

粗糙集及 PSO 优化 BP 网络的故障诊断研究

吴伟 李楠 郭茂耘

(重庆大学自动化学院 重庆 400030)

摘要 针对 BP 神经网络故障诊断存在网络结构复杂、训练时间长、精度不高的问题,将粗糙集、微粒群算法、遗传算法引入到柴油机故障诊断中,提出了基于粗糙集理论与改进 BP 神经网络相结合的柴油机故障诊断算法。算法采用自组织映射方法对连续属性离散化,利用粗糙集理论对特征参数进行属性约简,使用微粒群算法优化 BP 网络结构,从而缩短训练时间,有效提高故障诊断的准确度。最后用柴油机的实际诊断结果验证了该算法的可行性、快速性和准确性。

关键词 微粒群算法,遗传算法,BP 神经网络,粗糙集理论,故障诊断

中图分类号 TP183 **文献标识码** A

Fault Diagnosis Research by Rough Set Theory and the PSO-BP Neural Network

WU Wei LI Nan GUO Mao-yun

(College of Automation, Chongqing University, Chongqing 400030, China)

Abstract For the imperfections of BP network fault diagnosis model, including the complexity of the network structure, the long time of training, and the low precision, this article introduced rough set (RS), particle swarm optimization (PSO) and genetic algorithm (GA) into the diesel engine fault diagnosis, then proposed a new algorithm that is based on rough set theory and the improved BP neural network. The algorithm uses self-organization mapping net (SOM) to discretize the continuous attributes, rough set theory to make a reduction on the properties for characteristic parameters, and the particle swarm optimization (PSO) to optimize the BP network structure, so that it can shorten training time and improve the accuracy of fault diagnosis effectively. Finally, the result of the diesel engine's diagnosis proves the feasibility, rapidity, veracity of the algorithm.

Keywords Particle swarm optimization (PSO), Genetic algorithm (GA), BP neural network, Rough set (RS), Fault diagnosis

1 引言

在现代工业生产过程中,随着系统复杂程度的提高,对各种机械设备的可靠性要求也越来越高,一些基于数据学习的方法在设备故障诊断中得到了广泛的使用,如支持向量机和神经网络等。利用 BP 神经网络诊断机械故障,往往存在所选的特征参数太多,使得神经网络规模过于庞大、结构过于复杂、学习时间过长、算法收敛速度过慢、精度低及易陷入局部极小等问题,从而降低了诊断的可靠性和实用性。为了克服 BP 神经网络的这些缺点,人们提出了多种改进方法。例如,黄湘云等^[1]基于“等价偏差思想”,针对传感器故障,提出了一种基于改进 BP 神经网络的集成故障诊断方法。Rajakarunakaran, S 等^[2]通过引入自适应调整惯性系数,提出了改进的 BP 神经网络,实现了对旋转电机的故障诊断。沈红等^[3]在遗传算法中引入模拟退火机制,优化了 BP 算法,解决了在机械故障诊断系统中 BP 算法容易陷入局部极小值的问题。

本文将粗糙集理论与微粒群优化的神经网络结合起来,

提出了一种基于粗糙集及 PSO 优化 BP 神经网络的故障诊断方法。该方法利用粗糙集理论中的属性约简算法对诊断决策系统中的条件属性约简,减少了网络输入的维数,简化了网络结构,同时采用微粒群算法优化 BP 神经网络的权值和阈值。此算法可以有效地剔除冗余信息,缩短网络的训练时间,避免了用梯度下降法导致算法收敛速度慢和易陷入局部极小的问题,使得网络的收敛速度更快,提高了故障诊断精度。

2 粗糙集及 PSO 优化 BP 神经网络算法实现

2.1 粗糙集理论基础^[4-6]

2.1.1 不可分辨关系

给定一个论域 U 和 U 上的一簇等价关系 S , 若 $P \subseteq S$, 且 $P \neq \emptyset$, 则 $\cap P$ (P 中所有的等价关系的交集) 仍然是论域 U 上的一个等价关系, 称为 P 上的不可分辨关系, 记为 $IND(P)$, 而且, $\forall x \in U, [x]_{IND(P)} = [x]_P = \bigcap_{R \in P} [x]_R$ 。

在粗糙集理论中,集合可以理解作为一种等价关系,根据属性集 $C \subseteq A$ 对论域 U 进行划分得到的等价关系簇记为 U/C 。

到稿日期:2010-12-23 返修日期:2011-03-13 本文受中央高校基本科研业务费(CDJZR10170001)资助。

吴伟(1986-),男,硕士生,主要研究领域为数据挖掘、智能控制,E-mail:sf0078906@163.com;李楠(1972-),女,副教授,硕士生导师,主要研究领域为模式识别与智能系统;郭茂耘(1973-),男,副教授,主要研究领域为决策支持、智能信息处理。

2.1.2 集合的上、下近似

给定知识库 $K=(U, S)$ 和 U 的分类 U/R , 对每个子集 $X \subseteq U$, 把以下两个集合分别称为 X 的 R 下近似和 R 的上近似。 $\underline{R}X = \{x \in U; [x]_{R \subseteq X}\}$, 即当且仅当 $[x]_{R \subseteq X}$, $x \in \underline{R}X$ 。 $\overline{R}X = \{x \in U; [x] \cap X \neq \emptyset\}$, 即当且仅当 $[x] \cap X \neq \emptyset$, $x \in \overline{R}X$ 。集合 $bn_R(x) = \overline{R}X - \underline{R}X$ 称为 X 的 R 边界域; $pos_R(x) = \underline{R}(x)$ 称为 X 的 R 正域; $neg_R(x) = U - \overline{R}(x)$ 称为 X 的 R 负域。显然, $\overline{R}(x) = pos_R(x) \cup bn_R(x)$ 。

2.1.3 属性约简与核

令 R 为一等价关系簇, 且 $r \in R$, 如果 $IND(R) = IND(R - \{r\})$, 则称 r 为 R 中可省略的, 否则称 r 为 R 中不可省略的。若每个都为 R 中必要的, 则称 R 是独立的, 否则称 R 为依赖的。设 $Q \subseteq P$, 若 Q 独立, 且 $IND(Q) = IND(P)$, 则 Q 为 P 的一个约简, 用 $RED(P)$ 来表示。一个属性集 P 可以有多种约简, P 中所有约简属性都包含不可省略关系的集合, 即约简集 $RED(P)$ 的交集称为 P 的核, 记为 $CORE(P)$, 它是表达知识不可缺少的重要属性集。属性集 P 的约简与核的关系表示如下: $CORE(P) = \bigcap RED(P)$ 。决策表的约简就是化简表中的条件属性, 即去除冗余的条件属性, 在删除这些属性后不会影响原有的表达效果。

2.2 连续属性值的离散化^[7]

连续属性值的离散化, 是将条件属性值划分成若干个子区间, 以此子区间代替原有值, 从而使决策表泛化。粗糙集理论只对离散的属性值进行分析处理。因此, 在应用粗糙集理论对故障诊断决策系统进行属性约简处理之前, 需要对其中的连续属性值进行离散处理。本文应用自组织映射(SOM)

神经网络对连续属性值进行离散化处理^[8], 离散结果能够比较客观地反映数据分布情况。

SOM 网络量化连续属性步骤如下:

①初始化: 给网络的权值 w_{ij} 赋予 $[0, 1]$ 区间内的随机值; 确定学习率 $\eta(t)$ 的初值 $\eta(0)$; 确定领域的初值以及总的学习次数 T ;

②给定网络的输入样本模式 $X_k = (x_1, x_2, \dots, x_n)$;

③计算输入 X_k 与全部输出节点距离 $d_k = [\sum_{i=1}^n (X_k - w_{ij}(t))^2]^{\frac{1}{2}}$, 式中 $j=1, 2, \dots, n$;

④选取使 d_k 最小的神经元为获胜节点;

⑤对获胜节点及其几何邻域 $N_g(t)$ 内的所有节点的连接权值进行更新 $w_{ij}(t+1) = w_{ij}(t) + \eta(t)[x_k - w_{ij}(t)]$, 式中 $i=1, 2, \dots, n$;

⑥返回步骤②, 选取另一个模式输入网络, 直到样本中全部模式提供给网络;

⑦令 $t=t+1$, 返回步骤②, 重复至 $t=T$ 为止。

文中根据试验数据的特点, 利用 SOM 神经网络将每个属性离散为 3 类。首先应用训练数据对 SOM 网络进行训练, 保存网络参数的训练结果以及训练数据的离散结果, 然后应用训练好的网络对测试数据进行离散处理。表 1 为柴油机故障诊断数据及其离散化处理决策表, 其中, $a_1 \sim a_8$ 为 8 个传感器采集的故障征兆。D 为故障原因(其中 1 表示排气门间隙大, 2 表示排气门间隙小, 3 表示轻微漏气, 4 表示严重漏气, 5 表示正常状态)。

表 1 柴油机故障诊断数据及其离散化处理决策表

U	a_1	a_2	a_3	a_4	a_5	a_6	a_7	a_8	D
x_1	0.002/2	-0.007/2	0.020/3	-0.009/2	0.032/3	-0.004/2	0.038/3	0.039/3	1
x_2	-0.008/2	0.018/3	-0.009/2	0.001/2	0.032/3	-0.021/2	-0.018/2	0.014/3	1
x_3	0.011/3	0.011/3	-0.002/2	-0.011/2	0.010/2	0.029/3	0.021/3	-0.013/2	1
x_4	-0.003/2	-0.011/2	0.013/3	0.008/2	-0.024/2	0.013/3	-0.015/2	-0.027/1	1
x_5	0.014/3	0.008/2	-0.021/2	0.018/2	-0.004/2	-0.001/2	-0.015/2	-0.008/2	1
x_6	-0.001/2	-0.021/1	-0.011/2	-0.023/1	-0.010/2	-0.012/2	0.001/2	0.004/3	2
x_7	-0.003/2	0.004/2	0.018/3	0.029/3	-0.030/1	-0.020/2	0.038/3	0.009/3	2
x_8	0.006/3	-0.004/2	0.014/3	0.024/3	0.030/3	0.002/3	0.021/3	0.014/3	2
x_9	0.036/3	-0.023/1	-0.001/2	0.004/2	0.025/3	0.032/3	-0.045/1	-0.001/2	2
x_{10}	0.040/3	0.033/3	-0.013/2	0.026/3	-0.007/2	0.022/3	-0.043/1	0.004/3	2
x_{11}	0.004/2	0.053/3	0.004/3	0.041/3	0.00/2	-0.027/1	0.002/2	0.021/3	2
x_{12}	-0.003/2	0.031/3	0.001/3	0.007/2	0.022/3	-0.024/1	-0.001/2	0.038/3	2
x_{13}	-0.00/2	0.006/2	-0.037/1	0.011/2	-0.041/1	0.003/3	-0.021/1	0.031/3	3
x_{14}	-0.046/1	-0.013/2	-0.027/2	-0.001/2	0.005/2	-0.014/2	0.015/2	-0.023/1	3
x_{15}	0.005/3	-0.006/2	0.046/3	-0.009/2	-0.005/2	-0.056/1	0.022/3	-0.037/1	3
x_{16}	0.047/3	-0.008/2	0.022/3	0.001/2	-0.019/2	-0.053/1	0.015/2	-0.001/2	3
x_{17}	0.003/2	-0.025/1	-0.017/2	-0.016/2	-0.002/2	-0.002/2	0.008/2	0.009/3	3
x_{18}	0.025/3	-0.013/2	0.010/3	0.040/3	0.023/3	0.010/3	-0.012/2	-0.032/1	3
x_{19}	0.025/3	0.009/3	-0.008/2	0.013/2	-0.036/1	-0.004/2	-0.007/2	-0.018/2	3
x_{20}	-0.048/1	-0.017/1	0.013/3	0.004/2	-0.015/2	0.005/3	-0.014/2	0.003/3	4
x_{21}	0.013/3	-0.027/1	-0.016/2	0.024/3	-0.025/1	-0.003/2	0.003/2	-0.031/1	4
x_{22}	0.001/2	-0.027/1	-0.016/2	-0.003/2	-0.005/2	0/2	-0.017/2	-0.019/1	4
x_{23}	-0.026/1	-0.020/1	-0.012/2	-0.034/1	0.029/3	0.03/3	-0.027/1	0.003/3	4
x_{24}	-0.002/2	0.002/2	0.008/3	-0.001/2	-0.019/2	0.006/3	0.012/2	0.011/3	5
x_{25}	-0.007/2	0.002/2	-0.010/2	-0.005/2	0.018/3	0.006/3	-0.003/2	-0.006/2	5
x_{26}	0.003/2	0.019/2	-0.002/2	0.012/2	0.018/3	-0.018/2	-0.005/2	-0.004/2	5
x_{27}	0.020/3	0.004/2	0.005/3	0.017/2	0.020/3	0.001/3	-0.001/2	0.028/3	5
x_{28}	0.005/3	-0.013/2	-0.010/2	-0.012/2	-0.004/2	-0.016/2	0.016/3	0.000/3	5
x_{29}	0.005/3	-0.013/2	-0.010/2	-0.005/2	-0.011/2	-0.018/2	0.026/3	0.001/3	5
x_{30}	0.013/3	-0.005/2	0.003/3	-0.005/2	-0.004/2	0.011/3	-0.003/2	-0.011/2	5
x_{31}	-0.025/1	-0.006/2	-0.050/1	-0.008/2	-0.002/2	-0.046/1	-0.038/1	-0.006/2	2
x_{32}	0.010/3	-0.008/2	0.002/3	-0.013/2	0.005/2	0.049/3	0.003/2	-0.011/2	3
x_{33}	-0.007/2	-0.013/2	-0.017/2	-0.005/2	0.028/3	0.006/3	0.009/2	0.004/3	5

注: 表中“/”前的数据为故障诊断数据, “/”后为离散化后的类别号

2.3 基于粗糙集理论的决策系统属性约简

本文中采用遗传算法对决策表进行约简,其基本原理为^[9]:在遗传算法的编码中,每个位串代表区分矩阵的一项,即两个对象的区分属性集,某位为1时表示该属性存在,否则不存在,这样每个位串是一个约简的候选。定义适应度函数为:

$$fitness(t) = \lambda \frac{N - L_t}{N} + \frac{C_t}{(m^2 - m)/2}$$

式中, λ 为权重因子; N 是属性集合的长度; L_t 是位串 ν 中1的个数; C_t 是位串 t 能区分的对象组合的个数; m 是对象的个数。本文中取 $\lambda=1$,群体大小设为40,交叉率取0.6,变异率取0.01,终止代数取300。采用单点交叉的浮点数编码方式,应用遗传算法求得决策系统的3个最小约简为 $\{a_2, a_4, a_5, a_6, a_8\}, \{a_2, a_4, a_6, a_7, a_8\}, \{a_1, a_2, a_4, a_6, a_8\}$ 。以最大聚类比的原则,选取 $\{a_2, a_4, a_5, a_6, a_8\}$ 为最小约简,产生的最优故障诊断决策系统如表2所列。

表2 最优故障诊断决策系统表

U	a_2	a_4	a_5	a_6	a_8	D
x_1	2	2	3	2	3	1
x_2	3	2	3	2	3	1
x_3	3	2	2	3	2	1
x_4	2	2	2	3	1	1
x_5	2	2	2	2	2	1
x_6	1	1	2	2	3	2
x_7	2	3	1	2	3	2
x_8	2	3	3	3	3	2
x_9	1	2	3	3	2	2
x_{10}	3	3	2	3	3	2
x_{11}	3	3	2	1	3	2
x_{12}	3	2	3	1	3	2
x_{13}	2	2	1	3	3	3
x_{14}	2	2	2	2	1	3
x_{15}	2	2	2	1	1	3
x_{16}	2	2	2	1	2	3
x_{17}	1	2	2	2	3	3
x_{18}	2	3	3	3	1	3
x_{19}	3	2	1	2	2	3
x_{20}	1	2	2	3	3	4
x_{21}	1	3	1	2	1	4
x_{22}	1	2	2	2	1	4
x_{23}	1	1	3	3	3	4
x_{24}	2	2	2	3	3	5
x_{25}	2	2	3	3	2	5
x_{26}	2	2	3	2	2	5
x_{27}	2	2	3	3	3	5
x_{28}	2	2	2	2	3	5
x_{29}	2	2	2	2	3	5
x_{30}	2	2	2	3	2	5
x_{31}	2	2	2	1	2	2
x_{32}	2	2	2	3	2	3
x_{33}	2	2	3	3	3	5

2.4 微粒群优化BP神经网络算法

2.4.1 微粒群算法

微粒群(Particle Swarm Optimization, PSO)算法^[10]鲁棒性高,全局搜索能力强,且不需要借助问题本身的特征信息。

假设在一个 D 维的目标搜索空间中,有 m 个粒子组成的

一个群体,其中第 i 个粒子的群体中的位置为 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$,其速度为 $V_i = (v_{i1}, v_{i2}, \dots, v_{iD}), i=1, 2, \dots, m$ 。每一次迭代,粒子通过动态跟踪两个极值来更新其速度和位置:第一个极值是粒子从初始到当前迭代次数搜索产生的最优解,即粒子的个体最优位置,称为个体极值 $p_i = (p_{i1}, p_{i2}, \dots, p_{iD})$;第二个极值是粒子种群目前的最优解,即粒子的全局最优位置,称为全局极值 $p_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 。第 i 个粒子根据以下两个公式来更新其第 d 维粒子的速度和位置^[11]:

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (p_{id}^k - x_{id}^k) + c_2 r_2 (p_{gd}^k - x_{id}^k) \quad (1)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (2)$$

式中, $i=1, 2, \dots, m$ 。 m 是种群中粒子的总数; ω 为惯性权重,它使粒子保持运动惯性; v_{id}^k 为第 k 次迭代粒子 i 飞行速度矢量的第 d 维分量; x_{id}^k 为第 k 次迭代粒子 i 位置矢量的第 d 维分量; p_{id}^k 为粒子 i 个体最好位置 p_{best} 的第 d 维分量; p_{gd}^k 为粒子群体最好位置 g_{best} 的第 d 维分量; c_1 和 c_2 为非负的加速常数; r_1 和 r_2 为两个在 $[0, 1]$ 之间的随机数。

2.4.2 BP神经网络的建立

为了较全面地反映柴油机的实际故障模式,以提高网络对柴油机故障的识别率,本诊断系统把经过粗糙集约简后的条件属性 a_2, a_4, a_5, a_6, a_8 作为BP网络输入层的输入。并把经过编码后相对应的以下5种特征:排气门间隙大(输出编码为000)、排气门间隙小(输出编码为001)、轻微漏气(输出编码为010)、严重漏气(输出编码为011)、正常状态(输出编码为100)作为网络的输出。本诊断系统拓扑结构为5-8-3的3层BP网络。

2.5 微粒群优化的BP神经网络

由于BP算法使用梯度下降法推导出权值和阈值,使得BP网络收敛速度慢、容易陷入局部极小值。微粒群算法是基于种群的全局搜索策略,它具有记忆的特性,可以动态地跟踪当前的搜索情况,把PSO与BP算法相结合,可以提高网络的收敛速度,避免陷入局部极小值^[12]。

定义粒子的适应度函数如式(3)所示:

$$F = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^m (y_{ij} - t_{ij})^2 \quad (3)$$

式中, n 是训练样本的数目, m 是输出神经元个数; y_{ij} 是第 i 个样本的第 j 个输出节点的理想输出值; t_{ij} 是第 i 个样本的第 j 个输出节点的实际输出值。

微粒群优化BP网络的步骤如下。

①根据给定的训练样本集,确定神经网络的输入层、隐含层和输出层的节点数。本文根据表2数据设计网络的拓扑结构为5-8-3的3层BP网络;

②初始化粒子种群数目 N ,速度向量的维数 $D, D=$ 输入层至隐含层的连接权值个数+隐含层至输出层的连接权值个数+隐含层的阈值个数+输出层的阈值个数。惯性权重 ω ,加速常数 c_1, c_2 ;最大迭代代数,初始化BP网络权值和阈值为 $[0, 1]$ 之间的随机数;随机确定粒子的初始位置、速度矢量,范围控制在 $(0, 1)$ 之间。取每个粒子的 p_{best} 为初始位置, p_{best} 中的最好值为 g_{best} ;

③根据式(3)计算每个粒子的适应度函数值,如果该函数值好于粒子当前的最好位置的适应度值,则将其更新为该粒子个体最好位置。如果所有粒子中的最好位置的适应度值好于当前全局最好位置的适应度值,则将其更新为全局最好位置;

④按式(1)和式(2)对每个粒子的速度和位置进行更新,产生下一代的粒子群。检查粒子速度和位置是否越界,如果有越界,则排除越界后更新粒子的速度和位置;

⑤如果当前迭代次数达到预先设定的最大次数,则最后一次迭代的全局最优值 g_{best} 中每一维的权值和阈值就是所求的全局最优的权值和阈值;否则返回步骤③。

3 粗糙集及 PSO 优化 BP 网络用于柴油机故障诊断

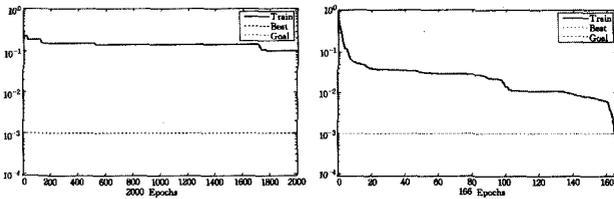


图1 BP算法训练误差曲线图

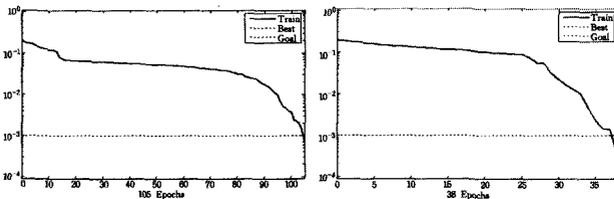


图2 GA-BP算法训练误差曲线图

图3 PSO-BP算法训练误差曲线图

图4 RS-PSO-BP算法训练误差曲线图

表3 3种算法预测误差比较

	样本一	样本二	样本三
期望输出	(0 0 1)	(0 1 0)	(1 0 0)
BP网络实际输出	(0.0007 0.9645)	(0.0000 0.0055)	(0.3030 0.4605)
GA-BP网络实际输出	(0.0021 0.0035 0.9676)	(0.0002 0.9961 0.0011)	(0.9701 0.0051 0.0025)
RS-PSO-BP网络实际输出	(0.0030 0.0000 0.9941)	(0.0000 0.9983 0.0000)	(0.9907 0.0009 0.0000)
BP网络误差	3.55%	1.25%	69.7%
GA-BP网络误差	3.24%	0.39%	2.99%
RS-PSO-BP网络误差	0.59%	0.17%	0.93%

选取表2中的前30组故障样本分别使用BP算法、GA-BP算法、PSO-BP算法和RS-PSO-BP算法对网络进行训练,试验中PSO算法的参数设定为:粒子种群数 $N=40$,惯性权重 $w=1$,加速常数 $c_1=c_2=2$,最大迭代次数取1500;遗传算法中的群体大小设为40,交叉率取0.6,采用单点交叉的浮点数编码方式,变异率取0.01,终止代数取300,网络的拓扑结构为5-8-3的3层BP神经网络,训练结果如图1—图4所示,

其中纵坐标为系统误差,横坐标为训练次数。从图中可以看出:RS-PSO-BP算法经过38次迭代,系统误差就达到了0.001,而GA-BP算法和PSO-BP算法分别经过166次和105次迭代系统误差才达到0.001。BP算法则陷入了局部最优,迭代了2000次,系统误差还未达到要求的精度。

选取表2的后3组故障样本分别对3种算法预测精度进行验证,并把诊断结果和实际故障进行比较,结果如表3所列。

结束语 从以上结果可以看出,与传统的BP算法和GA-BP算法相比,RS-PSO-BP算法简化了训练样本,优化了网络的结构,迭代次数少,收敛速度快,加快了神经网络的学习速度。

柴油机的诊断实例表明,该方法避免了BP网络易陷入局部最优的缺点,能使网络更快地收敛于最优解,同时能明显提高故障诊断的精度,且预报结果稳定,从而将在设备故障诊断领域里具有广泛的应用前景。

参考文献

- [1] 黄湘云,朱学峰,许建新.基于改进BP神经网络的传感器集成故障诊断[J].控制工程,2005,12(5):429-431
- [2] Rajakarunakaran S, Venkumar P, Devaraj D, et al. Artificial neural network approach for fault detection in rotary system [J]. Applied Soft Computing, 2008(8): 740-748
- [3] 沈红,胡玉兰,李雪梅.改进遗传算法优化的神经网络在智能故障诊断中的应用[J].机械设计与制造,2009(3):97-99
- [4] 王国胤.粗糙集理论与知识获取[M].西安:西安交通大学出版社,2001
- [5] 胡寿松,何亚群.粗糙决策理论与应用[M].北京:北京航空航天大学出版社,2006
- [6] Liu Sen, Chan F T S, Chung S H. A study of distribution center location based on the rough sets and interactive multi-objective fuzzy decision theory [J]. Robotics and Computer-Integrated Manufacturing, 2011(27): 426-433
- [7] 侯丽娟,王国胤.粗糙集理论中的离散化问题[J].计算机科学,2000,27(12):89-94
- [8] Kohonen T. The self-organizing map [J]. Neurocomputing, 1998, (21): 1-6
- [9] 谢川,倪世宏,张宗麟.基于粗糙集的飞行数据模式特征提取[J].计算机工程,2005,31(12):169-171
- [10] Kennedy J, Eberhart R C. Particle swarm optimization [A]// Proc. IEEE Int'l Conf. on Neural Networks [C]. Piscataway IEEE Service Center, 1995: 1942-1948
- [11] 高琳,孙海蓉,杨怀申.一种结合PSO及改进BP网络的辨识方法[J].计算机工程与应用,2010,46(21):36-39
- [12] 刘洪波,王秀坤,孟军.神经网络基于粒子群优化的学习算法研究[J].小型微型计算机系统,2005,26(4):638-640