

一种非线性系统参数辨识的耦合算法研究

付华, 乔德浩, 池继辉

(辽宁工程技术大学电气与控制工程学院, 125105, 辽宁葫芦岛)

摘要: 针对工程复杂性、时变性、非线性特点, 提出了基于混沌免疫粒子群算法(CIPSO)与 Elman 神经网络的耦合算法(CIPSO-ENN), 用于非线性动态模型参数辨识. CIPSO 优化算法将人工免疫系统中的克隆选择和混沌优化机制引入粒子群算法, 在粒子种群进化过程中, 该算法对粒子进行克隆选择, 提高其收敛速度, 对克隆后的粒子混沌变异以增强种群局部搜索能力. 最后, CIPSO 与动态反馈型 Elman 神经网络融合, 对其权值、阈值寻优, 建立了基于 CIPSO 和 ENN 的耦合算法系统辨识模型. 实验结果表明, 算法具有收敛速度快、收敛精度高、鲁棒性强的特点, 与单纯 Elman 网络辨识相比, 模型收敛速度提高了 10 倍, 拟合精度提高了 2 个数量级.

关键词: 混沌算法; 克隆选择; Elman 神经网络; 耦合算法; 非线性动态系统

中图分类号: TP183 **文献标志码:** A **文章编号:** 0253-987X(2011)02-0049-05

CIPSO-ENN Coupling Algorithm for Nonlinear Dynamic System Parameter Identification

FU Hua, QIAO Dehao, CHI Jihui

(Faculty of Electrical and Control Engineering, Liaoning Project Technology University, Huludao, Liaoning 125105, China)

Abstract: Aiming at the complexity, time varying and nonlinearity of the projects, a CIPSO-ENN coupling algorithm for identifying the parameters of nonlinear dynamic models is proposed, where the clonal selection of artificial immune system and chaotic mutation mechanism are embedded into standard particle swarm optimization. In the evolution of the particle swarm optimization population, this algorithm accelerates convergence of particle clonal selection and enhances the particle swarm local search capability after cloned particle chaotic mutation. Then CIPSO algorithm is merged with dynamic feedback Elman neural network to construct system identification model based on the CIPSO-ENN. The experiment results show that the identification model convergence rate is increased by 10 times and fitting accuracy is increased by 2 orders of magnitude compared with the pure Elman network identification method.

Keywords: chaos algorithm; clonal selection; Elman neural network; coupling algorithm; nonlinear dynamic system

动态反馈型 Elman 神经网络(ENN)具有很强的非线性动态映射能力, 是一种极具潜力的非线性系统辨识工具, 能为非线性参数的辨识提供一种行之有效的方法^[1].

为了提高 Elman 网络模型的辨识性能, 避免出现参数辨识过程中收敛速度慢和易收敛于局部极小点导致辨识误差过大的问题, 本文将擅长全局搜索的混沌免疫粒子群算法(CIPSO)与 Elman 神经网络

络进行有机结合,提出基于 CIPSO 的 Elman 神经网络的耦合算法(简称 CIPSO-ENN),采用数学方式建立 CIPSO-ENN 非线性参数辨识模型.通过 CIPSO 搜寻 ENN 最合适的一组权值和阈值,使辨识的目标函数值最小,实现辨识模型的输出接近输出的目标期望值,达到非线性参数辨识的目的.

1 混沌免疫粒子群算法原理

1.1 标准粒子群优化算法(PSO)

PSO 算法是将群体中的每个个体视为多维搜索空间中一个没有质量和体积的粒子,这些粒子在搜索空间以一定的速度飞行,并根据粒子本身的飞行经验以及同伴的飞行经验,对自己的飞行速度进行动态调整,即每个粒子通过统计迭代过程中自身的最优值和群体的最优值不断地修正自己的前进方向和速度,从而形成群体巡游的正反馈机制^[2-5]. 设在一个 D 维搜索空间中,存在一个由 N 个粒子组成的群体,群体中第 t 次迭代时粒子 i 的位置表示为 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{iD})$,相应的飞行速度表示为 $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{iD})$, $i = 1, 2, \dots, N$. 将 $\mathbf{X}_i$ 带入目标函数可得到其适应值. 记第 i 个粒子搜索到的最优位置为 $\mathbf{P}_i = (p_{i1}, p_{i2}, \dots, p_{iD})$,整个粒子群搜索到的最优位置为 $\mathbf{P}_g = (p_{g1}, p_{g2}, \dots, p_{gD})$,粒子状态更新操作为

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

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

式中: $i = 1, 2, \dots, N$; $d = 1, 2, \dots, D$; r_1, r_2 为 $[0, 1]$ 之间的随机数; c_1, c_2 为加速度因子; ω 为惯性因子.

1.2 混沌免疫粒子群优化算法

为加快收敛速度,同时保持粒子群的多样性,本文引入混沌算法和人工免疫系统中的克隆选择机制.将目标函数和约束条件视为抗原,粒子群视为抗体,将亲和度高的抗体按与其亲和度成正比进行克隆^[6],与亲和度成反比进行混沌变异;将亲和度低的抗体按一定比例重新初始化,以保证多样性.

基于混沌克隆选择的 PSO 算法的基本思路是:抗体在初始化后,首先利用式(1)、式(2)指导其“飞行”的方向,为加快收敛速度,选择亲和度高的抗体进行克隆操作,使抗体更多的聚集在“好”位置的附近;再对克隆后的抗体进行混沌变异,使抗体往“好”位置附近的各个方向进行搜索;最后抛弃亲和度最差的抗体,将它们重新初始化,以保证种群的多样性.本文针对克隆扩增和超突变现象设计混沌克隆

算子,设当前群体按式(1)、式(2)对所有粒子(抗体)的速度和位置进行更新后得到新的种群 $\mathbf{P}_K = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n\}$.

根据抗体抗原亲和度排序,亲和度最高的 M 个抗体组成精英克隆种群 $\mathbf{S}_K$,剩下的 $(N-M)$ 个抗体组成种群 $\mathbf{L}_K$,精英种群规模 M 是一个变量,设抗体亲和度函数为 $f(\mathbf{X})$,则 $\mathbf{S}_K$ 表示为

$$\left. \begin{aligned} \mathbf{S}_K &= \{\mathbf{X}_j \mid f(\mathbf{X}_i) \geq \bar{f}, i = 1, 2, \dots, N\} \\ \bar{f} &= \frac{1}{N} \sum_{i=1}^N f_i \end{aligned} \right\} \quad (3)$$

式中: $\mathbf{S}_K = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M\}$.

精英种群 $\mathbf{S}_K$ 中的 M 个抗体 $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M$ 的亲和度为 $f_1, f_2, \dots, f_M$,根据种群规模 N 和抗体亲和度, $\mathbf{X}_j$ 克隆为 q_j 个相同的点 $\mathbf{X}_{j1}, \mathbf{X}_{j2}, \dots, \mathbf{X}_{jq_j}$

$$q_j = \left[f(\mathbf{X}_j) / \sum_{i=1}^M f(i) \right] N / j, \quad j = 1, 2, \dots, M \quad (4)$$

由式(4)可知,抗体 $\mathbf{X}_i$ 的亲和度越高,抗体克隆的数目越多.

克隆后种群变为 $\mathbf{C}_K = \{\mathbf{S}'_1, \mathbf{S}'_2, \dots, \mathbf{S}'_M\}$,其中 $\mathbf{S}'_j = \{\mathbf{X}_{j1}, \mathbf{X}_{j2}, \dots, \mathbf{X}_{jq_j}\}$, $j = 1, 2, \dots, M$. 文中以混沌变异代替传统高斯变异算子,对克隆后的种群 $\mathbf{C}_K$ 进行变异操作,用 Ulam-von-Neumann 混沌映射^[7]实现混沌变异

$$p_{n+1} = 1 - 2p_n^2 \quad (5)$$

设 $x_{jq_j}(d)$ 为种群 $\mathbf{C}_K$ 中一抗体 $\mathbf{X}_{jq_j}$ 的第 d 个分量,其中 $j = 1, 2, \dots, M$; $d = 1, 2, \dots, D$,其取值范围为 $[\mathbf{L}_d, \mathbf{U}_d]$,根据式(5)将其映射到混沌遍历区间 $[-1, 1]$,然后根据式(7)和式(8)计算得到变异后的抗体 $\mathbf{X}'_{jq_j}$

$$p_{jq_j}(d) = -1 + [2/(\mathbf{U}_d - \mathbf{L}_d)] x_{jq_j}(d) \quad (6)$$

$$p'_{jq_j}(d) = f_{cm}(p_{jq_j}(d)) \quad (7)$$

$$x'_{jq_j}(d) = \mathbf{L}_D + p'_{jq_j}(d)(\mathbf{U}_d - \mathbf{L}_d)/2 \quad (8)$$

式中: f_{cm} 代表 $p_{n+1} = 1 - 2p_n^2$ 混沌映射公式.混沌变异后得到种群 $\mathbf{D}_K$, $\forall j = 1, 2, \dots, M$,存在抗体

$$\mathbf{d}_j = \{\mathbf{X}'_j \mid \max f(\mathbf{X}'_{jq_j})\} \quad (9)$$

则由 $\mathbf{d}_j$ 组成种群 $\mathbf{D}'_K$,由子代种群 $\mathbf{D}'_K$ 和初始种群 $\mathbf{S}_K$ 合并,选择竞赛规模 Q ,通过锦标联赛的方式^[8],形成新一代精英种群 $\mathbf{S}_{K+1}$.

混沌克隆算子通过空间的扩展与压缩,有效地提高局部寻优能力.对于种群 $\mathbf{L}_K$,模拟生物克隆选择中 $\mathbf{B}$ 细胞自然消亡的过程,在 $\mathbf{L}_K$ 中选择 d 个亲

和度最低的抗体,运用消亡算子 $\Gamma(*)$ 予以抛弃,将其重新初始化,得到 L_{K+1} ,可保持种群的多样性

$$\Gamma(\mathbf{X}) = \text{rand}()(\mathbf{U} - \mathbf{L}) + \mathbf{L} \tag{10}$$

式中: $\mathbf{L}, \mathbf{U}$ 分别表示抗体 $\mathbf{X}$ 的取值范围的下、上界。

对种群进行更新、克隆、变异等操作后,得到新一代种群

$$\mathbf{P}_{K+1} = \mathbf{S}_{k+1} \cup \mathbf{L}_{k+1}$$


如此循环进行下一次种群更新操作,直到达到期望结果。

1.3 CIPSO 数值实验


为了验证 CIPSO 算法的寻优性能,采用多峰、非凸的 peaks 函数作为优化问题的测试对象,分别用 CIPSO 算法与 SPSO 算法对其求解优化 peaks 的 $\min f(x,y)$. 函数表达式为

$$f(x,y) = 3(1-x)^2 e^{-[x^2+(y+1)^2]} - 10\left(\frac{x}{5} - x^3 - y^5\right)e^{-(x^2+y^2)} - \frac{1}{3}e^{-[(x+1)^2+y^2]} \tag{11}$$

粒子群规模为 20,加速因子 $c_1=c_2=2$,最大迭代次数为 50,惯性权值 ω 随迭代次数从 0.9 到 0.4 线性减小,竞赛规模 $Q=10$. 经过 50 次迭代实验结果如图 1 所示



(a)PSO 的求解结果



(b)CIPSO 的求解结果

图 1 CIPSO 和 PSO 寻优性能试验

由图 1 可以看出,本文提出的 CIPSO 算法比标准 PSO 算法的全局寻优能力以及收敛精度、收敛速度都有明显改进。

2 CIPSO-ENN 耦合算法

静态前馈神经网络对时变、动态系统进行辨识,其实质是将动态时间建模问题变为一个静态空间建模问题,这必然存在许多问题^[9]. 在系统辨识过程中,为提高辨识的准确性,常以网络的结构膨胀为代价,导致系统学习速度下降. 具有动态特性和递归作用的 Elman 神经网络则具有内部反馈、存储和利用过去时刻输入、输出信息的特点,除了能解决静态系统的建模问题外,还能实现动态系统的映射并更加直接地反映系统的动态特性,比前向神经网络系统具有更强的计算能力和网络稳定性^[10]. 如图 2 所示,Elman 神经网络一般分为 4 层:输入层、隐含层、结构层和输出层。




图 2 Elman 神经网络结构

对于非线性系统,Elman 神经网络的隐含层单元个数就是状态变量的个数,即系统的阶次. Elman 神经网络只需一个输入单元和一个输出单元. 如果有 n 个结构单元,则隐含层的输入有 $n+1$ 个,与静态网络所要求的神经元个数相比大为减少. Elman 神经网络自身具有动态环节,无需使用过多的系统状态输入,从而减少了输入层的单元个数。

此外,Elman 神经网络的动态特性仅由内部的连接提供,无需使用状态作为输入或训练信号,这也是 Elman 神经网络相对于静态前馈网络的优越之处,非常适合于动态系统辨识^[11]. 但是,在执行过程中,Elman 神经网络算法网络参数每次调整的幅度为一个与网络误差函数或其对权值的导数成正比的项乘以固定的学习率 γ ,在误差曲面平坦处误差下降很慢,在曲面曲率大处,误差函数最小点附近会发生过调整现象,从而引起震荡。

大量的数值仿真研究表明,由于 Elman 神经网络结构的复杂性,不同权值和阈值对同一样本的收敛速度不同^[12],从而使 Elman 神经网络算法存在学

习速度慢、精度低和鲁棒性差等缺陷,无法满足工程应用的需要。

CIPSO 的搜索能够遍及整个解空间,容易得到全局最优解,且不要求目标函数连续、可微,甚至不要求目标函数有显函数的形式,只要求问题可计算。因此,将擅长全局搜索的 CIPSO 与 Elman 神经网络进行有机结合,形成 CIPSO-ENN 算法,能有效提高 Elman 神经网络辨识性能。

2.1 CIPSO-ENN 耦合算法的学习过程

在 CIPSO 训练 Elman 神经网络时,首先定义粒子群位置向量 $\mathbf{X}$ 是以 Elman 网络全体节点之间的连接权值和节点的阈值组成粒子的位置参数

$$\mathbf{X} = [\mathbf{W}^1, \mathbf{W}^2, \mathbf{W}^3, \boldsymbol{\theta}^1, \boldsymbol{\theta}^2] \quad (12)$$

式中: $\mathbf{W}^1$ 为神经网络输入层与隐含层间的连接权值; $\mathbf{W}^2$ 为结构层与隐含层间的连接权值; $\mathbf{W}^3$ 为隐含层与输出层间的连接权值; $\boldsymbol{\theta}^1$ 为隐含层阈值; $\boldsymbol{\theta}^2$ 为输出层阈值。若 Elman 网络输入节点数是 V_1 , 结构层节点数是 V_2 , 隐含层节点是 V_3 , 输出节点数是 V_4 , 则 CIPSO 搜索空间维数为

$$D = V_3(V_1 + V_2 + V_3) + (V_2 + V_3) \quad (13)$$

采用 CIPSO 搜寻 Elman 网络最合适的一组权值和阈值,是通过参数的调整和优化,从而使得 Elman 网络的输出最接近输出的目标期望值,使网络输出和理想输出的误差平方和指标(适应值)达到最小,实现非线性动态系统的辨识。

定义适应度函数为

$$f(x) = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^O (y_{ji}^d - y_{ji})^2 \quad (14)$$

式中: N 为训练样本数; O 为输出神经元数; y_{ji}^d 为输出样本值; y_{ji} 为实际值。

2.2 算法流程

(1)确定种群规模 N_a , 适应阈值 ϵ , 最大迭代次数 $G_{\max}$, 学习因子 c_1, c_2 。

(2)随机初始化种群,确定每个粒子(抗体)的初始位置和速度。

(3)根据粒子(抗体) $\mathbf{X}_i$ 和训练样本,按式(14)计算每个粒子(抗体)的亲密度,并更新 $\mathbf{P}_i$ 和 $\mathbf{P}_g$ 。

(4)若达到结束条件,算法终止。

(5)按式(1)、式(2)对所有粒子(抗体)的速度和位置进行更新,并限制其不超过边界。

(6)对于当前种群 $\mathbf{P}_k$,根据抗体抗原亲和度排序,选出亲和度最高的 M 个粒子(抗体)组成精英克隆种群 $\mathbf{S}_K$,剩下的 $(N-M)$ 个粒子(抗体)组成种群 $\mathbf{L}_K$ 。

(7)对种群 $\mathbf{S}_K$ 中的粒子(抗体)进行克隆、混沌变异和选择操作,得到新一代精英种群 $\mathbf{S}_{K+1}$ 。

(8)在种群 $\mathbf{L}_K$ 中取得 d 个亲和度最低的粒子(抗体),运用消亡算子予以抛弃,将其重新初始化

$$\mathbf{X}_i' = \Gamma(\mathbf{X}_i), \quad i = 1, 2, \dots, d$$

得到新种群 $\mathbf{L}_{K+1}$ 。

(9)将种群 $\mathbf{S}_{K+1}$ 和 $\mathbf{L}_{K+1}$ 合并,得到新一代种群 $\mathbf{P}_{K+1} = \mathbf{S}_{K+1} \cup \mathbf{L}_{K+1}$ 。

(10)返回到(3)。

3 CIPSO-ENN 耦合算法的数值实验

分别采用 CIPSO-ENN 耦合算法、Elman 网络算法对非线性函数 $f_1(x)$ 进行计算,并比较其拟合程度与收敛性能。 $f_1(x)$ 表达式为

$$f_1(x) = 3\sin(4x) + e^{-2x} + 2\cos(x) + 5\cos(3x), \quad x \in [0, 10] \quad (15)$$

在数值实验中,两种算法均随机选取 100 个样本作为网络的训练输入,其输出作为相对应的测试输出,以此构成网络的训练样本集。网络的输入节点数 $V_1=1$, 隐含层节点数 $V_2=20$, 结构层节点数 $V_3=20$, 输出层节点数 $V_4=1$, 网络的隐含层神经元的激发函数选用 sigrnofd 函数,输出层神经元的激发函数采用 Pureline 函数。粒子群规模为 20, 加速因子 $c_1=c_2=2$, 最大迭代次数 $I_{\text{ter max}}=600$, 惯性权值 w 随迭代次数从 0.9 到 0.4 线性减小, 竞赛规模 $Q=10$ 。

由图 3、图 4 可以看出, CIPSO-ENN 耦合算法得到的拟合曲线几乎与原函数完全重合, 比 Elman 网络算法具有更好的逼近效果。 CIPSO-ENN 辨识模型最大拟合误差为 $2.385 \times e^{-6}$, Elman 辨识模型最大拟合误差为 $1.267 \times e^{-2}$ 。为了使结果更加直观,对最大拟合误差取自然对数,结果见图 5。由图 5 可以看出, CIPSO-ENN 算法收敛速度明显快于 Elman 算法,而且在迭代次数相同的情况下,具有更高的精度和收敛效果。显然,本文提出的算法具有很高的搜索效率和很强的鲁棒性,能够实现任意非线性函数的逼近以及对非线性多参数的实时辨识。

4 总 结

本文将克隆选择和混沌算法与粒子群优化算法结合,提出了一种混沌免疫粒子群优化算法。该算法具有收敛速度快、收敛精度高、鲁棒性强的特点,将其与具有动态反馈型 Elman 神经网络算法相结合,对 Elman 网络的权值与阈值进行训练。实验表明,




图3 Elman 算法的拟合结果




图4 CIPSO-ENN 算法的拟合结果




图5 CIPSO-ENN 与 Elman 收敛速度对比

本文提出的 CIPSO-ENN 耦合算法对动态非线性模型的辨识比传统 Elman 算法具有明显的优越性。

参考文献:

- [1] GERNASKY M, BENUSKOVA L. Simple recurrent network trained by RTRL and extended Kalmann filter algorithm [J]. Neural Network World, 2003, 13(3): 223-234.
- [2] 陈贵敏,贾建援,韩琪. 粒子群优化算法的惯性权值递减策略研究[J]. 西安交通大学学报, 2006, 40(1): 53-56.
- CHEN Guimin, JIA Jianyuan, HAN Qi. Study on the strategy of decreasing inertial weight in particle swarm optimization algorithm [J]. Journal of Xi'an Jiaotong University, 2006, 40(1): 53-56.
- [3] 潘峰,陈杰,甘明刚,等. 粒子群优化算法模型分析[J]. 自动化学报, 2006, 32(3): 368-377.
- PAN Feng, CHEN Jie, GAN Minggang, et al. Model

- analysis of particle swarm optimizer[J]. Acta Automatica Sinica, 2006, 32(3): 368-377.
- [4] HOLLAND J. Emergence: from chaos to order [M]. Redwood City, California: Addison Wesley, 1998.
- [5] 杨维,李歧强. 粒子群优化算法综述[J]. 中国工程科学, 2004, 6(5): 87-94.
- YANG Wei, LI Qiqiang. Survey on particle swarm optimization algorithm [J]. Engineering Science, 2004, 6(5): 87-94.
- [6] 陈曦,蒋加伏. 免疫粒子群优化算法求解旅行商问题[J]. 计算机与数字工程, 2006, 34(6): 10-29.
- CHEN Xi, JIANG Jiafu. Particle swarm optimization algorithms with immunity for traveling salesman problems[J]. Computer and Digital Engineering, 2006, 34(6): 10-29.
- [7] 尤勇,王孙安,盛万兴. 新型混沌优化方法的研究及应用[J]. 西安交通大学学报, 2003, 37(1): 69-72.
- YOU Yong, WANG Sun'an, SHENG Wanxing. New chaos optimization algorithm with application [J]. Journal of Xi'an Jiaotong University, 2003, 37(1): 69-72.
- [8] SCHWEFEL H P. Evolution and optimum seeking [M]. New York, USA: Wiley, 1995.
- [9] 王峰,邢科义,徐小平. 系统辨识的粒子群优化方法[J]. 西安交通大学学报, 2009, 43(2): 116-119.
- WANG Feng, XING Keyi, XU Xiaoping. A system identification method using particle swarm optimization [J]. Journal of Xi'an Jiaotong University, 2009, 43(2): 116-119.
- [10] 葛宏伟,梁艳春. 进化 Elman 神经网络模型与非线性系统辨识[J]. 吉林大学学报: 工学版, 2005, 35(5): 511-519.
- GE Hongwei, LIANG Yanchun. Evolutionary Elman neural network model and identification for non-linear systems[J]. Journal of Jilin University: Engineering and Technology Edition, 2005, 35(5): 511-519.
- [11] 李秀英,韩志刚. 非线性系统辨识方法的新进展[J]. 自动化技术与应用, 2004, 23(10): 5-7.
- LI Xiuying, HAN Zhigang. Advances in nonlinear system identification[J]. Techniques of Automation & Application, 2004, 23(10): 5-7.
- [12] 时小虎,梁艳春,徐旭. 改进的 Elman 模型与递归反传控制神经网络[J]. 软件学报, 2003, 14(6): 1110-1119.
- SHI Xiaohu, LIANG Yanchun, XU Xu. An improved Elman model and recurrent back-propagation control neural networks[J]. Journal of Software, 2003, 14(6): 1110-1119.

(编辑 杜秀杰)