

基于人工神经网络的回热系统主要故障预测模型

王 妍¹ 李 颜¹ 于军辉² 于亚军³

(1. 中国核电工程有限公司 深圳设计院 广东 深圳 518000; 2. 西安建筑科技大学 陕西 西安 710055;
3. 西安外国语大学 商学院 陕西 西安 710128)

摘 要: 为有效预测回热系统故障,分别基于 Traingda、Traincgf 和 Trainrp 算法建立回热系统故障征兆和故障现象的误差反向传播神经网络预测模型。输入层为故障征兆,输出层为故障现象。以某电厂的实测数据对 3 种预测模型进行训练和测试,训练和测试结果表明:基于 Traincgf 算法建立的预测模型测试误差最小、收敛速度较快。其模型网络为 9-7-9 结构,动量因子为 0.6,学习速率为 0.8。基于 Traincgf 算法建立的回热系统故障征兆和故障现象的误差反向传播神经网络预测模型可有效通过故障征兆预测回热系统的故障现象,对回热系统的故障检测有一定的参考价值。

关 键 词: 回热系统; 故障征兆; 故障现象; Traincgf 算法; 人工神经网络

中图分类号: TM621; TP277.3

文献标识码: A

引 言

回热系统是火电机组的主要辅助系统之一。由于回热系统长期处于高温高压的运行状态中,同时还要受到机组负荷突变带来的旁路切换等因素的影响,因此会频繁出现故障。回热系统故障主要是由抽气流量、抽气压力、进口压力、进口水温、出口水温、混合水温、出口端差、水位高度、输水温度等故障征兆造成回热系统的排气管不畅、排气量过大、管束污染、水路短路等故障现象^[1]。因此,研究回热系统的故障征兆和故障现象之间的关系、建立回热系统故障预测模型对保证回热系统的安全可靠运行具有重要意义。

回热系统的故障征兆与故障现象是非线性拟合关系。不同故障现象下的故障征兆需要进行实际测定,实际测定的结果真实可靠,但实现复杂。BP (Back-Propagation) 神经网络是基于实验数据寻求事物本质规律的一种统计方法,在很多领域已得到验证^[2-6]。该方法尤其适用于因果关系复杂、影响因素多的非线性问题。本研究基于 Traingda、Traincgf 和 Trainrp 3 种算法分别建立故障征兆与故

障现象的神经网络预测模型,以某电厂的前期测试数据对模型进行测试和验证,选择测试结果最为理想的模型,实现通过回热系统故障征兆有效地预测回热系统故障现象,并为回热系统的故障检测提供参考。

1 BP 神经网络模型

1.1 原理

BP 神经网络是目前应用最为广泛的网络之一,其主要通过调整网络权值和阈值使网络总误差达到最小。多层网络运用 BP 学习算法时,实际上包含了数据正向传播和误差反向传播两个过程组成。正向传播时,输入信息从输入层经隐含层逐层处理,并传向输出层,每一层神经元的状态会影响到下一层神经元的状态。如果输出层得不到实验期望的输出,则转向误差的反向传播阶段,误差信号沿原来的连接通道返回,通过修改各层神经元的权值和阈值,使误差信号最小。网络的求解过程为^[5-6]: (1) 随机地给全部权值和神经元阈值赋初始值; (2) 给定样本输入和期望输出; (3) 从输入层到输出层逐层计算每个神经元节点的输出; (4) 计算系统误差; (5) 修正权值; (6) 如果网络输出值达到误差精度或循环次数要求,则输出结果,否则回到步骤 3。

1.1.1 神经元节点输出的计算

在训练网络的学习阶段,设有 N 个训练样本,先假定用其中某一个样本 p 的输入 $\{X_p\}$ 和输出 $\{T_p\}$ 模式对网络进行训练,隐含层的第 i 个神经元节点在样本 p 的作用下输入为:

$$\text{net}_i^p = \sum_{j=1}^M w_{ij} O_j^p - \theta_i \quad (i=1, 2, \dots, q) \quad (1)$$

式中: O_j^p —输入单元 j 在样本 p 作用时的输入; w_{ij} —输入层神经元 j 与隐含层神经元 i 之间的连接权; θ_i —隐含层神经元 i 的阈值; q —隐含层的节点数。

隐含层第 i 个神经元的输出为:

收稿日期: 2010-07-06; 修订日期: 2010-08-11

作者简介: 王 妍 (1982-) 女, 辽宁沈阳人, 中国核电工程有限公司深圳设计院助理工程师。

$$O_i^p = f_1(\text{net}_i^p) \quad (i = 1, 2, \dots, q) \quad (2)$$

式中: $f_1(X)$ — Sigmoid 型激活函数, 满足:

$$f_1(X) = \frac{1}{1 + \exp(-X)}$$

隐含层第 i 个神经元的输出 O_i^p 将通过权系数向前传播到输出层第 k 个神经元并作为它的输出之一, 而输出层的第 k 个神经元的输入为:

$$\text{net}_k^p = \sum_{i=1}^q w_{ki} O_i^p - \theta_k \quad (k = 1, 2, \dots, L) \quad (3)$$

式中: w_{ki} —隐含层神经元 i 与输出层神经元 k 之间的连接权; θ_k —输出层神经元 k 的阈值; q —隐含层的节点数。

输出层第 k 个神经元的实际输出为:

$$O_k^p = f_2(\text{net}_k^p) \quad (k = 1, 2, \dots, L) \quad (4)$$

式中: $f_2(X)$ —分段线性激活函数满足:

$$f_2(X) = \begin{cases} 1 & X \geq 1; \\ X & -1 \leq X < 1; \\ -1 & X \leq -1; \end{cases}$$

1.1.2 系统误差的计算

每一个样本 p 的输入模式对应的二次型误差函数为:

$$E_p = \frac{1}{2} \sum_{k=1}^L (O_k^p - T_k^p)^2 \quad (5)$$

系统所有 N 个训练样本的总误差函数为:

$$E = \frac{1}{2} \sum_{p=1}^N \sum_{k=1}^L (O_k^p - T_k^p)^2 \quad (6)$$

式中: O_k^p —输出节点 k 在样本 p 作用时的输出; T_k^p —样本 p 在输入层节点 k 处的预期目标值。

1.1.3 权值的修正

从输出层开始, 将误差信号沿连接通路反向传播, 通过修正各权值使误差最小。

输出层任意神经元 k 在样本 p 作用时的加权系数改进式为:

$$w_{ki}(k+1) = w_{ki}(k) + \eta \delta_k^p O_i^p \quad (7)$$

隐含层任意神经元 i 在样本 p 作用时的加权系数改进式为:

$$w_{ij}(k+1) = w_{ij}(k) + \eta \delta_i^p O_j^p \quad (8)$$

式中: η —学习速率; $\delta_k^p = (T_k^p - O_k^p) \cdot (1 - O_k^p)$; $\delta_i^p = -\frac{\partial E_p}{\partial O_i^p} \cdot O_i^p \cdot (1 - O_i^p)$

1.2 网络训练和测试

网络训练是指样本数据正向运行并反向传播, 直到网络找出样本数据中输入与输出之间本质联系的过程。由于所收集的数据包含噪音, 当训练次数过多时, 网络会将包含噪音的数据记录下来。在极

端情况下, 训练后的网络可以实现相当于查表的功能, 但对于新的输入数据 (指不包含在训练数据范围) 却不能给出合适的输出。网络测试就是用一组非训练数据测验网络的泛化能力。测试过程中, 保持连接权值与阈值不变, 只将测试数据作为网络输入, 正向运行网络, 并检验输出的误差。

2 回热系统神经网络模型

2.1 数据采集

数据来源于前期对某电厂进行的实测。以抽气流量、抽气压力、进口压力、进口水温、出口水温、混合水温、出口端差、水位高度、输水温度为输入层单元, 以排气管不畅、排气量过大、管束污染、水侧短路、管束泄漏、输水不畅、输水阀故障、加热器满水、自身沸腾为输出层单元建立模型。为了平衡不同参数在网络训练过程中的权重, 需对回热系统故障征兆和故障现象样本数据进行标准化处理。

故障征兆标准化为:

$$X_{\text{normalized}} = \frac{2(X - X_{\min})}{X_{\max} - X_{\min}} - 1 \quad (9)$$

故障现象标准化为:

$$Y_{\text{normalized}} = \frac{Y - Y_{\min}}{Y_{\max} - Y_{\min}} \quad (10)$$

2.2 BP 神经网络模型的构建

选取 3 层 BP 网络建立回热系统故障征兆和故障现象样本数据之间关系的模型, 网络结构如图 1 所示。

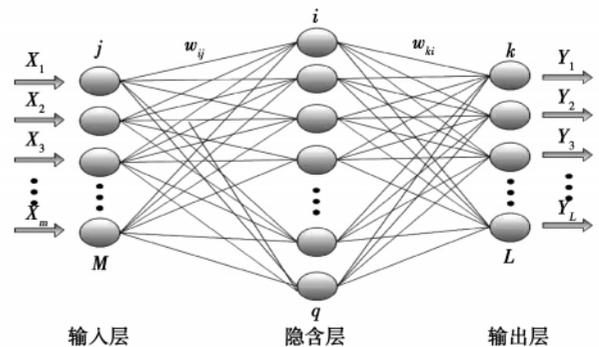


图 1 神经网络结构

假设有 M 个输入节点 $X_1, X_2, X_3, \dots, X_M$, L 个输出节点 $Y_1, Y_2, Y_3, \dots, Y_L$, 网络的隐含层共有 q 个神经元。标准 BP 网络非线性的映射过程存在隐含层节点难确定、收敛过程速度慢、“局部极小值”和过拟合等缺陷, 需要采取相应的措施加以消除。隐含

层节点确定原则是在能正确反映输入与输出映射关系的基础上,尽量选取较少隐含层节点数,使网络简单化。隐含层节点数选取范围为:

$$N_H = \sqrt{N_{in} + N_{out}} + a \quad (11)$$

式中: N_H —隐含层节点数; N_{in} —输入层节点数; N_{out} —输出层节点数; a —修正系数,范围为 0~10。

因此,神经网络隐层节点范围约 4~15 之间。通过试错法确定隐含层节点,以相对拟合率 R 描述实际值与网络输出值之间的精度, $R=1$ 说明拟合效果最好。相对拟合率 R 为:

$$R = \frac{\sum_{i=1}^N (E_i - \bar{E})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (E_i - \bar{E})^2 \sum_{i=1}^N (P_i - \bar{P})^2}} \quad (12)$$

式中: E_i —实际实测结果; P_i —网络输出值; \bar{E} 、 \bar{P} —实测结果和网络输出值的平均值。

表 1 不同算法的神经网络模型运算结果

算法	网络结构	训练误差	测试误差	运算耗时/s	迭代次数
Traingda	9-7-9	0.673 4	0.534 2	98.015	15 322
Traincgf	9-7-9	0.952 2	0.923 0	22.673 5	3 197
Trainrp	9-7-9	0.853 2	0.795 1	32.609 0	9 860

表 1 为不同算法下的神经网络运算结果比较。可见,基于 Traincgf 算法的 BP 神经网络模型有收敛速度快,误差小的特点。因此,选择以基于 Traincgf 算法的误差反向传播神经网络模型进行模型训练。

2.3 Traincgf 算法神经网络模型训练与测试

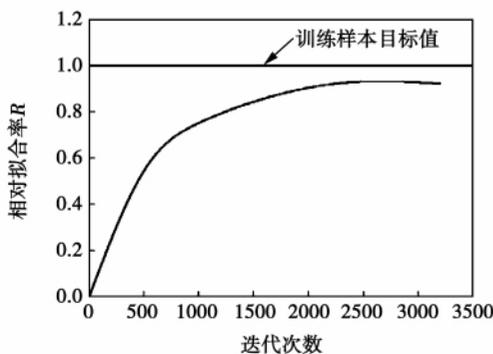


图 2 迭代次数与 R 值关系

图 2 为训练过程中迭代次数与 R 值的关系图,从图中可以看出,随着迭代次数的增加,网络预测的结果逐渐接近于网络训练样本的目标值。图 3 为不同隐含层单元数与 R 值的关系。当隐含层节点为 7 时,网络测试的 R 值最大。图 4 和图 5 表明动量因子和学习速率分别为 0.6 和 0.8 时,网络的测试误

差最小。因此,确定网络结构为 9-7-9,动量因子为 0.6,学习速率为 0.8。

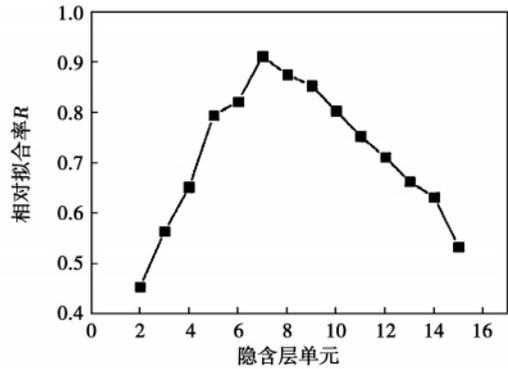


图 3 隐含层单元与 R 值关系

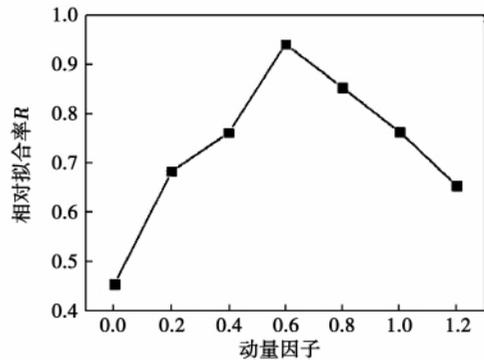


图 4 动量因子与均方误差的关系

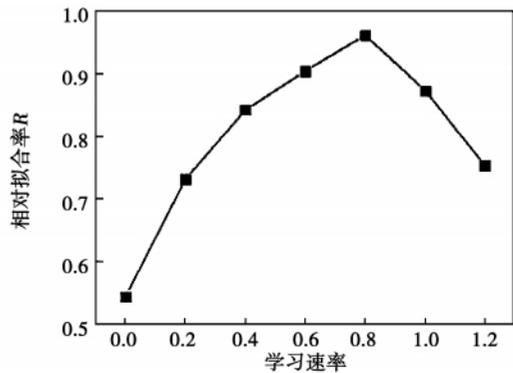


图 5 学习速率与 R 的关系

为了检验网络模型的精确度,用预留的 5 组测试数据对网络进行测试,其测试故障征兆和故障结果如表 2 和表 3 所示。

可见,基于 Traincgf 算法的回热系统故障征兆与故障现象的神经网络模型的拟合精度很高,可有效通过故障征兆预测回热系统的故障现象,既通过采集抽气流量、抽气压力、进口压力、进口水温、出口水温、混合水温、出口端差、水位高度、输水温度故障

征兆的样本值预测出回热系统会出现排气管不畅、排气量过大、管束污染、水路短路中哪类故障现象。其模型对回热系统的故障检测有一定的参考价值。

表 2 测试用故障征兆样本

抽气 流量	抽气 压力	进口 压力	进口 水温	出口 水温	混合 水温	出口 端差	水位 高度	疏水 温度
0.25	0.60	0.50	0.05	0.05	0.50	0.75	0.50	0.50
0.75	0.40	0.75	0.05	0.05	0.50	0.50	0.50	0.50
0.25	0.60	0.50	0.05	0.25	0.25	0.75	0.50	0.50
0.25	0.60	0.50	0.05	0	0	1	0.50	0.50
0.75	0.40	0.75	0.05	0.25	0.25	0.75	1	0.25

表 3 测试用故障现象

故障现象	对应描述	
	实验值	模拟值
排气管不畅	0010	10
排气量过大	0011	11
管束污染	0100	100
水侧短路	0101	101
管束泄漏	0110	110

3 结 论

为有效预测回热系统故障,分别基于 Traingda、Traincgf 和 Trainrp 算法建立回热系统故障征兆和故障现象的误差反向传播神经网络预测模型,输入层为故障征兆,输出层为故障现象。以某电厂的实测

数据对 3 种预测模型进行训练和测试,得出结论:

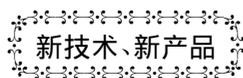
(1) 基于 Traincgf 算法建立的预测模型测试误差最小、收敛速度较快。

(2) 基于 Traincgf 算法网络模型的输入层与输出层节点数均为 9,当隐含层节点数为 7 时相对拟合率 R 最大,当动量因子为 0.6、学习速率为 0.8 时测试误差最小。

基于 Traincgf 算法建立的回热系统故障征兆和故障现象的误差反向传播神经网络预测模型可有效通过故障征兆预测回热系统的故障现象,对回热系统的故障检测有一定的参考价值。

参考文献:

- [1] 李国勇. 神经模糊控制理论及应用[M]. 北京: 电子工业出版社, 2009.
- [2] 张艳萍. 用于故障诊断的凝汽器真空模型研究[D]. 北京: 华北电力大学, 2009.
- [3] YAZDANMEHR M, MOUSAVIANIJAN S H, BAHRAMI A. Using GA-ANN algorithm to optimize soft magnetic properties of nanocrystalline mechanically alloyed Fe-Si powders[J]. Computational Materials Science, 2009, 44: 1218 - 1221.
- [4] MIRZADEH H, NAJAFIZADEH A. Correlation between processing parameters and strain - induced martensitic transformation in cold worked AISI 301 stainless steel[J]. Materials Characterization, 2008, 59: 1650 - 1654.
- [5] SUMANTRA MANDAL, SIVAPRASAD P V, VENUGOPAL S, et al. Artificial neural network modeling to evaluate and predict the deformation behavior of stainless steel type AISI 304L during hot torsion[J]. Applied Soft Computing, 2009, 9: 237 - 244.
- [6] 李国勇. 智能控制及其 MATLAB 实现[M]. 北京: 电子工业出版社, 2005.



新技术、新产品

西门子公司为电力诊断和专业监测提供设备

西门子电厂运行和维护的专业监视器为电力诊断远程监测系统的辅助设备,该系统可以进行叶顶振动监测和叶片应力诊断。包括如下内容:

汽机间: 信号采集、模拟、预处理;

控制室: 数字、预处理、100 MHz 计数器、模拟输入、所有测量变量的可视化、使用寿命分析、趋势图、存档、系统状态;

联合循环电厂的专业监视器;

燃气轮机专业监视器: 燃烧室的压力、声音;

发电机专业监视器: 局部放电、定子端绕组振动、转子绕组短路线图、氢耗;

汽轮机专业监视器: 叶顶振动、所有关键部件的疲劳;

转子和轴承座振动。

《柴油机和燃气轮机世界》2011 年 1 - 2 月刊

that of the cooling chamber will increase with an increase of the static bed height , fluidized air speed and fluidization time duration. When both chambers are in operation simultaneously at a partition wall height of 1 000 mm and the fluidization air speeds in both elutriation and cooling chamber are 5 m/s and 0.6 m/s respectively , more than 80% of the particles in the material returned are less than 0.15 mm in diameter , basically in the range of the particle diameters of the ash cycled to the outside. **Key words:** circulating fluidized bed , fluidized bed slag cooler , fine particle , material return characteristics

基于人工神经网络的回热系统主要故障预测模型 = Model for Predicting the Major Faults of a Regenerative System Based on an Artificial Neural Network [刊 汉] WANG Yan , LI Yan (Shenzhen Designing Institute , China Nuclear Power Project Co. Ltd. , Shenzhen , China , Post Code: 518000) , YU Jun-hui (Xi'an University of Architectural Science and Technology , Xi'an , China , Post Code: 710055) , YU Ya-jun (Commercial College , Xi'an University of Foreign Languages , Xi'an , China , Post Code: 710128) // Journal of Engineering for Thermal Energy & Power. - 2011 , 26(4) . - 424 ~ 427

To effectively predict the faults of a regenerative system , established were three error BP (back propagation) neural network models for predicting the fault signs and phenomena of a regenerative system based on the Traincda , Traincgf and Trainrp algorithm respectively. In such a case , the input layer was the fault signs and the output one was the fault phenomena. The data actually measured in a power plant were used to conduct a training and testing of the three prediction models. The training and testing results show that the model based on the Traincgf algorithm has the smallest testing error and a relatively quick converging speed. Its network was of a 9-7-9 structure with its momentum factor being 0.6 and the learning speed being 0.8. The error BP neural network model based on the Traincgf algorithm can effectively predict the fault phenomena of a regenerative system by using the fault signs , thus providing a certain reference value for testing the faults of a regenerative system. **Key words:** regenerative system , fault sign , fault phenomenon , Traincgf algorithm , artificial neural network

无模型自适应预测控制在过热汽温控制中的应用 = Application of the Model-free Self-adaptive Prediction Control in Superheated Steam Temperature Control [刊 汉] FENG Yu-cang , SHI Dong-lin (College of Automation Engineering , Northeast University of Electric Power , Jilin , China , Post Code: 132012) // Journal of Engineering for Thermal Energy & Power. - 2011 , 26(4) . - 428 ~ 431

By using the concept of the pseudo gradient vector , a prediction model was obtained through a linear dynamic treatment of the system under control. On this basis , an improved model-free self-adaptive prediction control algorithm was presented. This new method was used in a cascade control system for superheated steam temperatures in a ther-