

数据融合在 APMP 盘磨故障诊断中的应用研究

Research and Application of Data Fusion in Fault Diagnosis of APMP Disc Refiner

饶智达¹ 汤伟²

(陕西科技大学电气与信息工程学院¹,陕西 西安 710021; 陕西科技大学机电工程学院²,陕西 西安 710021)

摘要: 针对碱性过氧化氢化学机械浆(APMP)盘磨故障诊断在同一征兆域中很难区分多种故障的实际情况,利用其他征兆域的诊断信息进行了全局信息融合的研究。在数据处理的检测层、特征层、决策层上分别提出了不同的数据融合算法,即检测层采用小波包分析的融合方法提取故障特征,特征层通过神经网络的融合为决策层的 D-S 证据理论提供可信度分配。试验数据表明,通过三个层面的优势互补,可以使证据理论的可信度分配不再完全依赖主观专家经验;利用各种故障的冗余和互补信息,可提高诊断的准确率。

关键词: 故障诊断 数据融合 小波包分析 BP 神经网络 D-S 证据理论

中图分类号: TH113+.1 **文献标志码:** A

Abstract: In fault diagnosis of alkaline peroxide mechanical pulp(APMP) disc refiner, it is difficult to distinguish actual conditions of various faults in the same symptom domain. Aiming at this situation, by adopting the diagnosis information of other symptom domains, the global information integration is carried out and researched. Different data fusion algorithms are proposed respectively for detection layer, feature layer and decision making layer. In detection layer, wavelet packet analysis is adopted to extract fault feature; in feature layer, through neural network fusion, the probability assignment is provided for the D-S evidence theory of decision making layer. The experimental data indicate that because of the complementary advantages of these three layers, the probability assignment of the evidence theory may not fully depend on subjective experience of experts; and the diagnostic accuracy can be improved by adopting the redundant and complementary information of various failures.

Keywords: Fault diagnosis Data fusion Wavelet packet analysis BP neural network D-S evidence theory

0 引言

大盘磨机通常由 10 000 kW 以上的高压电机带动。作为化学机械浆生产过程中的主体设备,大功率盘磨机是整个化机浆生产系统中最复杂、最核心的设备,它的正常运行关系到成浆质量以及产量。盘磨机是典型的机、电、液一体化设备。在针对盘磨机的故障诊断中,往往一个故障征兆可以由多个故障模式引起,同时系统中的一个故障模式往往会引起多个故障征兆,是典型的多对多形式,因此依靠单一的信息源往往无法得出准确的故障位置。盘磨出现如磨齿损坏、悬臂轴变形、磨机与电机同轴度偏差等故障时,往往会导致振动频率在某个范围出现奇异点^[1-3]。

小波分析具有良好的时频域局部化特性,能够同

时提供非平稳信号的时域与频域信息;D-S 证据理论对不确定性信息有较好的处理能力,那是由于其对不确定信息的描述采用区间估计而非点估计。同时,鉴于人工神经网络较适合拟合故障征兆与故障模式之间的非线性对应关系,因此选用人工神经网络,并引入多传感器信息融合的思想对各征兆域进行前期局部诊断。将证据理论和神经网络方法相结合,通过吸收神经网络的自学习、自适应和容错能力,可使得系统对不确定信息的融合具有较强的鲁棒性^[4-7]。

1 数据融合故障诊断模型

基于数据融合的故障诊断一般分为三个部分:原始数据、特征级和决策级。

基于数据融合的盘磨故障诊断系统首先通过安装在轴承处的径向和轴向振动测量仪以及基座振动测量仪获得数据,通过小波包进行特征提取,提取的特征值作为神经网络的输入信号;然后对所有特征参数在神经网络中进行特征级局部融合分类,挖掘整理特征参数间的内在关系,并为 D-S 证据理论提供基本概率分配;最后对局部诊断结果进行决策级融合^[8-10]。

陕西省科学技术研究发展计划基金资助项目(编号:2012K09-10);

咸阳市科技计划基金资助项目(编号:2011K07-18)。

修改稿收到日期:2012-09-04。

第一作者饶智达(1987-),男,现为陕西科技大学控制理论与控制工程专业在读硕士研究生;主要从事工业过程高级控制、大功率盘磨的故障监测与控制系统研发方面的研究。

盘磨故障诊断框架如图 1 所示。




图 1 盘磨故障诊断框架

Fig. 1 Fault diagnosis framework of the disc refiner

2 基本原理

2.1 小波包提取故障特征

小波分析具有良好的时频域局部化特性,能够同时提供非平稳信号的时域与频域的局部化信息。小波包分析方法是对小波变换的一种改进,能够对信号进行更加细致的分析和重构。它在全频带进行多层次的频带划分,对没有细分的高频带作进一步细分。对小波包分解的各个节点进行系数重构,重构的信号可以反映该节点所对应频段成分在原始信号中的分布情况,从而实现对原始信号的频域抽取。在故障诊断系统中,通过频率的变化来反映状态特征变化、突出故障特征。信息熵是对一个随机变量的信息和不确定性的测量,通常用来测量一个系统的“无序”程度、度量系列的未知程度、估计随机信号的复杂性。

2.1.1 小波包分解算法

离散信号按小波包分解时,分解为低通滤波和高通滤波两部分,每一次分解就将上层(j+1)的第n个频带进一步分割变细为下层j的第2n及(2n+1)两个子频带。离散信号小波包分解算法为:

$$\begin{cases} d_i(j, 2n) = \sum_k a_{k-2i} d_k(j+1, n) \\ d_i(j+1, n) = \sum_k b_{k-2i} d_k(j+1, n) \end{cases} \quad (1)$$

式中: a_k 、 b_k 为小波分解共轭滤波器系数。

2.1.2 小波包重构算法

小波包重构即对小波包分解后的信号进行重构,其重构算法如下:

$$d_i(j+1, n) = \sum_k [p_{i-2k} d_k(j, 2n) + q_{i-2k} d_k(j, 2n+1)] \quad (2)$$

式中: p_k 、 q_k 为小波重构共轭滤波器系数。

2.1.3 小波包能量熵计算

① 对采集信号进行j层小波包分解,得到 $S(j, k)$, 其中 $k = 0, 1, 2, \dots, 2^{j-1}$ 。根据信号的时间域特性, 可得:

$$Q_{i(j,k)} = \int_{t_0}^{t_i} |A_i(t)|^2 dt \quad (3)$$

式中: $A_i(t)$ 为第i分段的幅值, $i = 1, 2, \dots, N$; (t_0, t_i) 为第i分段的起止时间点。

② 根据式(4),将信号的各个分段能量进行归一化处理,得到归一化值:

$$\varepsilon_{i(j,k)} = \frac{Q_{i(j,k)}}{\sum_{m=1}^N Q_{i(j,k)}} \quad (4)$$

③ 根据信息熵基本理论,定义小波分解的第j层k节点的小波包熵为:

$$H_{i(j,k)} = -\sum_{i=1}^N \varepsilon_{i(j,k)} \lg \varepsilon_{i(j,k)} \quad (5)$$

④ 用 Daubchies 小波系列的 db5 小波进行七层小波包分解,分解得到七个频段,分别将七个频段的小波包能谱熵组成特征向量,作为神经网络的输入信号:

$$T = [H_0, H_1, H_2, H_3, H_4, H_5, H_6] \quad (6)$$

2.2 BP 神经网络

在运用 D-S 证据理论解决故障诊断问题时,首先要构造出各个证据,对故障模式的基本概率进行分配。该过程通常是非线性的而且复杂,而由 BP 神经网络的特点可知,通过大量样本的学习可以使网络具有较强的泛化能力,从而可以很好地描述这种非线性的复杂关系。

任意闭区间内的一个连续函数都可以用一个隐层的 BP 神经网络来逼近,因而一个三层的 BP 神经网络可以完成任意的 n 维到 m 维的非线性映射。BP 神经网络由输入层、隐含层、输出层三层构成。其中,输入层节点数为 n,隐含层为 r,输出层为 m,第 i 个输入节点与第 j 个隐层节点的连接权值为 w_{ji} ,第 j 个隐层节点与输出节点之间的权值为 v_{kj} ,隐层阈值为 θ_j ,输出节点的阈值为 θ_k ,并设有 N 个学习样本 $X_\rho = [x_{\rho 0}, x_{\rho 1}, \dots, x_{\rho(N-1)}]^T$,为第 ρ 个学习样本的输入向量; $Y_\rho = [y_{\rho 0}, y_{\rho 1}, \dots, y_{\rho(M-1)}]^T$ 为第 ρ 个学习样本的输出向量。BP 网络拓扑结构如图 2 所示。




图 2 单隐层 BP 神经网络拓扑结构

Fig. 2 Topological structure of BP neural network with single hidden layer

2.3 D-S 证据融合

2.3.1 证据理论原理

定义 1 设 U 表示 X 所有可能取值的一个论域集合,且所有在 U 内的元素间互不相容,则称 U 为 X 的识别框架,有函数 $m: 2^U \rightarrow [0, 1]$ 满足下列条件:

- ① $m(\Phi) = 0$;
- ② $\sum_{A \subseteq U} m(A) = 1$;

则称 $m(A)$ 为 A 的基本概率分配 (basic probability assignment, BPA)。当 A 为 U 的子集且 $m(A) \neq 0$ 时, 称 A 为 m 的焦点。

定义 2 命题的信任函数 BEL 和似真函数 PL 定义为:

$$\textcircled{1} BEL(A) = \sum_{B \subseteq A} m(B) \quad \forall A \subseteq U$$

$$\textcircled{2} PL(A) = 1 - BEL(\bar{A}) = \sum_{B \cap A \neq \emptyset} m(B)$$

信任函数与似真函数之间有如下关系: 对所有的 $A \subseteq \theta$ 有 $A \subseteq \theta, PL(A) \geq BEL(A)$, 对 A 的不确定性, 用对偶区间 $[BEL(A), PL(A)]$ 表示, $[0, BEL(A)]$ 被称为信任区间。

2.3.2 D-S 证据合成法则

应用 D-S 证据理论就是在同一识别框架下, 将不同特征的证据体合并成一个新的证据体的过程。设 $\{M\} = \{A_1, A_2, \dots, A_M\}$ 和 $\{N\} = \{B_1, B_2, \dots, B_N\}$ 为识别框架 D 的两个子集, 而且满足:

$$\sum_{A \cap B \neq \emptyset} m_1(A) m_2(B) \leq 1 \quad (7)$$

则利用式 (8) 计算两个基本可信度数的正交和。

$$\begin{cases} m(C) = \frac{\sum_{A \cap B} m_1(A) m_2(B)}{1 - K} \\ K = \sum_{A \cap B} m_1(A) m_2(B) \end{cases} \quad (8)$$

3 试验分析

盘磨常见故障模式有: 电机与磨机同轴度偏差、动定盘不对中、磨齿损坏、转轴弯曲、轴承损坏、轴间隙过大这六种; 加上盘磨无故障运行状态时所对应的正常模式, 盘磨的运行状态模式共有七种。为了便于分析, 这里以某纸厂采集现场出现故障和正常的的数据为基础来检验效果。

3.1 运用小波包提取故障特征

试验中采样频率为 1 200 Hz, 选取 40 组数据作为研究对象, 其中 20 组作为神经网络训练, 另外 20 组数据作为检验数据。根据盘磨故障信号特点, 采用基于 Matlab 中自带的 db5 进行七层分解, 并对分解后的信号进行重构。限于篇幅, 这里只给出轴承振动信号同轴度偏差以及磨片损坏两种故障的小波包分析结果以及部分样本数据分解重构后的能量熵值, 如图 3、图 4 所示, 图 3、图 4 中纵坐标均表示振动位移, 单位为 μm 。从图 3 和图 4 可以看出, 不同故障模式下各个频段区别明显, 不同故障模式下的重构信号区别明显; 以小波包能量熵为基础提取的故障特征能够表征特定故障模式。将采集到的部分故障数据以及正常数据根据式 (3) ~ (6) 进行能量计算, 结果如表 1 所示。

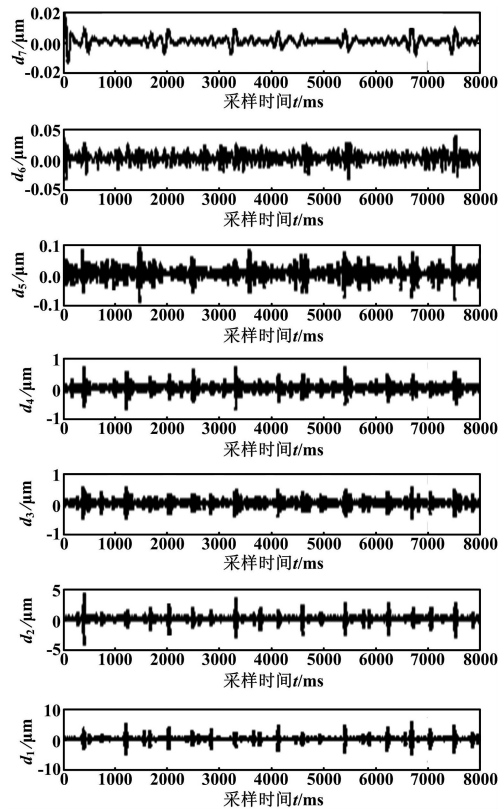


图 3 同轴度偏差信号小波包重构

Fig.3 Wavelet packet reconstruction for the coaxiality deviation signal

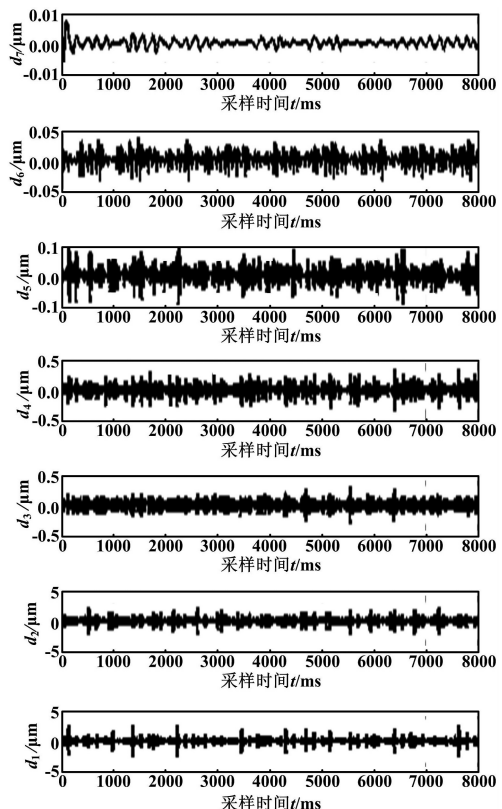


图 4 磨片损坏信号小波包重构

Fig.4 Wavelet packet reconstruction for the damaged signal

表 1 部分样本数据能量熵计算值

Tab.1 Energy entropy calculation values of partial sample data

盘磨状态模式	D_1	D_2	D_3	D_4	D_5	D_6	D_7
同轴度偏差	0.654 3	0.210 6	0.101 5	0.080 4	0.022 5	0.008 5	0.005 3
	0.621 8	0.180 9	0.095 6	0.091 5	0.021 8	0.007 6	0.006 8
	0.664 7	0.201 1	0.096 4	0.086 6	0.023 7	0.008 8	0.004 8
磨片损坏	0.456 7	0.384 5	0.098 5	0.027 8	0.015 3	0.008 4	0.003 2
	0.463 2	0.370 9	0.101 2	0.030 2	0.014 2	0.007 7	0.002 8
	0.449 8	0.379 2	0.089 7	0.028 5	0.016 8	0.009 1	0.003 7
定动盘偏差过大	0.523 6	0.276 8	0.105 5	0.078 3	0.027 8	0.011 3	0.008 6
	0.523 6	0.276 8	0.105 5	0.078 3	0.027 8	0.011 3	0.008 6
	0.523 6	0.276 8	0.105 5	0.078 3	0.017 8	0.011 3	0.008 6
正常	0.039 6	0.235 2	0.437 2	0.134 6	0.097 4	0.028 3	0.019 7
	0.032 9	0.242 1	0.447 3	0.123 7	0.088 5	0.022 2	0.020 4
	0.041 1	0.236 8	0.425 6	0.130 6	0.092 8	0.026 7	0.019 3

表 1 中, $D_1 \sim D_7$ 为频段 1 ~ 频段 7 的熵值, 其作为神经网络的输入信号。从表 1 可以看出, 正常情况下能量熵值主要集中在频段 2 ~ 频段 4, 而出现故障主要集中在频段 1 ~ 频段 3。此外, 不同的故障模式下各个频段所反映的小波包能量熵值不同。因此, 通过对振动信号的能量特征提取, 根据能量谱特性的分布, 可以提取盘磨的故障特征, 对盘磨故障进行监测、诊断。如果能够获得足够的故障数据样本, 对其小波包分解重构, 找出同类故障的能量熵值分布共性, 可以进一步提升故障诊断的准确率。

3.2 融合决策输出

以图 1 所示诊断系统结构进行诊断。将采集到的 40 组数据中的 25 组作为训练样本, 另外 15 组作为检验样本。根据设定的目标函数值, 将故障信号小波包分解重构计算后的能量熵值作为网络输入, 故障的分类作为网络的输出, 则神经网络的结构为: 输入为七层、输出为七层、隐含层为 14 层。采用有动量、自适应梯度下降法训练网络, 隐含层及输出层分别采用 tansig、logsig 传递函数, 以测试数据作为训练好的神经网络的输入。部分测试数据输出结果如表 2 所示。

表 2 部分测试数据输出比较

Tab.2 Comparison of partial test data outputs

故障模式	诊断方式	诊 断 概 率							诊断结果
		$m(A)$	$m(B)$	$m(C)$	$m(D)$	$m(E)$	$m(F)$	$m(G)$	
同轴度偏差	BP1	0.524 3	0.013 0	0.302 5	0.001 6	0.125 2	0.060 1	0.000 2	未知
	BP2	0.794 3	0.033 0	0.101 5	0.162 3	0.005 2	0.008 1	0.000 1	A
	融合	0.944 3	0.003 0	0.012 5	0.011 6	0.010 2	0.011 1	0.001 2	A
动定盘不对中	BP1	0.006 6	0.872 1	0.044 7	0.000 2	0.012 5	0.008 1	0.000 3	B
	BP2	0.057 2	0.402 2	0.354 6	0.080 7	0.032 3	0.108 2	0.073 5	未知
	融合	0.016 6	0.952 1	0.000 7	0.020 2	0.012 5	0.008 1	0.005 3	B
转轴弯曲	BP1	0.015 2	0.122 2	0.771 6	0.113 5	0.017 7	0.001 3	0.001 2	C
	BP2	0.105 3	0.062 1	0.821 3	0.013 5	0.027 2	0.003 3	0.001 6	C
	融合	0.025 2	0.022 2	0.941 6	0.013 5	0.000 7	0.005 3	0.003 2	C

表 2 中: A、B、C、D、E、F 分别对应电机与磨机同轴度偏差、动定盘不对中、磨齿损坏、转轴弯曲、轴承损坏、轴间隙过大六种故障状态下的状态模式, 另外 G 代表盘磨没有运行故障时的正常状态模式; “BP1” 表示由轴承轴向振动位移传感器所测得的数据通过式(1) ~ (6) 神经网络学习训练后的输出值; “BP2” 表示径向振动位移传感器所对应的神经网络输出值; “融合” 表示将两个神经网络的输出通过 D-S 证据理论融合后的输出结果; $m(A)$ 、 $m(B)$ 、 $m(C)$ 、 $m(D)$ 、 $m(E)$ 、 $m(F)$ 、 $m(G)$

分别代表对状态模式 A、B、C、D、E、F、G 的概率分配, 这些概率的大小代表针对某种状态模式的靠近程度。从图 1 中的诊断结构可以看出, 在数据融合的诊断中间层通过神经网络提供 D-S 理论的基本概率分配, 同时因为 BP 神经网络能够模拟一切非线性的特点, 其输出的概率也是对故障的初步判断。

从表 2 中可以看出, BP1 神经网络和 BP2 神经网络输出存在输出概率不高的情况, 即存在对故障判断

(下转第 28 页)