

电站热力系统故障智能诊断系统的功能结构及诊断模型

马良玉¹, 段 巍², 高建强¹, 王兵树¹, 佟振声¹

(1. 华北电力大学仿真与控制技术研究所, 河北省保定市 071003; 2. 华北电力大学机械工程系, 河北省保定市 071003)

摘要: 简要介绍了火电机组热力系统故障智能诊断系统的总体功能结构和诊断模型构成。结合某 300 MW 火电机组高压给水加热器系统故障诊断实例, 详细阐述各模块的功能和实现方法。针对模型软件开发中的关键技术, 详细论述了电站热力系统故障诊断中语义型和趋势型两种征兆的模糊数学表达及合成计算方法, 该综合运用有利于提高故障诊断的及时性和诊断结果的可靠性; 给出了模糊模式识别和人工神经网络两种故障智能诊断模型, 讨论了两种模型的技术要点。给出了高压给水加热器系统具体诊断算例, 验证了所述技术和方法的有效性。

关键词: 火电机组; 故障诊断; 征兆计算; 模糊模式识别; 人工神经网络

中图分类号: TK38; TP277

0 引言

电站热力系统状态监测及故障诊断系统的开发和应用, 对提高火电机组运行的安全和经济性具有明显、重要的意义, 近几年来已成为电力科研工作者的研究热点。“火电机组热力系统故障智能诊断系统”作为国家电力公司科技项目子课题, 旨在结合火电机组仿真技术的优势, 总结、完善热力系统的常见故障知识库, 并运用专家系统、神经网络等现代智能诊断理论和方法, 开发一套实用的热力系统故障智能诊断软件平台, 经仿真验证后最终应用于电站实际热力系统。

本文首先简要介绍火电机组热力系统故障智能诊断系统的总体功能结构, 然后结合某 300 MW 火电机组高压给水加热器系统故障诊断实例, 具体阐述各模块的功能和实现, 重点对系统开发中采用的征兆模糊处理方法、基于神经网络及模糊模式识别的智能诊断模型等关键技术进行讨论。

1 故障智能诊断系统的总体功能结构

热力系统故障智能诊断系统目前已包括凝汽器、高压加热器、低压加热器等设备和系统的故障智能诊断, 且诊断对象在不断扩充。故障诊断系统按其功能可包括特征参数预处理和征兆计算、诊断知识库、诊断方法库、系统管理和过程控制模块、诊断结果显示处理等模块。各个模块共同完成实时参数和特征参数提取、故障征兆计算、故障实时判别、诊断

结果输出等功能^[1], 如图 1 所示。

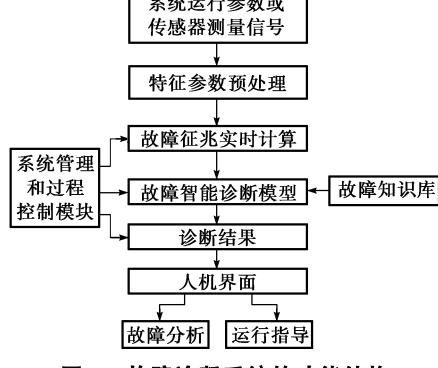


图 1 故障诊断系统的功能结构
Fig. 1 General structure of the fault diagnosis system functions

2 故障智能诊断系统各模块功能及其实现

为阐明故障诊断模型开发中采用的主要技术, 并使理论研究紧密结合具体工程应用, 下面结合 300 MW 火电机组高压给水加热器系统故障诊断, 详细介绍图 1 中各主要模块的功能和实现方法。

2.1 特征参数预处理

特征参数预处理的功能是: ①从数据采集系统(DAS)获得的机组运行数据中提取与具体热力设备或子系统故障紧密相关的特征参数; ②对提取的特征参数进行数据的有效性校验、数字滤波等预处理。

特征参数提取时, 有些 DAS 参数可直接用作故障特征参数, 有些特征参数需由 DAS 数据经二次计算得到。300 MW 火电机组高压加热器系统的故障包括: 高压加热器管系泄漏、进出水室短路、给水管束部分堵塞、传热管结垢、汽侧空气积聚影响传热

等。可根据高压加热器的性能特点,确定其给水端差、疏水端差、给水温升、疏水调门开度、进汽压力等故障特征参数。其中,疏水调门开度、进汽压力均为 DAS 测量参数;其他 3 个特征参数需由 DAS 参数经二次计算得到:给水温升为高压加热器出口水温 t_o 与进口水温 t_i 之差,给水端差为加热器抽汽压力相应的饱和温度 t_s 与 t_o 之差,疏水端差等于离开加热器壳侧的疏水温度 t_d 与 t_i 之差。

在进行故障征兆实时计算前,需对上述已确定的故障特征参数进行预处理,包括软件滤波、参数变化率计算等。为了克服测量仪表本身误差和测量参数随机波动的影响,可采取多种软件滤波方法,在高压加热器故障诊断中采用了滑动时间窗均值滤波法。由于故障征兆中采用了反映监测测量动态变化过程的趋势型征兆,因此需要实时计算参数变化率。

2.2 故障征兆实时计算

电站热力系统不同故障下特征参数(征兆)的变化可分为以下 3 类^[2]:①不同参数间的比较(例如 A 侧压力高于 B 侧压力);②参数波动(例如电动机电流、给水压力等的波动);③参数升降/增减(例如温度增加、压力下降等)。

上述特征参数变化中,参数升降/增减是热力系统故障诊断中最常见、应用最广的一种类型。对于此类征兆,有以下两种表达方法:①趋势型征兆:以参数单位时间变化率的正负和大小确定参数升高或降低及其变化快慢;②语义型征兆:用当前负荷参数实际运行值与应达到的目标值进行比较,并考虑不同偏差阈值,确定参数升高或降低及其程度。

下面以高压加热器系统故障发生时其给水温升的变化为例,详细介绍征兆计算模块中两种征兆的具体计算方法^[3]。

2.2.1 语义型征兆的模糊表示

在 300 MW 稳定负荷下,1 号高压加热器给水温升正常值 t_o 为 32 °C。对应于高压加热器系统不同故障,其给水温升可能增加也可能减少。为计算语义型征兆值,需预先确定高压加热器系统不同故障下 t_o 的最大可能变化范围 $(t_o - a, t_o + b)$,其中, a 为给水温升最大减小值, b 为给水温升最大增加值。由电站全仿真机对高压加热器系统不同故障进行仿真实验,确定 a, b 值为: $a = 6$ °C, $b = 7$ °C。假定参数正常时征兆值取 0,参数增大到上限时征兆值取 1,参数减小到下限时征兆值取 -1。征兆计算式若选取平方根函数形式,则高压加热器给水温升的语义型征兆值 $\mu(t)$ 的计算式如下:

$$\mu(t) = \begin{cases} 1 & t \geq t_0 + b \\ \sqrt{\frac{t - t_0}{b}} & t_0 < t < t_0 + b \\ 0 & t = t_0 \\ -\sqrt{\frac{t_0 - t}{a}} & t_0 - a < t < t_0 \\ -1 & t \leq t_0 - a \end{cases} \quad (1)$$

根据式(1),在“1 号高压加热器进出水室短路”故障发生后,若 1 号高压加热器给水温升降低了 5 °C(降低到 27 °C),则温升变化语义型征兆值为: $\mu(t)|_{t=27\text{ }^{\circ}\text{C}} = -\sqrt{(32 - 27)/6} = -0.91$;若“2 号高压加热器进出水室短路”故障发生后,使相邻的 1 号高压加热器温升变为 35 °C,则此时语义型征兆值应为: $\mu(t)|_{t=35\text{ }^{\circ}\text{C}} = \sqrt{(35 - 32)/7} = 0.65$ 。

2.2.2 趋势型征兆的模糊表示

趋势型征兆的表达方法与语义型征兆相似。由于对应于高压加热器系统的不同故障,其给水温升可能增加也可能减少,因此,给水温升变化率可正可负。为计算趋势型征兆值,同样需合理确定给水温升变化率 t' 的最大允许范围 $(-c, d)$,其中, $-c, d$ 分别为给水温升的负向、正向最大变化率。若隶属函数同样选取平方根函数形式,无故障稳定工况下特征参数的趋势征兆值取 0,参数最大正向趋势征兆值取 1,参数最大反向趋势征兆值取 -1,则趋势征兆值 $\mu(t')$ 的计算式如下:

$$\mu(t') = \begin{cases} 1 & t' \geq d \\ \sqrt{\frac{t'}{d}} & 0 < t' < d \\ 0 & t' = 0 \\ -\sqrt{\frac{|t'|}{c}} & -c < t' < 0 \\ -1 & t' \leq c \end{cases} \quad (2)$$

2.2.3 语义型征兆和趋势型征兆的合成

趋势型征兆和语义型征兆的特点不同,在故障诊断中的作用也不同。趋势型征兆在故障发生初期对故障的反应十分灵敏,有利于及早发现故障。但随着故障的持续,设备逐渐进入故障平衡态运行时,趋势型征兆值逐渐变为 0,对故障诊断不再起作用。因此,趋势型征兆的作用主要在故障发生后系统由一个稳定工况向另一稳定工况过渡的动态变化过程中体现出来,对突发型故障,在故障发生瞬间和开始阶段,其作用尤为明显。而语义型征兆当考虑偏差阈值

时在故障发生一段时间后才能表现出来,但征兆出现后可长久保持,且随故障发展征兆逐渐明显,有利于诊断结果的可靠性。

鉴于两种征兆各有优缺点,在高压加热器系统故障诊断中,对各故障特征参数均运用了两种征兆表示法,以达到故障诊断及时、可靠的目标。为此,在运用故障智能诊断模型和高压加热器系统故障知识库进行故障在线实时诊断前,首先要对两种征兆进行合成计算,将最后得到的合成征兆值用于征兆实时判别。两种征兆合成计算的方法如下:①趋势型征兆值和语义型征兆值符号相同,均大于0或小于0,此时合成征兆值 $\mu(+)$ 取两者中绝对值较大者。②趋势型征兆值和语义型征兆值符号相反,此时语义型征兆值比趋势型征兆值更能真实体现特征参数与故障间的瞬态关系,因此合成征兆值 $\mu(+)$ 取语义型征兆值。

2.2.4 从连续型数值征兆到离散阶梯型数值征兆的转换

运用上述征兆模糊表示法经合成计算得到的最终合成征兆值为 $[-1, +1]$ 区间的连续数值。为得到较为规范的典型故障样本知识库以及便于故障诊断过程的应用,有必要将连续型数值征兆转换为离散阶梯型数值征兆,例如 $\{-1, 0, 1\}$ 型3值征兆集(对应于参数减小、不变、增加)或 $\{-1, -0.5, 0, 0.5, 1\}$ 型5值征兆集(对应于参数明显减小、略微减小、不变、略微增加、明显增加)等。该过程的关键是合理确定各转换阈值,这往往需要通过多次实践进行优选。

2.3 故障知识库

高压加热器系统故障诊断知识库由典型故障集合、故障特征参数集合、故障-征兆模糊关系矩阵等部分构成。为了得到故障-征兆模糊关系矩阵,首先对可能发生的故障进行编号,依次称 u_1, u_2, \dots ;同时对选取的各特征参数进行编号,依次称 x_1, x_2, \dots 。在此基础上,借助火电机组全范围仿真机对各典型故障进行仿真实验,运用本文故障征兆计算方法求取各典型故障的模糊征兆值,最后形成高压加热器系统的 $\{-1, -0.5, 0, 0.5, 1\}$ 型5值模糊故障知识库。由于篇幅所限,这里不再具体列出高压加热器系统故障-征兆的模糊关系矩阵。

2.4 故障智能诊断模块

在高压加热器系统故障智能诊断模块中采用了故障模糊模式识别和反向传播(BP)神经网络两种故障智能诊断模型^[3]。

2.4.1 故障模糊模式识别模型

由于高压加热器系统故障识别的对象基本是清

楚的,因此采用模糊模式识别中的直接法,通过建立故障模糊隶属函数,借助高压加热器系统故障模糊知识库,结合阈值原则和最大隶属原则对故障进行判别。其过程是:首先用选定的隶属函数计算待识别故障征兆对各典型故障模式的隶属度,然后运用阈值原则判断当前征兆集是否健康,在征兆集健康的前提下再运用最大隶属原则确定故障。

采用模糊模式识别方法诊断热力系统故障,效果好坏的关键在于隶属函数的建立。隶属函数的建立应遵循如下原则:①具有较高的故障分离效果;②对故障发生时间和微小故障的反应比较灵敏;③避免对正常运行工况的误诊断。根据这些原则,对不同的故障征兆表示法,模型应相应地采用不同形式的故障模糊隶属函数对故障进行识别。

为了实现故障模糊模式识别模型的通用化,使其适于采用 $\{0, 1\}$ 型、 $\{-1, 0, 1\}$ 型、 $\{-1, -0.5, 0, 0.5, 1\}$ 型等不同征兆表达方法的故障模糊知识库,根据上述原则,建立了如下通用故障模糊隶属函数计算公式:

$$\mu_{u_i}(u_0) = \left[1 - \frac{d_i(u_0, u_i)}{D} \right]^2 \quad (3)$$

$$d_i(u_0, u_i) = \frac{\sum_{j=1}^{S_{\max}} |x_j - x_{ij}|}{\sum_{j=1}^{S_{\max}} |x_{ij}|} \quad (4)$$

$$D = \max d_i(u_0, u_i) \quad (5)$$

式中, $d_i(u_0, u_i)$ 为待识别对象 $u_0 = (x_1, x_2, \dots, x_{S_{\max}})$ 与典型故障模式 u_i 的一种距离; D 为其中的最大值; x_{ij} 为典型故障模式 u_i 的各征兆取值; $i = 1, 2, \dots, F_{\max}; j = 1, 2, \dots, S_{\max}$; F_{\max}, S_{\max} 分别为某具体热力设备或系统包括的典型故障模糊模式的个数、故障征兆向量包含的征兆个数。

2.4.2 故障的BP神经网络诊断模型

由于由输入层、隐含层、输出层构成的前向多层神经网络具有中间隐含层(也称特征抽取层),因而具有高度的非线性模式识别能力。为此,本文开发的神经网络诊断模型采用3层前向神经网络诊断热力系统故障^[4]。网络中间层和输出层的神经元响应函数均取为 S 函数: $f(x) = 1/(1 + e^{-x})$ 。

神经网络诊断模型包括网络训练和故障实时识别两部分。训练过程将热力系统的故障模糊知识库以网络连接权值的形式分布式存储在网络中,训练完成后即可实时快速识别热力系统运行中发生的故障。这一过程的关键在于网络训练过程,要保证网络有较高的收敛精度,并有较快的收敛速度。

传统误差 BP 算法网络训练的收敛速度很慢。为加速网络收敛速度,本文模型中采用恒误差修正率控制的网络学习率 α, β 自适应调整算法对 BP 算法进行改进。该算法的基本思想是:保证每次学习后的综合误差比上一次的综合误差减小一定百分比^[5]。

运用上述学习率自适应调整方法,可大大加快 BP 网络的收敛速度。对于本文高压加热器系统典型故障模式,网络输入层单元数为 19,输出层单元数为 19,中间隐含层单元数取 25,学习率 α 和 β 初值分别取 0.4 和 0.4, c_s 取 0.004, η_{\max} 取 0.8。运用上述方法学习 824 次后综合误差即小于 0.0001,学习终了, α 和 β 计算值分别为 17.24 和 17.24。若不采用学习率自适应调整的方法,达到同样的精度需要学习 18 324 次。可见本文网络学习方法的有效性。

2.5 系统管理和过程控制模块

系统管理和过程控制模块主要实现对特征参数预处理模块、征兆实时计算模块、故障知识库、故障智能诊断模块的管理和控制功能。通过这一模块,对于特征参数预处理模块可选择滤波方法、设定参数变化率计算周期;对于征兆计算模块,可设定各特征参数正常运行值、语义型征兆值的允许变化范围、趋势型征兆的最大正向和负向变化率,可选择不同形式的征兆计算式;对于故障知识库,可进行修改和维护;对于故障智能诊断模块,可选择故障模糊隶属函数的形式、修改故障判别阈值;对于神经网络诊断模型,可选择网络初始参数,可控制网络训练和诊断过程。

3 诊断实例

为说明本文方法和诊断模型的效果,给出高压加热器系统故障诊断的具体实例。以电站全仿真机模拟“1号高压加热器进出水室短路 10%”故障,在系统进入故障后的平衡态运行时用两种方法进行故障识别,结果见表 1。

表 1 “1号高压加热器进出水室短路 10% 故障”用两种方法诊断的结果

Table 1 Diagnostic results for “No. 1 heater water-room short circuit 10%” fault with two methods

诊断方法	最可能故障 (故障隶属度)	次可能故障 (故障隶属度)
模糊模式识别方法	0.884 ^①	0.737 ^②
神经网络方法	0.662 ^③	0.024 ^④

注:①1号高压加热器进出水室短路;②1号高压加热器汽侧积聚空气影响传热;③1号高压加热器传热管结垢导致传热特性不良。

对“1号高压加热器管系泄漏 1%”故障,表 2 给出了在故障发生后两种模型首次正确诊断和得到较

为稳定的正确诊断结果的时间和结果。

表 2 “1号高压加热器管系泄漏 1% 给水量”故障发生后两种方法正确判定故障的时间和结果比较

Table 2 Diagnostic results for “No. 1 heater water tubes leakage 1%” with two different methods

诊断方法	首次正确诊断		给出稳定诊断结果	
	时间/s	故障隶属度	时间/s	故障隶属度
模糊模式识别方法	10	0.455 ^① 0.146 ^②	55	0.571 ^① 0.376 ^②
神经网络方法	5	0.520 ^① 0.356 ^②	175	0.511 ^① 0.003 ^②

注:①1号高压加热器管系泄漏;②3号高压加热器给水管束部分堵塞;③2号高压加热器管系泄漏;④2号高压加热器传热管结垢导致传热不良。

从表 1、表 2 可看到,两个故障实例下,两种模型对最可能发生故障的判定结果是一致的,最大故障隶属度值和次大故障隶属度值的差值是明显的,说明模型的故障分离效果较好。从表 2 还可看到,两种模型对“1号高压加热器管系泄漏”故障首次正确判定时间仅为故障发生后 5 s 和 10 s,这时语义型征兆尚不明显,起主要作用的是趋势型征兆,体现了趋势型征兆对故障的及时诊断作用。两种模型给出较为稳定的正确诊断结果的时间分别为 55 s 和 175 s,此时,随着故障的持续,趋势型征兆作用减弱,语义型征兆起主要作用,因此给出的诊断结果较为稳定。

4 结语

本文介绍了火电机组热力系统故障智能诊断系统的总体功能结构,结合某 300 MW 火电机组高压给水加热器系统故障诊断实例,阐述各功能模块的功能和实现方法。重点对系统开发中采用的征兆模糊处理方法、基于神经网络及模糊模式识别的智能诊断模型等关键技术进行讨论。

针对模型软件的主要算法模块,详细论述了电站热力系统故障诊断中常见的语义型和趋势型两种征兆的模糊数学表达方法,综合运用可有效增加热力设备故障诊断过程的及时性及诊断结果的稳定可靠性。给出了模糊模式识别和人工神经网络两种故障智能诊断模型,讨论了两种模型的技术要点。这些技术已经在“火电机组热力系统故障智能诊断系统”的开发中得到应用,取得了良好的效果,对其他生产过程和设备的故障诊断也有较好的参考价值。

参 考 文 献

- 蒲莹,史家燕,罗应立,等(Pu Ying, Shi Jiayan, Luo Yingli, et al). 汽轮发电机在线故障诊断系统的功能结构和运行模式(General Scheme and Running Mode of an On-line Turbine

- Generator Fault Diagnosis Expert System). 电力系统自动化 (Automation of Electric Power Systems), 2001, 25(19): 37~40
- 2 马良玉, 王兵树, 范海红, 等(Ma Liangyu, Wang Bingshu, Fan Haihong, et al). 对分式凝汽器故障诊断的模糊模式识别及神经网络方法(Fuzzy Pattern Recognition and Artificial Neural Network Used for Fault Diagnosis of the Double-channel Condenser). 中国电机工程学报(Proceedings of the CSEE), 2001, 21(8): 68~73, 78
- 3 吴今培, 肖建华(Wu Jinpei, Xiao Jianhua). 智能故障诊断与专家系统(Intelligent FD & ES). 北京: 科学出版社(Beijing: Science Press), 1997
- 4 王伟(Wang Wei). 人工神经网络原理——入门与应用(Principle of Artificial Neural Network: Introduction and Application). 北京: 北京航空航天大学出版社(Beijing: Beijing Astronautic & Aeronautic University Press), 1995
- 5 马良玉, 王兵树, 范海红, 等(Ma Liangyu, Wang Bingshu, Fan Haihong, et al). 对分式凝汽器典型故障模式及其神经网络诊断(Investigation on Typical Fault Patterns of the Halving-style Condenser and Its Fault Diagnosis with BP Neural Network). 华北电力大学学报(Journal of North China Electric Power University), 2001, 28(2): 40~45

马良玉(1972—), 男, 博士研究生, 从事电站热力设备和系统仿真与建模、性能分析与故障智能诊断研究。E-mail: mlydw@163.net

段巍(1972—), 女, 硕士, 讲师, 从事机械可靠性设计、机械故障诊断等方面的教学和研究工作。

高建强(1966—), 男, 高级工程师, 从事火电机组仿真与建模、热力系统性能分析研究工作。

STRUCTURE AND MODEL OF A FAULT INTELLIGENT DIAGNOSIS SYSTEM FOR POWER STATION THERMAL SYSTEMS

Ma Liangyu, Duan Wei, Gao Jianqiang, Wang Bingshu, Tong Zhensheng

(North China Electric Power University, Baoding 071003, China)

Abstract: The general function and structure of a fault intelligent diagnosis system for power station thermal system is described. Taking a high-pressure feed-water heater system of a 300 MW unit as an example, the fuzzy expression method for two different symptoms and their synthesizing calculation under different conditions are explained, which the reliability of the fault diagnosis is improved with. Two intelligent fault diagnosis models, fuzzy pattern recognition method and artificial neural network method are presented. The key issues of the two models are discussed. Finally, the fault diagnosis examples are given, which verify the effectiveness of above models and methods.

This project is supported by State Power Company (No. SPKJ016—22).

Key words: thermal power unit; fault diagnosis; symptom calculation; fuzzy pattern recognition; artificial neural network