

智能异构模型在电机故障诊断中的研究*

刘建成** 蒋新华 吴今培

(中南大学信息工程学院 长沙 410075)

【摘要】提出以测试电机的三相电流噪声为电机故障特征信号的诊断方法,建立电机电流噪声多元时序模型,将时序模型的多元残差序列化为一元序列作为故障总体检测指标。针对多元时序模型参数的特点,提出了多层NN的故障类型识别模型,应用APEX网络提取初始模式向量的分类信息,利用前馈网络建立其识别函数,实践证明该诊断方法是正确的。

关键词 故障诊断;时序模型;神经网络;模式向量

中图分类号 TM307.1 文献标识码 A

Research of Intelligent Various Structure Models in Motor Faults Diagnosis

Liu Jianchen Jiang Xinhua Wu Jinpei

(School of Information Engineering, Central South University ChangSha 410075)

Abstract The paper puts forward a set of faults diagnosis methods of testing the noise of the three-phase motor current which shows the characteristics of the motor faults. and multi-varieties time series models of the noise is established, the multi-varieties residual series is changed to the monistical as the fault detection index. In the fight of trait of the model parameter, presenting a faults classification recognition model based on the multi-layer NN structure, using APEX network extracts classification information of the initial pattern vector, making use of feedforward network establishes the classification function. The diagnosis way is correct by practising.

Key words faults diagnosis; time series model; neural network; pattern vector

从电机原理角度,电机电流噪声与电机的磁噪声密切相关^[1]。电机故障时,磁噪声受转子槽或定子槽的偏心、不对称、磁饱和、机械轴承引起的转子不平衡电机等效阻抗发生变化产生的电磁力波的影响,进而影响电流噪声发生变化。电磁力波在电流噪声上表现为各噪声频率分量的大小、相位发生变化,故电流噪声全面反映了电机故障的状态信息。本文应用时序分析和神经网络等方法对电机电流噪声进行分析、处理,实现电机故障的总体检测和故障诊断。

电流噪声在电机工作电流中所占能量较低,直接对电机电流处理进行故障诊断,不能得到准确的结果。利用噪声分量表明故障特征,需设计一套电流噪声测试方法^[2],该方法必须要有较高的线性度、足够的通频带和抗干扰性、不影响被测试系统运行的特性。测试系统主要由取样、光电隔离、50 Hz工频陷波、低通/高通、高速A/D转换等硬件模块组成。

2002年8月28日收稿

* 湖南省自然科学基金资助项目,编号:01JJY2063;湖南省专项资金资助项目,编号:00JCY2008

** 男 39岁 博士 副教授 主要从事智能信息处理、设备状态监测与故障诊断方面的研究

1 电机故障总体检测研究

1.1 电流噪声模型的辨识

电机电流噪声信号包含了电机运行特性、故障状态特征的三相信号 $X_1(t)$ 、 $X_2(t)$ 、 $X_3(t)$, 利用其建立起电机电流噪声的三元时序模型, 使电机系统的各种信息存于模型的结构及参数中。电机系统的ARV时序模型为^[2]:

$$X_t = \sum_{i=1}^n \Phi_i X_{t-i} + A_t \quad (1)$$

式中 X_t 为 3×1 电流噪声向量; A_t 为 3×1 白噪声向量; Φ_i 为 3×3 参数矩阵; n 为模型阶数。

用Levinson递推算法估计模型的参数, 模型阶数的确定采用最小最终预报误差准则^[3]。

1.2 检测原理研究

由式(1)可知, 在正常状态下, 电机运行状态特性包含在动态模型中。模型是一个滤波器, 它能消除已知系统的动态信息, 剩下白噪声向量为:

$$A_t = X_t - \sum_{i=1}^n \Phi_i X_{t-i} \quad (2)$$

当电机发生故障, 系统的动态特征亦相应变化, 正常状态下的模型不能滤波出现行系统的所有信息, 因此, 由式(2)得到的残差向量 A_t , 不是白噪声向量, 而是有色的。把残差序列变化的显著程度作为故障检测指标来判断电机是否发生故障。

由于多元问题的复杂性及背景知识的不明确性, 需把多元问题化为一元问题来研究残差序列的变化程度。

定义随机变量: $g_t = a^T A_t$, 则 $g_t \sim N(0, a^T \Gamma a)$, 式中: $a^T = [a_1, a_2, a_3]$ 为任意常向量; $\Gamma = E(A_t A_t^T)$ 为 A_t 的方差。定义统计量

$$Z = 1/(N-n) \sum_{t=n}^N g_t^2 \quad (3)$$

即

$$Z = 1/(N-n) \sum_{t=n}^N (a^T A_t)(a^T A_t)^T = 1/(N-n) a^T \left(\sum_{t=n}^N A_t A_t^T \right) a = a^T Q a \quad (4)$$

由 $Q \sim W_3(N-n, \Gamma)$, 则

$$Z \sim a^T \Gamma a \chi^2(N-n)$$

设: 待检电机的电流噪声序列为 $X_T = \{X_{T,j}; j=0,1,2,\dots,N\}$, 由 X_T^T 得到的模型参数为 $\Phi_T = \{\Phi_i; i=1,2,\dots,n\}$; 则其残差序列为 $A_T = \{A_{T,t}; t=n+1,\dots,N\}$ 。将 X_T 代入式(2)(电机正常运行时的模型)中, 其残差序列为 A_{RT} , N 为采样数据序列长度。同样可得到:

$$Z_{RT} = 1/(N-n) (a^T A_{RT} A_{RT}^T a) = a^T Q_{RT} a \quad (5)$$

$$Z_T = 1/(N-n) (a^T A_T A_T^T a) = a^T Q_T a \quad (6)$$

当 $|A_{RT} A_{RT}^T| > |A_T A_T^T|$ 时, $Z_{RT} > Z_T$ 反之亦然。即要检验所观测电机的运行状态, 就是检验 Z_{RT} 与 Z_T 之间的显著变化程度。

根据式(5)、(6), 当电机运行正常时, Z_{RT} 、 Z_T 服从 $a^T \Gamma a \chi^2(N-n)$ 分布, 构造统计检验量

$$F = \frac{Z_{RT} / N_1}{Z_T / N_2} \quad (7)$$

式(7)为自由度(N_1, N_2)的 F 统计量, 即 $F \sim F(N_1, N_2)$ 。

以式(7)为统计量标准, 取置信度 δ , 查 F 分布表得 $F(N_1, N_2)$ 。

1) $F > F(N_1, N_2)$, 待检电机运行状态变化显著, 可能有故障, 可信度为 $(1-\delta) \times 100\%$ 。

2) $F < F(N_1, N_2)$, 被检验电机运行状态变化不显著, 电机工作正常。

2 电机故障类型识别研究

由于电机各故障类型机理不同,电磁噪声引起的电流噪声各频率分量的大小、相位也不相同,在模型参数矩阵上也有一定的差异性。通过其差异性,在电机故障总体检测基础上,应用多层结构的神经网络方法识别电机故障类型。

2.1 初始模式向量的形成

电流噪声时序模型参数矩阵 Φ_i 全面反映了电机系统的内在特性及电机故障状态信息,用 Φ_i 作为诊断系统的模式向量空间,其特点是对故障类型较敏感,易于度量、提取,对同一故障类型相对稳定。

电机状态的初始模式向量定义为: $W = [\Phi_1, \Phi_2, \dots, \Phi_n] = [w_1, w_2, \dots, w_N]$ 。模式向量空间的特征维数: $N = 9 \times n$ 。

2.2 模式向量的主特征提取

对于故障类型, N 个特征含有的类型识别信息量不同,有些特征对类型识别非常重要。各个特征之间存在较大程度的相关冗余,向量维数太高 ($N > 40$),导致类型识别问题复杂化,在训练样本有限时,类型识别模型推广能力较差^[4]。所以要利用现有特征,通过降维映射方法,构造成少数新特征(主成分),每个新特征是原有特征的函数,用新特征来反映电机状态模式向量空间的整体特征。

常用降维映射提取主成分方法是 Karhunen-loeve 变换,它基于最小均方差准则,对样本模式向量相关矩阵进行特征值分解计算。本文采用自适应主成分提取神经网络递推算法(APEX)^[5],其主要特点是若给出前 $P-1$ 个主成分,就可递推得到第 P 个主成分,各主成分互不相关。

网络学习完成后,网络输入输出关系为

$$Y = U \cdot W \quad (8)$$

式中 $Y^T = [y_1, y_2, \dots, y_p]$ 为经 APEX 网络映射提取的 P 个主成分输出向量; $U = [u_{ij}, i=1, 2, \dots, N, j=1, 2, \dots, p]$ 为 APEX 神经元节点连接权矩阵。

按照文献[6]所提供的递推算法,当样本足够大时,可得到如下3个结论:

- 1) 连接权矩阵 U 满足正交规一条件: $U_i \cdot U_j^T = 0 (i \neq j)$, $U_i \cdot U_i^T = 1$ 。
- 2) 新特征 y_i 两两之间不相关; 设 $E[y_i^2] = \lambda_i$, 则 $\lambda_1 > \lambda_2 > \dots > \lambda_p$ 。
- 3) λ_i 的大小反映特征 y_i 所包含的信息量。

在信息量基本不变的前提下,剔除 λ_i 较小的特征,降低向量空间维数,即确定合适的 P , 利于故障识别。前 P 个主成分的识别信息累计贡献率定义为

$$\xi = \frac{\sum_{i=1}^P \lambda_i}{\sum_{i=1}^N \lambda_i} \quad (9)$$

根据一般经验 $\xi \geq 85\%$ 时^[6], 即可认为包含了主要的信息要素,可用前 P 个主成分构成新的模式向量 Y 。

在式(9)中,要求递推出所有 λ_i , 当 P 与 N 相差较大时,需要增加较长的学习时间。

由于 $\sum_{i=1}^N E[w_i^2] = E[W \cdot W^T] = E[UYY^T U^T] = UU^T \sum_{i=1}^N E[y_i^2] = \sum_{i=1}^N \lambda_i$, 所以式(9)变为:

$$\xi = \frac{\sum_{i=1}^P \lambda_i}{\sum_{i=1}^N E[w_i^2]} \quad (10)$$

式中 $E[w_i^2]$ 采用估计式 $\frac{1}{m-1} \sum_{j=1}^m w_{ij}^2$ (m 为样本数)。式(10)与式(9)比较,减少了学习时间。

2.3 故障类型模式识别

通过对模式向量空间的 APEX 网络主成分提取,进一步凝聚电机故障类型鉴别信息,得到一个较低维的模式向量,在此基础上对电机故障类型识别。根据电机故障机理,电机故障类型集合可定义为: $X = \{X_1(\text{轴弯曲}), X_2(\text{轴承故障}), X_3(\text{转子断条}), X_4(\text{相间短路}), X_5(\text{相间绝缘低}), X_6(\text{匝间短路}), X_7(\text{绕阻接地}), X_8(\text{过载运行})\}$, 现场测试故障电机样本分别属于这八种类型。

电机类型识别是根据已知电机故障类样本模式信息构造一个分类判别函数,来判别未知类属的电机故障类型。本文采用三层结构的前馈神经网络构造类型判别函数。设网络的输入层节点个数为 P , 输出层节

点个数为故障类型数8, 隐层节点数 M 由经验公式确定^[4], $M = \sqrt{P+8} + d$, d 为1~10之间的常数, 本文取 $d=5$ 。

对于网络的学习, 采用同伦BP算法^[7], 避免陷入局部最小和网络振荡。学习时, 已知第 i 类故障的输入模式向量为 Y , 则对应输出向量为: $X = \{X_j; i \neq j, X_j = 0; i = j, X_j = 1\}$, 把它们分别加入到类型识别网络的输入层和输出层。通过网络学习, 达到稳定后, 则故障分类知识存储在各自网络权值上。

故障类型识别时, 经APEX网络压缩后的输出主成分向量输入到类型识别网络得到输出值。取

$$X_i = \max(X) \quad (11)$$

则可认为该故障模式属于第 i 类故障。

3 应用分析

按照文献[2]的测试方法, 现场实测了多种型号电机, 其中一种型号为JO₂-82-2型电机, 容量为70 kW, 三角形接线; 在转子断条时的电流噪声信号如图1所示。

3.1 故障总体检测应用分析

从电机系统ARV模型估计结果, 同一类型的正常电机, 其结构、参数变化较小, 即模型的鲁棒性好。本文用正常电机模型作为故障检测的参考模型, 以JO₂-82-2型电机为例说明其检测过程, 采样数据长度为128。

常数向量 $a = [a_1, a_2, a_3]$ 是残差序列方差矩阵各元素之和的加权值, 对于故障总体检测, 各元素对检测效果的贡献是等同的, 所以 $a = [1, 1, 1]$ 。

待检电机电流噪声信号代入参考模型中得到的残差方差矩阵为

$$Q_{RT} = \begin{bmatrix} 13.63 & 6.41 & 3.12 \\ 9.17 & 13.45 & 11.59 \\ 1.46 & 2.51 & 3.75 \end{bmatrix}$$

待检电机电流噪声模型的残差矩阵为

$$Q_T = \begin{bmatrix} 6.32 & 3.92 & 3.37 \\ 2.21 & 4.50 & 7.39 \\ 1.52 & 2.55 & 2.92 \end{bmatrix}$$

根据式(5)、(6)、(7), 有 $Z_{RT} = a^T Q_{RT} a = 65.09$, $Z_T = a^T Q_T a = 43.70$, $F = \frac{Z_{RT} / N_1}{Z_T / N_2} = 1.49$, $N_1 = N_2 = N - n = 123$ 。

取 $\delta = 0.15$, 查 F 分布表得 $F(123, 123) \approx 1^{[6]}$, 即 $F > F(123, 123)$, 说明 Q_{RT} 或 A_{RT} 变化显著, 电机异常。

3.2 电机故障类型识别应用分析

对于JO₂-82-2型电机, 其多元时序模型阶数为5, 初始模式向量的特征数为45, 在样本数较小, 特征之间相关性较强时, 必须对初始模式向量重新构造, 使分类信息凝聚在少数几个主要特征中, 再进行故障类型识别。按照主特征提取方法及故障类型识别方法, 构成故障类型识别模型如图2所示。




图2 电机故障类型识别模型

模型中的预处理主要是消除稳态分量和输入模式向量的归一化处理。模型分阶段学习, 先学习APEX网络, 再训练前馈网络。对于APEX网络, 训练样本为所有实测故障电机(43台); 对于前馈网络, 训练样本为33台, 另外10台为效验样本, 在训练中选取合适的学习率、动量因子。APEX网络模型训练稳定后, 按




图1 三相电流噪声信号

照式(10), 可得 $P=10$, 即由45维的初始模式向量经APEX网络变换, 形成10维的模式向量。

将10台故障电机的初始模式向量输入到图2所示的类型识别模型中, 得到的模型输出结果如表1所示, 按式(11)类型识别, 从识别结果可以看出, 模型类型识别是正确的。

表1 效验样本模型输出结果

效验样本 已知类型	模型输出								故障识别 类型
	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	
5	0.14	0.21	0.09	0.16	0.86	0.42	0.34	0.23	第5类
2	0.47	0.69	0.31	0.23	0.17	0.08	0.11	0.31	第2类
4	0.22	0.17	0.08	0.79	0.53	0.36	0.34	0.19	第4类
3	0.43	0.27	0.65	0.15	0.25	0.13	0.20	0.26	第3类
1	0.61	0.43	0.41	0.16	0.08	0.15	0.17	0.29	第1类
2	0.40	0.59	0.35	0.13	0.20	0.11	0.07	0.26	第2类
8	0.16	0.23	0.24	0.38	0.35	0.42	0.36	0.67	第8类
7	0.13	0.09	0.06	0.32	0.44	0.30	0.58	0.43	第7类
6	0.07	0.20	0.19	0.29	0.31	0.65	0.47	0.37	第6类
8	0.15	0.17	0.08	0.35	0.33	0.41	0.28	0.54	第8类

4 结论

通过大量现场实测及电机故障诊断分析, 可得到如下结论:

1) 提出的基于多元时序模型的电机电流噪声故障总体检测方法是正确的, 具有较高的检测精度。对于不同类型的电机, 其模型的结构、参数差异较大, 只能按类进行电机的故障检测。

2) 针对样本空间较小, 故障特征向量维数较高, 各特征之间相关性较强, 提出应用APEX网络对特征向量降维处理, 提取其主要故障类型识别信息, 再应用前馈神经网络方法对故障类型识别, 实践证明这种方法可行的, 保证了诊断识别模型具有推广能力。

参 考 文 献

- [1] 陈永校. 电机噪声分析[M]. 杭州: 浙江大学出版社, 1987
- [2] 刘建成, 吴今培. 电机电流噪声在线测试及其故障检测[J]. 长沙铁道学院学报, 1998, 16(3): 67-71
- [3] 扬叔子. 时间序列分析的工程应用[M]. 武汉: 华中理工大学出版社, 1991
- [4] 黄德双. 神经网络模式识别系统理论[M]. 北京: 电子工业出版社, 1996
- [5] Kung S Y, Diamantaras K I. A neural network learning algorithm for adaptive principal component extraction (APEX)[J]. Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing ICASSP-90, II, New York: IEEE, 1990, 861-863
- [6] 方开泰. 实用多元统计分析[M]. 上海: 华东师范大学出版社, 1989
- [7] 高小榕, 杨福生. 采用同伦BP算法进行多层前向神经网络的训练[J]. 计算机学报, 1996, 19(2): 687-694

编辑 漆 蓉