

文章编号: 1001-0920(2013)12-1884-05

基于 EPSO-BP 的 Elman 网络及其在飞行轨迹预测中的应用

王俭臣^a, 齐晓慧^a, 单甘霖^b

(军械工程学院 a. 无人机工程系, b. 电子与光学工程系, 石家庄 050003)

摘要: 针对 BP 训练方式采用梯度法易导致局部收敛的不足, 提出一种融合进食粒子群算法 (EPSO) 和梯度法的 Elman 网络优化方法. 首先, 通过模拟鸟群进食行为得到一种 EPSO 算法, 以改善标准 PSO 的全局性能; 然后, 将 EPSO 用于 Elman 网络权值的全局优化, 同时将梯度法用于 EPSO 的进食过程局部搜索, 以提高解的局部收敛性能; 最后, 将该网络优化方法用于飞行轨迹预测实验, 仿真结果表明了其有效性.

关键词: Elman 网络; 融合方法; 进食过程; 轨迹预测

中图分类号: TP18

文献标志码: A

Elman network based on EPSO-BP and its application in flight trajectory prediction

WANG Jian-chen^a, QI Xiao-hui^a, SHAN Gan-lin^b

(a. Department of Unmanned Plane Engineering, b. Department of Electronics and Optics Engineering, Ordnance Engineering College, Shijiazhuang 050003, China. Correspondent: WANG Jian-chen, E-mail: lichen197@163.com)

Abstract: To overcome the local convergence shortcoming of the gradient method used by the BP approach in the Elman network training process, a combined training method of the exhaustion particle swarm optimization (EPSO) and gradient method is built. An enhanced PSO algorithm (EPSO), which has better global property, is proposed by simulating feeding behavior of birds. Then, the EPSO algorithm is applied to optimizing Elman network weights across the whole solution space, and the gradient method is used in the exhaustion process of EPSO to improve the local convergence property. Finally, the proposed training method is applied to flight trajectory prediction experiment, and simulation results show the effectiveness of this method.

Key words: Elman network; combined method; exhaustion process; trajectory prediction

0 引言

非线性系统辨识是控制理论研究的一个重要分支, 特别适用于不确定性、高度复杂的动态系统. 神经网络具有很强的非线性拟合能力, 是解决非线性、时变等复杂系统辨识问题的有力工具^[1-2]. 但是, 神经网络应用的一个难点是缺乏工程化的设计原则, 其网络结构和权值的优化问题一直备受关注. 针对网络权值的优化问题, 传统基于梯度法的 BP 算法虽然搜索效率高, 但对初始值依赖大且不具备全局搜索能力^[3]. 近年来, 由于粒子群算法 (PSO) 具有全局性好并且操作简单等优点, 在神经网络权值优化问题中得到了广泛应用^[4-5], 但 PSO 也存在易陷入局部最优和后期搜索速度慢等缺陷.

为避免陷入局部最优, 文献 [5-7] 分别利用变异、

克隆以及多种群竞争来改善粒子种群多样性, 但算法后期收敛速度慢的问题仍没有得到改善. 针对算法后期收敛速度慢的不足, 文献 [8] 将单纯形法作为局部搜索器用于 PSO 后期收敛过程, 提高了后期收敛速度和精度, 但对于复杂多极值问题仍不能保证获得全局最优. 为兼顾全局收敛性和局部搜索性能, 本文首先通过模拟鸟群进食行为, 提出一种全局性的进食粒子群算法 (EPSO), 并将传统梯度法作为局部搜索器用于 EPSO 的进食过程, 从而得到一种混合优化方法; 然后给出利用该方法的 Elman 网络权值优化过程; 最后, 将所提出的方法用于无人机飞行轨迹预测实验, 其结果表明了所提出方法的有效性.

1 引入进食过程的 EPSO 算法

粒子群算法 (PSO) 是由 Eberhart 等^[9]提出的一种

收稿日期: 2012-08-28; 修回日期: 2013-01-31.

基金项目: 国防预研基金项目(513270203); 武器装备预研重点基金项目(9140A27020211JB3402).

作者简介: 王俭臣(1987—), 男, 博士生, 从事系统辨识、故障诊断的研究; 齐晓慧(1962—), 女, 教授, 博士生导师, 从事最优化理论、智能控制等研究.

群智能优化技术,其基本思想源于鸟群觅食行为.大量实践表明,PSO 算法初期,种群过早地向当前的最优粒子聚集,没有对整个解空间进行充分搜索,从而使算法易陷入局部最优,出现早熟现象.文献[5]通过引入变异操作使 PSO 种群跳出局部最优,改善了搜索的全局性,但通过个别粒子的随机性变异使算法跳出局部最优的效率较低,这是因为变异粒子需要较长的进化时间才能找到比当前局部最优更好的解,而大量粒子的变异又容易造成算法不稳定.

1.1 优化策略

考虑到自然界鸟群“觅食-进食-再觅食”整个觅食过程,提出一种具有进食过程的进食粒子群算法(EPSO).其基本思想是:鸟群觅食一定时间后,将会找到一个局部最优的食物源;此后一定时间内,若鸟群不能发现更好的食物源,则当前最优食物源附近的小鸟将进食该食物源,以便为继续觅食补充体力;进食完毕后,小鸟将快速飞离当前位置并继续觅食;同时,被进食过的最优食物源将不再是最优的.

EPSO 算法引入的几个名词定义如下:

1) 决策(徘徊)时间 T . 表示种群在当前最优食物源附近搜索的最大时间.若 T 时间后仍找不到更好的食物源,则食物源附近一定比例的粒子(小鸟)将进食该食物源.

2) 进食过程. 进食过程中,整个种群包含两个子群,即进食群和非进食群.两子群按照更新规则独立搜索,即最优解 p_g 在各自群内查找,以避免非进食群个体继续朝最优食物源方向移动,以保证种群多样性.

3) 进食速率 α . 表示进食过程中,当前最优食物源在一次迭代时间内被进食的速率,其取值范围为 $(0, 1)$. 最优食物源的食物量用最优粒子 p_g 的适应度值 f_g 表示.经 k 步进食后,剩余食物量为

$$f = \alpha^k f_g, k \leq K. \quad (1)$$

其中: k 为当前进食时间, K 为最大进食时间.

4) 二次飞行. 进食完毕后,进食粒子将具有新的飞行速度 v_r . 为保证进食粒子能够飞离局部最优,取 v_r 与进食群的分布范围相关,即

$$v_r = 10 \text{rand} \cdot (p_g - p_{\text{fst}}). \quad (2)$$

其中: rand 为方向随机的单位向量, p_{fst} 为进食群中离 p_g 最远的粒子. 需要注意, p_g 和进食粒子的个体最优 p_{id} 也要在二次飞行后进行更新.

5) 记忆库. 局部最优食物源被进食后,将其位置信息及进食后的适应度值放入记忆库.若此后某些粒子飞入记忆库内的某个位置,则此粒子的适应度将被赋值为该位置被进食后的适应度值,以表示该位置食物量的减少,从而有效避免重复搜索.

1.2 EPSO 算法流程

EPSO 算法流程如图 1 所示.

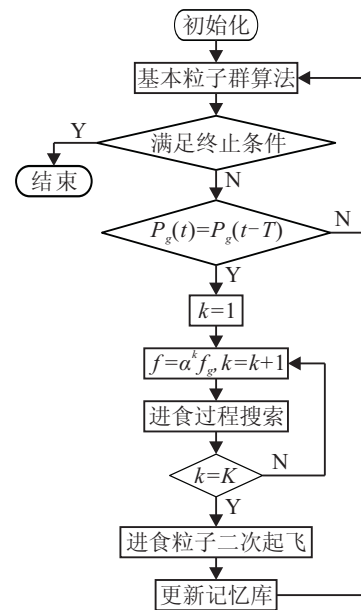


图 1 EPSO 算法流程

算法的具体流程描述如下.

Step 1: 初始化粒子种群及算法参数.

Step 2: 更新粒子位置及速度,并判断是否满足终止条件,若满足,则算法结束.

Step 3: 判断当前全局最优 p_g 是否等于 T 步前的 p_g ,若是,则执行 Step 4,否则返回 Step 2.

Step 4: 执行进食过程搜索.

Step 4.1: 初始化进食迭代步数 $k = 1$,并按一定比例将种群划分为进食群和非进食群;

Step 4.2: 根据式(1)计算剩余食物量(适应度值);

Step 4.3: 进食群和非进食群分别在各自群内按照更新规则独立搜索.

Step 4.4: $k = k + 1$,判断 k 是否等于 K ,若是,则进食结束,执行 Step 5,否则返回 Step 4.2.

Step 5: 按式(2)给进食粒子赋予新的速度,然后更新种群的全局最优和个体最优.

Step 6: 更新记忆库,返回 Step 2.

2 融合 EPSO 和梯度法的连续优化方法

PSO 算法后期,大量粒子向最优粒子附近聚集,由粒子更新公式可知^[9],此时粒子速度趋近于零.大量粒子的低速搜索直接影响了整个种群的收敛速度.

针对连续优化问题,传统的梯度法采用沿梯度方向“爬山”的思想,具有良好的局部收敛速度和精度.假设优化问题的目标函数 $f(\mathbf{x})$ 为一阶连续可微,根据一阶泰勒展开公式,将 $f(\mathbf{x} + \alpha \mathbf{d})$ 在点 \mathbf{x}_0 处写成如下形式:

$$f(\mathbf{x}_0 + \alpha \mathbf{d}) = f(\mathbf{x}_0) + \alpha \nabla f(\mathbf{x}_0)^T \mathbf{d} + o(\|\alpha \mathbf{d}\|). \quad (3)$$

其中: \mathbf{d} 为单位向量; α 为一个小值, 称为步长因子; $\nabla f(\mathbf{x}_0)$ 为 $f(\mathbf{x})$ 在 \mathbf{x}_0 处的梯度.

将梯度法用于 EPSO 的进食种群搜索过程, 从而形成一种混合优化方法, 具体步骤如下.

Step 1: 采用 EPSO 找到局部最优解 P_{pg} .

Step 2: 执行进食过程. 与 1.2 节不同之处在于进食种群改用梯度法搜索, 即以 P_{pg} 为初始值, 采用梯度法进一步搜索, 以获得更好的局部最优解 P_g .

Step 3: 同 1.2 节 Step 5, 给进食粒子赋予新的速度, 并更新全局最优和个体最优.

Step 4: 更新记忆库. 以 P_g 为中心, $|P_g - P_{pg}|$ 为半径, 将其位置和适应度信息加入记忆库, 返回 Step 1.

3 Elman 网络及训练方法

3.1 Elman 网络简介

Elman 网络是一种多层动态神经网络^[10], 由于其动态递归的结构特点, 该网络具有良好的非线性动态辨识能力^[11].

假设 Elman 网络的输入为 \mathbf{x} , 输出为 \mathbf{y} , 承接层状态向量为 \mathbf{x}_c , 隐含层输出向量为 \mathbf{z} , 则根据 Elman 网络结构^[10], 有如下非线性空间表达式:

$$\begin{cases} \mathbf{x}_c(k+1) = \mathbf{z}(k), \\ \mathbf{z}(k+1) = f(\mathbf{w}^1 \mathbf{x}(k) + \mathbf{w}^r \mathbf{x}_c(k)), \\ \mathbf{y}(k+1) = g(\mathbf{w}^2 \mathbf{z}(k+1)). \end{cases} \quad (4)$$

其中: \mathbf{w}^1 、 \mathbf{w}^2 、 \mathbf{w}^r 分别代表输入层-隐含层、隐含层-输出层、隐含层-承接层的连接权值, 一般取 $f(\cdot)$ 为 Sigmoid 函数, $g(\cdot)$ 为线性求和函数.

3.2 网络训练

假设训练样本为 $\{\mathbf{x}(k), \tilde{\mathbf{y}}(k)\}$, $k = 1, 2, \dots, n$, 令向量 $\mathbf{w}^1 = [\mathbf{w}^1, \mathbf{w}^r]$, $\mathbf{x} = [\mathbf{x}, \mathbf{x}_c]$. 在增量式学习的情况下, 若采用误差平方和(误差能量)作为目标函数, 则样本 $\mathbf{x}(k)$ 对应的网络误差函数为

$$E = \frac{1}{2} [g(\mathbf{w}^2 f(\mathbf{w}^1 \mathbf{x}(k))) - \tilde{\mathbf{y}}(k)]^2. \quad (5)$$

对于一个新设计的 Elman 网络, 由于网络参数的任意设置, 网络误差会很大. 网络训练的目的是找到一组最优的 $\mathbf{w}^* = [\mathbf{w}^{1*}, \mathbf{w}^{r*}, \mathbf{w}^{2*}]$, 使得

$$E(\mathbf{w}^*) = \min E(\mathbf{w}). \quad (6)$$

因此, Elman 网络的训练本质上是网络参数的优化.

将本文所提出的混合优化方法用于 Elman 网络训练问题, 其训练过程包括基于 EPSO 的全局优化和基于梯度法的局部优化.

3.2.1 基于 EPSO 的训练方法

首先应明确 Elman 网络参数优化问题的维数, 以产生一定规模而且维数合理的粒子种群. 对于结构为 N - M - L 的 Elman 网络, 其待优化参数包含如下几部

分: $\mathbf{w}^{1(N \times M)}$, $\mathbf{w}^{2(M \times L)}$, $\mathbf{w}^r(M \times M)$ 及隐含层和输出层阈值向量 $\mathbf{b}^{1(M \times 1)}$ 和 $\mathbf{b}^{2(L \times 1)}$.

由于以上参数向量之间维数不统一, 为了操作方便, 设置种群粒子的位置属性包含两部分, 即

$$\mathbf{P}(i) = \{\mathbf{P}_1(i)^{(M \times (N+M+L+1))}, \mathbf{P}_2(i)^{(L \times 1)}\}. \quad (7)$$

其中: i 为粒子编号; $\mathbf{P}_1(i)^{(M \times (N+M+L+1))} = [(\mathbf{w}^1)^T, \mathbf{w}^2, \mathbf{w}^r, \mathbf{b}^1]$; $\mathbf{P}_2(i)^{(L \times 1)} = \mathbf{b}^2$. 由粒子群算法可知, 粒子速度属性的维数与位置属性保持一致.

对于种群中的任意粒子, 将其位置属性所包含的 Elman 网络参数代入式(5)即可求得相应的目标函数 E . 注意到网络训练的目的是使目标函数 E 达到最小, 而混合优化方法的搜索方向是使目标函数最大, 因此采用 $-E$ 作为优化问题的目标函数.

3.2.2 基于梯度法的训练方法

基于梯度下降法的网络训练就是利用误差梯度去减小网络误差, 这里的误差梯度是指目标函数平面 E 的斜率, 它反映了 E 对网络参数的灵敏度. 同样, 若取 $-E$ 作为目标函数, 则梯度下降法变为梯度爬山法.

仍假设 Elman 的网络结构为 N - M - L , 根据链式规则, 将 $-E$ 分别对权值 \mathbf{w}^1 , \mathbf{w}^2 , \mathbf{w}^r 求偏导数, 可得到网络权值的修正量为

$$\begin{aligned} \Delta \mathbf{w}_{ml}^2 &= \\ -\varepsilon_2 \frac{\partial E(k)}{\partial \mathbf{w}_{ml}^2} &= -\varepsilon_2 \frac{\partial E(k)}{\partial y_l(k)} \frac{\partial y_l(k)}{\partial \mathbf{w}_{ml}^2} = \\ -\varepsilon_2 (y_l(k) - \tilde{y}_l(k)) g'_l(z_m(k)), \end{aligned} \quad (8)$$

$$\begin{aligned} \Delta \mathbf{w}_{hm}^r &= \\ -\varepsilon_r \frac{\partial E(k)}{\partial \mathbf{w}_{hm}^r} &= -\varepsilon_r \frac{\partial E(k)}{\partial y(k)} \frac{\partial y(k)}{\partial z_m(k)} \frac{\partial z_m(k)}{\partial \mathbf{w}_{hm}^r} = \\ -\varepsilon_r \sum_{l=1}^L (y_l(k) - \tilde{y}_l(k)) \mathbf{w}_{ml}^2 g'_l(z_m(k)) f'_m(z_m(k-1)), \end{aligned} \quad (9)$$

$$\begin{aligned} \Delta \mathbf{w}_{nm}^1 &= \\ -\varepsilon_1 \frac{\partial E(k)}{\partial \mathbf{w}_{nm}^1} &= -\varepsilon_1 \frac{\partial E(k)}{\partial y(k)} \frac{\partial y(k)}{\partial z_m(k)} \frac{\partial z_m(k)}{\partial \mathbf{w}_{nm}^1} = \\ -\varepsilon_1 \sum_{l=1}^L (y_l(k) - \tilde{y}_l(k)) g'_n(z(k)) f'_n(x_n(k)). \end{aligned} \quad (10)$$

其中: $\varepsilon_1, \varepsilon_2, \varepsilon_r$ 分别为 $\mathbf{w}^1, \mathbf{w}^2, \mathbf{w}^r$ 的学习率; $n = 1, 2, \dots, N, m = 1, 2, \dots, M, l = 1, 2, \dots, L, h = 1, 2, \dots, M$. 通过求解权值修正量, 新的网络权值可表示为

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \Delta \mathbf{w}(k). \quad (11)$$

4 仿真实验及分析

无人机是典型的复杂非线性系统. 若采用模型方法对其飞行控制性能进行解析研究, 通常需要对模型进行线性化处理, 甚至将无人机的运动分解为互不耦

合的纵向和横侧向运动. 这些近似处理降低了所建模型与实际系统的一致性. 相反, 采用系统辨识的方法可以得到与实际系统更为一致的系统模型.

以某型无人机回收过程为研究对象进行飞行轨迹预测实验. 首先, 利用该型无人机飞行试验数据, 采用曲线插值方法得到无人机建模所需的气动系数. 在此基础上, 建立无人机机体坐标系下的动力学和运动学方程; 然后, 利用 Matlab/Simulink 中的 Aerospace Blockset 工具箱及部分自定义模块, 搭建所研究对象的非线性仿真模型.

4.1 飞行仿真实验

仿真时采用降落跑道上某点为坐标原点, 以原点至无人机回收点在地平面投影点的连线为 x 轴, 建立类大地坐标系. 设置无人机初始高度为 3000 m, 初始迎角为 0.1143 rad, 初始速度为 $200[\cos \alpha_0; 0; \sin \alpha_0]$ m/s, 初始角速度为 0 rad/s, 初始欧拉角为 $[0; -0.2; 0]$. 在不考虑风场扰动条件下, 仿真模型的输入激励分别是无人机升降舵偏转角 δ_e 、方向舵偏转角 δ_r 及发动机推力 δ_T , 均采用伪随机信号形式. 由于回收过程中无人机的机动强度不大, 设置合理的输入激励变化范围分别为 $\delta_e \in [15, 20]$, $\delta_r \in [-3, 3]$, $\delta_T \in [0, 10]$. 仿真得到不同的无人机飞行轨迹如图 2 所示.




图 2 不同飞行轨迹

4.2 轨迹预测实验及分析

通过飞行仿真实验得到 28 条飞行轨迹. 将所得仿真数据归一化到 $[-1, 1]$, 并以其中 20 条轨迹作为训练样本, 其余 8 条作为测试样本.

将 Elman 网络辨识方法用于飞行轨迹预测实验, 网络的输入是当前的控制输入和当前无人机的位置, 输出为下一时刻的无人机位置. 根据样本的输入输出维数确定网络的结构为 6-4-3.

分别采用梯度法、变异粒子群 (MPSO) 和本文混合优化方法训练 Elman 网络 (依次简称为 Grads_Elman、MPSO_Elman、EG_Elman), 并用于飞行轨迹预测. 采用梯度法训练时, 权值学习率 $\varepsilon_1, \varepsilon_2, \varepsilon_r$ 均设为 0.05, 最大迭代次数为 400; 采用 MPSO 和 EPSO 训练时, 粒子群规模均设为 500, 网络权值的搜索区间为 $[-5, 5]$, 最大迭代次数为 400, 加速因子 c_1, c_2 均取 2,

惯性系数 ω 采用从 0.9 线性下降至 0.4. 此外, MPSO 中的变异概率取 0.01, EPSO 中的决策时间 T 取 15, 进食群规模占整个种群的比例为 0.25, 进食速率 α 取 0.9, 进食时间 K 取 5.

采用以上方法所得到的网路训练误差进化曲线如图 3 所示. 此外, 为比较 Elman 与 BP 网络的性能, 同时采用 Grads_BP 方法训练神经网络.






图 3 训练误差进化曲线

由图 3 可以看出: Grads_Elman 方法的最终训练误差小于 Grads_BP 方法, 体现了 Elman 网络在动态系统辨识中的优势; MPSO_Elman 方法的训练结果显示, 单纯采用粒子群算法所获得的搜索精度还不及传统的梯度法; 采用 EG_Elman 方法获得的训练误差小于其他 3 种方法, 表明该方法既保持了粒子群算法的全局搜索能力, 又兼顾了梯度法搜索精度高的特性. 另外, 在 EG_Elman 方法的进化曲线中, 迭代步数为 105 和 234 时, 算法通过进食粒子的二次飞行跳出了局部最优. 此时, 当前最优解虽然出现了“反弹”, 但通过改变种群中当前最优解的位置, 有效避免了其余粒子继续朝局部最优移动, 从而防止了早熟现象.



(a) Grads_BP 与 MPSO_Elman 的测试误差曲线



(b) Grads_Elman 与 EG_Elman 的测试误差曲线

图 4 测试误差曲线

为验证网络的泛化性能,将测试样本输入训练后的神经网络,测试结果如图4所示.由图4可以看出,EG-Elman也具有最小的测试误差.

需要指出,由于PSO并行计算的特点,在相同的迭代步数时,EPSO-Elman和MPSO-Elman方法的实时性比梯度法差,而且随着优化问题维数和种群规模的增加,实时性的差距会更明显.另一方面,由于在EPSO算法中引入了进食过程,增加了算法复杂性,也在一定程度上影响了算法实时性.因此,文中所用神经网络均采用离线训练方式.将进食行为用于具有快速收敛性能的PSO算法,以提高算法实时性,是后续研究要解决的问题.

5 结 论

本文通过模拟自然界鸟群“觅食-进食-再觅食”过程,提出了一种EPSO算法.将该算法与梯度法相结合得到一种混合优化方法,并将其用于Elman网络权值优化问题.最后,将所提出的方法用于无人机轨迹预测实验,结果表明该方法既保持了梯度法的局部精细搜索特性,又增强了对最优权值的全局搜索能力.

参考文献(References)

- [1] 于开平, 牟晓明. 基于前向神经网络的非线性时变系统辨识改进EKF算法[J]. 振动与冲击, 2010, 29(8): 5-8.
(Yu K P, Mou X M. Improved EKF algorithm for nonlinear time-varying system identification based on feed forward neural network[J]. J of Vibration and Shock, 2010, 29(8): 5-8.)
- [2] Bidyadhar S, Debashisha J. A differential evolution based neural network approach to nonlinear system identification[J]. Applied Soft Computing, 2011, 11: 861-871.
- [3] Rumelhard D E, Hinton G E, Willianms R J. Learning representations by back-propagation errors[J]. Nature, 1986, 323: 533-536.
- [4] Masoud F, Mohammad R R, Mahdi M, et al. The selection of milling parameters by the PSO-based neural network modeling method[J]. The Int J of Advanced Manufacturing Technology, 2011, 57: 49-60.
- [5] 甘旭升, 端木京顺, 孟月波, 等. 基于粒子群优化的WNN飞行数据气动力建模[J]. 航空学报, 2012, 33(7): 1209-1217.
(Gan X S, DuanMu J S, Meng Y B, et al. Aerodynamic modeling from flight data based on WNN optimized by particle swarm[J]. Acta Aeronautica et Astronautica Sinica, 2012, 33(7): 1209-1217.)
- [6] 王巧灵, 高晓智, 王常虹, 等. 基于克隆选择和粒子群思想的动态多群体优化算法[J]. 控制与决策, 2008, 23(9): 1073-1076.
(Wang Q L, Gao X Z, Wang C H, et al. Dynamic multi-swarm optimization based on clonal selection and particle swarm[J]. Control and Decision, 2008, 23(9): 1073-1076.)
- [7] Zhao S Z, Liang J J, Suganthan P N, et al. Dynamic multi-swarm particle swarm optimizer with local search for large scale global optimization[C]. Proc of 2008 IEEE Congress on Evolutionary Computation. Hong Kong: IEEE Press, 2008: 3845-3852.
- [8] 朱奇光, 王洪瑞, 陈颖. 基于IC-PSO和ISM的反馈控制算法设计[J]. 光电子·激光, 2010, 21(7): 1007-1012.
(Zhu Q G, Wang H R, Chen Y. Design of feedback control algorithm based on IC-PSO and ISM[J]. J of Optoelectronics · Laser, 2010, 21(7): 1007-1012.)
- [9] Eberhart R C, Kennedy J. A new optimizer using particle swarm theory[C]. Proc of the 6th Int Symposium on Micro Machine and Human Science. Piscataway: IEEE, 1995: 39-43.
- [10] Sandhya S. 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, 等译. 北京: 机械工业出版社, 2009: 382-399.
(Sandhya S. Neural networks for applied sciences and engineering—From fundamentals to complex pattern recognition[M]. Shi X X, et al Translate. Beijing: China Machine Press, 2009: 382-399.)
- [11] Yu Q Z, Guo J, Zhou C. A system identification using DRNN based on swarm intelligence[J]. Lecture Notes in Computer Science, 2010, 6146(1): 132-139.