

神经网络和遗传算法相结合 实现非线性传感特性的线性化

刘 清

(南京师范大学数学与计算机科学学院, 210042, 南京)

[摘要] 对测量系统非线性传感特性的线性化常用最小二乘回归、几何逼近或一次近似的方法, 易引入较大的非线性误差, 为此, 提出了利用神经网络和遗传算法相结合实现非线性传感特性线性化的方法, 该方法将测量系统的非线性模型改造成为与实际物理过程相一致的不失真的线性模型, 从而减小非线性误差. 通过应用实验, 验证了该方法的有效性.

[关键词] 测量, 非线性特性, 线性化, 误差, 神经网络, 遗传算法

[中图分类号] TP18; [文献标识码] A; [文章编号] 1672-1292(2002)03-0011-05

0 引言

在测量系统中, 被测对象输入的物理量 x 与系统输出的观测值 y 可表示为:

$$y = f(x) \quad (1)$$

$f(\cdot)$ 是一个非线性函数, 即: 测量系统的传感特性是非线性的, 特别是在 x 的两端. 但是, 目前大多数测量系统对非线性的传感特性采用直线或分段直线拟合的方法线性化^[1-2], 由此产生的非线性误差成为许多测量系统的主要误差来源. 因此, 这些测量系统只能在非线性误差较小的一段范围内使用. 而对测量精度高和范围宽的系统, 只能采用其它方法, 即用非线性补偿方法对传感特性线性化. 非线性补偿环节的实现有多种方法: 采用硬件补偿, 该方法难以做到全量程补偿, 并且补偿硬件的漂移会影响整个测量系统的精度, 因此可靠性和精度低, 应用受到限制. 采用软件补偿, 该方法是测量系统中串联一个补偿环节(如图1所示), 使得非线性的传感特性被线性化, 该补偿环节是传感特性函数 $f(x)$ 的反函数 $z = f^{-1}(y)$ ^[3], 通过函数的合成, 得到测量系统输出值 z . 测量系统的输出与输入之间的函数关系可表示为:

$$z = f^{-1}(y) = f^{-1}[f(x)] = x \quad (2)$$

显然, 测量系统由非线性模型被改造成不失真的线性模型, 该方法的补偿环节由测量系统中的计算机实现, 所以, 可靠性和精度高, 应用广泛.

采用软件补偿的关键是得到 $f^{-1}(x)$, 而 $f^{-1}(x)$ 也是一个非线性函数, 无法用准确的数学公式描述, 为此, 近几年人们研究利用人工神经网络进行非线性传感特性的线性化. 由于神经网络能逼近任意连续非线性函数, 所以, 通过少量的样本点学习, 让网络逼近 $f^{-1}(x)$, 这样, 利用网络的泛化能力, 对于每一个输出值 x , 通过公式(2)得到测量系统的输出值 $z = x$, 即实现了对非线性传感特性的线性化和测量系统非线性误差的校正. 在文献[4~6]中使用BP网络进行误差校正, 但BP网络的局部寻优和收敛速度慢的缺点, 使得实际使用十分困难. 为此, 本文提出了利用神经网络和遗传算法相结合的方法, 实现对非线性传感特性的线性化, 该方法并克服了BP网络的缺点, 取得了十分满意的效果.

收稿日期: 2002-04-25

作者简介: 刘清, 1962-, 南京师范大学数学与计算机科学学院副教授, 博士研究生, 主要从事计算机测控等方面的教学与研究




图1 非线性补偿的测量系统

1 神经网络和遗传算法结合的原理

遗传算法(GA)是一种基于群体进化的全局优化算法,它能够获得近似最优的全局解,而且不会陷入局部极小;另外,它的寻优过程不依赖梯度信息,而且搜索效率高,具有很强的鲁棒性^[7].但是,遗传算法的收敛精度低,微调差,在最优解附近,但很难得到最优解^[8],所以,很难直接使用该算法进行寻优. BP网络是目前应用最广泛的一种神经网络模型,它的优点是能逼近任意连续非线性函数,但是, BP算法本质上是一种基于梯度下降的局部优化搜索,所以,训练学习的收敛速度慢,且易陷入局部极小点,这些缺点限制了BP网络的使用.因此,将两者有机的结合起来,能够更好的发挥神经网络在非线性系统中的应用.本文提出了一种采用遗传算法和BP算法相结合的混合算法

在该算法中,神经网络的拓扑结构仍然采用多层网络,网络初始连接权值为随机数.对网络连接权值的训练分为两步:第一步,利用遗传算法的全局寻优和收敛速度快的特点,训练网络的权值,得到的一个接近权值最优解的空间 $B(W^*)$. 第二步,利用BP算法具有任意精度逼近能力和局部寻优能力强的特点,在接近最优解的 $B(W^*)$ 空间中进一步寻优,得到网络权值的最优值 W^* . 采用这样两个步骤训练,可以提高网络训练的精度和学习收敛的速度.

网络结构如图2所示. $y(i)$ 是网络输入值,它是传感器在 i 时刻的输出值,通过对 y 采样得到的. $z(i)$ 是对应 $y(i)$ 的网络输出值,它是补偿环节的输出值,即测量系统的输出值,网络对应的前向计算公式如下:

$$z(i) = h(W^o S(i) + \theta_1) \quad (3)$$

$$S(i) = h(W^l y(i) + \theta_2) \quad (4)$$

其中, $y(i)$ 和 $z(i) \in \mathbf{R}$ (\mathbf{R} 为实数集); $W^o \in \mathbf{R}^{1 \times P}$, P 为隐层单元数, W^o 为隐层到输出层网络权值; $S(i) \in \mathbf{R}^{P \times 1}$, 为隐层输出; $W^l \in \mathbf{R}^{P \times 1}$, W^l 为输入层到隐层网络权值; $\theta_1 \in \mathbf{R}^{1 \times 1}$, $\theta_2 \in \mathbf{R}^{1 \times 1}$, 分别为隐层单元和输出单元的阈值; h 为激励函数, $h(x) = 1/(1 + e^{-x})$.




图2 神经网络结构

2 神经网络和遗传算法结合的实现

使用遗传算法和BP算法相结合,实现对多层网络的权值训练过程如下.

2.1 多层网络的权值遗传算法

使用遗传算法对图2所示的多层神经网络训练,得到接近网络权值 $W = (W^o, W^l)$ 最优解的空间 $B(W^*)$.

2.1.1 染色体编码方案的选择

用遗传算法训练神经网络,需要把网络权值转为染色体编码,本文采用二进制编码.考虑精度,我们

将网络权值 w 的取值范围定义在 $[0.0001, 0.9999]$ 之间, 每一个权值对应 m 位二进制编码, 转换公式为:

$$w = 0.0001 + (k)_{10} * (0.9999 - 0.0001) (2^m - 1) \quad (5)$$

其中, $(k)_{10}$ 为二进制串 k 对应的十进制数, 将网络所有权值的编码串联起来, 就得到一个染色体编码 K , 该编码的长度 $L = m * p$, 其中 p 是神经网络的权值数. 同样对于一个长度为 L 的二进制编码, 也可以按长度为 m 分解成 p 个子串, 每一个子串经过公式(5)可转换成网络权值. 这样, 我们就在网络权值和染色体编码之间, 建立了一个一对一的映射.

2.1.2 适应度函数的确定

适应度函数是遗传算法指导寻优搜索的关键, 这里我们定义适应度函数为

$$f(K) = E^{-1} = \left[\sum_{i=1}^q (z(i) - d(i))^2 \right]^{-1}$$

其中 K 为网络的权值所对应的个体编码, 通过公式(5)转换成网络权值, 并通过公式(3)和(4)计算出网络对应第 i 个输入样本点输出 $z(i)$, $d(i)$ 是希望输出, E 是神经网络的误差平方和, q 是总的学习样本数. 这样, 可以保证通过该适应度函数所选择出的优质个体的网络误差较小.

2.1.3 遗传算法的实现

在本研究中, 使用遗传算法并不是要得到网络权值的最优解 W^* , 而是得到一个接近最优解的空间 $B(W^*)$, 所以, 遗传算法的早期收敛不存在问题, 本研究恰好利用这种早期收敛性, 迅速得到权值最优解空间 $B(W^*)$, 提高学习的收敛速度. 遗传算法描述如下:

(1) 确定种群大小 N , 交叉概率 P_c 和变异概率 P_m . 因为, 这里不考虑早期收敛问题, 所以, 遗传繁殖的代数不多, 因而种群数 N 可以选择的大一些. 另外, 对 P_c 和 P_m 采用自适应调整, 促进遗传算法的收敛, 调整算法为:

$$P_c = \begin{cases} (f_{\max} - f_c) / 2(f_{\max} - f_{av}) & f_c > f_{av} \\ 1 & f_c \leq f_{av} \end{cases} \quad (6)$$

$$P_m = \begin{cases} (f_{\max} - f) / 2(f_{\max} - f_{av}) & f > f_{av} \\ 1 & f \leq f_{av} \end{cases} \quad (7)$$

其中, f_c 为交叉前父代双亲适应度值大者, f_{av} 为需要变异个体的适应度值. 通过调整, 使之对优质个体(适应度值高于种群平均适应度值), P_c 和 P_m 取小一些, 有利于算法收敛, 而对适应度值低于种群平均适应度值的个体, P_c 和 P_m 取大一些, 避免算法陷入局部解^[8].

(2) 产生初始种群 Z . 根据网络的结构, 产生 N 个 (W^o, W^l) , 通过二进制编码方案, 将每一个 (W^o, W^l) 转换成一个染色体, 这样, 将得到由 N 个染色体组成的初始种群 Z ;

(3) 选择优质个体, 产生新种群. 计算出每个个体的适应度 f_i , 按赌轮盘法进行优质个体的选择^[8].

(4) 个体配对交叉, 产生新个体.

(5) 个体基因串中某一位变异, 防止种群陷入某超平面.

(6) 重复(3)、(4)和(5)步, 直到网络误差 E , 对连续几代种群不超过某一阈值或趋于稳定, 则进化计算结束.

2.2 前向网络的 BP 算法

在用遗传算法得到一个接近最优的网络权值后, 利用 BP 算法得到网络权值最优解 W^* . BP 算法是梯度下降法, 前向计算采用公式(3)和(4); 反向调整权值计算公式为^[9]:

$$W = - \frac{\partial E}{\partial W}$$

$$W_{\text{new}} = W_{\text{old}} + \eta \frac{\partial E}{\partial W}$$

其中 W 为 W^o 和 W^l , η 为学习率, E 是神经网络的误差平方和. 使用梯度下降法可以使总的误差向减小

方向变化,逼近到网络权值的最优值.

3 应用与实验

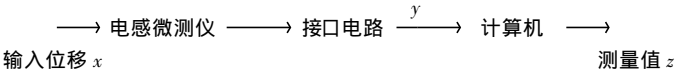


图3 所示为一个位移测量系统,传感器采用有明显非线性传感特性的电感微测仪,其有效量程为 395 m,按通常的方法,在测量范围内选定两点进行定标,其余各点进行直线拟合,则测量系统输出值与被测物理量(实际位移)之间出现了严重的非线性误差(如图 4 所示).利用本文提出的方法,可以解决这个问题.为了验证该方法的有效性,作者进行了应用实验,实验过程与结果如下:

在实验中,神经网络模型的输入层有 1 个神经元,隐层有 8 个神经元,输出层有一个神经元.学习率 为 0.58;遗传算法参数选取如下:种群数 $N = 50$,交叉概率 P_c 、变异概率 P_m 由公式(6) 和(7) 自适应调整.整个实验分为两步骤:

步骤 1: 网络学习

(1) 学习样本点的获得.在传感器的量程 $[0, 395]$ 区间中(考虑传感器的对称性,只用正端),随机插入 28 个点,将传感器输入量程分为 30 个值(x_1, x_2, \dots, x_{30}).通过标准量块将 $x_i (i = 1, \dots, 30)$ 送到传感器的输入端,传感器相应输出经过采样后得到 y_i ,让 $Y = (y_1, y_2, \dots, y_{30})$ 作为神经网络的输入样本, $X = (x_1, x_2, \dots, x_{30})$ 作为网络的希望输出.这里,要对 X 和 Y 进行归一化处理.




图 4 测量系统直线拟合的误差曲线

(2) 利用遗传算法对网络进行训练.在进化 30 次后,网络误差 $E < 0.7$,得到一个接近最优的网络权值,进化结束.

(3) 利用 BP 算法对网络进行训练.在迭代训练 100 次后,得到一个最优的网络权值,网络误差 $E < 0.01$,训练学习结束.

步骤 2: 产生另一组传感器实际输入值 X 和输出值 Y 作为校验样本,样本数 $q = 50$,将 Y 作为完成训练的神经网络输入, Z 为神经网络输出,比较 X 和 Z 进行验证,校验的结果数据如表 1 所示,从表 1 中可知,神经网络的输出值 x 与传感器的实际输入 z 非常接近,补偿环节实现了对测量系统非线性传感特性的线性化,使测量系统的量程扩大和精度提高.

表 1 用网络补偿线性化后结果

实际值	0.0	4.1	11.2	21.1	25.7	35.5	45.2	55.1	71.0	81.3	90.1	101.2	120.4	130.2
量值	0.0	4.0	11.1	21.0	25.5	35.6	45.2	55.0	71.0	81.3	90.0	101.2	120.5	130.2
误差	0.0	0.1	0.1	0.1	0.2	0.1	0.0	0.1	0.0	0.0	0.1	0.0	0.1	0.0
实际值	149.2	169.4	189.0	228.8	249.6	270.4	291.0	310.2	331.2	350.6	377.8	395.0		
测量值	149.0	169.4	189.1	229.0	249.6	270.4	290.9	310.2	331.3	350.6	377.9	395.0		
误差	0.2	0.0	0.1	0.2	0.0	0.0	0.1	0.0	0.1	0.0	0.1	0.0		

4 结语

用神经网络补偿的方法实现非线性传感特性的线性化,可以扩大测量系统量程和减小非线性误差,并且补偿环节采用计算机软件实现,从而降低补偿环节的成本,提高了系统的可靠性;另外,本文采用遗

传算法和 BP 算法相结合对神经网络进行学习训练, 克服了遗传算法和 BP 算法的缺点, 使得神经网络学习收敛速度快且精度高. 该方法不仅可以用于测量系统, 也可以用于非线性逆控制, 改善控制系统的动态特性.

[参考文献]

- [1] 金篆荃, 王明时. 现代传感器[M]. 北京: 电子出版社, 1995.
- [2] Antonio B, Gaetano C. Optimal design of multivariate sensor[J]. Measure Sci and Tech. 1994, 4(5): 319~ 322.
- [3] 冯之敬, 刘金凌, 等. 测量与控制系统中非线性特性的不失真线性化方法[J]. 清华大学学报(自然科学版), 1996, 36(8): 18~ 23.
- [4] Dempsey G I, Alig J S, *et al.* Control Sensor Linearization using Artificial Neural Network[J]. Analog Integrated Circuits and Signal Processing. 1997, 13(3): 321~ 322.
- [5] 王庆玮, 王安, 等. 色度传感器非线性误差校正的神经网络模型[J]. 传感器技术, 1998, 17(2): 299~ 300.
- [6] 庄哲民, 黄惟一, 等. 提高传感器精度的神经网络方法[J]. 计量学报, 2002, 23(1): 78~ 80.
- [7] Vladik K. Genetic Algorithms: What Fitness Scaling is Optimal[M]. Cybernetic and System, 1993(24), 9~ 26.
- [8] 徐丽娜. 神经网络控制[M]. 哈尔滨: 哈尔滨工业大学出版社, 1999, 91~ 101.
- [9] 闻新, 周露, 王丹力, 熊晓英. MATLAB 神经网络应用设计[M]. 北京: 科学出版社, 2000.

Linearization of Sensor s Nonlinearity by Using Genetic Algorithms and Neural Network

Liu Qing

(College of Mathematics Science and Computer Science, Nanjing Normal Univ, 210042, Nanjing, PRC)

Abstract: The sensor s nonlinearity of measurement is usually linearized by means of the least square method and the first approximation etc. . Therefore, a nonlinear error will be made which limits the accuracy and performance of the system. In this paper, a method is put forth that linearizes sensor s nonlinearity by using genetic algorithms and neural network. With the method used, the nonlinear model of the measuring system can be retrofitted into a non-distortion linear model that is consistent with the actual physical process, and the nonlinear error of the system can be greatly reduced. An example is introduced, with the experimental results showing that the method is practicable.

Key words: measurement, nonlinearity, linearization, error, neural network, genetic algorithms

[责任编辑: 刘健]