) 申请人 电子科技大学

地址 611731 四川省成都市高新区(西区)西源大道 2006 号

(72) 发明人 李波 张浩

(74) 专利代理机构 电子科技大学专利中心

代理人 陈一鑫

(51) Int. CI

权利要求说明书 说明书 幅图

(54) 发明名称

一种基于设备所处生命周期阶段的
设备状态预测方法

(57) 摘要

该发明公开了一种基于设备所处生命周期阶段的设备状态预测方法，涉及数据处理领域，具体是结合设备生命周期理论对设备特定状态指标进行预测的方法。针对现有设备远程监测系统的不足，提供了一种基于设备所处生命周期阶段的设备状态预测方法。本方法针对传统的远程监

测系统未考虑设备长期使用过程中故障率呈阶段性变化的特性进行改进，引入设备生命周期理论用来描述被监测设备在不同生命周期阶段中的故障率表现，并根据监测的状态数据进一步对 ARIMA SVR 组合预测模型做出改进，提高对设备未来状态的预测精度。

法律状态

法律状态公告日

法律状态信息

法律状态

2021-11-02

授权

授权

2019-03-19

实质审查的生效

实质审查的生效

2019-02-22

公开

公开

权利要求说明书

1.一种基于设备所处生命周期阶段的设备状态预测方法,该方法包括:

步骤 1:将设备的生命周期分为磨合期 q

1

、健壮期 q

2

、衰退期 q

3

三个状态;

步骤 2:根据监测数据使用隐马尔可夫模型判断设备所处生命周期阶段,并确定其对应的影响因子;

步骤 3:根据步骤 2 中求得的设备生命周期影响因子对 ARIMA-SVR 组合预测模型进行改进,依据状态监测数据预测设备未来状态信息。

步骤 2:根据监测数据使用隐马尔可夫模型判断设备所处生命周期阶段,并确定其对应的影响因子;

步骤 2.1 模型学习:依据设备历史监测数据,使用 Baum-Welch 算法对隐马尔可夫模型 $\lambda = (\pi, A, B)$ 各参数进行估计;

给定模型初始参数 λ

0

$= \{ \pi$

0

, A

0

, B

0

$\}$, π 为隐含状态初始概率分布,即初始状态 q

i

对应的概率为 π

i

, A 为状态转移概率矩阵, B 为观测状态概率矩阵; 递推 Baum-Welch 算法对参数估计公式为:

其中,

表示状态转移概率矩阵 A 中的第 (i, j) 元素的估计值,

表示观测状态概率矩阵 B 状态为 j 观测为 k 的概率估计值,

表示状态 q_i

i

对应概率的估计值, \hat{a}_{ij}

t

表示 t 时刻观测值, v_t

k

表示观测值为 k, T 表示总时间, ξ

t

(i, j) 表示给定观测序列 O 及隐马尔可夫模型的前提下 t 时刻为隐含状态为 q_i

i

及 t+1 时刻为隐含状态 q_j

j

的概率, $\gamma_{ij}(t)$

t

(i, j) 表示给定观测序列 O 及隐马尔可夫模型的前提下 t 时刻为隐含状态 q_i

i

的概率;

使用 Baum-Welch 算法计算所得的

作为新的初始参数,迭代使用 Baum-Welch 算法计算 π 、 A 、 B 的值,直到达到收敛误差或最大迭代步长,最终确定模型各参数最后估计值;

步骤 2.2 在步骤 2.1 隐马尔可夫模型估计参数的基础上 $\lambda = (\pi, A, B)$ 新的观测序列

$O = (o$

1

, o

2

, ..., o

T

), 使用 Viterb 算法计算观测序列对应的最优隐含状态序列

其中

表示 t 时刻最优隐含状态;

步骤 2.3 以 π

i

作为每个生命周期阶段对应的影响度,且设备所处生命周期阶段判定为最优隐含状态序列中出现次数最多的状态;影响因子为

其中,

为状态

对应的初始概率, T 为总时间;

步骤 3: 根据步骤 2 中求得的设备生命周期影响因子对 ARIMA-SVR 组合预测模型进行改进,依据状态监测数据预测设备未来状态信息;

步骤 3.1 通过现有监测数据,使用自回归积分滑动平均模型 ARIMA(p, d, q) 进行预测,

得到观测值的预测值

步骤 3. 1. 1. 监测数据监测序列平稳化处理;采用 ADF 方法验证监测序列是否平稳,如果序列不满足平稳条件,则通过差分操作使其符合平稳性监测序列的条件;

步骤 3. 1. 2. 模型识别;通过平稳化后的监测序列的自相关系数 ACF 和偏自相关系数 PACF 是否拖尾或者截尾来确定选用的模型,并最终确定模型的阶数 p 和 q ;模型的选择方法为:

若自相关系数 ACF 拖尾和偏自相关系数 PACF p 阶截尾,则选择自回归模型 $AR(p)$;

若自相关系数 ACF q 阶截尾和偏自相关系数 PACF 拖尾,则选择滑动平均模型 $MA(q)$;

若自相关系数 ACF 拖尾和偏自相关系数 PACF 拖尾,则选择自回归滑动平均模型 $ARMA(p, q)$;

步骤 3. 1. 3. 使用最小二乘法进行对参数 p, q, d 进行估计以及对模型选择是否正确进行诊断;

步骤 3. 1. 4. 使用得到的模型对已获得的监测序列进行预测;其 $ARIMA(p, d, q)$ 模型公式如下;

其中,其中 Δ

d

y

t

表示 y

t

经 d 次差分转换后的监测序列, ε

t

表示 t 时刻的随机误差,是相互独立的白噪声监测序列,并且服从标准正态分布; ϕ

i

($i=1, 2, \dots$ 和 p)

j

($j=1, 2, \dots$ 表示模型的待估参数, p 和 q 为模型的阶数;通过模型可以根据现有状态监测数据的监测序列对未来时刻进行预测;

步骤 3.2 计算 ARIMA 模型的预测残差

其中 x

t

为 t 时刻真实值,

为步骤 3.1 得到的 t 时刻的预测值;

步骤 3.3 使用 SVR 模型对得到的预测残差进行预测,得到预测结果

步骤 3.3. 构造高维中的回归函数 $f(x) = \omega$

T

$\phi(x) +$ 其中 ω

T

为权重矢量, ϕ (表示将输入向量 x 映射为特征空间向量, b 为阈值;

步骤 3.3. 引入不敏感损失函数 $\varepsilon > 0$ 转化为优化目标函数;

满足约束条件

其中,其中 $C > 0$ 为惩罚参数,表示函数回归模型的复杂度和样本拟合精度综合评定值,值越小表示拟合效果越差, ξ

i

,

为松弛变量;

步骤 3.3.3 引入拉格朗日乘子 α

i

和

及核函数,转化为等价对偶问题;

满足约束条件

其中, l 为训练样本的个数, $K(x$

i

, x

j

)为核函数,实现高维映射的同时又不会增加可调参数的个数;常见的核函数如下:

步骤 3.3.4 得到回归函数,并进行计算残差

回归函数如下

步骤 3.3.5 对得到的残差,引入生命周期影响因子进行修正;

步骤 3.3. 将 ARIMA 预测值

与 SVR 及生命周影响因子修正的残差预测值

求和,得到最终的预测值

2.如权利要求 1 所述的一种基于设备所处生命周期阶段的设备状态预测方法,其特征
在于所述步骤 2.2 的具体步骤如下:

初始化 δ

1

$(i) = \pi$

i

b

i

$(o$

1

) $i=1, 2, \dots, N$

ψ

1

$(i)=0 i=1, 2, \dots, N$

其中 δ

1

(i 表示 $t=1$ 时刻状态为 i 的所有单个路径(i

1

, i

2

, ..., i

t

)中概率最大值, π

i

表示状态 q

i

对应概率, b

i

(o

1

)表示隐含状态为 i 观测值为 o

1

的概率, N 表示隐含状态的个数, ψ

1

(i 表示 $t=1$ 时刻状态为 i 的所有单个路径(i

1

, i

2

, ..., i

t

)中概率最大的路径的第 $t-1$ 个节点;

递推对 $t=2, 3, \dots, T$

其中 a

j_i

表示状态转移概率矩阵 A 中的第 (i, j) 的元素值;

终止

其中 P

*

表示最优路径的概率,

表示 T 时刻最优隐含状态;

最优路径回溯,对 $t=T-1, T-2, \dots, 1$

得最优路径

3.如权利要求 1 所述的一种基于设备所处生命周期阶段的设备状态预测方法,其特征
在于所述步骤 3.1. 的方法为:

Δy

t

$=X$

t

$-X$

$t-1$

$(t>1)$

Δ

2

y

t

$= \Delta y$

t

$-\Delta y$
 $t-1$
 $(t>2)$

Δ
 d
 y
 t
 $=\Delta$
 $d-1$
 y
 t
 $-\Delta$
 $d-1$
 y
 $t-1$
 $(t>d)$

其中, Δ

d
 y
 t

为经过 d 次差分所得的 t 时刻的值, X

t
、 X
 $t-1$

分别表示 $t, t-1$ 时刻原始时间序列的值。

4.如权利要求 1 所述的一种基于设备所处生命周期阶段的设备状态预测方法,其特征

在于所述步骤 3.3.3 中采用的核函数为下列其中的一种：

1) 线性核函数： $k(x, y) = x \cdot y$, γ 表示核函数参数；

2) 多项式核函数： $k(x, y) = (\gamma (x \cdot y) + c)^d$

d

, 默认值为 $1/k$, k 为类别数、 c 表示参数值默认为 0、 d 表示最高项次数；

3) RBF 高斯径向基核函数： $k(x, y) = \exp(-\frac{\gamma}{2} \|x - y\|^2)$

2

), 默认值为 $1/k$, 为类别数；

4) 多层感知机 Sigmoid 核函数： $k(x, y) = \tanh(\gamma * x \cdot y + c)$, 默认值为 $1/k$, k 为类别数, \tanh 表示双曲正切函数, c 表示参数值默认为 0。

说明书

<p>技术领域

本发明涉及数据处理领域,具体是结合设备生命周期理论对设备特定状态指标进行预测的方法。

背景技术

当前随着信息技术和计算机网络技术的发展,设备远程监测系统已经广泛运用到企业生产设备管理中,利用生产设备上的传感器实时传送被监测设备的状态数据,便于管理者对设备的运行状态进行实时掌控,正因如此设备远程监测系统扮演着越来越重要的角色。

然而为了应对设备将来有可能出现的故障问题,企业在更好地获知设备现在时刻运行状态的基础上,也亟需对设备未来运行状态进行估计。但传统的监测系统很少会考虑设备在长期运行中的故障率呈阶段性变化的特性,仅仅通过监测到的设备状态监测序列数据对设备未来状态进行预测,忽视了设备自身所处阶段的故障率表现,这就使得预测精准度有所欠缺。

发明内容

本发明针对现有设备远程监测系统的不足,提供了一种基于设备所处生命周期阶段的设备状态预测方法。本方法针对传统的远程监测系统未考虑设备长期使用过程中故障率呈阶段性变化的特性进行改进,引入设备生命周期理论用来描述被监测设备在不同生命周期阶段中的故障率表现,并根据监测的状态数据进一步对 ARIMA-SVR 组合预测模型做出改进,提高对设备未来状态的预测精度。

本发明的技术方案是一种基于设备所处生命周期阶段的设备状态预测方法,该方法

包括:

步骤 1:将设备的生命周期分为磨合期 q

1

、健壮期 q

2

、衰退期 q

3

三个状态;

步骤 2:根据监测数据使用隐马尔可夫模型 (HiddenMarkovModel, HMM) 判断设备所处生命周期阶段,并确定其对应的影响因子;

步骤 3:根据步骤 2 中求得的设备生命周期影响因子对 ARIMA-SVR(自回归积分滑动平均-支持向量回归)组合预测模型进行改进,依据状态监测数据预测设备未来状态信息。

步骤 2:根据监测数据使用隐马尔可夫模型 (HMM) 判断设备所处生命周期阶段,并确定其对应的影响因子;

步骤 2.1模型学习:依据设备历史监测数据,使用 Baum-Welch(鲍姆-韦尔奇)算法对隐马尔可夫模型 $\lambda = (\pi, A, B)$ 各参数进行估计;

给定模型初始参数 λ

0

$= \{ \pi$

0

, A

0

, B

0

}, π 为隐含状态初始概率分布, 即初始状态 q

i

对应的概率为 π

i

, A 为状态转移概率矩阵, B 为观测状态概率矩阵; 递推 Baum-Welch 算法对参数估计公式为:

其中,

表示状态转移概率矩阵 A 中的第 (i, j) 元素的估计值,

表示观测状态概率矩阵 B 状态为 j 观测为 k 的概率估计值,

表示状态 q

i

对应概率的估计值, o

t

表示 t 时刻观测值, v

k

表示观测值为 k , T 表示总时间, ξ

t

(i , 表示给定观测序列 O 及隐马尔可夫模型的前提下 t 时刻为隐含状态为 q

i

及 $t+1$ 时刻为隐含状态 q

j

的概率, γ

t

(i 表示给定观测序列 O 及隐马尔可夫模型的前提下 t 时刻为隐含状态 q

i

的概率;

使用 Baum-Welch 算法计算所得的

作为新的初始参数,迭代使用 Baum-Welch 算法计算 π 、 A 、 B 的值,直到达到收敛误差或最大迭代步长,最终确定模型各参数最后估计值;

步骤 2.2在步骤 2.1隐马尔可夫模型估计参数的基础上 $\lambda = (\pi, A, B)$ 新的观测序列

$O = (o$

1

$, o$

2

$, \dots, o$

T

) ,使用 Viterb(维特比)算法计算观测序列对应的最优隐含状态序列

其中

表示 t 时刻最优隐含状态;

进一步的,所述步骤 2.2 的具体步骤如下:

初始化 δ

1

$(i) = \pi$

i

b

i

(o

1

) $i=1, 2, \dots, N$

ψ

1

$(i)=0, i=1, 2, \dots, N$

其中 δ

1

(i 表示 $t=1$ 时刻状态为 i 的所有单个路径(i

1

, i

2

, ..., i

t

)中概率最大值, π

i

表示状态 q

i

对应概率, b

i

(o

1

)表示隐含状态为 i 观测值为 o

1

的概率, N 表示隐含状态的个数, ψ

1

(i 表示 $t=1$ 时刻状态为 i 的所有单个路径 (i

1

, i

2

, ..., i

t

) 中概率最大的路径的第 $t-1$ 个节点;

递推对 $t=2, 3, \dots, T$

其中 a

j_i

表示状态转移概率矩阵 A 中的第 (i, j) 的元素值;

终止

其中 P

*

表示最优路径的概率,

表示 T 时刻最优隐含状态;

最优路径回溯,对 $t=T-1, T-2, \dots, 1$

得最优路径

步骤 2.3以 π

i

作为每个生命周期阶段对应的影响度,且设备所处生命周期阶段判定为最优隐含状态序列中出现次数最多的状态;影响因子为

其中,

为状态

对应的初始概率, T为总时间;

步骤 3:根据步骤 2 中求得的设备生命周期影响因子对 ARIMA-SVR 组合预测模型进行改进,依据状态监测数据预测设备未来状态信息;

步骤 3.1通过现有监测数据,使用 ARIMA (p, d, q) 模型(自回归积分滑动平均模型)进行预测,步骤如(图 5)得到观测值的预测值

步骤 3.1. 监测数据监测序列平稳化处理;采用 ADF (AugmentDickey-Fullertes增强 DF 单根检验)方法验证监测序列是否平稳,如果序列不满足平稳条件,则通过差分操作使其符合平稳性监测序列的条件;

进一步的,所述步骤 3.1. 的方法为:

$$\Delta y$$
$$t$$
$$=X$$
$$t$$
$$-X$$
$$t-1$$
$$(t>1)$$
$$\Delta$$
$$2$$
$$y$$
$$t$$
$$= \Delta y$$

t

$-\Delta y$

t-1

(t>2)

Δ

d

y

t

$= \Delta$

d-1

y

t

$-\Delta$

d-1

y

t-1

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/797046130061010006>