

基于进化策略的动态递归神经网络建模与辨识*

史天运 贾利民

(铁道部科学研究院智能控制技术研究中心 北京 100081)

摘要 提出一种采用进化策略实现动态递归神经网络结构、权重和自反馈增益同时进化的学习算法,以及自适应进化机制。与改进 BP 算法相结合,各取所长,形成集成化动态递归神经网络建模辨识算法。实际应用结果表明,所提出算法不仅明显提高了动态递归网络模型辨识算法的收敛速度和精度,而且实现了动态递归网络的全自动优化设计。

关键词 进化策略,自适应进化,动态递归网络,建模和辨识,集成化

分类号 TP 273

Evolutionary Strategy Based Dynamic Recursive Neural Network Modeling and Identification

Shi Tianyun, Jia Limin

(China Academy of Railway Sciences)

Abstract The learning algorithm of the dynamic recursive neural network based on evolutionary strategy is presented, which realizes the evolution of network construct, weights and self-feedback coefficient of the dynamic recursive neural network together. The adaptive evolutionary method is also advanced. The identification algorithm integrating the forward evolutionary algorithm and improved BP algorithm for the dynamic recursive neural network model is formed. The result of the application shows that the advanced algorithm not only improves the learning speed and model precision, but also realizes the fully automatic optimization design for the dynamic recursive neural network.

Key words evolutionary strategy, adaptive evolution, dynamic recursive neural network, modeling and identification, integration

1 引言

建立被控对象和控制器的动态神经网络模型,可为复杂系统的控制和仿真提供良好的解决方案。一般有两种建模方法:一种是利用多层前馈神经网络对动态系统进行辨识,实际上是将动态时间建模变成静态空间建模问题;另一种是利用多层动态递归神经网络,即神经网络中引入动态环节,自动记忆部分历史影响信息。前者与后者相比具有如下不足:

- 1) 需要假定系统的 NARMA 模型类,对结构模型进行定阶;
- 2) 当系统阶次增加或未知时,网络结构增加,使学习算法收敛速度变慢;

3) 辨识模型应用时,必须将系统输出的历史信息转换成当前的输入向量,应用不便;

4) 大量输入节点将使相应的辨识系统对外部噪声特别敏感。因此,动态递归神经网络是控制系统建模、辨识和控制中最具发展潜力的网络。

动态递归神经网络分为完全递归网络和部分递归网络^[1]。Elman 网络是结构最简单的部分动态递归网络,但网络中反馈仅利用前一时刻的信息,所以该网络仅能辨识一阶动态系统。为解决高阶系统的辨识问题,文献[1]提出一种修改的 Elman 网络,如图 1 所示。

该网络在结构单元中有一个固定增益权的反馈连接,因此结构单元在 k 时刻的输出,就等于隐层在 $k-1$ 时刻的输出加上结构单元在 $k-1$ 时刻输出值的 α 倍,即




图1 一种修改的 Elman 网络结构

$$x_{c,l}(k) = \alpha x_{c,l}(k-1) + x_l(k-1) \quad (1)$$

$$l = 1, 2, \dots, q$$

其中 $x_{c,l}(k)$ 和 $x_l(k)$ 分别表示第 l 个结构单元和第 l 个隐层单元的输出, α 为自反馈增益。当 $\alpha = 0$ 时, 即为基本的 Elman 网络。

修改的 Elman 网络描述的非线性状态空间表达式为

$$\begin{cases} \mathbf{x}(k) = f[\mathbf{W}^{(1)}\mathbf{x}_c(k) + \mathbf{W}^{(2)}\mathbf{u}(k)] \\ \mathbf{x}_c(k) = \mathbf{x}(k-1) + \alpha\mathbf{x}_c(k-1) \\ \mathbf{y}(k) = f[\mathbf{W}^{(3)}\mathbf{x}(k)] \end{cases} \quad (2)$$

修改的 Elman 网络可利用标准 BP 算法辨识高阶动态系统, 但存在如下问题:

- 1) BP 算法本身固有的学习速度较慢, 且易陷入局部极小;
- 2) 自反馈增益 α 需人工试凑确定, 学习效率低;
- 3) 若网络结构 (即隐层神经元数目) 不与权重同时学习, 则势必先确定隐层单元数目再学习权重, 这样可能破坏 Kosmogorov 定理^[2], 无法保证良好的动态逼近能力。

为此, 本文提出采用进化策略 (ES) 实现动态递归网络结构、权重和自反馈增益 α 同时进化, 并提出自适应进化机制, 与改进 BP 算法相结合, 从而提高了动态神经网络模型辨识算法的收敛速度和精度。

2 进化策略

2.1 基本进化策略

进化策略基于自然界中变异与选择原理, 对于每一父代, 通过变异产生一个子代, 二者通过竞争获得生存, 通过选择以消除低劣解, 这就是最初的 (1+1)-ES。然后注重于多个父代与多个子代的进化和自适应进化机制, 以消除点到点搜索的脆弱性^[3]和过慢的收敛效率。主要有 3 种途径:

- 1) $(\mu + \lambda)$ -ES: μ 个父代用于产生 λ 个子代, 所有 $\mu + \lambda$ 个解同时竞争生存, 其中最佳的 μ 个被选

作下一代的父代;

- 2) (μ, λ) -ES: μ 个父代用于产生 λ 个子代, 仅有 λ 个子代参与生存竞争, 最佳的 μ 个被选作下一代的父代, 注意每一代的父代均被完全替代;

- 3) 自适应进化策略: 策略参数 (进化步长) 的自适应机制参见 2.2 节。

这样, 种群规模的扩大和策略参数自适应进化机制将大大提高优化速度。以求 $f(x)$ 的极小值为例, 采用 $(\mu + \lambda)$ -ES, 具体实现算法如下:

- 1) 随机选择 μ 个个体, 组成初始种群, 每个个体均为向量 $\mathbf{x} = x_i (i = 1, 2, \dots, n)$ 的初始值, 力求个体分布的均匀性和全面性;

- 2) 对于每一父代向量 \mathbf{x} , 通过向 \mathbf{x} 的各个分量 x_i 增加一均值为 t , 方差为 θ^2 的 Gauss 分布随机变量 N 来实施变异, 使每个个体产生 $\lambda\mu$ 个子代 ($\lambda\mu$ 为整数), 即

$$x_i^{(k+1)} = x_i^{(k)} + \sigma_k N(t, \theta^2) \quad (3)$$

其中, σ_k 为进化步长, 一般取 $t = 0, \theta = 1$;

- 3) 计算所有 μ 个父代和 λ 个子代的适应度, 即求 $f(x_i^{(k+1)}) (i = 1, 2, \dots, n)$, 选择其值最小的 μ 个个体作为下一代的父代, 抛弃其它个体;

- 4) 判断是否产生一个满意适应度的个体, 是则停止, 否则转向 2)。

2.2 自适应进化策略

为避免陷入局部极小点和提高进化效率, 一种有效的措施是实现自适应进化, 即进化步长的自适应机制。具体有 2 种情形:

- 1) 当出现相邻 N_k 代的最优解变化甚微, 即搜索停滞不前时, 应加大进化步长 σ_k ;

- 2) 每次变异中寻找最优的 σ_k , 以保证下一代平均适应度比上一代尽可能高。

对于情形 1), 一般取 $N_k = 4$, 这里取 4。每产生一个新代, 则比较其最优解 $f_{\min}(x_i^{(k+1)})$ 与前 3 代的最优解 $f_{\min}(x_i^{(k)})$, $f_{\min}(x_i^{(k-1)})$ 和 $f_{\min}(x_i^{(k-2)})$ 。

$$\begin{aligned} \text{IF } & |f_{\min}(x_i^{(k+1)}) - f_{\min}(x_i^{(k)})| < \epsilon \\ & \text{and } |f_{\min}(x_i^{(k+1)}) - f_{\min}(x_i^{(k-1)})| < \epsilon \\ & \text{and } |f_{\min}(x_i^{(k+1)}) - f_{\min}(x_i^{(k-2)})| < \epsilon \\ \text{THEN } & \sigma_{k+1} = \eta_1 \sigma_k, \eta_1 = 1 \sim 2 \end{aligned} \quad (4)$$

对于情形 2), 优化算法如下:

- 1) 在每一父代变异产生下一代时, 先假定进化步长 $\sigma_k = 1$, 计算所产生的最好的 μ 个个体的平均适应度 $f_{\min}(x_i, \sigma_k)$;

- 2) 令 $\sigma_k = \sigma_k + \eta_2$, 重新实施变异, 计算所产生

表 1 网络参数排列顺序

自反馈增益	隐神经元数目	有关第 1 个隐节点的所有权重			...	有关第 q 个隐节点的所有权重		
		$w_{i1}^{(1)}$	$w_{1m}^{(3)}$	$w_{11}^{(2)}, w_{21}^{(2)}, \dots, w_{q1}^{(2)}$		$w_{iq}^{(1)}$	$w_{qm}^{(3)}$	$w_{1q}^{(2)}, w_{2q}^{(2)}, \dots, w_{qq}^{(2)}$
α	q	输入节点与第 1 个隐节点间权重	输出节点与第 1 个隐节点间权重	结构单元与第 1 个隐节点间权重	...	输入节点与第 q 个隐节点间权重	输出节点与第 q 个隐节点间权重	结构单元与第 q 个隐节点间权重

的最好的 μ 个个体的平均适应度 $\bar{f}_{\min}(x_i, \sigma_k)$; 一般取 $\eta_2 = 0.1 \sim 0.5$;

3) 比较 $\bar{f}_{\min}(x_i, \sigma_k)$ 与 $\bar{f}_{\min}(x_i, \sigma_k)$, 若 $\bar{f}_{\min}(x_i, \sigma_k) < \bar{f}_{\min}(x_i, \sigma_k)$, 则令 $\sigma_k = \sigma_k$, 返回 2) 继续; 否则, 转向 4);

4) 停止寻优, 取前一次的 α 作为该代最优的进化步长。

算法在进化中选取适应度 $\bar{f}_{\min}(x_i, \sigma_k)$ 值最小的个体生存, 是为了实现求极小值, 非常适合神经网络的训练, 因为神经网络是以均方差作为评价标准, 即求极小值问题。若求极大值问题, 则进化中选取适应度值最大的个体生存。实际上二者均是适应度最高的个体被生存。

3 采用进化策略辨识动态递归神经网络模型

由于 ES 直接用实数进行优化, 因此利用 ES 设计动态递归神经网络不需要编码。但由于要实现网络权重和网络结构的同时进化, 而随着网络结构的变化, 网络权重数目也发生变化, 所以当对这些网络参数同时进化时, 需要对其按一定顺序排列, 以保证进化中随网络结构变化, 相应的权重能正确增加或删除。

设网络输入层、隐层和输出层神经元数目依次为 r, q 和 p , 神经元函数为 Sigmoid 函数, 输入层与隐层、结构单元与隐层、隐层与输出层间的连接权重依次为 $w_{ij}^{(1)}, w_{lj}^{(2)}, w_{jm}^{(3)}$ (包括阈值), 其中, $i = 1, 2, \dots, r; l, j = 1, 2, \dots, q; m = 1, 2, \dots, p$ 。则需优化的网络参数排列顺序如表 1 所示。

直接采用网络输出均方差 E 作为 ES 算法的适应度, 所有隐节点的权重按上述自适应 ES 算法进行优化学习。为保证神经网络的综合性能, 自反馈增益 α 按其进化概率 P_r 来确定是否进化, 即每代根据 P_r 进行变异, 具体进化方法则采用基本 ES 算法。为实现网络结构(即隐层神经元数目 q) 的进化, 需要附加“增加”与“删除”操作:

增加: 进化中按增加概率 P_α 来决定是否增加某

个隐神经元, 同时增加与之关联的连接权重, 新增权重值可根据初始范围随机选择。

删除: 进化中按删除概率 P_e 来决定是否删除某个隐神经元, 若删除, 可根据随机概率确定删除第几个隐神经元, 同时将与之关联的连接权重一并删除。

对于自反馈增益 α 进化概率 P_r , 隐层神经元数目增加概率 P_α 和删除概率 P_e , 一般需反复调试才能合理确定。为保证进化的合理性, 提高进化效率, 采用自适应原则, 即根据解的适应度减小而减小, 保证 $P_r, P_\alpha, P_e \in [0.01, 0.3]$ 。

网络参数初始值选择原则如下:

- 1) 所有权重初始值范围为 $[-1, 1]$;
- 2) 自反馈增益 α 的初始值为 0.3;
- 3) 隐层神经元数目 q 初始值根据经验公式确定为

$$q = \frac{N_w}{rp} \text{ 或 } N_w \cdot L / (1 + \log_2 L) \quad (5)$$

其中, N_w 为权值数目, L 为最大样本数。

在神经网络学习初期, 作为全局优化算法的进化策略效果较好, 但当达到一定程度还未满足最终精度要求时速度极慢, 大规模群体搜索代价太高。而此时网络结构和自反馈增益参数已经固定, 因而应与 BP 算法相结合, 在确定的网络结构和神经元参数的基础上, 将 ES 进化所得的网络权重作为 BP 算法的起始点, 采用梯度法进行快速学习。

为了提高学习效率, 采用步长自寻优改进 BP 算法(即 OSBP)^[4] 与 $(\mu + \lambda)$ -ES 集成。集成的动态递归神经网络学习算法如下:

- 1) 根据网络参数初始值选择原则, 随机选择 ES 的初始群体(μ 个个体), 令 $k = 1$;
- 2) 对于每个个体计算其网络误差作为 ES 适应度, 并计算第 k 代 μ 个个体平均适应度 \bar{f} 和最佳适应度 f_{\min} ;
- 3) 根据 2.2 节自适应进化策略, 优化确定第 k 代的进化步长 σ_k ;
- 4) 由自适应原则确定自适应策略, 计算第 k 代自反馈增益进化概率 P_r , 隐层神经元数目增加概率 P_α 和删除概率 P_e ;
- 5) 进化操作: 包括变异、增加和删除、选择等;

- 6) 判断连续 6 次最大适应度变化是否小于 ϵ , 是则转向 7); 否则令 $k = k + 1$, 转向 2);
- 7) 固定网络结构和递归参数, 以此时的权重作为 BP 算法的初始值, 并调用 OSBP 算法, 对权重进行学习;
- 8) 判断最终网络误差是否满足要求, 是则停止学习; 否则转向 7) 继续学习。

4 应用结果

将上述建模辨识算法用于一实际工程项目煤气发生炉, 对其建立动态递归神经网络模型(见图 2)。其中, $P_a(t)$ 为 t 时刻鼓风压力, $P_s(t)$ 为 t 时刻蒸汽压力, $P_c(t)$ 为 t 时刻煤气压力, $T_h(t)$ 为 t 时刻混合汽温度, DRNNF 为煤气发生炉动态递归神经网络模型函数。




图 2 煤气发生炉动态递归神经网络模型

以实测运行数据作为训练样本, 并与步长自寻优 BP 算法辨识效果相比较。实际选择的学习样本和测试样本有 270 个。ES 算法参数取为: $\mu = 10$, $\lambda = 60$, 即(10, 60)—ES; 隐层神经元初选为 5, 6, 7, 8; 设定网络最终学习误差 $E = 0.017$ 。

经过实际训练, 基于自适应进化策略和步长自寻优 BP 相结合的集成化学习算法训练后, 确定最优的递归网络结构为 $2 \times 6 \times 2$, 其中 6 为隐层节点数, 自反馈增益 $\alpha = 0.1$ 。对于步长自寻优 BP 算法也同样选取。两种算法辨识效果和对测试样本的测试精

表 2 两种算法辨识效果比较

算 法	迭代次数	训练时间(s)	测试精度
步长自寻优 BP 算法 (OSBP)	84 062	270	0.028
基于 ES + OSBP 的 集成化算法	180 + 3 444	41 + 20	0.025

度如表 2 所示。

此外, 作者对其它系统也进行了建模和辨识, 结果表明, 基于自适应进化策略和步长自寻优 BP 相结合的集成学习算法比其它算法具有明显的优势。

5 结 语

采用自适应进化策略和步长自寻优 BP 相结合的集成化学习算法辨识动态递归神经网络模型, 具有如下优点: 1) 考虑了 ES 的自适应问题, 避免了局部陷入极小, 大大提高了建模效率; 2) 所提出的动态递归神经网络的自反馈增益、网络结构和网络权重的同时优化学习策略, 保证了算法的合理性, 实现了动态递归神经网络的全自动设计。其不足在于动态递归神经网络的辨识速度比多层前馈神经网络和径向基函数神经网络的学习速度要慢些。因此, 在辨识算法和网络结构方面加强研究, 拓宽其应用范围, 加深其应用力度, 是一项很有意义的工作。

参 考 文 献

- 1 孙增圻, 张再兴. 智能控制理论与技术. 北京: 清华大学出版社, 1997
- 2 王强, 邵惠鹤. 遗传算法生成前向神经网络. 见: 中国智能自动化学术会议论文集. 天津, 1995. 1125 ~ 1139
- 3 张光铎, 王志. 模拟进化理论及其实现方法. 见: 中国智能自动化学术会议论文集. 天津, 1995. 1149 ~ 1154
- 4 史天运. FMS 状态监测与故障诊断技术研究. 北京理工大学博士学位论文, 1998
- 5 Garrison W Greenwood. Training multiple-layer perceptrons to recognize attractors. IEEE Trans on Evolutionary Computation, 1997, 1(4): 244 ~ 248

作 者 简 介

史天运 男, 1967 年生. 1998 年于北京理工大学获博士学位, 现为铁道部科学研究院博士后人员。目前主要从事复杂工业过程的智能建模和控制, 神经网络, 进化计算等研究。

贾利民 男, 1963 年生. 1991 年于铁道部科学研究院获博士学位, 现为铁道部科学研究院研究员, 博士生导师。主要研究领域为模糊控制与决策, 神经网络, 智能控制等。