

主成分分析与遗传神经网络在制冷系统故障诊断中的应用

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: 针对低温试验系统制冷设备测点多、数据间存在强相关性等特点, 将主成分分析法和遗传神经网络智能识别方法进行组合, 引入制冷系统的故障诊断中; 结合专家经验和主成分分析客观地对多传感器信息进行了科学合理的故障特征优选, 从而确定了神经网络的输入空间; 为了克服神经网络易陷入局部最小的缺陷, 利用遗传算法的全局搜索能力, 对神经网络的初始权值和阈值进行了优化; 运用该方法对制冷系统各故障状态进行识别, 结果表明, 简洁有效的网络结构不仅缩短了训练时间, 而且提高了网络的稳定性和分类精度, 为监测系统提供了一种有效的故障诊断方法。

关键词: 故障诊断; 主成分分析法; 遗传神经网络; MATLAB

Application of Principal Component Analysis and Genetic Neural Network in Fault Diagnosis of Refrigeration System

Zhang Qi¹, Wu Yafeng², 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: According to the characteristics of data measured from refrigeration equipment in low temperature test system, such as a huge number of points, a strong correlation between the data, genetic neural network combined with principal component analysis (PCA) is introduced into fault diagnosis in the refrigeration system. With the knowledge of expert experience and PCA, the fault feature is extracted from multi sensor information in a scientific and reasonable way, so the input space of the neural network is fixed. The defects of neural network is easy to fall into the minimum in local space, but genetic algorithm (GA) has global search ability, aim at eliminating the defects, GA is used to optimize the initial weights and thresholds of neural network. Using the method into the fault state identification of the refrigeration system, it showed that the simple and effective network structure not only shorten the training time, but also improve the network stability and classification accuracy, so it provides an effective method of fault diagnosis for the monitoring system.

Keywords: fault diagnosis; principal component analysis; genetic neural network; MATLAB

0 引言

由于低温模拟试验系统设备组成复杂, 任务负荷大, 温控要求高, 其设备安全可靠的运行至关重要。制冷设备一旦出现故障, 将造成巨大的经济损失和社会影响。因此需要对系统设备实时开展故障诊断, 及时监测设备的运行状况, 识别故障早期征兆, 对故障部位、故障程度和发展趋势做出准确判断, 以实现设备的预知性维修, 即由计划维修向状态检修过渡, 提高机组的可靠性和可利用率。

故障诊断的本质是对工况状态模式的识别过程。神经网络作为模式分类器应用非常普遍, 其强大的自学习机制能够实现输入和输出之间的非线性映射。误差反向传播的前馈型网络(BP)是神经网络中最精华的部分, 应用于实例的神经网络约80%~90%都采用了BP网络或它的变形。由于神经网络具有自身容易陷入局部最小的缺陷, 有必要利用遗传算法的全局搜

索能力对网络的连接权值与阈值进行优化, 改善网络识别的稳定性和精度。针对实际状态、特征信息种类多, 强关联的特点, 应用主成分分析法(PCA)提取出可反映样本绝大部分信息的少数相互独立的综合变量。本文结合PCA和GABP网络的优点, 将控制系统测量信息作为输入, 9个典型故障类型作为输出, 仿真结果表明, 该组合算法结构简洁, 识别速度快, 分类精度较高。

1 主成分分析法

1.1 主成分分析法的基本思想

由于模式识别方法的日益成熟, 识别精确的关键很大程度上取决于从原始数据中提取的特征变量。为了降低计算的复杂性, 避免海量数据引起的效率低下、高维特性导致的维数灾难问题和非线性特性带来的线性模型失效问题等, 对原始数据进行降维是很有必要的。主成分分析正是利用降维的思想, 研究原始变量相关矩阵的内部结构, 找出几个综合指标, 综合指标是原来变量的线性组合。在故障诊断中, 不同故障表现出的部分征兆可能是相同的, 多种征兆的强相关性使得诊断结果准确性不能得到保证。通过对输入故障征兆的降维, 去除冗余信息, 降低数据间的相关性, 使得不同类特征的类间距离最大, 同类特征的类内距离最小, 对这一特征更敏感。其优点在于实

收稿日期: 2016-02-27; 修回日期: 2016-04-18。

作者简介: 张琪(1984-), 女, 陕西咸阳人, 硕士研究生, 工程师, 主要从事故障诊断与预测方向的研究。

吴亚锋(1966-), 男, 陕西渭南人, 博士研究生导师, 主要从事信号与信息处理方向的研究。

现了可观的数据压缩,降低了对通信带宽和数字信号处理器的要求,有利于实时处理。

1.2 主成分分析法的代数和几何意义

主成分分析是一种多元统计分析方法。通过把高维信息投影到低维子空间,并保留其主要过程信息。具体方法是借助一个正交变换 T ,将其分量相关的原随机向量 $x = (x_1, x_2, \dots, x_p)^T$,转化成其分量不相关的新随机向量 $u = (u_1, u_2, \dots, u_p)^T$,这在代数上表现为将 x 的协方差阵变换成对角形阵,在几何上表现为将远坐标系变换成新的正交坐标系,使之指向样本点散步最开的 p 个正交方向,以一个较高的精度转换成低维度变量系统。根据数据变化的方差大小来确定变化方向的主次位置,按主次顺序得到各个彼此独立主成分。为了便于理解,在二维空间中进行说明。

假设有 n 个样本,每个样本包含 2 个观测量 x_1 和 x_2 ,在 x_1 、 x_2 所确定的二维平面中, n 个样本点的散步情况如图 1 所示。




图 1 x_1 和 x_2 坐标系下样本点的分布

从图 1 可知,这 n 个样本点在坐标轴的任意方向上都具有很大的离散性,如果仅考虑 x_1 和 x_2 中的一个,则会损失很多原始数据的信息。通过同时把 x_1 和 x_2 轴逆时针旋转 θ 角度,从而得到坐标轴 y_1 和 y_2 ,如图 2 所示。旋转的主要目的是令 n 个样本点在 y_1 轴方向最大程度的离散,此时, y_1 的方差达到最大,新变量包含了原始数据的绝大部分信息(譬如方差贡献率 85% 以上),在研究问题时可以不考虑 y_2 ,两个变量缩减成一个,降维简化了问题。




图 2 y_1 和 y_2 坐标系下样本点的分布

根据旋转公式:

$$\begin{aligned} y_1 &= x_1 \cos\theta + x_2 \sin\theta \\ y_2 &= -x_1 \sin\theta + x_2 \cos\theta \end{aligned}$$

我们看到新变量 y_1 和 y_2 是原变量 x_1 和 x_2 的线性组合,它的矩阵表示形式为:

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = U'x$$

其中: U' 为旋转变换矩阵,是正交矩阵,即有 $U' = U^{-1}$, $U'U = I$ 。

主成分分析法在实际问题的应用中,设某个控制过程有 p 个变量,如果系统状态可以由指标中的 k 个主分量 ($k < p$) 来描述,那么可以通过监测 k 个新变量的变化作为识别的输入,来判断状态正常与否。

1.3 主成分分析的数学模型

在实际问题中,常见的情况如 n 个样品 p 个变量 x_1, x_2, \dots, x_p ,原始数据矩阵为:

$$x = \begin{bmatrix} x_{11} & \dots & x_{1p} \\ \vdots & & \vdots \\ x_{n1} & \dots & x_{np} \end{bmatrix} \quad (1)$$

为了使采集到的不同量纲的多源数据它们具有可比性,先对原始数据进行标准化处理,使得每个变量均值为 0,方差为 1。常用的标准化方法是 z -score 标准化:

$$x_{ij}^* = \frac{x_{ij} - \bar{x}_j}{\sigma_j} \quad (2)$$

式中, \bar{x}_j 和 σ_j 分别是第 j 个变量的均值和标准差; $i = 1, 2, \dots, n$; $j = 1, 2, \dots, p$ 。

协方差 C_X 为:

$$C_X = E[X^* X^{*T}] \quad (3)$$

计算 C_X 的特征值 $\lambda_1, \lambda_2, \dots, \lambda_p$ 和对应的归一化特征向量 U_1, U_2, \dots, U_p :

$$C_X U_j = \lambda_j U_j \quad j = 1, 2, \dots, p \quad (4)$$

式中, $U_j = [u_{1j}, u_{2j}, \dots, u_{nj}]^T$ 。设特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$, 则 $y_j = U_j^T X$ ($j = 1, 2, \dots, p$) 即为输入矩阵在特征向量下的投影,就是 X 的 j 个主分量。这样就将 $x = (x_1, x_2, \dots, x_p)^T$ 的 p 个变量转换成 p 个新的综合变量了,新变量 y_j 可有原变量 x_1, x_2, \dots, x_p 线性表示,即:

$$\begin{cases} y_{1p} = u_{11}x_1 + u_{12}x_2 + \dots + u_{1p}x_p \\ y_{2p} = u_{21}x_1 + u_{22}x_2 + \dots + u_{2p}x_p \\ \dots \\ y_{np} = u_{n1}x_1 + u_{n2}x_2 + \dots + u_{np}x_p \end{cases} \quad (5)$$

系数 u_{ij} 的确定原则为:

(1) y_j 与 y_{ij} ($i \neq j$; $i, j = 1, 2, \dots, p$) 相互无关;

(2) y_1 为 x_1, x_2, \dots, x_p 一切线性组合中方差最大者; y_2 为与 y_1 不相关的 x_1, x_2, \dots, x_p 的所有线性组合中方差最大者; y_p 为 y_1, y_2, \dots, y_{p-1} 都不相关的 x_1, x_2, \dots, x_p 所有线性组合中方差最大者。

按以上方法确定的综合变量 y_1, y_2, \dots, y_p 分别称为原变量的第 1, 第 2, \dots , 第 p 个主成分。并且 y_1 在总方差中所占比例是最大的,其余 y_2, y_3, \dots, y_p 的方差在总方差中所占比例依次递减。主成分的个数选取由主成分的累积方差贡献率决定,累计贡献率越大,说明保留原始的数据信息越多,通常累积方差贡献率大于 80% 以上即可。

累积贡献率定义为:

$$\Phi(L) = \frac{\sum_{j=1}^L \lambda_j}{\sum_{j=1}^p \lambda_j} \quad (6)$$

当累积贡献率大于 85% 时,将前 L 个特征向量 u_1, u_2, \dots, u_L 构成的低维空间作为投影空间,将原始变量投影得到

新的综合变量, 至此完成原数据降维处理。这种选择几个方差最大的成分, 以达到简化结构, 抓住问题实质的目的。

2 遗传神经网络

2.1 BP 神经网络与遗传算法结合的动因

人工神经网络是数据驱动的故障诊断中普遍和灵活的机器学习工具, 是现代数据分析中的热点, 可以处理“黑箱”这类非线性辨识问题。神经元的广泛互联与并行工作使整个网络呈现出高度的非线性特点。网络可以高度自适应地学习和记忆各输入量和输出量之间的关系, 学习对象是网络输入层的大量样本, 通过对各层的神经元进行训练, 在以网络输出均方误差最小的训练目标下, 连接权重和阈值不断被调整到最佳值, 最终将知识以权值和阈值的形式储存于网络中, 以此进行新样本的状态识别。前馈型网络 (BP) 利用误差的反向传播逐步调整到网络的最佳状态。

遗传算法 (GA) 在工程问题中, 染色体对应的是数据或数组, 通常是由一维的串结构数据来表示, 串上各个位置对应基因的取值。基因组成的串就是染色体, 或者称为基因型个体。一定数量的个体组成了群体。群体中个体的数目称为群体大小, 也称为群体规模。而各个个体对环境 (评价准则, 如最小均方误差) 的适应程度叫做适应度。神经网络和遗传算法这两种智能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, 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, 加之无法准确获得网络结构、初始连接权值和阈值, 而它们却是影响网络训练效果的主要因素。因此, 有必要采用遗传算法对神经网络进行优化。

2.2 遗传算法与神经网络的结合过程

遗传算法优化 BP 神经网络是为了得到最佳的网络连接权值和阈值, 其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。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, 从而克服网络陷入局部最小的缺点, 提高网络的学习精度。遗传 BP 神经网络 (以下简称 GABP) 算法的流程如图 3 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。根据样本的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, 获取一组随机数, 这个参数是影响网络训练的重要因素, 但是随机的通常不准确, 为了得到最佳的权值和阈值, 运用遗传算法对训练过程进行优化。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 :

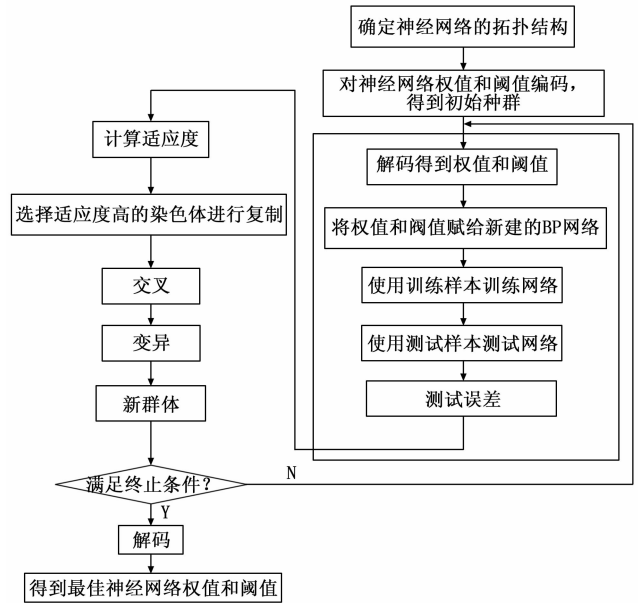


图 3 遗传算法优化神经网络算法流程

$$E = \frac{1}{L} \sum_{l=1}^L [O_k(l) - T_k(l)]^2 \quad (7)$$

(O_k, T_k 分别为输出层输出和目标值), 进而得到遗传进化的适应度, 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的个体, 即使网络的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的误差精度, 如果未达到, 网络将继续学习, 以相同的条件判定是否结束, 最终得到最优的权值与阈值输入网络进行识别。

3 主成分分析法与遗传神经网络结合在制冷系统故障诊断中的应用

3.1 故障样本的获取

低温制冷系统大多故障过程属于缓变故障, 温度、压力、流量、转速等多种信号具有变化缓慢、频率较低、波形没有剧烈起伏的特点, 设备从正常运行到故障征兆出现再到故障灾害发生是一个较慢的过程, 这个故障征兆累计过程中大多数状态量是连续变化的。

核心设备涡轮出现故障将是系统故障的顶事件, 很多原因能够引起顶事件的发生, 即制冷系统制冷量不足或不能制冷, 而且几种征兆往往同时出现, 目前常用且成熟的诊断方法是基于各种故障所对应的征兆。进行诊断时, 按照由专家经验和系统机理制定的数据统计处理规则, 将从设备运行中采集到的各种信号提取特征信息, 从而获得故障的相关征兆, 利用此征兆进行诊断是否故障和哪类故障。

总结低温制冷系统主要故障征兆与故障类型的对应关系。提取了与低温制冷系统故障相关的 40 个征兆参数, 作为故障类型 C_i ($i=1, 2, \dots, 9$) 的特征指标, 即 $A = \{A_1, A_2, \dots, A_{50}\}$ 。 A_i 按以下规则取值: $A_i = \begin{cases} 1 & \text{异常} \\ 0 & \text{正常} \end{cases}$, 于是对应的故障论域为: $C = \{ (A_1, A_2, \dots, A_{50}), A_i = 0, 1 \ i=1, 2, \dots, 50\}$ 。用故障论域来表示低温制冷系统标准故障模式集。

3.2 主成分分析法的制冷系统故障特征提取

依据制冷系统典型故障域特征向量，利用 SPSS 数据分析软件进行主成分特征提取。具体分析结果如下。

1) 提取特征值及主成分个数：

如表 1 所示， $\lambda_1=13.792$ ， $\lambda_2=11.302$ ， $\lambda_3=8.164$ ， $\lambda_4=5.955$ ， $\lambda_5=5.197$ ， $\lambda_6=2.516$ ， $\lambda_7=1.950$ ， $\lambda_8=1.125$ ， $\lambda_9=\lambda_{10}=\dots=\lambda_{50}=0$ ，可以看出，前 8 个因子特征值大于 1，且它们的累积方差贡献率几乎达到了 100%，符合了达到 85% 以上的提取要求，可以认为这 8 个因子包含了大部分的信息。这与主成分碎石图的分析结果相吻合。

表 1 各成分特征值、方差贡献率及累计方差贡献率

成份	初始特征值			提取平方和载入		
	合计	方差的%	累积%	合计	方差的%	累积%
1	13.792	27.583	27.583	13.792	27.583	27.583
2	11.302	22.604	50.187	11.302	22.604	50.187
3	8.164	16.327	66.514	8.164	16.327	66.514
4	5.955	11.910	78.424	5.955	11.910	78.424
5	5.197	10.394	88.818	5.197	10.394	88.818
6	2.516	5.032	93.850	2.516	5.032	93.850
7	1.950	3.900	97.750	1.950	3.900	97.750
8	1.125	2.250	100.000	1.125	2.250	100.000
9	3.638E-15	7.276E-15	100.000			
10	2.591E-15	5.183E-15	100.000			
11	2.405E-15	4.810E-15	100.000			
12	1.777E-15	3.553E-15	100.000			
13	1.279E-15	2.557E-15	100.000			
14	1.145E-15	2.290E-15	100.000			

2) 生成新变量：

上述确定了前 8 个特征值作为制冷系统故障体系的主要因素，而相应的主成分成份矩阵即表达了新的影响因子 $Y_1, Y_2, Y_3, Y_4, Y_5, Y_6, Y_7, Y_8$ 与原始变量之间的关系，即新的故障模式样本表 2 所示。




图 4 主成分分析碎石图

根据该矩阵写出新变量表达式：

$$Y_1 = 0.389X_1 - 0.450X_2 - 0.450X_3 + 0.389X_4 + 0.389X_5 + 0.389X_6 + 0.853X_7 + 0.943X_8 + 0.376X_9 + 0.376X_{10} + \dots - 0.443X_{19} - 0.450X_{50}$$

$$Y_2 = -0.065X_1 + 0.747X_2 + 0.747X_3 - 0.065X_4 - 0.065X_5 - 0.065X_6 - 0.008X_7 + 0.062X_8 + 0.517X_9 + 0.517X_{10} - 0.705\dots - 0.705X_{19} + 0.747X_{50}$$

表 2 提取成分荷载矩阵
成份矩阵^a

	成份							
	1	2	3	4	5	6	7	8
A1	.389	-.065	-.441	.332	.734	.036	.000	.000
A2	-.450	.747	.281	.275	.190	-.220	.000	.000
A3	-.450	.747	.281	.275	.190	-.220	.000	.000
A4	.389	-.065	-.441	.332	.734	.036	.000	.000
A5	.389	-.065	-.441	.332	.734	.036	.000	.000
A6	.389	-.065	-.441	.332	.734	.036	.000	.000
A7	.853	-.008	.286	-.066	.430	.017	.000	.000
A8	.943	.062	.077	.285	-.044	.136	.000	.000
A9	.376	.517	-.020	.596	.104	.001	.474	.000
A10	.376	.517	-.020	.596	.104	.001	-.474	.000
A11	-.443	-.705	.399	.362	.072	.107	.000	.000
A12	-.443	-.705	.399	.362	.072	.107	.000	.000
A13	.696	.047	-.209	.444	-.017	.147	.500	.000
A14	.696	.047	-.209	.444	-.017	.147	-.500	.000
A15	.137	.589	.272	.407	-.380	-.024	.500	.000
A16	.137	.589	.272	.407	-.380	-.024	-.500	.000
A17	-.443	-.705	.399	.362	.072	.107	.000	.000
A18	-.443	-.705	.399	.362	.072	.107	.000	.000
A19	-.299	.046	.743	.281	.145	-.079	-.500	.000
A20	-.299	.046	.743	.281	.145	-.079	.500	.000
A21	.674	.041	.658	-.326	-.067	-.008	.000	.000
A22	.674	.041	.658	-.326	-.067	-.008	.000	.000
A23	-.564	.662	.054	-.148	.178	.433	.000	.000
A24	-.564	.662	.054	-.148	.178	.433	.000	.000
A25	.092	.588	.595	-.397	.092	.355	.000	.000
A26	.412	.576	.534	.249	-.388	-.026	.000	.000
A27	-.443	-.705	.399	.362	.072	.107	.000	.000
A28	.299	-.434	.846	-.046	-.011	.064	.000	.000
A29	-.443	-.705	.399	.362	.072	.107	.000	.000
A30	.943	.062	.077	.285	-.044	.136	.000	.000
A31	-.450	.747	.281	.275	.190	-.220	.000	.000
A32	-.443	-.705	.399	.362	.072	.107	.000	.000
A33	.210	.109	-.307	.550	-.715	.190	.000	.000
A34	-.150	-.134	-.296	-.308	-.119	-.447	.000	-.750
A35	-.150	-.134	-.296	-.308	-.119	-.447	.000	-.750
A36	.210	.109	-.307	.550	-.715	.190	.000	.000
A37	.210	.109	-.307	.550	-.715	.190	.000	.000
A38	.943	.062	.077	.285	-.044	.136	.000	.000
A39	-.450	.747	.281	.275	.190	-.220	.000	.000
A40	-.450	.747	.281	.275	.190	-.220	.000	.000
A41	-2.97	.128	-.210	-.471	.046	.792	.000	.000
A42	.853	-.008	.286	-.066	.430	.017	.000	.000
A43	.674	.041	.658	-.326	-.067	-.008	.000	.000
A44	-.564	.662	.054	-.148	.178	.433	.000	.000
A45	.674	.041	.658	-.326	-.067	-.008	.000	.000
A46	.853	-.008	.286	-.066	.043	.017	.000	.000
A47	-.564	.662	.054	-.148	.178	.433	.000	.000
A48	.674	.041	.658	-.326	-.067	-.008	.000	.000
A49	-.443	-.705	.399	.362	.072	.107	.000	.000
A50	-.450	.747	.281	.275	.190	-.220	.000	.000

$$Y_8 = -0.750X_{34} + 0.750X_{35}$$

3.3 基于 GABP 神经网络的状态故障诊断网络建模

网络输入是被测对象的故障征兆特征值, 输出是该状态对应的故障模式。下面对制冷系统分别用 BP 网络和 PCA-GABP 网络建模进行故障识别。前者根据制冷系统典型故障论域特征向量选取 50 个征兆参数 $A = \{A_1, A_2, \dots, A_{50}\}$ 作为 BP 网络的输入, 以 9 类故障 $C_i (i=1, 2, \dots, 9)$ 作为输出, 经验证, 这里取隐含层节点数为 17, BP 网络结构 $50 \times 17 \times 9$ 。PCA-GABP 网络的结构与 GABP 网络仅区别于输入层节点数不同。由 3.2 节可知, 表征低温系统状态的征兆参数有 8 个, 即网络输入节点数目为 8, PCA-GABP 网络结构为 $8 \times 13 \times 9$ 。遗传算子染色体长度分别为 1029 和 243, 种群大小和遗传代数分别设定为 50 和 100。输出变量是故障模式代号, 用布尔值串表示。如第 3 种故障 C3 就是 $T = [001000000]$ 。隐含层和输出层神经元传递函数均采用 S 型函数, 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 , 并调用遗传算法工具箱优化初始值对网络进行训练, 可提高网络的稳定性和训练速度。训练目标 0.01, 自学习率 0.08, 训练次数 5 000 次。

待检状态样本 1: 低温试验系统在降温过程中, 测控系统测得的制冷系统运行状态为: 1 号涡轮转速超高、2 号涡轮转速超高 1 号涡轮膨胀机出口温度降低、2 号涡轮膨胀机出口温度降低、回冷器冷侧进口温度升高、低温室室内压差为 0、低温室回气阀位增至全开等。其故障论域的特征向量可表示为: $\text{test1} = [0000000000110000111100110011001000000000000000010]$ 。

待检状态样本 2: 低温试验系统在保温过程运行中发现如下症状: 水冷器进出水温差小、水冷器出口气体温度高、空冷器热侧出口气体温度高、涡轮膨胀机进口温度高、1 号涡轮压气机出口温度高、2 号涡轮压气机出口温度高、回冷器冷侧进口温度升高。其故障论域的特征向量可表示为: $\text{test2} = [000000000000000000000000111000000000000001001001010]$ 。

由上述主成分分析法进行特征优选, 得到降维约简后的特征向量: $P_test1 = [-4.9752 \ -4.6545 \ 5.6303 \ 3.1172 \ 1.2140 \ 1.6260 \ 0.0000 \ 0.0000]$; $P_test2 = [-2.5208 \ 2.7679 \ 0.4479 \ 1.1261 \ -1.8676 \ 2.9149 \ 0.0000 \ 0.0000]$ 。

3.4 网络训练与测试

PCA-GABP 网络的训练: 按照上面设计的网络参数进行训练, 训练过程如图 5 所示。

由图 5 可以看出: PCA-GABP 网络达到了较高的网络性能要求, 但在训练过程中发现, PCA-GABP 网络的稳定性明显高于 BP 网络, 且缩短了训练时间。

网络测试: 训练好网络后, 分别将 P_test1 和 P_test2 作为测试输入向量, 对网络进行仿真测试, 识别结果如表 3 所示。

表是实例 1 和实例 2 经过两种网络测试结果。实例 1 中两种网络的识别结果均显示是第 9 种故障, 即试验室密封不严密, 这与实际情况相一致。实例 2 中均显示是第 6 种故障, 即水冷器冷侧壁面结垢严重换热效率低, 也是正确的。通过比较可以得出, 这两种网络均能够识别出故障, 但 PCA-GABP 网络的输出隶属度稍高, 提高了网络的识别精度。

4 结论

本文提出的主成分分析法与 GABP 神经网络组合的诊断方法, 在保证网络的识别精度不变的前提下, 能够消除变量间的冗余信息, 简化 GABP 网络结构, 缩减网络训练时间, 是

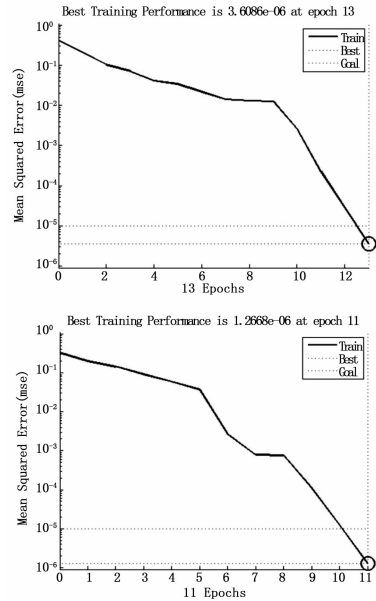


图 5 PCA-GABP 网络训练过程

表 3 PCA-GABP 和 BP 网络对实例 1 与实例 2 的测试结果

	Test1		Test2	
	PCA-GABP	BP	PCA-GABP	BP
C1	0.000210623	4.47E-05	0.0012	9.53E-05
C2	0.108144858	0.001259	0.0046	0.000673
C3	0.000186068	7.08E-05	3.55454E-04	0.003641
C4	0.00139665	0.000262	0.0109	6.72E-05
C5	0.002142502	0.000298	0.0235	8.06E-05
C6	0.008252837	0.002326	0.9998	0.99929
C7	0.531392909	0.000187	0.4552	7.2E-05
C8	0.003046723	5.1E-05	0.0032	0.00061
C9	0.999992112	0.995124	1.2224E-04	0.00482

实时在线监测的有效方法。利用这一网络可以在很短的时间内诊断出故障, 以便于操作人员及时做出应对处理。

参考文献:

- [1] Abhijit S Pandya, Robert B Macy. 神经网络模式识别及其实现 [M]. 徐勇, 荆涛, 等译. 北京: 电子工业出版社, 1999.
- [2] 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.
- [3] 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.
- [4] 陈明. MATLAB 神经网络原理与实例精解 [M]. 北京: 清华大学出版社, 2013.
- [5] 徐磊. 基于遗传算法的多目标优化问题的研究与应用 [D]. 长沙: 中南大学, 2007.
- [6] 史峰, 王辉, 等. 智能算法 30 个案例分析 [M]. 北京: 北京航空航天大学出版社, 2011.
- [7] 韩晓娟. 多源信息融合技术在火电厂热力系统故障诊断中的应用研究 [D]. 北京: 华北电力大学, 2008.
- [8] 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.
- [9] 李向前. 复杂装备故障预测与健康关键技术研究 [D]. 北京: 北京理工大学, 2014.