

文章编号: 1000-8055(2009)02-0458-07

粒子群优化的粗糙集-神经网络在航空发动机故障诊断中的应用

杨海龙, 孙健国

(南京航空航天大学 能源与动力学院 南京 210016)

摘 要: 提出了一种基于粒子群优化算法的邻域粗糙集-神经网络的发动机智能故障诊断方法, 首先利用基于邻域粗糙集模型的属性约简方法对样本数据进行属性约简, 然后采用粒子群优化算法替代传统 BP 算法来训练神经网络的权值和阈值, 再用训练好的神经网络对航空发动机气路故障进行诊断. 仿真结果表明: 该方法降低了神经网络结构的复杂性, 减少了网络训练时间, 提高了诊断精度.

关 键 词: 粗糙集; 粒子群优化算法; 神经网络; 航空发动机; 故障诊断

中图分类号: V233.7

文献标识码: A

Application of PSO-based rough set theory and neural network to aeroengine fault diagnosis

YANG Hai-long, SUN Jian-guo

(College of Energy and Power Engineering,

Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: A new method based on neighborhood rough set model and neural networks (NN) integrated with particle swarm optimization (PSO) algorithm was presented in this paper for fault diagnosis of aeroengine. Firstly, using the algorithm of attribute reducing based on neighborhood rough set model, we deleted the unnecessary attributes from the decision table. Secondly, the PSO was used to train the weights and the thresholds of NN instead of BP algorithm. Therefore, The NN trained by PSO was applied to aeroengine fault diagnosis. The simulation results indicate that the method has shortened the training time and increased the diagnosis accuracy.

Key words: rough set; particle swarm optimization algorithm; neural networks; aeroengine; fault diagnosis

航空发动机是一个十分复杂的非线性研究对象, 其故障诊断难度较大. 随着计算机技术的发展, 促进了人工智能技术在故障诊断中的应用^[1], 也使基于神经网络的故障诊断技术得以迅速发展.

神经网络技术由于其具有自学习、非线性模

式识别、联想能力, 以及很强的泛函逼近能力, 因此在故障诊断中得到广泛应用^[2]. 其中 BP 算法是最普遍的神经网络训练算法. 但是, 实践证明, 该算法有收敛速度慢, 易陷入局部极小的问题^[3]. 此外, 神经网络对航空发动机故障进行定性诊断具有良好的效果, 但是将其运用于定量故障诊断

收稿日期: 2008-01-31; 修订日期: 2008-07-18

基金项目: 国家自然科学基金(50576033)

作者简介: 杨海龙(1981-), 男, 陕西绥德人, 硕士生, 主要从事航空发动机故障诊断研究.

就会出现需要输入量多和网络结构庞大的缺点^[4].

本文将粒子群优化算法和邻域粗糙集-神经网络结合起来,应用于航空发动机气路故障诊断中.该方法利用邻域粗糙集模型对网络的输入维数进行了约简,减少了网络输入的维数,简化了网络结构,而用 PSO 算法训练神经网络,可以避免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,使网络的收敛速度更快,提高该网络的诊断精度.

1 基于邻域粗糙集模型的属性约简算法

波兰学者 Pawlak 等人提出的粗糙集(Rough set,简称 RS)理论^[5]是用来研究不完整数据、不精确知识的表示、学习、归纳等问题的.该理论一个突出的优点是具有很强的定性分析能力,即不需要预先给定某些特征或属性的数量描述,如统计学中的概率分布、模糊集理论中的隶属度或隶属函数等,而是直接从给定问题的描述集合出发,通过不可分辨关系和不可分辨类确定问题的近似域,找出问题中的内在规律.但经典粗糙集理论定义在等价关系基础上,只能处理名义型数据,对数值型数据必须通过离散化后才能处理.连续数据经过离散化处理后可能会丢失重要信息,并且不同的离散化方法会影响处理效果^[6-7].所以,引入了邻域粗糙集模型^[8]来进行数值属性约简和分类器构造.该方法能直接处理数值型数据,与经典粗糙集方法相比,省去了对数据的离散化过程.

1.1 邻域粗糙集的性质分析

对于 $x_i \in U$,定义 x_i 的邻域为 $\delta_B(x_i) = \{x_j | x_j \in U, \Delta_B(x_i, x_j) \leq \delta\}$,其中 Δ 是一个距离函数.对于 $\forall x_1, x_2, x_3 \in U$, Δ 满足如下关系^[8]

$\Delta(x_1, x_2) \geq 0$, $\Delta(x_1, x_2) = 0$,当且仅当 $x_1 = x_2$;

$\Delta(x_1, x_2) = \Delta(x_2, x_1)$;

$\Delta(x_1, x_3) \leq \Delta(x_1, x_2) + \Delta(x_2, x_3)$.

对于 N 个属性的样本集,距离常用 P 范数表示为

$$\Delta_P(x_1, x_2) = \left(\sum_{i=1}^N |f(x_1, a_i) - f(x_2, a_i)|^P \right)^{1/P}$$

其中 $f(x_1, a_i)$ 为样本 x 在属性 a_i 上的取值.

$\Delta_P(x_1, x_2)$ 定义是对数值型属性集而言,但邻域模型很容易将距离计算扩展到含有符号和数

值型的数据上来.对于符号型属性 a_i ,可定义如下:

1) $|f(x_1, a_i) - f(x_2, a_i)| = 0$,若 x_1, x_2 在 a_i 上取值相同;

2) $|f(x_1, a_i) - f(x_2, a_i)| = 1$,若 x_1, x_2 在 a_i 上取值不同.

从而邻域粗糙集下近似、上近似、边界分别为

$$N_-(X) = \{x_i | \delta(x_i) \subseteq X, x_i \in U\}$$

$$N_+(X) = \{x_i | \delta(x_i) \cap X \neq \emptyset, x_i \in U\}$$

$$BN_B(X) = N_+(X) - N_-(X)$$

1.2 属性选择算法

定义 1. 给定邻域信息系统 $\langle U, A, D, f \rangle$, $B \subseteq A$, $\forall a \in B$,如果 $\gamma_{B-a}(D) < \gamma_B(D)$,则 a 相对于 B 而言是必不可少的,否则 $\gamma_{B-a}(D) = \gamma_B(D)$,称 a 是多余的.如果 $\forall a \in B$ 都是必不可少的,则 B 是独立的.

定义 2. 给定邻域决策系统 $\langle U, A, D, f \rangle$,称 $B \subseteq A$ 是 A 的一个约简,如果 B 满足

1) $\forall a \in B, \gamma_{B-a}(D) < \gamma_B(D)$;

2) $\gamma_B(D) = \gamma_B(D)$.

定义 3. 给定邻域决策系统 $\langle U, A, D, f \rangle$, $B \subseteq A$, $a \in A - B$,定义 a 相对于 B 的重要度为

$$\text{sig}(a, B, D) = \gamma_{B \cup a}(D) - \gamma_B(D)$$

基于属性重要度指标,可以构造贪心式属性约简算法.该算法以空集为起点,每次计算全部剩余属性的重要度,从中选择属性重要度值最大的属性加入约简集合中,直到所有剩余属性的重要度为 0,即加入任何新的属性,系统的依赖性函数值不再发生变化^[8].

输入:决策表 $\langle U, A, D, f \rangle$,其中 $A = \{a_1, a_2, \dots, a_n\}$, $C = \{c_1, c_2, \dots, c_r\}$, $D = \{d_1, d_2, \dots, d_i\}$.输出:属性约简子集 r .

步骤 1:初始化属性约简子集 r ,令 $r = \emptyset$;

步骤 2:对于任意 $a_i \in A - R$ 计算

$$\text{sig}(a_i, r, D) = \gamma_{B \cup a_i}(D) - \gamma_B(D);$$

步骤 3:选择 a_k ,满足条件如下:

$$\text{sig}(a_k, r, D) = \max_i(\text{sig}(a_i, r, B));$$

步骤 4:如果 $\text{sig}(a_k, r, D) > 0$,则 $r = r \cup a_k$,并跳至步骤 2,继续执行程序;

否则,返回属性子集 r ;

步骤 5:程序结束.

2 粒子群优化算法

粒子群优化算法(PSO)是一种进化计算技

术,是由 Kenney 与 Eberhart 于 1995 年提出^[9],源于对鸟群捕食行为的研究,是一种基于迭代的优化工具.目前已广泛应用于函数优化、神经网络训练、数据挖掘、模糊系统控制以及其他的应用领域.

粒子群优化算法的基本思想是,每个优化问题的潜在解都是搜索空间的粒子,所有的粒子都有一个被优化的函数决定的适应值,每个粒子还有一个速度向量决定他们飞翔的方向和距离,然后粒子们就追随当前的最优粒子在解空间中搜索. PSO 初始化为一群随机粒子(随机解),然后通过迭代找到最优解.在每一次迭代中,粒子通过跟踪两个“极值”来更新自己.一个是粒子本身所找到的最优解叫做个体极值 p_{best} ,另一个是整个种群目前找到的最优解,这个极值是全局极值 g_{best} .

在找到这两个最优值时,每个粒子根据如下公式来更新自己的速度和新的位置

$$V_{k+1} = wV_k + c_1 r_1 (g_{best,k} - x_k) + c_2 r_2 (p_{best,k} - x_k) \tag{1}$$

$$x_{k+1} = x_k + V_{k+1} \tag{2}$$

其中 v_k 是粒子的速度向量; x_k 是当前粒子的位置; $p_{best,k}$ 表示粒子本身所找到的最优解的位置; $g_{best,k}$ 表示整个种群目前找到的最优解的位置; w 是加权系数, c_1, c_2 表示群体认知系数,也被称作学习因子.通常, $c_1 = c_2 = 2$. r_1, r_2 一般介于 $(0,1)$ 之间的随机数.

粒子通过不断学习更新,最终飞至解空间中最优解所在的位置,搜索过程结束.最后输出的 g_{best} 就是全局最优解.在更新过程中,粒子每一维的最大速率被限制为 v_{max} ,粒子每一维的坐标也被限制在允许范围之内.图 1 为该粒子群优化算法流程图.

粒子群优化算法没有交叉与变异运算,所以算法结构简单,运行速度快.但是,基本粒子群优化算法在解空间内搜索时,有时会出现粒子在全局最优解附近“振荡”的现象,为了避免这个问题,可以作如下改进^[10]:随着迭代进行,速度更新公式中的加权因子 w 由最大加权因子 w_{max} 线性减小到最小加权因子 w_{min} .即

$$w = w_{max} - iter \times \frac{w_{max} - w_{min}}{iter_{max}} \tag{3}$$

其中 $iter$ 为当前迭代数,而 $iter_{max}$ 是总的迭代次数.




图 1 粒子群优化算法流程图

Fig.1 Flow chart of PSO

3 粒子群优化的 BP 网络

由于 BP 算法中用梯度下降法推导出的权值、阈值修正公式,这使得 BP 网络收敛速度慢、易陷入局部极小值.粒子群优化算法避免了梯度下降法中要求函数可微、对函数求导的过程;与遗传算法相比,PSO 保留了基于种群的全局搜索策略,但是其采用的速度 - 位移模型操作简单,避免了复杂的遗传操作(选择、交叉、变异).它特有的记忆使其可以动态跟踪当前的搜索情况.因此本文就用粒子群优化算法替代传统 BP 算法的梯度下降法^[11-12].

粒子的适应度函数可以由下式表示,其中: N 为训练集的样本数; $Y_{j,i}$ 为第 i 个样本的第 j 个网络输出节点的理想输出值; $y_{j,i}$ 为第 i 个样本的

第 j 个网络输出节点的实际输出值; c 为网络输出神经元的个数.

$$J = \frac{1}{N} \sum_i \sum_j^c (Y_{j,i} - y_{j,i})^2 \quad (4)$$

实现该算法的步骤如下:

1) 初始化 BP 网络结构, 设定网络的输入层、隐含层、输出层的神经元的个数.

2) 初始化粒子群及每个粒子的速度:

① 粒子种群数 N 、速度向量的维数 D , D = 输入层至隐层的连接权值个数 + 隐层至输出层的连接权值个数 + 隐层的阈值个数 + 输出层的阈值个数.

② 在初始化粒子群及每个粒子速度时, 先初始化一个二维矩阵 X , 前面 N 列表示粒子位置的各维, 后面 D .

列表示粒子速度的各维, 最后一列表示粒子的适应度.

3) 计算每个粒子的适应度:

① 先输入一个粒子, 对每一个样本而言, 都可以按 BP 网络的前向计算方法计算出一个网络的输出值, 然后计算其误差; 再按式 (4) 计算所有样本的均方差, 即该粒子的适应度.

② 返回到 ① 步骤, 继续输入其它粒子, 直至计算出所有粒子的适应度:

4) 比较适应度, 确定每个粒子的个体极值点和全局最优极值点:

若 $\text{Present} < P_{\text{best}}$, $P_{\text{best}} = \text{Present}$, $P_{\text{best}} = X_i$; 否则, P_{best} 不变;

若 $\text{Present} < g_{\text{best}}$, $g_{\text{best}} = \text{Present}$, $g_{\text{best}} = X_i$; 否则, g_{best} 不变.

其中 Present 为当前粒子的适应度, P_{best} 为粒子的个体极值, g_{best} 为全局最优值.

5) 更新每个粒子的位置和速度:

根据式 (1) 和式 (2) 更新粒子的位置和速度, 并且考虑更新后的位置和速度是否在限定的范围内.

考虑位置:

$X_{ij}(t+1) > X_{\max}$, 则 $X_{ij}(t+1) = X_{\max}$;

$X_{ij}(t+1) < X_{\min}$, 则 $X_{ij}(t+1) = X_{\min}$; 否则

$X_{ij}(t+1)$ 为式 (2) 结果.

考虑速度:

若 $V_{ij}(t+1) > V_{\max}$, $V_{ij}(t+1) = V_{\max}$;

若 $V_{ij}(t+1) < -V_{\max}$, $V_{ij}(t+1) = -V_{\max}$; 否则

$V_{ij}(t+1)$ 为式 (1) 结果.

其中 $X_{\max}$, $X_{\min}$, $V_{\max}$ 都是常数, 可以自己

设定.

6) 比较次数是否达到最大迭代次数和预设的精度. 若满足预设精度, 算法收敛, 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; 否则返回步骤 2), 算法继续迭代.

4 故障诊断原理

4.1 发动机故障诊断原理

发动机气路故障诊断的目的就是要得到发动机部件特性的衰退和故障情况. 对低压压气机、高压压气机、高压涡轮和低压涡轮这四大部件进行了性能监视. 一般情况下, 燃烧室的效率在使用中不易发生变化, 因此为简化起见, 不对其进行监视. 将 BP 网络应用于航空发动机故障诊断的方法是对发动机的稳态测量参数进行定量分析, 通过网络的映射能力可以将各个部件的故障程度诊断出来.

该系统的输入为发动机的测量参数. 由于客观条件的限制, 无法获得航空发动机的试车数据, 所以本文以某型发动机部件级模型为研究对象, 所有采集的数据均来自于该模型. 为了模拟发动机部件出现故障和性能衰退, 在模型的各部件相应性能参数上乘以一个故障系数 (0.95~1.00), 此时采集的数据为发动机出现故障时的测量数据. 即使发动机部件级模型的 8 个性能参数依次发生程度不同的下降, 来获得训练需要的学习样本. 例如: 风扇效率下降量 $\Delta\eta_{\text{fan}}$ 分别为 1%, 2%, 5%, 其它部件不出现性能下降时, 发动机模型计算出的测量参数值为学习样本的输入量. 同时样本的输出量 η_{fan} 对应的元素分别为: 0.99, 0.98, 0.95, 其他元素为 1.00. 依次类推, 得到其他故障的训练样本.

4.2 诊断结果和分析

以巡航状态的数据作为训练样本, 取 $H = 11 \sim 12$ km, $Ma = 0.8 \sim 0.9$, $PLA = 30 \sim 50$ 共 4536 组数据. 其中各部件的效率和流量依次从 1.0 下降至 0.95. 在进行邻域粗糙集处理之前, 将条件属性中的可测量参数标准化到 [0 1] 区间, 以减少因各属性量纲不一致或数值相差太大对结果的影响. 样本中共有 10 个条件属性 ($S_1 \sim S_{10}$), D 为决策属性. 这 10 个条件属性为发动机的可测量参数, 而且发动机各个部件的故障与其有紧密联系. 各条件属性的含义如表 1 所示, 表 2 为决策属性

含义.

利用邻域粗糙集模型对标准化后的训练样本进行属性约简.当邻域阈值取值较小,约简算法得到的属性特征较少,但是相应的分类精度也较低;当邻域阈值取值较大时,约简算法得到的属性特征较多,约简效果不明显.经过反复测试并比较约简结果,邻域阈值 δ 选为 0.15 效果最好,即邻域的直径为 0.3 时无量纲最终得到约简后的属性为 $PNF, PNC, P_{22}, T_{42}, T_{46}, p_{46}$ 共 6 个条件属性,即网络的 6 个输入.图 2 为训练样本未进行属性约简前的训练曲线,其中纵坐标为训练目标误差精度,横坐标为训练步数.图 3 为利用邻域粗糙集属性约简算法对训练样本进行处理后的训练曲线.表 3 为属性约简前后的故障诊断系统的诊断结果比较.

表 1 条件属性含义
Table 1 Condition attribute

序 号	条件属性内容
S_1	PNF :高压转子转速
S_2	PNC :低压转子转速
S_3	T_{22} :风扇出口总温
S_4	p_{22} :风扇出口总压
S_5	T_3 :压气机出口总温
S_6	p_3 :压气机出口总压
S_7	T_{42} :高压涡轮出口总温
S_8	p_{42} :高压涡轮出口总压
S_9	T_{46} :低压涡轮出口总温
S_{10}	p_{46} :低压涡轮出口总压

表 2 决策属性含义
Table 2 Decision attribute

序号	决策属性内容
$D_1(0\ 0\ 0\ 0)$	无故障
$D_2(1\ 0\ 0\ 0)$	风扇故障
$D_3(0\ 1\ 0\ 0)$	压气机故障
$D_4(0\ 0\ 1\ 0)$	高压涡轮故障
$D_5(0\ 0\ 0\ 1)$	低压涡轮故障

表 3 故障诊断结果比较
Table 3 Comparison of diagnosis results

	属性集	训练步数	诊断准确度/ %
属性约简前	$S_1 \sim S_{10}$	921	100
属性约简后	$S_1, S_2, S_4, S_7, S_9, S_{10}$	49	100




图 2 原始数据的网络训练曲线图
Fig. 2 Training curve by original data




图 3 约简属性后的网络训练曲线图
Fig. 3 Training curve by reduced data

从表 3 及图 2 中可以看出,未进行粗糙集处理的样本需属性个数为 10 个,神经网络训练步数为 921,实际所耗时间也很长;利用邻域粗糙集模型属性约简算法处理后的样本数据,属性个数减到 6 个,减少了发动机可测参数的采集量,降低了采集数据的难度,同时神经网络训练步数只有 49,得到大幅度的减少,训练时间相应缩短了很多,而且该系统的诊断准确度仍为 100 %,说明诊断准确度没有受到属性约简的影响.

为了实现定量诊断发动机故障,本文将粒子群优化算法引入邻域粗糙集-神经网络.将风扇部件作为故障诊断对象,神经网络的输出量是反映发动机性能的参数,分别为: e_{fan} , e_{hcm} ,共 2 个,其含义分别为风扇效率和风扇流量系数.邻域粗糙集-神经网络的拓扑结构为 6-13-2,该网络的训练曲线如图 4 所示.定义粒子群规模为 40, $c1 = c2 = 2$,最大速度 v_{max} 为 5,粒子位置的最大值为 1,最小值为 -1. $w_{max} = 0.9$, $w_{min} = 0.3$.最大迭代次数 $iter_{max} = 2000$,预设误差为 10^{-8} .图 5 为粒子群优化后的邻域粗糙集-神经网络网络的训练曲线.其中纵坐标为训练目标误差精度,横坐标为训练步数.




图 4 邻域粗糙集-神经网络训练曲线

Fig. 4 Training curve of rough set network




图 5 粒子群优化后的邻域粗糙-神经网络训练曲线

Fig. 5 Training curve of the network optimized by PSO

将图 4 与图 5 比较,粒子群优化后的邻域粗糙集-神经网络比邻域粗糙集-神经网络收敛误差小很多,前者训练步数为 2 000 步时误差为 10^{-5} ,而后者训练 963 步后误差就减小到了 10^{-8} ;粒子群优化后的邻域粗糙集-神经网络比邻域粗糙集-神经网络的收敛速度快很多,所需

的训练步数少得多.

随机用训练样本以外的 20 个样本作为测试样本对两种算法的网络进行测试,两种算法的诊断误差如表 4 所示.

从表 4 的数据中可以看出,用邻域粗糙集-神经网络进行测试时,诊断平均误差为 1.72%,而粒子群优化后的邻域粗糙集-神经网络的诊断平均误差为 0.12%,前者的诊断误差比后者大很多.因此,基于粒子群优化的邻域粗糙集-神经网络的诊断精度高于邻域粗糙集-神经网络.

表 4 两种算法的误差比较

Table 4 Errors of two algorithms

算法名称	e_{fan} 最大 误差/ %	w_{a22} 最大 误差/ %	平均 误差/ %
邻域粗糙集-神经网络	1.85	2.24	1.72
粒子群优化后的邻域粗糙集-神经网络	0.15	0.27	0.12

5 结 论

本文首先将邻域粗糙集与神经网络结合起来,应用于航空发动机定性气路故障诊断中.并将该方法与常规 BP 网络进行了比较.然后在邻域粗糙集-神经网络的基础上引入了粒子群优化算法,对航空发动机进行了定量故障诊断.该方法与邻域粗糙集-神经网络也进行了比较.通过实验结果,本文得出如下结论:

- 1) 将邻域粗糙集与神经网络结合起来应用于定性故障诊断,对特征参数进行了属性约简,简化了训练样本和神经网络结构,在保障诊断准确度不变的前提下加快了神经网络的学习速度.
- 2) 将基于粒子群优化算法的邻域粗糙集-神经网络应用于航空发动机定量故障诊断中,取得了良好的效果.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.

参考文献:

[1] Lu P J, Zhang M C, Hsu T C, et al. An evaluation of engine faults diagnostics using artificial neural networks [J]. Journal of Engineering for Gas Turbines and Power, 2001, 123(2), 340-360.

- [2] Sampath S, Gulati A, Singh R. Artificial intelligence techniques for gas turbine engine fault diagnostics[R]. 38th AIAA/ ASME/ SAE/ ASEE Joint Propulsion Conference & Exhibit, 2002, Indianapolis: AIAA, 2002-4308.
- [3] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back propagating errors[J]. Nature, 1986, 323: 533-536.
- [4] 郝英, 孙健国, 白杰. 航空燃气涡轮发动机气路故障诊断现状与展望[J]. 航空动力学报, 2003, 18(6): 753-760.
HAO Ying, SUN Jianguo, BAI Jie. State-of-the-art and prospect of aircraft engine fault diagnosis using gas path parameters[J]. Journal of Aerospace Power, 2003, 18(6): 753-760. (in Chinese)
- [5] Pawlak Z. Rough Set[J]. International Journal of Information and Computer Sciences, 1982, 11: 341-356.
- [6] 谢宏, 程浩忠, 牛东晓. 基于信息熵的粗糙集连续属性离散化算法[J]. 计算机学报, 2005, 28(9): 1570-1574.
XIE Hong, CHENG Haozhong, NIU Dongxiao. Discretization of continuous attributes in rough set theory based on information entropy[J]. Chinese Journal of Computers, 2005, 28(9): 1570-1574. (in Chinese)
- [7] 陈恬, 孙健国. 粗糙集与神经网络在航空发动机气路故障诊断中的应用[J]. 航空动力学报, 2006, 21(1): 207-212.
CHEN Tian, SUN Jianguo. Aeroengine gas path fault diagnosis using rough sets and neural networks[J]. Journal of Aerospace Power, 2006, 21(1): 207-212. (in Chinese)
- [8] HU Qinghua, YU Daren, XIE Zongxia. Neighborhood classifiers[J]. Expert System with Applications, 2008, 34(2): 866-876.
- [9] Kennedy J, Eberhart R C. Particle swarm optimization[R]. Proceedings of IEEE International Conference on Neural Networks, Perth, Australia, 1995: 1942-1948.
- [10] Kennedy J, Eberhart R C, Shi Y. Swarm intelligence[M]. San Francisco: Morgan Kaufman Publishers, 2001.
- [11] 潘昊, 侯清兰. 基于粒子群优化算法的 BP 网络学习研究[J]. 计算机工程与应用, 2006, 42(16): 41-44.
PAN Hao, HOU Qianlan. A BP neural networks learning algorithm research based on particle swarm optimizer[J]. Computer Engineering and Applications, 2006, 42(16): 41-44. (in Chinese)
- [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.
LIU Hongbo, WANG Xiukun, MENG Jun. Neural network training algorithm based on particle swarm optimization[J]. Journal of Chinese Computer Systems, 2005, 26(4): 638-640. (in Chinese)