



(12) 发明专利

(10) 授权公告号 CN 115935153 B

(45) 授权公告日 2023. 06. 20

(21) 申请号 202310015478.0

G06F 18/21 (2023.01)

(22) 申请日 2023.01.06

G01M 13/045 (2019.01)

(65) 同一申请的已公布的文献号

申请公布号 CN 115935153 A

(56) 对比文件

CN 104374575 A, 2015.02.25

CN 104390780 A, 2015.03.04

(43) 申请公布日 2023.04.07

审查员 王玲

(73) 专利权人 香港理工大学深圳研究院

地址 518057 广东省深圳市南山区粤海街
道高新技术产业园南区粤兴一道18号
香港理工大学产学研大楼205室

(72) 发明人 王友武 倪一清 郑有梁

(74) 专利代理机构 深圳市君胜知识产权代理事

务所(普通合伙) 44268

专利代理师 谢松

(51) Int. Cl.

G06F 18/20 (2023.01)

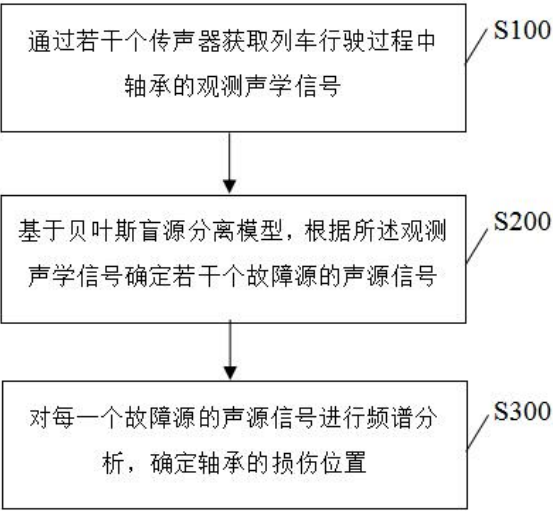
权利要求书3页 说明书7页 附图3页

(54) 发明名称

一种基于贝叶斯盲源分离技术的列车轴承故障诊断方法

(57) 摘要

本发明公开了一种基于贝叶斯盲源分离技术的列车轴承故障诊断方法,包括:通过若干个传声器获取列车行驶过程中轴承的观测声学信号;基于贝叶斯盲源分离模型,根据观测声学信号确定若干个故障源的声源信号;对每一个故障源的声源信号进行频谱分析,确定轴承的损伤位置。通过传声器获取列车在行驶过程中轴承所产生的声音,形成观测声学信号,并基于贝叶斯盲源分离模型,从观测声学信号中分离出各故障源的声源信号,针对每一个故障源的声源信号进行频谱分析,确定轴承的损伤位置,实现轴承的故障诊断。采用贝叶斯盲源分离模型对观测声学信号进行分离,分离出轴承上故障源的声源信号,降低了轴承故障诊断的难度。



1. 一种基于贝叶斯盲源分离技术的列车轴承故障诊断方法, 其特征在于, 包括步骤:
 通过若干个传声器获取列车行驶过程中轴承的观测声学信号;
 基于贝叶斯盲源分离模型, 根据所述观测声学信号确定若干个故障源的声源信号;
 对每一个故障源的声源信号进行频谱分析, 确定轴承的损伤位置;
 所述贝叶斯盲源分离模型为:

$$p(\mathbf{A}, \mathbf{S}, \Sigma_z, h, \varepsilon | \mathbf{X}) \propto p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma_z) \times p(\mathbf{S} | K) \times p(\mathbf{A} | \varepsilon) \times p(\varepsilon) \times p(h) \times p(\Sigma_z),$$

$$p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma_z) = \prod_{t=1}^L \mathcal{N}(\mathbf{X}(t); \mathbf{A}\mathbf{S}(t), \Sigma_z),$$

$$\mathbf{X}(t) = \mathbf{A}\mathbf{S}(t) + \mathbf{Z}(t),$$

$$p(\mathbf{Z} | \Sigma_z) = \prod_{t=1}^L \mathcal{N}(\mathbf{Z}(t); \mathbf{0}, \Sigma_z),$$

其中, $p(\mathbf{A}, \mathbf{S}, \Sigma_z, h, \varepsilon | \mathbf{X})$ 表示联合概率后验分布, \propto 表示正比于, $p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma_z)$ 表示观测声学信号 \mathbf{X} 的似然函数, $p(\mathbf{S} | K)$ 表示故障源的声源信号 \mathbf{S} 的先验分布, K 表示平方指数核函数的方差, $p(\mathbf{A} | \varepsilon)$ 表示混合矩阵 \mathbf{A} 的先验分布, $p(\varepsilon)$ 表示方差 ε 的先验分布, $p(h)$ 表示特征尺度 h 的先验分布, $p(\Sigma_z)$ 表示对角协方差矩阵 Σ_z 的先验分布, \prod 表示连乘积, t 表示时间, L 表示观测声学信号的截止时间, $\mathcal{N}(\cdot)$ 表示正态分布, \mathbf{Z} 表示噪声水平, $\mathbf{X}(t)$ 表示时间 t 的观测声学信号, $\mathbf{S}(t)$ 表示时间 t 的故障源的声源信号, $\mathbf{Z}(t)$ 表示时间 t 的噪声水平;

所述故障源的声源信号的先验分布为:

$$p(\mathbf{S} | K) = \prod_{j=1}^n \mathcal{GP}(\mathbf{S}_j^T; \mathbf{0}, K_j),$$

$$K_j(t, t') = \partial \times \exp \left[-\frac{|t - t'|^2}{2h_j^2} \right],$$

其中, $\mathcal{GP}(\cdot)$ 表示广义帕累托分布, \mathbf{S}_j 表示第 j 个故障源的声源信号, T 表示转置, n 表示故障源的数量, K_j 表示第 j 个故障源的平方指数核函数的方差, h_j 表示第 j 个故障源的特征尺度, t' 表示核函数自变量, ∂ 表示比例因子, $\exp(\cdot)$ 表示以自然常数 e 为底的指数函数;

所述混合矩阵的先验分布为:

$$p(\mathbf{A} | \varepsilon) = \prod_{i=1}^m \prod_{j=1}^n \mathcal{N}(a_{ij}; \mathbf{0}, \varepsilon_{ij}),$$

其中, a_{ij} 表示混合矩阵 \mathbf{A} 中第 i 行第 j 列的元素, ε_{ij} 表示 a_{ij} 的方差;

所述方差的先验分布为:

$$p(\varepsilon) = \prod_{i=1}^m \prod_{j=1}^n IG(\varepsilon_{ij} | \alpha_a, \beta_a),$$

其中, $IG(\cdot)$ 表示逆伽马分布, α_a, β_a 表示超参数;

所述特征尺度的先验分布为:

$$p(h) = \prod_{j=1}^n G(h_j | \alpha_s, \beta_s),$$

其中, $G(\cdot)$ 表示伽马分布, h_j 表示第 j 个故障源的特征尺度, α_s, β_s 表示超参数;
所述对角协方差矩阵的先验分布为:

$$p(\Sigma_z) = \prod_{i=1}^m IG(\sigma_i^2 | \alpha_z, \beta_z),$$

其中, σ_i^2 表示对角协方差矩阵的对角线上第 i 个方差, α_z, β_z 表示超参数;

所述基于贝叶斯盲源分离模型, 根据所述观测声学信号确定若干个故障源的声源信号, 包括:

利用马尔可夫链蒙特卡罗算法, 根据所述观测声学信号估算贝叶斯盲源分离模型中联合概率后验分布的各个变量的概率分布, 以确定若干个故障源的声源信号;

所述利用马尔可夫链蒙特卡罗算法, 根据所述观测声学信号估算贝叶斯盲源分离模型中联合概率后验分布的各个变量的概率分布, 以确定若干个故障源的声源信号, 具体包括:

步骤(1) 采样源分布 $S_j^{(r+1)}$,

$$p(S_j^{(r+1)} | X, A_{(i,j)}^{(r)}, \Sigma_z^{(r)}, h_j^{(r)}) \propto p(X | A_{(i,j)}^{(r)}, S_j, \Sigma_z^{(r)}) \times p(S_j | h_j^{(r)}),$$

其中, $S_j^{(r+1)}$ 表示第 $r+1$ 次采样得到的源分布; $A_{(i,j)}^{(r)}$ 表示第 r 次采样得到的混合矩阵; $\Sigma_z^{(r)}$ 表示第 r 次采样得到误差对角协方差矩阵; $h_j^{(r)}$ 表示第 r 次采样得到的特征尺度; S_j 表示上一时刻的源分布;

步骤(2) 采样混合矩阵分布 $A_{(i,j)}^{(r+1)}$,

$$p(A_{(i,j)}^{(r+1)} | X, S_j^{(r+1)}, \Sigma_z^{(r)}, \varepsilon_j^{(r)}) \propto p(X | A_{(i,j)}, S_j^{(r+1)}, \Sigma_z^{(r)}) \times p(A_{(i,j)} | \varepsilon_j^{(r)}),$$

其中, $A_{(i,j)}^{(r+1)}$ 表示第 $r+1$ 次采样得到的混合矩阵; $A_{(i,j)}$ 表示上一时刻的混合矩阵;

步骤(3) 采样误差对角协方差矩阵 $\Sigma_z^{(r+1)}$,

$$p(\Sigma_z^{(r+1)} | X, S^{(r+1)}, A^{(r+1)}) \propto \prod_{i=1}^m p(X_i^T | A_{(i,i)}^{(r+1)}, S^{(r+1)}, \sigma_i^2) \times p(\sigma_i^2),$$

其中, $\Sigma_z^{(r+1)}$ 表示第 $r+1$ 次采样得到误差对角协方差矩阵;

步骤(4) 采样混合矩阵超参数 $\varepsilon_{ij}^{(r+1)}$,

$$p(\varepsilon_{ij}^{(r+1)} | A^{(r+1)}) \propto p(A^{(r+1)} | \varepsilon_{ij}) \times p(\varepsilon_{ij}),$$

步骤(5) 从分布 $q(h_j^{(r)} | h_j^*)$ 中采样新特征尺度 h_j^* , 按照以下准则判断是否接受新采样数据;

$$\min \left(1, \frac{p(S_j^{(r+1)} | h_j^*) p(h_j^*)}{p(S_j^{(r+1)} | h_j^{(r)}) p(h_j^{(r)})} \right),$$

步骤(6) 重复步骤(1) - 步骤(5)的步骤直到获取足够的样本获得每个故障源的声源信

号。

2. 根据权利要求1所述的基于贝叶斯盲源分离技术的列车轴承故障诊断方法, 其特征在于, 所述对每一个故障源的声源信号进行频谱分析, 确定轴承的损伤位置, 包括:

对每一个故障源的声源信号进行频谱分析, 计算每一个故障源对应的频率;

确定所述频率中的异常频率;

根据所述异常频率, 确定轴承的损伤位置。

3. 一种计算机设备, 包括存储器和处理器, 所述存储器存储有计算机程序, 其特征在于, 所述处理器执行所述计算机程序时实现权利要求1至2中任一项所述方法的步骤。

4. 一种计算机可读存储介质, 其上存储有计算机程序, 其特征在于, 所述计算机程序被处理器执行时实现权利要求1至2中任一项所述的方法的步骤。

一种基于贝叶斯盲源分离技术的列车轴承故障诊断方法

技术领域

[0001] 本发明涉及列车的轴承故障检测技术领域,尤其涉及的是一种基于贝叶斯盲源分离技术的列车轴承故障诊断方法。

背景技术

[0002] 高速铁路的发展对车辆走行部的安全提出更高要求,滚动轴承作为铁路列车走行部的关键部件,对车辆安全性起着非常重要的作用。在列车运行过程中,轴承是发生故障的主要部位,且多种故障同时出现的情况普遍存在。然而实际中不能安装较多的传感器,传感器的数量小于信号源数量的情况非常普遍;通过传感器测得复合故障信号是各故障源的混叠信号,其传递过程不明确且包含强烈的噪声,这给复合故障的诊断带来很大困难。针对轨旁监听系统噪声强度大、源信号的平稳性差和系统不确定大的特点。

[0003] 因此,现有技术还有待于改进和发展。

发明内容

[0004] 本发明要解决的技术问题在于,针对现有技术的上述缺陷,提供一种基于贝叶斯盲源分离技术的列车轴承故障诊断方法,旨在解决现有技术中复合故障的诊断难度大的问题。

[0005] 本发明解决技术问题所采用的技术方案如下:

[0006] 一种基于贝叶斯盲源分离技术的列车轴承故障诊断方法,其中,包括步骤:

[0007] 通过若干个传声器获取列车行驶过程中轴承的观测声学信号;

[0008] 基于贝叶斯盲源分离模型,根据所述观测声学信号确定若干个故障源的声源信号;

[0009] 对每一个故障源的声源信号进行频谱分析,确定轴承的损伤位置;

[0010] 所述贝叶斯盲源分离模型为:

$$[0011] \quad p(\mathbf{A}, \mathbf{S}, \Sigma_z, h, \varepsilon | \mathbf{X}) \propto p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma_z) \times p(\mathbf{S} | K) \times p(\mathbf{A} | \varepsilon) \times p(\varepsilon) \times p(h) \times p(\Sigma_z)$$

$$[0012] \quad p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma_z) = \prod_{t=1}^L \mathcal{N}(\mathbf{X}(t); \mathbf{A}\mathbf{S}(t), \Sigma_z)$$

$$[0013] \quad \mathbf{X}(t) = \mathbf{A}\mathbf{S}(t) + \mathbf{Z}(t)$$

$$[0014] \quad p(\mathbf{Z} | \Sigma_z) = \prod_{t=1}^L \mathcal{N}(\mathbf{Z}(t); 0, \Sigma_z)$$

[0015] 其中, $p(\mathbf{A}, \mathbf{S}, \Sigma_z, h, \varepsilon | \mathbf{X})$ 表示联合概率后验分布, \propto 表示正比于, $p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma_z)$ 表示观测声学信号 \mathbf{X} 的似然函数, $p(\mathbf{S} | K)$ 表示故障源的声源信号 \mathbf{S} 的先验分布, K 表示平方指数核函数的方差, $p(\mathbf{A} | \varepsilon)$ 表示混合矩阵 \mathbf{A} 的先验分布, $p(\varepsilon)$ 表示方差 ε 的先验分布, $p(h)$ 表示特征尺度 h 的先验分布, $p(\Sigma_z)$ 表示对角协方差矩阵 Σ_z 的先验分布, Π 表示连乘积, t 表示时间, L 表示观测声学信号的截止时间, $\mathcal{N}(\cdot)$ 表示正态分布, \mathbf{Z} 表示噪声水平, $\mathbf{X}(t)$ 表示时间 t 的观测声学信号, $\mathbf{S}(t)$ 表示时间 t 的故障源的声源信号, $\mathbf{Z}(t)$ 表示时间 t 的噪声水平。

[0016] 所述的基于贝叶斯盲源分离技术的列车轴承故障诊断方法,其中,所述故障源的声源信号的先验分布为:

$$p(\mathbf{S}|\mathbf{K}) = \prod_{j=1}^n \mathcal{GP}(\mathbf{S}_j^T; 0, \mathbf{K}_j)$$

[0017]

$$K_j(t, t') = \partial \times \exp \left[-\frac{|t - t'|^2}{2h_j^2} \right]$$

[0018] 其中, $\mathcal{GP}(\cdot)$ 表示广义帕累托分布, \mathbf{S}_j 表示第 j 个故障源的声源信号, \mathbf{T} 表示转置, n 表示故障源的数量, \mathbf{K}_j 表示第 j 个故障源的平方指数核函数的方差, h_j 表示第 j 个故障源的特征尺度, t' 表示核函数自变量, ∂ 表示比例因子, $\exp(\cdot)$ 表示以自然常数 e 为底的指数函数;

[0019] 所述混合矩阵的先验分布为:

$$p(\mathbf{A}|\boldsymbol{\varepsilon}) = \prod_{i=1}^m \prod_{j=1}^n \mathcal{N}(a_{ij}; 0, \varepsilon_{ij})$$

[0021] 其中, a_{ij} 表示混合矩阵 \mathbf{A} 中第 i 行第 j 列的元素, ε_{ij} 表示 a_{ij} 的方差。

[0022] 所述的基于贝叶斯盲源分离技术的列车轴承故障诊断方法,其中,所述方差的先验分布为:

$$p(\boldsymbol{\varepsilon}) = \prod_{i=1}^m \prod_{j=1}^n IG(\varepsilon_{ij} | \alpha_a, \beta_a)$$

[0024] 其中, $IG(\cdot)$ 表示逆伽马分布, α_a, β_a 表示超参数;

[0025] 所述特征尺度的先验分布为:

$$p(h) = \prod_{j=1}^n G(h_j | \alpha_s, \beta_s)$$

[0027] 其中, $G(\cdot)$ 表示伽马分布, h_j 表示第 j 个故障源的特征尺度, α_s, β_s 表示超参数;

[0028] 所述对角协方差矩阵的先验分布为:

$$p(\boldsymbol{\Sigma}_z) = \prod_{i=1}^m IG(\sigma_i^2 | \alpha_z, \beta_z)$$

[0030] 其中, σ_i^2 表示对角协方差矩阵的对角线上第 i 个方差, α_z, β_z 表示超参数。

[0031] 所述的基于贝叶斯盲源分离技术的列车轴承故障诊断方法,其中,所述对每一个故障源的声源信号进行频谱分析,确定轴承的损伤位置,包括:

[0032] 对每一个故障源的声源信号进行频谱分析,计算每一个故障源对应的频率;

[0033] 确定所述频率中的异常频率;

[0034] 根据所述异常频率,确定轴承的损伤位置。

[0035] 所述的基于贝叶斯盲源分离技术的列车轴承故障诊断方法,其中,所述基于贝叶斯盲源分离模型,根据所述观测声学信号确定若干个故障源的声源信号,包括:

[0036] 利用马尔可夫链蒙特卡罗算法,根据所述观测声学信号估算贝叶斯盲源分离模型中联合概率后验分布的各个变量的概率分布,以确定若干个故障源的声源信号。

[0037] 一种计算机设备,包括存储器和处理器,所述存储器存储有计算机程序,其中,所

述处理器执行所述计算机程序时实现上述任一项所述方法的步骤。

[0038] 一种计算机可读存储介质,其上存储有计算机程序,其中,所述计算机程序被处理器执行时实现上述任一项所述的方法的步骤。

[0039] 有益效果:通过传声器获取列车在行驶过程中轴承所产生的声音,形成观测声学信号,并基于贝叶斯盲源分离模型,根据观测声学信号确定故障源的声源信号,即从观测声学信号中分离出各故障源的声源信号,然后针对每一个故障源的声源信号进行频谱分析,确定轴承的损伤位置,实现轴承的故障诊断。采用贝叶斯盲源分离模型对观测声学信号进行分离,分离出轴承上故障源的声源信号,可以降低轴承故障诊断的难度。

附图说明

[0040] 图1是本发明中基于贝叶斯盲源分离技术的列车轴承故障诊断方法的流程图。

[0041] 图2是本发明中嵌入高斯过程的贝叶斯盲源分离技术原理图。

[0042] 图3是本发明中真实故障源的声源信号的示意图。

[0043] 图4是本发明中观测声学信号的示意图。

[0044] 图5是本发明中真实故障源的声源信号与估算的故障源的声源信号的对比示意图。

具体实施方式

[0045] 为使本发明的目的、技术方案及优点更加清楚、明确,以下参照附图并举实施例对本发明进一步详细说明。应当理解,此处所描述的具体实施例仅仅用以解释本发明,并不用于限定本发明。

[0046] 请同时参阅图1-图5,本发明提供了一种基于贝叶斯盲源分离技术的列车轴承故障诊断方法的一些实施例。

[0047] 如图1-图2所示,本发明的基于贝叶斯盲源分离技术的列车轴承故障诊断方法,包括以下步骤:

[0048] 步骤S100、通过若干个传声器获取列车行驶过程中轴承的观测声学信号。

[0049] 步骤S200、基于贝叶斯盲源分离模型,根据所述观测声学信号确定若干个故障源的声源信号。

[0050] 步骤S300、对每一个故障源的声源信号进行频谱分析,确定轴承的损伤位置。

[0051] 具体地,通过传声器获取列车在行驶过程中轴承所产生的声音,形成观测声学信号,并基于贝叶斯盲源分离模型,根据观测声学信号确定故障源的声源信号,即从观测声学信号中分离出各故障源的声源信号,然后针对每一个故障源的声源信号进行频谱分析,确定轴承的损伤位置,实现轴承的故障诊断。采用贝叶斯盲源分离模型对观测声学信号进行分离,分离出轴承上故障源的声源信号,可以降低轴承故障诊断的难度。

[0052] 步骤S100具体包括:

[0053] 步骤S110、通过所述升降支撑座调整所述传声器的高度,以使所述传声器位于与列车的轴承对应的位置。

[0054] 步骤S120、启动所述传声器以获取列车行驶过程中轴承的观测声学信号。

[0055] 具体地,通过升降支撑座调整传声器的高度,从而使得传声器对应于轴承的位置,

便于采集轴承的声音,得到观测声学信号。需要说明的是,由于传声器有若干个,各传声器所采集的观测声学信号并不完全相同。

[0056] 贝叶斯盲源分离问题可以写成:

$$[0057] \quad \mathbf{X} = \mathbf{Y} + \mathbf{Z} = \mathbf{A}\mathbf{S} + \mathbf{Z}$$

$$[0058] \quad \mathbf{X} = [\mathbf{X}(1), \mathbf{X}(2), \dots, \mathbf{X}(t), \dots, \mathbf{X}(L)]$$

$$[0059] \quad \mathbf{Y} = [\mathbf{Y}(1), \mathbf{Y}(2), \dots, \mathbf{Y}(t), \dots, \mathbf{Y}(L)]$$

$$[0060] \quad \mathbf{Z} = [\mathbf{Z}(1), \mathbf{Z}(2), \dots, \mathbf{Z}(t), \dots, \mathbf{Z}(L)]$$

$$[0061] \quad \mathbf{S} = [\mathbf{S}(1), \mathbf{S}(2), \dots, \mathbf{S}(t), \dots, \mathbf{S}(L)] = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_j, \dots, \mathbf{s}_n]^T$$

$$[0062] \quad \mathbf{X}(t) = \mathbf{Y}(t) + \mathbf{Z}(t) = \mathbf{A}\mathbf{S}(t) + \mathbf{Z}(t)$$

$$[0063] \quad \mathbf{X}(t) = [\mathbf{x}_1(t), \mathbf{x}_2(t), \dots, \mathbf{x}_i(t), \dots, \mathbf{x}_m(t)]^T$$

$$[0064] \quad \mathbf{S}(t) = [\mathbf{s}_1(t), \mathbf{s}_2(t), \dots, \mathbf{s}_j(t), \dots, \mathbf{s}_n(t)]^T$$

$$[0065] \quad \mathbf{Z}(t) = [\mathbf{z}_1(t), \mathbf{z}_2(t), \dots, \mathbf{z}_i(t), \dots, \mathbf{z}_m(t)]^T$$

[0066] 其中, \mathbf{X} 表示观测声学信号, \mathbf{Y} 表示无噪声污染的理想观测信号, \mathbf{A} 表示混合矩阵, 即从故障源到观测声学信号的传递函数, \mathbf{S} 表示故障源的声源信号, \mathbf{Z} 表示噪声水平, $\mathbf{X}(t)$ 表示时间 t 的观测声学信号, m 表示传声器的数量, $\mathbf{x}_i(t)$ 表示时间 t 的第 i 个传声器的观测声学信号, $\mathbf{Y}(t)$ 表示时间 t 的无噪声污染的理想观测信号, $\mathbf{S}(t)$ 表示时间 t 的故障源的声源信号, n 表示轴承上故障源的数量, \mathbf{s}_j 表示第 j 个故障源的声源信号, $\mathbf{s}_j(t)$ 表示时间 t 的第 j 个故障源的声源信号, $\mathbf{Z}(t)$ 表示时间 t 的噪声水平, $\mathbf{z}_i(t)$ 表示时间 t 的第 i 个传声器的噪声水平, T 表示转置。

[0067] 所述贝叶斯盲源分离模型为:

$$[0068] \quad p(\mathbf{A}, \mathbf{S}, \Sigma_z, h, \varepsilon | \mathbf{X}) \propto p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma_z) \times p(\mathbf{S} | K) \times p(\mathbf{A} | \varepsilon) \times p(\varepsilon) \times p(h) \times p(\Sigma_z)$$

$$[0069] \quad p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma_z) = \prod_{t=1}^L p(\mathbf{X}(t); \mathbf{A}\mathbf{S}(t), \Sigma_z) = \prod_{t=1}^L \mathcal{N}(\mathbf{X}(t); \mathbf{A}\mathbf{S}(t), \Sigma_z)$$

$$[0070] \quad \mathbf{X}(t) = \mathbf{A}\mathbf{S}(t) + \mathbf{Z}(t)$$

$$[0071] \quad p(\mathbf{Z} | \Sigma_z) = \prod_{t=1}^L \mathcal{N}(\mathbf{Z}(t); 0, \Sigma_z)$$

[0072] 其中, $p(\mathbf{A}, \mathbf{S}, \Sigma_z, h, \varepsilon | \mathbf{X})$ 表示联合概率后验分布, \propto 表示正比于, $p(\mathbf{X} | \mathbf{A}, \mathbf{S}, \Sigma_z)$ 表示观测声学信号 \mathbf{X} 的似然函数, $p(\mathbf{S} | K)$ 表示故障源的声源信号 \mathbf{S} 的先验分布, K 表示平方指数核函数的方差, $p(\mathbf{A} | \varepsilon)$ 表示混合矩阵 \mathbf{A} 的先验分布, $p(\varepsilon)$ 表示方差 ε 的先验分布, $p(h)$ 表示特征尺度 h 的先验分布, $p(\Sigma_z)$ 表示对角协方差矩阵 Σ_z 的先验分布, Π 表示连乘积, t 表示时间, L 表示观测声学信号的截止时间, $\mathcal{N}(\cdot)$ 表示正态分布, \mathbf{Z} 表示噪声水平, $\mathbf{X}(t)$ 表示时间 t 的观测声学信号, $\mathbf{S}(t)$ 表示时间 t 的故障源的声源信号, $\mathbf{Z}(t)$ 表示时间 t 的噪声水平。

[0073] 故障源的声源信号的先验分布为:

$$p(\mathbf{S}|\mathbf{K}) = \prod_{j=1}^n \mathcal{GP}(\mathbf{S}_j^T; 0, K_j)$$

[0074]

$$K_j(t, t') = \partial \times \exp \left[-\frac{|t - t'|^2}{2h_j^2} \right]$$

[0075] 其中, $p(\mathbf{S}_j^T)$ 表示第 j 个故障源的声源信号的先验分布, $\mathcal{GP}(\cdot)$ 表示广义帕累托分布, \mathbf{S}_j 表示第 j 个故障源的声源信号, T 表示转置, n 表示故障源的数量, K_j 表示第 j 个故障源的平方指数核函数的方差, h_j 表示第 j 个故障源的特征尺度, t' 表示核函数自变量, ∂ 表示比例因子, $\exp(\cdot)$ 表示以自然常数 e 为底的指数函数。

[0076] 混合矩阵的先验分布为:

$$[0077] \quad p(\mathbf{A}|\varepsilon) = \prod_{i=1}^m \prod_{j=1}^n p(a_{ij}) = \prod_{i=1}^m \prod_{j=1}^n \mathcal{N}(a_{ij}; 0, \varepsilon_{ij})$$

[0078] 其中, $p(a_{ij})$ 表示混合矩阵 \mathbf{A} 中第 i 行第 j 列的元素的先验分布, a_{ij} 表示混合矩阵 \mathbf{A} 中第 i 行第 j 列的元素, ε_{ij} 表示 a_{ij} 的方差。

[0079] 方差的先验分布为:

$$[0080] \quad p(\varepsilon) = \prod_{i=1}^m \prod_{j=1}^n IG(\varepsilon_{ij}|\alpha_a, \beta_a)$$

[0081] 其中, $IG(\cdot)$ 表示逆伽马分布, α_a, β_a 表示超参数。

[0082] 特征尺度的先验分布为:

$$[0083] \quad p(h) = \prod_{j=1}^n p(h_j) = \prod_{j=1}^n G(h_j|\alpha_s, \beta_s)$$

[0084] 其中, $G(\cdot)$ 表示伽马分布, $p(h_j)$ 表示第 j 个故障源的特征尺度的先验分布, h_j 表示第 j 个故障源的特征尺度, α_s, β_s 表示超参数。

[0085] 对角协方差矩阵的先验分布为:

$$[0086] \quad p(\Sigma_z) = \prod_{i=1}^m p(\{\Sigma_z\}_i|\alpha_z, \beta_z) = \prod_{i=1}^m IG(\sigma_i^2|\alpha_z, \beta_z)$$

[0087] 其中, $p(\{\Sigma_z\}_i|\alpha_z, \beta_z)$ 表示在 α_z, β_z 条件下第 i 个协方差矩阵 $\{\Sigma_z\}_i$ 对应的概率, $\{\Sigma_z\}_i$ 表示第 i 个协方差矩阵, σ_i^2 表示对角协方差矩阵的对角线上第 i 个方差, α_z, β_z 表示超参数。

[0088] 步骤S200具体包括:

[0089] 步骤S210、利用马尔可夫链蒙特卡罗算法,根据所述观测声学信号估算贝叶斯盲源分离模型中联合概率后验分布的各个变量的概率分布,以确定若干个故障源的声源信号。

[0090] 具体地,为解决这个复杂的高维的联合概率分布函数,利用马尔可夫链蒙特卡罗算法(MCMC)算法中sequential Metropolis-Hasting联合采用算法,估算出联合分布中和各个变量的概率分布,这样就可以确定每个故障源的声源信号。

[0091] 步骤:(1)采样源分布 $\mathbf{S}_j^{(r+1)}$

$$[0092] \quad p\left(\mathbf{S}_j^{(r+1)} \mid \mathbf{X}, \mathbf{A}_{(:,j)}^{(r)}, \Sigma_z^{(r)}, h_j^{(r)}\right) \propto p\left(\mathbf{X} \mid \mathbf{A}_{(:,j)}^{(r)}, \mathbf{S}_j, \Sigma_z^{(r)}\right) \times p\left(\mathbf{S}_j \mid h_j^{(r)}\right)$$

[0093] 其中, $\mathbf{S}_j^{(r+1)}$ 第 $r+1$ 次采样得到的源分布; $\mathbf{A}_{(:,j)}^{(r)}$ 表示第 r 次采样得到的混合矩阵; $\Sigma_z^{(r)}$ 表示第 r 次采样得到误差对角协方差矩阵; $h_j^{(r)}$ 表示第 r 次采样得到的特征尺度; \mathbf{S}_j 表示上一时刻的源分布。

[0094] (2) 采样混合矩阵分布 $\mathbf{A}_{(:,j)}^{(r+1)}$

$$[0095] \quad p\left(\mathbf{A}_{(:,j)}^{(r+1)} \mid \mathbf{X}, \mathbf{S}_j^{(r+1)}, \Sigma_z^{(r)}, \varepsilon_j^{(r)}\right) \propto p\left(\mathbf{X} \mid \mathbf{A}_{(:,j)}, \mathbf{S}_j^{(r+1)}, \Sigma_z^{(r)}\right) \times p\left(\mathbf{A}_{(:,j)} \mid \varepsilon_j^{(r)}\right)$$

[0096] 其中, $\mathbf{A}_{(:,j)}^{(r+1)}$ 表示第 $r+1$ 次采样得到的混合矩阵; $\mathbf{A}_{(:,j)}$ 表示上一时刻的混合矩阵。

[0097] (3) 采样误差对角协方差矩阵 $\Sigma_z^{(r+1)}$

$$[0098] \quad p\left(\Sigma_z^{(r+1)} \mid \mathbf{X}, \mathbf{S}^{(r+1)}, \mathbf{A}^{(r+1)}\right) \propto \prod_{i=1}^m p\left(\mathbf{X}_i^T \mid \mathbf{A}_{(i,:)}^{(r+1)}, \mathbf{S}^{(r+1)}, \sigma_i^2\right) \times p\left(\sigma_i^2\right)$$

[0099] 其中, $\Sigma_z^{(r+1)}$ 表示第 $r+1$ 次采样得到误差对角协方差矩阵。

[0100] (4) 采样混合矩阵超参数 $\varepsilon_{ij}^{(r+1)}$

$$[0101] \quad p\left(\varepsilon_{ij}^{(r+1)} \mid \mathbf{A}^{(r+1)}\right) \propto p\left(\mathbf{A}^{(r+1)} \mid \varepsilon_{ij}\right) \times p\left(\varepsilon_{ij}\right)$$

[0102] (5) 从分布 $q\left(h_j^{(r)} \mid h_j^*\right)$ 中采样新特征尺度 h_j^* , 按照以下准则判断是否接受新采样数据。

$$[0103] \quad \min\left(1, \frac{p\left(\mathbf{S}_j^{(r+1)} \mid h_j^*\right) p\left(h_j^*\right)}{p\left(\mathbf{S}_j^{(r+1)} \mid h_j^{(r)}\right) p\left(h_j^{(r)}\right)}\right)$$

[0104] (6) 重复1-5的步骤直到获取足够的样本获得每个故障源的声源信号。

[0105] 步骤S300具体包括:

[0106] 步骤S310、对每一个故障源的声源信号进行频谱分析, 计算每一个故障源对应的频率。

[0107] 步骤S320、确定所述频率中的异常频率;

[0108] 步骤S330、根据所述异常频率, 确定轴承的损伤位置。

[0109] 具体地, 根据上面贝叶斯盲源分离技术分离出每个故障源的声源信号, 然后对每一个故障源的声源信号 \mathbf{S}_j 进行频谱分析, 计算每一个声源对应的频率, 根据频率信息找出异常频率, 由此确定轴承相应的损伤位置。

[0110] 如图3所示, 故障源有3个, 且真实的故障源的声源信号各不相同。如图4所示, 传声器有2个, 采集的观测声学信号也完全不相同。如图5所示, 基于贝叶斯盲源分离模型估算的故障源的声源信号与真实的故障源的声源信号基本一致, 表明本发明的基于贝叶斯盲源分离模型的预测效果较好。

[0111] 基于上述任意一实施例所述的基于贝叶斯盲源分离技术的列车轴承故障诊断方法,本发明还提供了一种计算机设备的实施例:

[0112] 本发明的计算机设备,包括储器和处理器,所述存储器存储有计算机程序,所述处理器执行所述计算机程序时实现如上述任意一实施例所述方法的步骤。

[0113] 基于上述任意一实施例所述的基于贝叶斯盲源分离技术的列车轴承故障诊断方法,本发明还提供了一种计算机可读存储介质的实施例:

[0114] 本发明的计算机可读存储介质,其上存储有计算机程序,所述计算机程序被处理器执行时实现如上述任意一实施例所述方法的步骤。

[0115] 应当理解的是,本发明的应用不限于上述的举例,对本领域普通技术人员来说,可以根据上述说明加以改进或变换,所有这些改进和变换都应属于本发明所附权利要求的保护范围。

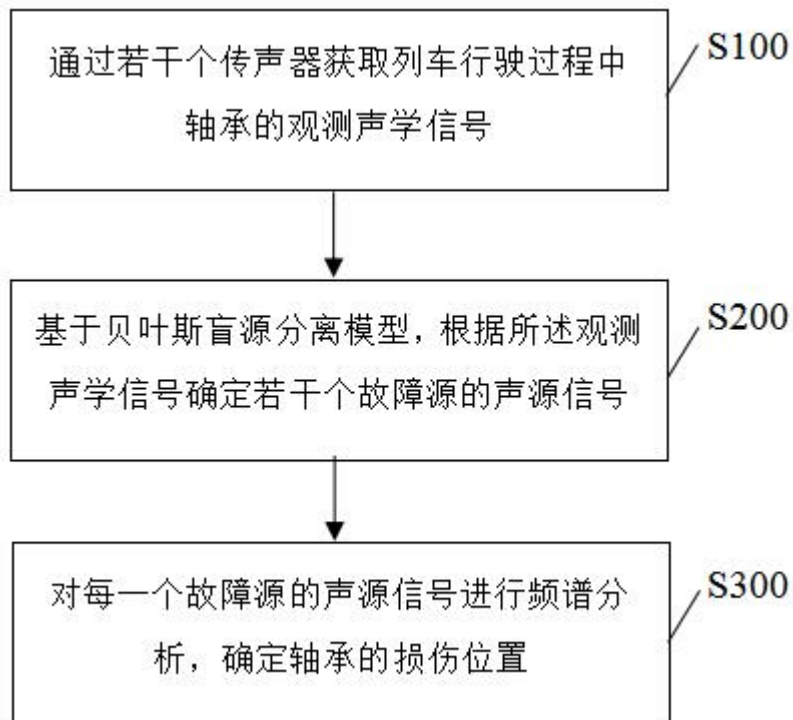


图1

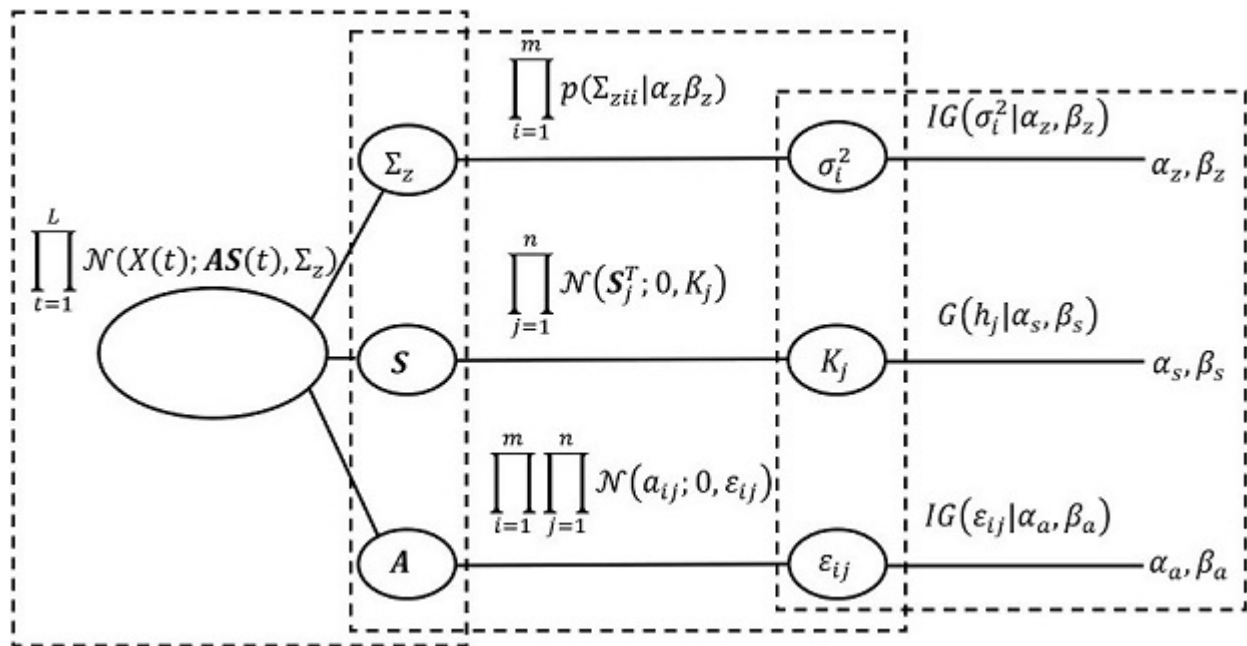


图2




图3




图4




图5