

一种新的基于向量投影的在线故障诊断方法

肖德云 周 京

(清华大学自动化系, 北京)

杨友堂

(清华大学精仪系, 北京)

摘要: 本文提出一种新的基于向量投影的在线故障诊断方法. 此方法的核心是要建立故障信号向量, 并利用 Lattice 滤波器算法^[1], 通过观察故障信号向量在观测信号空间上的投影来实现故障检测和分离的. 本方法除了得到仿真实验的验证外, 还在实际的转子模拟实验台上, 对三种典型的故障——摩擦、油膜涡动和油膜振荡实现了在线故障诊断. 实验结果表明这种方法是有用的, 而且比谱分析法对故障有更高的灵敏度.

关键词: 故障检测; 故障诊断; 向量投影; Lattice 滤波器算法

1 引言

近些年来, 各种用于大型旋转机械故障诊断方法及其应用的研究得到前所未有的重视, 尤其是谱分析故障诊断法发展得更为迅速, 用得也更为广泛. 但是, 谱分析法对数据的利用是批处理性质的, 不能适应实时在线故障诊断的需要, 而且计算量也比较大.

本文提出一种基于向量投影的在线故障诊断方法. 在适当的硬件支持下, 可用于大型旋转机械的实时故障诊断. 在实现故障分离的同时, 能给出故障的大小程度, 而且较谱分析法对故障有更高的灵敏度, 计算量也比较小.

2 基于向量投影的故障诊断理论

2.1 信号向量

设 $y(0), y(1), \dots, y(t)$ 是给定的观测样本, 定义

$$y_i = [0, \dots, 0, y(0), \dots, y(t)]$$

为信号向量, 它是 Euclidean 空间内长度为 N 、且具有通常内积的行向量.

考虑到大型旋转机械故障诊断中所用的振动测量信号需要用二阶非平稳过程来描述, 本文引用了 Kailath 等人提出的位移秩(displacement rank)概念^[1], 假设所处理的信号向量的位移秩 $\alpha = 1$. 如果信号向量的位移秩 $\alpha > 1$, 下面的结论仍然可用.

2.2 信号空间

对给定的信号向量序列 $\{y_i, i=0, 1, 2, \dots\}$, 记

$$m = \min_i \{i \mid \lim_{t \rightarrow \infty} e_{i,t} = 0, \lim_{t \rightarrow \infty} r_{i,t-1} = 0, i = 1, 2, \dots\}.$$

式中

$$e_{i,t} = [0, \dots, 0, e_i(0), \dots, e_i(t)] = y_i - \hat{y}_i | U,$$

$$r_{i,t-1} = [0, \dots, 0, r_i(0), \dots, r_i(t-1-i)] = y_{i-1-i} - \hat{y}_{i-1-i} | U,$$

$$U = \{y_{t-i}, \dots, y_{t-1}\}.$$

其中, $e_{i,t}$ 称作 t 时刻 i 阶向前残差, $r_{i,t-1}$ 称作 $t-1-i$ 时刻 i 阶向后残差; $\hat{y}_t|U$ 和 $\hat{y}_{t-1}|U$ 分别为 y_t 和 y_{t-1} 在 U 张成的空间上的投影. 当 t 足够大时, 由信号向量序列 $\{y_t, t=0, 1, 2, \dots\}$ 构成的空间 $\text{span}\{y_{t-m}, \dots, y_{t-1}\}$ 称作信号空间, m 为信号空间的维数.

2.3 故障诊断问题的几何叙述

考虑一个正常的信号向量序列 $\{y_t, t=0, 1, 2, \dots\}$, 当 t 充分大时, y_t 总能用 $y_{t-m}, y_{t-m-1}, \dots, y_{t-1}$ 的线性组合表示, 或者说 y_t 总能用其前面 m 个时刻的信号向量所张成的信号空间来描述, 也就是说, 正常状态下新的信号向量总不会脱离正常的信号空间. 如果在 $t=t_L$ 时刻设备出现了某种故障, 这之后的信号向量就会脱离原有的正常信号空间. 根据这一事实, 有下面的故障可检测定理.

定理 1^[2] 对给定的信号通道, 通过该通道可检测出某种故障的充分必要条件是 $\hat{y}_{t+t_L}|U \neq y_{t+t_L}$, 其中 t_L 是故障发生的时刻, U 是故障发生前正常信号空间的一组基.

2.4 故障信号向量

定理 1 表明, 当故障发生之后, 新的信号向量将脱离原有的正常信号空间. 这意味着故障对信号内部特征的影响已不会存在于原有的正常信号空间内. 要想进一步提取故障信息, 实现故障分离, 必须到与原有正常信号空间互补的空间上去考虑. 也就是说故障的特征信息需从相对于原有正常信号空间新增加的子空间内提取. 为提取这种存在于子空间内的故障特征信息, 下面定义一种故障信号向量. 设

$$x_i^{(j)} = [0, \dots, 0, x_i^{(j)}(0), \dots, x_i^{(j)}(t)]$$

是一个含有第 j 种故障的信号向量, 它在 U 张成的子空间的正交补空间上投影称作故障信号向量. 由此概念可导出下面的故障可分离定理.

定理 2^[2] 对给定的信号通道, 如果它对两种故障同时敏感, 则一种故障可以从另一种故障中分离出来的充分必要条件是两种故障的故障信号向量正交.

2.5 向量投影的计算

定理 1 和 2 表明, 为了实现故障的检测和分离, 必须解决信号向量的投影和故障信号向量的计算问题. 本文采用 Kailath 等人提出的最小二乘自适应 Lattice 滤波器算法^[1], 成功地解决了这一问题, 从而使上述基于向量投影的故障诊断方法付诸于实现.

对单通道、位移秩 $\alpha=1$ 的过程来说, 文献 2 导出了关于计算向量投影的一整套闭合递推算法:

$$K_i(t) = G\{K_i(t-1), \eta_{i-1}(t), \mu_{i-1}(t)\}, \quad (1a)$$

$$\eta_i(t) = F\{\eta_{i-1}(t), K_i(t), \mu_{i-1}^*(t)\}, \quad (1b)$$

$$\mu_i(t) = F\{\mu_{i-1}(t), K_i^*(t), \eta_{i-1}^*(t)\}, \quad (1c)$$

$$\varphi_i(t) = [1 - \mu_{i-1}^*(t)\mu_{i-1}(t)]^{1/2}\varphi_{i-1}(t), \quad (1d)$$

$$h_i^{(j)}(t) = \sqrt{\lambda} h_i^{(j)}(t-1)[1 - \mu_{i-1}(t)\mu_{i-1}^*(t)]^{*1/2} + \tilde{x}_{i-1}^{(j)}(t)\varphi_{i-1}^{-1}(t)\mu_{i-1}^*(t), \quad (1e)$$

$$\tilde{x}_i^{(j)}(t) = \tilde{x}_{i-1}^{(j)}(t) - h_i^{(j)}(t)\mu_{i-1}(t)\varphi_{i-1}(t). \quad (1f)$$

其中, 星号“*”表示 Hermitian 转置, 且

$$G\{A, B, C\} = (1 - BB^*)^{1/2}A(1 - CC^*)^{*1/2} + BC^*,$$

$$F\{A, B, C\} = (1 - BB^*)^{-1/2}(A - BC^*)(1 - CC^*)^{-*1/2}.$$

初始值为

$$\begin{aligned} K_i(0) &= 0, \quad h_i(0) = 0, \quad \varphi_0(t) = 1, \\ \eta_0(t) &= \mu_0(t) = R_y^{-1/2}(t)y(t), \quad R_y(t) = \lambda R_y(t-1) + y(t)y^*(t), \quad R_y(0) = 0, \\ \tilde{x}_0^{(j)}(t) &= x^{(j)}(t). \quad \lambda \text{ 可取 } 1. \end{aligned}$$

上述闭合递推集的(1a)~(1c)式称作主部, (1d)~(1f)式称作联合部. 主部的输入信号是 t 时刻的测量信号 $y(t)$. 当 t 充分大时, 有^[1]

$$\begin{aligned} \eta_i(t) &= \langle \bar{e}_{i,t}, \pi \rangle \varphi_i^{-1}(t-1) = \bar{e}_i(t) \varphi_i^{-1}(t-1), \\ \mu_i(t) &= \langle \bar{r}_{i,t}, \pi \rangle \varphi_i^{-1}(t) = \bar{r}_i(t) \varphi_i^{-1}(t), \\ \pi &= [0, \dots, 0, 1]. \end{aligned}$$

其中, $\bar{e}_{i,t}$, $\bar{e}_i(t)$, $\bar{r}_{i,t}$ 和 $\bar{r}_i(t)$ 分别为它们的归一化形式. 这表明由主部可获得 t 时刻的 i 阶向前和向后残差, 那么根据定理 1 就可实现故障检测. 联合部的输入是含有某种故障的 t 时刻测量值 $x^{(j)}(t)$, 计算达到稳定之后, 便可获得该故障的故障信号向量

$$\begin{aligned} \tilde{x}_{i,t}^{(j)} &= [0, \dots, 0, \tilde{x}_i^{(j)}(0), \dots, \tilde{x}_i^{(j)}(t)] = x_i^{(j)} - \hat{x}_i | U_3, \\ U_3 &= \{y_{t-i+1}, \dots, y_t\}. \end{aligned}$$

利用这个故障信号向量可实现故障分离.

2.6 故障检测

设计故障诊断系统时, 需要合理选择所用的信号通道, 使之对特定的故障敏感. 那么, 当该故障发生之后, 新的信号向量就会脱离原有的正常信号空间. 这意味着含有故障的信号向量所构成的信号空间的维数较原有的正常信号空间的维数将有所增加. 因此, 只要判定信号空间的维数是否增加了, 便可实现故障检测.

这一故障检测准则可写成:

$$\text{如果 } \eta_{m_0}(t) \varphi_{m_0}^{-1}(t-1) \leq \varepsilon \quad \text{且} \quad \mu_{m_0}(t-1) \varphi_{m_0}^{-1}(t-1) \leq \varepsilon,$$

则过程无故障, 否则必有故障.

其中, $\eta_{m_0}(t) \varphi_{m_0}^{-1}(t-1)$ 和 $\mu_{m_0}(t-1) \varphi_{m_0}^{-1}(t-1)$ 称作故障检测指标(FDI); m_0 为正常信号空间的维数; ε 为阈值.

2.7 故障分离

实现上述故障检测只需要闭合递推集的主部, 因此计算量是比较小的. 当检出有故障发生时, 将事先准备好的 M 种含有不同故障特征的信号向量 $x_i^{(j)}$, $j=1, 2, \dots, M$ 分别输入到联合部, 计算出故障分离指标(FII) $J_{j_2}(t)/E_j(t)$, $j=1, 2, \dots, M$, 其中, $J_{j_2}(t)$ 是含有第 j 种故障特征的信号向量 $x_i^{(j)}$ 在信号空间 U_3 上的投影能量; $E_j(t)$ 是含有第 j 种故障特征的故障信号向量 $\tilde{x}_{m_0,t}^{(j)}$ 在 t 时刻的能量. $J_{j_2}(t)$ 和 $E_j(t)$ 的计算公式为

$$\begin{aligned} J_{j_2}(t) &= \sum_{i=1}^{m_0} h_i^{(j)}(t) [h_i^{(j)}(t)]^*, \\ E_j(t) &= \langle \tilde{x}_{m_0,t}^{(j)}, \tilde{x}_{m_0,t}^{(j)} \rangle. \end{aligned}$$

如果 $J_{j_2}(t)/E_j(t) \leq \delta$, 则认为第 j 种故障没有发生, 反之则认为第 j 种故障发生了, 其中 δ 为阈值, 其值范围为 $0 < \delta < 1$. 可见, 利用故障分离指标(FII)可实现完全的故障分离. 此外, 故障分离指标又是用来衡量故障大小程度的一个标准, 其值越大, 说明故障越严重.

VPDS 故障诊断软件包及实验研究

VPDS (Vector Projection Diagnosis System) 是专为本文提出的基于向量投影的在线故障诊断方法所配置的软件包。它包括数据采集、数据预处理、故障信号向量的生成、故障检测、故障分离及结果显示等功能。它与柔性转子模拟实验台、振动信号传感器、A/D 变换装置及 PC/XT 等硬件资源组成一个完整的在线故障诊断系统。

利用 VPDS 软件包, 我们在柔性转子模拟实验台 (示意图见图 1) 上, 针对旋转机械三种典型的故障——摩擦、油膜涡动和油膜振荡, 进行了大量的在线故障诊断的实验研究。实验结果表明, 采用 VPDS 软件包分析出的故障类型及大小和实际情况完全相符, 而且较最大熵谱分析故障诊断法对故障有更高的灵敏度。图 2 是正常状态下的诊断结果, 故障检测指标 (FDI) 和故障分离指标 (FII) 均未超越阈值 (见图 2(a)、(b)), 说明系统没有故障发生。






图 1 柔性转子模拟实验台示意图



故障检测指标 (FDI)



① 油膜涡动 ② 摩擦

故障分离指标 (FII)




图 2 正常状态下的诊断结果 (转子频率为 83.65Hz)

这和用最大熵谱分析法得出的结论是一致的 (见图 2(c), 谱图上只出现一个与转子频率一致的成份, 说明系统是正常的)。图 3 是弱油膜涡动情况下的诊断结果, 这时 FDI 和 FII ①均已越界 (见图 3(a)、(b)), 说明系统有油膜涡动故障出现。但是, 这种情况下用最大熵谱分析法不能诊断出故障来 (见图 3(c), 谱图上仍只有一个频率成份), 只有油膜涡动比

较严重时,最大熵谱分析法才能诊断出故障(见图 3(d),谱图上出现两个频率成份,一个是正常的转子频率成份,另一个为转子频率的一半,这个频率正是油膜涡动的故障特征频率)。这表明本文的方法对故障的灵敏度要优于最大熵谱分析法。图 4 是同时出现油膜涡动和轴摩擦情况下的诊断结果,FII①和 FII②分别是油膜涡动和轴摩擦的故障分离指标,这时它们均越界了,说明两种故障同时存在。




图 3 出现油膜涡动情况下的诊断结果




图 4 同时出现油膜涡动和轴摩擦情况下的诊断结果

4 结束语

本文提出的基于向量投影的在线故障诊断方法具有计算量小,对故障灵敏度高,且在分离故障的同时,能给出故障的大小程度等优点。

(下转第 356 页)