

装备通用质量特性及寿命评估

基于遗传神经网络的除湿机故障诊断与寿命预测

张琪¹, 吴亚锋², 徐建¹(1.中国华阴兵器试验中心 环境模拟室, 陕西 华阴 714200;
2.西北工业大学 动力与能源学院, 西安 710072)

摘要: 目的 识别除湿机的性能状态和预测吸附剂的剩余寿命。方法 针对除湿机故障过程缓变的特点, 提出一种基于数据驱动的遗传神经网络模型。首先, 为解决设备失效程度划分模糊的问题, 由5个热力参数组成反映吸附剂劣化程度的特征向量, 关联分析得到除湿机的5类故障模式。其次, 利用遗传神经网络建立状态参数和故障模式的映射关系。最后, 对表征设备吸附能力的主参数进行外推预测。结果 训练好的诊断网络可准确地识别出设备的劣化程度及其演变过程, 预测网络的预测精度非常高。结论 该方法可有效地实现对除湿机的故障诊断与预测。

关键词: 遗传算法; 神经网络; 除湿机; 露点温度

DOI: 10.7643/issn.1672-9242.2017.01.018

中图分类号: TJ07; TP391.5

文献标识码: A

文章编号: 1672-9242(2017)01-0078-06

Fault Diagnosis and Life Prediction of Genetic Neural Network-based Dehumidifier

ZHANG Qi¹, WU Ya-feng², XU Jian¹(1. Department of Environment Simulation, Huayin Ordinance Test Centre, Huayin 714200, China;
2. School of Power and Energy, Northwestern Polytechnical University, Xi'an 710072, China)

ABSTRACT: Objective To identify performance state of dehumidifier and predict residual life of adsorbent. **Methods** A data driving-based genetic neural network model was proposed in view of the slow variable failure process of dehumidifier. Firstly, to solve the issue fuzzy division of equipment failure degree, 5 failure patterns of the dehumidifier were obtained with correlation analysis according to characteristic vectors formed by 5 thermodynamic parameters which reflect adsorbent degradation. Secondly, the mapping relationship between state parameters and failure patterns was established with genetic neural network. Finally, principal parameters reflecting adsorption capacity of equipment were predicted by extrapolation. **Results** The diagnosis network could determine deterioration degree and evolution process of equipment accurately. It possessed very high accuracy in network prediction. **Conclusion** This method can effectively finish fault diagnosis and prediction of dehumidifier.

KEY WORDS: genetic algorithm; neural network; dehumidifier; dew point temperature

某低温制冷系统采用空气涡轮制冷, 由于涡轮是精密设备, 且其进气温度低至 -40°C , 为防止空气携带的水蒸气结冰于涡轮中造成事故的发生, 在涡轮前端设置除湿机, 利用其填料铝胶和分子筛吸附除去

空气中的水分, 使湿度降低到安全范围内, 保证了涡轮的安全运行。近几年来, 随着使用时间的增加, 除湿机频繁出现故障。据统计, 由于吸附效率低下导致的制冷系统停机、再生过程加热丝烧毁等故障 20 余

收稿日期: 2016-06-16; 修订日期: 2016-07-13

作者简介: 张琪(1984—), 女, 咸阳人, 硕士, 工程师, 主要从事环境适应性试验、设备故障诊断与寿命预测等方面的研究。

通讯作者: 吴亚锋(1966—), 男, 渭南人, 博士生导师, 从事现代信号处理方面的研究。

次，对试验进程造成了很大的影响。因此，建立故障诊断与预测系统，加强设备的监测和预知性维修势在必行^[1]。

实际问题都是非线性和时变的，很难建立精确的数学模型描述其失效机理。目前，基于数据驱动的机器学习方法对解决“黑箱”问题上优势突出，例如，一个三层神经网络可以模拟任意非线性对象的输入输出关系。

文中以除湿机为研究对象，利用收集到的状态数据得出故障生长模型，将吸附剂失效这类典型故障进行故障程度的关联划分，并结合出口气体露点温度的变化趋势作出综合评价，通过遗传神经网络实现对除湿机状态的识别和露点温度的趋势预测。

1 遗传算法组合 BP 神经网络模型

神经网络和遗传算法这两种智能仿生算法都是模拟生物结构去表达输入输出之间隐性关系的。虽然神经网络具有结构简单、可调整参数多、训练算法多、可操作性好的特点^[2]，但其自身也存在缺陷。由于搜索求解算法是沿梯度下降的，导致网络存在收敛速度慢的缺点，难以保证复杂网络的全局优化而易导致陷入局部极小值。这都是由于随机选取网络初始权值和阈值的影响，所以要对初始值进行优化选择。遗传算法具有极佳的全局搜索能力和高度的鲁棒性，故采用遗传算法对神经网络初始权值和阈值进行优化。

遗传算法优化 BP 神经网络的原理是把网络的初始权值和阈值作为染色体，建立种群，利用生物遗传特性（复制、交叉、变异）逐代进行选择，高收敛精度与速度保证了搜索到全局范围内的最优解^[3]。这个最优解就是最佳的网络结构，比用经验和试验判断更能使网络参数合理化，它的交叉因子和变异因子在网络陷入局部极值时能很好地跳出来，提高网络的学习精度和稳定性^[4]。遗传 BP 神经网络（以下简称 GABP）算法的流程如图 1 所示。

该组合算法由三部分组成：BP 神经网络结构确定、权值与阈值的遗传优化、网络训练及仿真。根据样本输入和输出参数的个数来确定 BP 神经网络拓扑结构，进而得出遗传算法待优化参数的数目，也就能计算出种群中个体的编码长度，染色体长度 $s=R \times s_1 + s_1 \times s_2 + s_1 + s_2$ （ R, s_1, s_2 分别为输入层，中间隐含层和输出层的神经元个数），并编码成二进制形式。交叉概率和变异概率这两个关键的遗传参数是根据适应度的大小进行选择的。训练网络的第一步需要初始化参数，随机获取一组网络连接的权值和阈值，遗传算法按照其染色体的复制、交叉、变异原则调整网络的连接权值和阈值，计算出 BP 网络输出与测试目标的均方误差 E ，见式（1）：

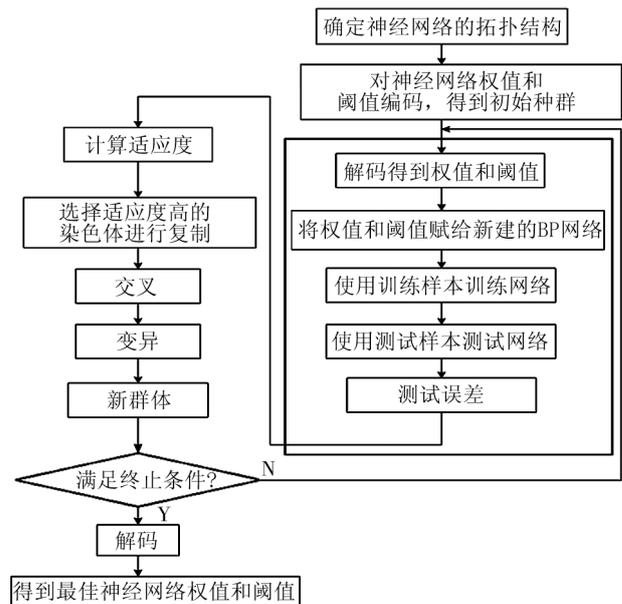


图 1 遗传算法优化神经网络算法流程

$$E = \frac{1}{L} \sum_{i=1}^L [O_k(i) - T_k(i)]^2 \quad (1)$$

式中： O_k 为输出层输出； T_k 为输出层目标值。

进而得到遗传进化的适应度 $\text{fitness} = 1/E$ ，向着适应度增大（即网络输出误差最小）的方向在进化代中搜寻最优个体，即使网络均方误差最小的权值和阈值。将全部样本按步骤让网络学习一遍后，训练结束的条件是全部样本的输出误差均小于设定误差精度。如果未达到，网络将继续学习，以相同的条件判定是否结束，将最终得到最优的权值与阈值输入网络进行识别或预测。

对设备状态进行模式识别，首先就要选择与设备本身相关的各监测参数，各监测参数是以一定时间间隔采集的实时数据。选择以表征进入除湿机气体工况的制冷气体入口露点、流量、压力、温度和除湿机出口露点温度等 5 个参数为特征参数。由这些热力参数组成的参数集作为识别网络的输入，故障模式的类型作为网络的输出^[5]。

2 除湿机故障模式的划分

2.1 吸附剂失效程度的区间设定

除湿机吸附剂吸附失效属于缓变故障，从未发生到严重故障的生长过程可细分为不同严重程度的状态^[6]。鉴于尽可能精确评估低温除湿机的状态，采用 4 个故障程度评价指数，故障等级序列号为 k （ $k=1, 2, 3, 4$ ），分别表示“报废”、“待修”、“堪用”、“良好”四级。对于出口露点温度， $-50\text{ }^\circ\text{C}$ 是低温控制系统报警设定值，而 $-40\text{ }^\circ\text{C}$ 是涡轮膨胀机进口温度下限值（即露点温度高于该值则会结冰）。由于两台除湿机

并联工作,以两路出口气体的总气流作为除湿机的输出,因此扩大单台设备工作允差范围,延拓了出口气体露点温度最差方向的下限至-20℃,增设“特差”级。

为了验证数据对故障描述的准确性和全面性,对2015年7月20日夏季某次低温试验系统-40℃保温期间,每隔6s采集1次1号除湿机露点温度的典型数据,全程记录了露点温度超高变化的过程。记录数据见表1。

表1 吸附剂失效故障参数(节选)

序号	出口露点温度 $Y_0/^\circ\text{C}$	进口露点温度 $X_1/^\circ\text{C}$	温度 $X_2/^\circ\text{C}$	流量 $X_3/(L\cdot h^{-1})$	压力 X_4/MPa
1	-71	-8	45.44	6	0.66145
2	-68.31018	-4	45.37	12	0.66030
3	-63.50694	-1	45.5	20	0.66001
4	-56.5625	4	45.11	50	0.65075
5	-53.32176	5.8	45.07	70	0.64641
6	-51.2963	6.4	45.4	80	0.64380
7	-48.48959	6.8	45.41	92	0.64265
8	-42.23959	7.2	45.3	95	0.63975
9	-30.63657	8	44.98	97	0.63252
10	-20.94329	9.5	45.25	99	0.61921

2.2 故障状态的关联分析

根据待检模式与参考模式之间的接近程度,进行状态划分。根据设备各特征参数之间的内部联系与发展态势的相似程度来衡量参数之间的关联程度^[7]。具体应用过程如下。

1) 表1中故障数据的前两组表示正常状态,将这两组数据作为参考模式向量,其他数据作为待检模式向量,由这两组参考模式向量构成参考模式矩阵。

$$X_1 = \{X_1(1), X_1(2), X_1(3), X_1(4), X_1(5)\} \quad (2)$$

式中: X_1 为第1个参考模式向量。每种标准参考模式特征向量中包含5个元素,即表1中所列的设备故障诊断的特征参数。

2) 待检模式各向量构成待检模式矩阵:

$$Y_j = \{Y_j(1), Y_j(2), Y_j(3), Y_j(4), Y_j(5)\} \quad (3)$$

($j=1, 2, \dots, 638$)

式中: Y_j 为第 j 个待检模式向量。

3) 关联系数计算。待检模式向量和参考模式向

量状态之间的关联程度定义为:

$$\xi_{ij} = \frac{\min_i \min_j |Y_j(k) - X_i(k)| + \rho \max_i \max_j |Y_j(k) - X_i(k)|}{|Y_j(k) - X_i(k)| + \rho \max_i \max_j |Y_j(k) - X_i(k)|} \quad (i=1; j=1, 2, \dots, 8) \quad (4)$$

式中: ρ 为分辨系数; ξ_{ij} 为待检模式向量和参考模式向量之间的关联系数。

ρ 越小,参数之间分辨力越大,一般 ρ 取值在[0, 1]区间内。不同的 ρ 值实际意义不大,只影响 $\xi_j(k)$ 的相对排列顺序,作为衡量参数间密切程度相对大小的指标。一般取 0.5。

4) 关联度计算

$Y_j(k)$ 对 $X_1(k)$ 的关联度的定义是不同点关联系数的平均值,即:

$$r = \frac{1}{5} \sum_{k=1}^5 \xi_j(k) \quad (j=1, 2, \dots, 638) \quad (5)$$

如用第三组数据与第一组数据求关联度: $\zeta(1)=0.6697, \zeta(2)=0.3903, \zeta(3)=0.7425, \zeta(4)=0.6682, \zeta(5)=1, r=0.6941$ 。

在 MATLAB 中编写上述方法的相关程序,将全部数据序列进行与参考模式序列的关联度计算,得到吸附剂失效程度的关联度。

通过比较每个待检模式序列对参考模式序列的关联程度大小,按其大小顺序排列起来组成关联序。它直接反映了各个待检模式向量对同一参考序列的“主次”或“优劣”关系^[8]。从而依照从大到小的排列顺序,相当于把待检模式向量划归典型模式的可能性大小依次排列,见表2。

表2 除湿机吸附剂失效程度的关联度划分

序号	关联度	状态划分
1—42	1.0000	良好
43—242	0.7851~0.6451	堪用
243—287	0.7621~0.5597	待修
288—377	0.6447~0.5882	报废
378—637	0.5696~0.3343	特差

2.3 除湿机故障模式分类

由表2中显示的设备状态数据对应的故障状态关联度结合操作人员人工经验,确定各指标对故障等级的区间划分^[9],见表3。

表3 故障等级评价指标

状态	出口露点 $Y_0/^\circ\text{C}$	入口露点 $X_1/^\circ\text{C}$	入口温度 $X_2/^\circ\text{C}$	入口流量 $X_3/(L\cdot h^{-1})$	入口压力 X_4/MPa
良好	$-73 \leq Y_0 < -68$	$-8 \leq X_1 < -3$	$20 \leq X_2 < 26$	$4 \leq X_3 < 16$	$0.60 \leq X_4 < 0.66$
堪用	$-68 \leq Y_0 < -55$	$-3 \leq X_1 < 5.5$	$26 \leq X_2 < 32$	$16 \leq X_3 < 60$	$0.52 \leq X_4 < 0.60$
待修	$-55 \leq Y_0 < -50$	$5.5 \leq X_1 < 6.5$	$32 \leq X_2 < 39$	$60 \leq X_3 < 90$	$0.47 \leq X_4 < 0.52$
报废	$-50 \leq Y_0 < -40$	$6.5 \leq X_1 < 7.7$	$39 \leq X_2 < 42$	$90 \leq X_3 < 96$	$0.42 \leq X_4 < 0.47$
特差	$-40 \leq Y_0 < -20$	$7.7 < X_1 < 10$	$42 \leq X_2 < 45$	$96 \leq X_3 < 100$	$0.38 \leq X_4 < 0.42$

3 除湿机故障诊断网络

除湿机诊断网络的输出层节点数由吸附剂吸附能力的优劣程度确定^[10]，即良好、堪用、待修、报废和特差等，输出层节点数就选为 5。按照表 3 的每类标准故障指标将表 1 中的样本分类作为相应诊断子网络的输入，网络结构为 5-8-5。隐含层和输出层神经元传递函数均采用 S 型函数^[11]，分别为 S 型正切函数 tansig 和 S 型对数函数 logsig，网络训练函数取 trainlm 学习算法。训练目标 0.01，自学习率 0.08，训练次数 5000 次。遗传算法染色体长度为 243，种群大小和遗传代数分别设定为 50 和 100。首先训练网络，为了验证诊断网络的准确性和普适性，分别将 1 号除湿机和 2 号除湿机冬季和夏季的状态数据作为测试数据，将这四类故障测试样本作进一步的测试。网络识别结果见表 4。

表 4 对不同故障样本的识别结果

状态	1 号夏季	2 号夏季	1 号冬季	2 号冬季
良好	0.0198	2.3287e-04	0.9988	0.0026
堪用	2.7255e-07	1.4847e-08	1.3334e-04	0.9976
待修	0.9999	1.1707e-05	1.9950e-05	0.0284
报废	0.0039	1.0000	1.2277e-04	0.5527
特差	4.2456e-08	5.5062e-08	5.2055e-08	3.4936e-08
识别正确率	65.28%	66.85%	90.01%	79.89%

从测试中得知，待修和报废这两类故障的隶属度非常接近，互相识别错误的情况较多，无法识别是哪类故障。夏季空气湿度较大，引起吸附剂负荷重，除湿效果较差；冬季空气干燥，吸附剂状态相对较优。

对单台设备这样连续测量与识别能够看出失效演变的过程^[12]。以夏季大湿度极端条件为例，如连续测量 1 号除湿机某次试验的状态数据，样本 1 至样本 4 是按时间发展先后排列的待测样本，诊断子网络对此系列的失效程度识别结果见表 5。

表 5 对 1 号除湿机夏季某次试验测量的故障识别结果

状态	样本 1	样本 2	样本 3	样本 4	诊断结论
良好	1.5276e-04	0.0587	0.0330	0.0416	由堪用 到待修
堪用	0.9999	9.1354e-07	1.7433e-06	1.9332e-07	
待修	2.8149e-05	0.9997	0.9999	0.9996	
报废	1.3107e-08	0.0023	5.8184e-04	0.0114	
特差	1.11040e-04	1.0740e-07	7.8354e-07	6.7114e-09	

用柱状图直观表现此次测量的 1 号除湿机吸附剂失效趋势情况，如图 2 所示。

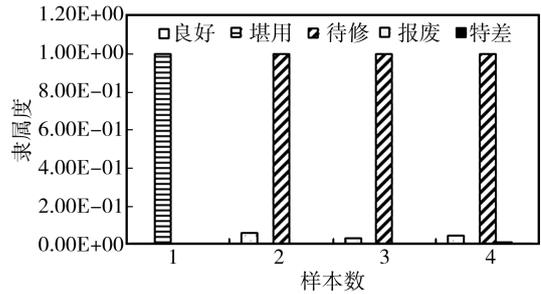


图 2 1 号除湿机吸附剂失效变化趋势

从图 2 中可以看出，网络诊断的结果是吸附剂状态由堪用到待修转变，与除湿机出口露点温度划分区间的变化趋势相匹配，网络分类结果与实际过程一致，说明此诊断网络分类精度高。

4 露点温度变化趋势预测

状态预测是状态监控研究领域中的一个重要课题，准确的故障预报可以帮助操作人员及时采取有效措施，减少经济损失和维修时间成本^[13]。考虑到除湿机出口气体露点温度监测的意义重大，有必要对露点温度进行预测，从而准确掌握吸附剂除湿能力，一旦发现故障前兆，就可以做到在故障发生前合理处置安全隐患。采用新陈代谢模型，即随着时间的推移，将新数据补充到数据序列最后，去掉历史数据序列的第一个数据，从而使数据序列长度保持不变，依次进行类推^[14]。从预测的角度看，随着时间的推移，旧数据的信息意义逐步降低，在不断去掉历史信息（老数据），补充新信息（新数据）的同时，数据序列不断被修正，这样就可以对低温环境试验设备除湿机出口露点温度进行动态预测，并能提高预测精度。

4.1 数据采集

以上已对吸附剂正常工作划分了区间，露点温度在 -73~ -50 ℃ 之间是设备正常工作范围。如果超出 -50 ℃ 的报警值，操作人员务必立刻进行停机维修，更换吸附剂填料或者进行彻底的干燥再生过程。采集了表 1 中的 1 号除湿机夏季工作过程中吸附剂失效过程的数据，用于遗传神经网络训练，并对 2015 年 8 月 13 日的一次试验中降温段和保温段的数据进行了测试。

4.2 网络训练与测试

首先，建立网络预测模型。将露点温度数据列的前 4 个数作为网络输入，对应第 5 个数作为网络输出，然后加入第 5 个数并去掉第一个数作为下一次的输入，输出第 6 个数，依次类推外推。训练网络结构 4-9-1。再次，设定网络训练目标为 1e-04，自学习率

为 0.08, 学习步数为 5000, 遗传算子的参数设定同上节诊断网络的情况。

将训练好的网络结构进行存储, $W1$, $W2$ 分别是输入层与隐含层、隐含层与输出层之间的连接权值, $B1$, $B2$ 分别是隐含层和输出层的阈值, 权值系数和阈值为:

$$W1 = \begin{bmatrix} -0.6429 & -0.6429 & -0.6619 & 0.3480 \\ 0.3331 & 0.6044 & -0.0333 & 0.6872 \\ 0.0928 & -0.9387 & -0.7019 & 0.2451 \\ -0.2531 & 0.0730 & 0.8932 & 0.8869 \\ 0.5545 & 0.4094 & 0.4484 & -0.2334 \\ 0.2328 & -0.0747 & -1.2194 & 0.6895 \\ -0.3078 & 1.1854 & -0.2732 & 0.2614 \\ 1.0769 & 0.2388 & 0.3431 & 0.8468 \\ 0.7655 & 0.5829 & -0.3002 & 0.4628 \end{bmatrix}$$

$$W2 = [-0.3150 \quad 0.9595 \quad -0.6291 \quad 1.4809$$

$$0.1109 \quad 0.0444 \quad -0.0879 \quad -0.2930 \quad 0.0764]$$

$$B1 = [0.1885 \quad -1.1693 \quad -0.5384 \quad -1.1353$$

$$-0.6115 \quad 1.0115 \quad 0.3172 \quad 0.5512 \quad 0.0339]$$

$$B2 = 0.4298$$

用训练好的网络对测试数据进行预测, 结果如图 3 所示。

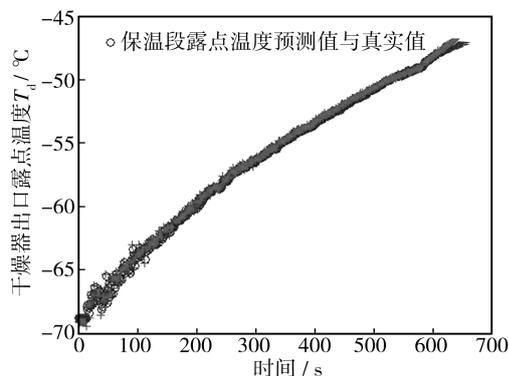


图 3 保温段除湿机露点温度测试值与真实值对比

图 3 显示的是露点温度预测值和真实值的对比情况, 可以看出, 预测值非常接近于真实值, 误差很小。训练好的 GABP 网络对除湿机出口气体露点温度的预测非常精确, 可以作为除湿机吸附性能的预报工具。

接下来利用训练好的网络进行外推预测。考虑到露点温度 -50°C 的报警阈值, 增设提前量至 -55°C , 对良好状态演变到堪用状态的数据进行后 200 步智能外推^[15], 给出报警值出现的时间, 以供操作人员视情查找故障原因, 及早维护, 以防止故障的发生。外推预测的结果如图 4 和图 5 所示。

从图 4 和图 5 可以看出, 不同的工作状态下, 当除湿机工作到某个时刻, 故障对应的露点温度达到报警阈值, 此时完成吸附剂失效趋势预测, 认为在该点

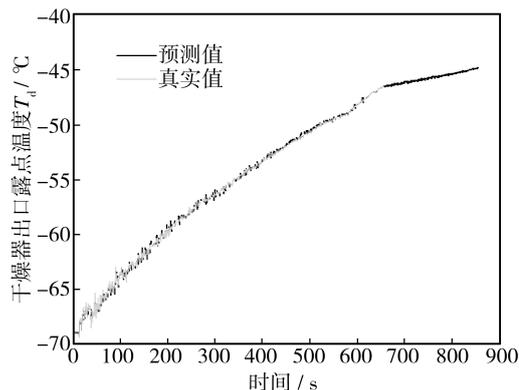


图 4 降温段不同时刻对应的露点温度值

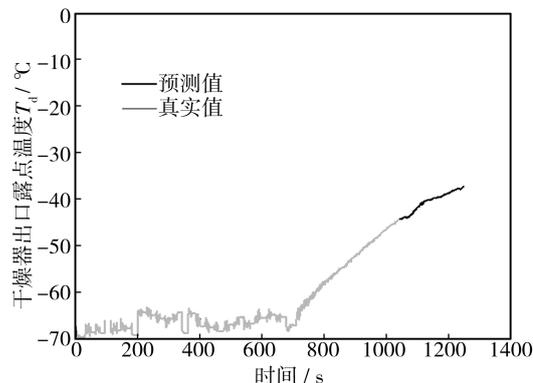


图 5 保温段不同时刻对应的露点温度值

制冷压缩空气中的水分含量过高, 达到了引发故障的状态。露点测量仪的采样间隔是 1 s。对照图中结果表明, 在降温段, 除湿机运行大约再运行 1'50" (时间=时序数/采样频率) 发生故障, 即除湿机出口露点温度将在第 1570 个时刻高于 -50°C , 吸附剂进入报废状态, 这个预测结果与实际的第 2162 个时刻点基本吻合; 在保温段, 除湿机运行大约再经过 2'37", 即在第 587 个时刻点发生故障, 与实际的第 646 个时刻点高度一致。由此可以看出, 该网络的预测与实际情况比较吻合, 预测的露点温度值完全落在划分的故障程度区域内。通过对除湿机出口气体露点的实时预测, 就可以准确地定位吸附剂失效程度, 也就可以计算出什么时间会达到报废的程度, 继而实现设备的预知性维修。

5 结语

目前, 大部分的故障诊断系统只能识别到故障类型这一阶段, 不能确定故障的具体程度, 且缺少对设备状态的预测功能。针对这些问题, 提出了遗传算法与神经网络相结合的方法, 对低温试验系统关键设备除湿机的吸附剂失效程度进行了诊断研究, 并应用网络模型对除湿机出口气体温度这一主要特征参数进行了仿真预测, 诊断和预测效果比较理想。主要研究

成果如下。

1) 对除湿机评估体系失效程度进行区间划分, 将其作为神经网络的输出模式进行训练。通过神经网络的训练与测试, 识别结果不仅能够准确反映出故障程度, 而且可以清晰地表明故障演变的过程。

2) 将遗传神经网络应用于除湿机出口气体露点温度的预测, 结合吸附剂失效程度各区间阈值, 能够准确掌握吸附剂的工作能力, 为低温环境模拟试验的正常运行、制定维修策略及开展设备维护维修具有重要意义。

参考文献:

- [1] 曾声奎, MICHAEL G P, 吴际. 故障预测与健康管理 (PHM)技术的现状与发展[J]. 航空学报, 2005, 26(5): 626—631.
- [2] 秦衡峰. 基于神经网络的设备状态预测方法及在风机上的应用[D]. 长沙: 中南大学, 2004.
- [3] 林香, 姜青山, 熊腾科. 一种基于遗传BP神经网络的预测模型[J]. 计算机研究与发展, 2006, 43 (S1): 338—343.
- [4] 张琪, 吴亚锋, 李锋. 基于遗传神经网络的旋转机械故障预测方法研究[J]. 计算机测量与控制, 2016(2): 11—15.
- [5] PECK L K. A Hybrid of Back Propagation Neural Network and Genetic Algorithm for Optimization of Collagen Extraction from Malaysian Cultured Catfish[J]. Biotechnology and Bioprocess Engineering, 2013, 18: 257—265.
- [6] NASSERI M, ASGHARI K. Optimized Scenario for Rainfall Forecasting Using Genetic Algorithm Coupled with Artificial Neural Network[J]. Expert Systems with Applications, 2008, 35: 1415—1421.
- [7] SAMARASINGHE Sandhya.. 神经网络在应用科学和工程中的应用: 从基本原理到复杂的模式识别[M]. 史晓霞, 陈一民, 译. 北京: 机械工业出版社, 2010: 55—62.
- [8] 周开利, 康耀红. 神经网络模型及其 MATLAB 仿真程序设计[M]. 北京: 清华大学出版社, 2005: 17—19.
- [9] 李洪刚, 赵兴锋, 李刚, 等. 基于 CBR 的新型防空导弹故障诊断专家系统研究[J]. 装备环境工程, 2013, 10(4): 90—93.
- [10] 何建新, 李继红, 方堃, 等. 基于 Matlab 编程实现 Arrhenius 模型寿命预测[J]. 装备环境工程, 2013, 10(3): 87—90.
- [11] 徐小力. 设备运行状态监测与故障诊断的现代技术[C]//全国设备监测与诊断学术会议论文集.北京: 中国机械工程学会设备与维修工程分会, 2005.
- [12] 陈建宏, 刘浪, 周智勇, 等. 基于主成分分析与神经网络的采矿方法优选[J]. 中南大学学报, 2010, 41(5): 1967—1972.
- [13] 蒋一然. 基于遗传神经网络的柴油机故障诊断技术研究[D]. 大连: 大连海事大学, 2009.
- [14] 秦兴生, 胡觉亮, 丁佐华. 基于神经网络集成的软件故障预测及实验分析[J]. 计算机工程与应用, 2014, 50(14): 44—56.
- [15] 李锋, 汤宝平, 刘文艺. 遗传算法优化最小二乘支持向量机的故障诊断[J]. 重庆大学学报, 2010, 33(12): 14—20.