

基于神经网络逆运算的传感器非线性误差补偿

张小勇^{1,2}, 刘清^{1,2}

(1 南京师范大学计算机科学与技术学院, 江苏 南京 210097)

(2 江苏省信息安全技术工程研究中心, 江苏 南京 210097)

[摘要] 提出了一种采用神经网络逆运算补偿传感器非线性误差的方法. 该方法先通过静态标定得到实验数据, 然后采用单输入/单输出的模糊小脑神经网络(SISO FCMAC)建立传感器静态非线性模型, 再由 SISO FCMAC 的逆运算建立静态逆模型. 与直接用神经网络建立逆模型的补偿方法相比较, 具有学习简单、精度高和可在线标定等优点, 且算法可以在单片机上实现. 最后, 通过实验验证了该方法的有效性.

[关键词] 测量, 非线性特性, 神经网络, 逆运算

[中图分类号] TP18 [文献标识码] A [文章编号] 1001-4616(2010)04-0172-05

Nonlinear Error Compensation of Sensor Based on Neural Network Inverse Operation

Zhang Xiaoyong^{1,2}, Liu Qing^{1,2}

(1. School of Computer Science and Technology, Nanjing Normal University, Nanjing 210097, China)

(2. Jiangsu Research Center of Information Security & Confidential Engineering, Nanjing 210097, China)

Abstract This paper presents a method to compensate non-linearity of sensor using. With static calibration of experimental data, the nonlinear model of the sensor is built on a Single Input Single Output Fuzzy Cerebellar Model Articulation Controller (SISO FCMAC), and the inverse model is established by inverse operation of SISO FCMAC. This method is compared with the direct use of neural network inverse model compensation, with the advantages of simple study, high precision and of online calibration, and algorithm can be implemented on the MCU. Finally, the experimental results show that the scheme is effective.

Key words measurement, nonlinear characteristics, neural network, inverse operation

传感器的误差大小直接影响到测控系统的性能,而非线性误差是传感器的主要误差.为了消除或补偿传感器的非线性误差,国内外不少学者提出了非线性传感特性线性化的神经网络方法^[1-4].由于神经网络(如 BP 网络)结构复杂,无法实现逆运算,所以,通过静态标定得到的实验数据,不能直接作为神经网络的学习数据.在这些方法中,大多数采用神经网络直接建立传感器静态非线性逆模型,即:在传感器的输出量程内取若干个点作为神经网络的输入,同时,以这些输出所对应的测量真值,作为神经网络的监督信号.而在实验装置中,由输出值确定输入值十分困难,这样,使学习样本点选取就受到一定的限制.另外,传感器的输出是存在一定噪声扰动的,且神经网络的学习算法大多以均方误差(Mean Squared-Error,即 MSE)为准则.而在有输入噪声扰动下,采用 MSE 为准则的学习算法,会使神经网络的权值存在一定的偏差^[5],影响到补偿效果.为此,本文研究了一种具有逆运算功能的单输入/单输出模糊小脑神经网络(Single-Input Single-Output Fuzzy Cerebellar Model Articulation Controller,即 SISO FCMAC).在传感器非线性误差补偿时,先采用静态标定的实验数据作为学习样本,由 SISO FCMAC 直接建立传感器静态非线性模型;再通过 SISO FCMAC 的逆运算建立静态逆模型.该方法具有收敛速度快、算法简单和补偿直接输出的特点.

收稿日期: 2010-06-10

基金项目: 国家自然科学基金(60774060).

通讯联系人: 张小勇, 实验师, 研究方向: 智能控制与模式识别. E-mail: 0521@njjnu.edu.cn

1 单输入 / 单输出小脑神经网络 (SISO CMAC)

为了有效的逼近传感器静态非线性函数 $f(\bullet)$, 我们在这里研究了一种单输入单输出 (SISO) 的模糊小脑神经网络 (SISO-FCMAC).

1.1 SISO-FCMAC 的结构

SISO-FCMAC 结构如图 1 所示, S_k 为输入量 v 的量化值. 量化的方法是:

$$R_s = (v_{\max} - v_{\min}) / (N - 1), \quad (1)$$

$$S_k = \text{int}(v - v_{\min}) R_s = k, \quad (2)$$

其中, v 取值范围为 $[v_{\min}, v_{\max}]$, N 为量化等级, R_s 为等间距的量化步长, $\text{int}(\ast)$ 是取整函数. 对任意输入的 v , 将其量化成 $0 \sim N - 1$ 范围内的一个整数 $S_k = k$. 通过用直接映射方法找到将要激活的 2 个权值的首地址 $a_k = k$, 故 SISO-FCMAC 中不存在 hash 映射压缩. 为了增强 SISO-FCMAC 的泛化能力, 引入了一个模糊算子 Ω . Ω 通过对 v 进行模糊化得到, 设 v 的量化值为 k , 模糊化过程为

$$\begin{cases} m_k = (v - v_{\min}) R_s - k, \\ \mu_k(v) = 1 - m_k, \\ \mu_{k+1}(v) = m_k, \\ \mu_j(v) = 0 & j \neq k, k + 1 \end{cases} \quad (3)$$

这样, 输入 v 所对应的模糊算子:

$$\Omega = [\mu_0(v), \mu_1(v), \mu_2(v), \dots, \mu_N(v)],$$

v 对应的 SISO-FCMAC 输出为:

$$p = \mathbf{W} \Omega^T = \sum_{i=0}^N \mu_i(v) w_i = \sum_{i=k}^{k+1} \mu_i(v) w_i \quad (4)$$

权值 $\mathbf{W} = [w_0, w_1, w_2, \dots, w_N]$ 通过学习得到.

1.2 SISO-FCMAC 的学习过程

在每一个量化区间 S_i 上, 随机选取一个输入样本点 $v_i (i = 0, 1, 2, \dots, N - 1)$, v_i 所对应的网络实际输出和希望输出为 p_i 和 p_{di} . 这样得到训练样本点的集合, 即 $\{(v_0, p_{d0}), \dots, (v_{N-1}, p_{dN-1})\}$. 设误差 $e_i = |p_i - p_{di}|$, 能量函数为

$$E = \frac{1}{2} \sum_{i=0}^{N-1} e_i^2 = \frac{1}{2} \sum_{i=0}^{N-1} (p_i - p_{di})^2. \quad (5)$$

学习训练采用梯度下降法, 由式 (4) 可知, 在区间 $[v_{\min} + kR_s, v_{\min} + (k + 1)R_s]$ 内的 v_i , 每次训练只影响 2 个权值 w_k 和 w_{k+1} , 权值调整具体如下:

$$\begin{cases} \frac{\partial E}{\partial w_k} = \mu_k(v_i) e_i \\ \frac{\partial E}{\partial w_{k+1}} = \mu_{k+1}(v_i) e_i. \end{cases} \quad (6)$$

SISO-FCMAC 的权值参数调整为

$$\begin{cases} \Delta w_k = \beta \mu_k(v_i) e_i \\ \Delta w_{k+1} = \beta \mu_{k+1}(v_i) e_i \end{cases} \quad (7)$$

其中, β 为学习率.

1.3 SISO-FCMAC 的收敛性分析

由于样本集合中的第 i 训练点 (v_i, p_{di}) , 其量化区间为 $S_i = i$ 所以, 在引入模糊算子 Ω 后, v_i 的联想向量 $\mathbf{L}(i)$ 为

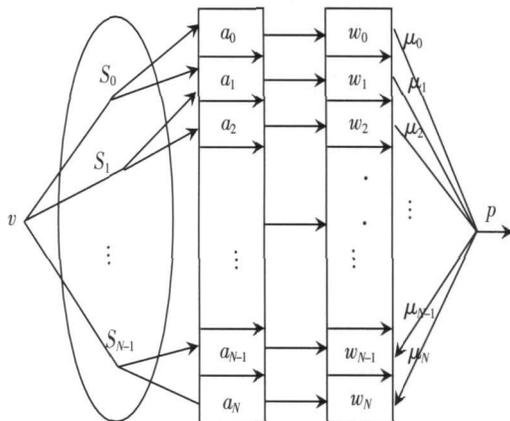


图 1 SISO FCMAC 结构

Fig.1 The SISO FCMAC structure diagram

$$L(i) = \{ \underbrace{0 \dots 0}_i, 1 - m_i, m_i, \underbrace{0 \dots 0}_{N-i-1} \}$$

m_i 为 v_i 所对应的模糊值. 当 v_i 第 1 次学习时, SISO-FCMAC 的输出误差为

$$e_i(1) = p_{di} - \mathbf{W}L(i)^T, \tag{8}$$

则被第 i 个样本激活的存储单元中权值的修正量为

$$\Delta \mathbf{W}(1) = \beta e_i(1) \mathbf{L}(i). \tag{9}$$

因为 CMAC 具有局域泛化能力, 这种修正将对其他样本输出产生影响. 此时, 第 k 个样本的输出变为

$$p_k = \mathbf{W}L(k)^T + \Delta \mathbf{W}(1) \mathbf{L}(k)^T = \mathbf{W}L(k)^T + \beta e_i(1) \mathbf{L}(i) \mathbf{L}(k)^T = \mathbf{W}L(k)^T + \alpha_{ki} \beta e_i(1), \tag{10}$$

其中, $\alpha_{ki} = \mathbf{L}(i) \mathbf{L}(k)^T$ 表示第 k 和 i 样本的关联性, 显然 $\alpha_{ki} = c_{ki}$. 经过 l 次学习后, 令: $\Delta_i = \sum_l \beta e_i(l)$ 为累积权误差. Δ_i 对第 k 个样本的输出贡献为 $\alpha_{ki} \Delta_i$.

当 CMAC 算法收敛时, 随着 $e_i(l) \rightarrow 0$, $\Delta_i \rightarrow \text{const}$. 若可由 Δ_i 计算 \mathbf{W} , 则在网络算法中可以换一个角度, 将累积权误差 Δ_i 而不是将权值 \mathbf{W} 视为需要学习的变量, 这样 CMAC 的收敛问题便可转化为 Δ_i 的收敛问题. 设网络初始权值为 0 则对任意输入向量 v_k , 第 l 次学习的网络输出为

$$p_k(l) = \sum_{i=0}^{N-1} c_{ki} \Delta_i, \quad k = 0, 1, \dots, N-1 \tag{11}$$

学习的目的是使

$$p_k(l) = p_{dk}, \quad \text{即} \quad \sum_{i=0}^{N-1} c_{ki} \Delta_i = p_{dk} \tag{12}$$

写成矩阵形式有: $C \Delta = P$, 其中, $C = (c_{ij})$, $i, j = 0, 1, \dots, N-1$, $\Delta = [\Delta_0, \Delta_1, \dots, \Delta_{N-1}]^T$, $P = [p_{d0}, p_{d1}, \dots, p_{dN-1}]^T$. 矩阵 C 称为关联矩阵, 则根据 c_{ij} 的定义很容易得出 $C = LL^T$.

在采用增量学习算法时, 令 $C = R + D + U$, 其中 R, U 分别是 C 不含对角线元素的下三角和上三角阵, D 为 C 对角线元素构成的对角阵, 则由式 $C \Delta = Y$ 可得 CMAC 累积权误差的修正公式为^[6]

$$\Delta(l+1) = (I + \beta R)^{-1} (I - \beta(D + U)) \Delta(l) + \beta(I + \beta R)^{-1} P, \tag{13}$$

式 (13) 恰好是方程组 $C \Delta = P$ 的松弛迭代法的公式, β 是松弛因子. 根据线性方程组迭代理论^[6], 有如下引理:

引理 1 松弛迭代收敛的必要条件是松弛因子 ω 满足 $0 < \omega < 2$

引理 2 若 A 为正定矩阵, 当松弛因子 ω 满足 $0 < \omega < 2$ 时, 线性方程组 $AX = b$ 的松弛迭代恒收敛.

定理 1 SISO-FCMAC 网络的关联矩阵 C 有如下性质:

- ① C 为实对称矩阵, 所有元素均为非负整数;
- ② C 是正定矩阵.

定理 2 SISO-FCMAC 增量学习算法收敛的充要条件是学习率满足 $0 < \beta < 2$

定理 1 和定理 2 的证明见文献 [7].

2 SISO-FCMAC 的逆运算

SISO-FCMAC 的算法只涉及到 2 个参数, 在 SISO-FCMAC 通过正向学习得到权值 \mathbf{W} 后, 将 $S = \{S_0, S_1, \dots, S_{N-1}\}$ 中每一个 S_i 作为 v_i 由公式 (3) 和 (4) 的计算, 建立起 S 所对应的输出表 $Y = f(S) = \{Y_0, Y_1, \dots, Y_{N-1}\}$, 可对 SISO-FCMAC 的任意输出 p , 进行逆运算.

- 1) 通过查输出表 Y , 确定 p 在表中的位置 k
- 2) 由 (4) 式可得

$$y = \mu_k(v) w_k + \mu_{k+1}(v) w_{k+1} = (1 - m_k) w_k + m_k w_{k+1} \tag{14}$$

对 (14) 式求解, 并结合 (3) 式可得 p 的逆运算为

$$\begin{cases} m_k = (p - w_k) / (w_{k+1} - w_k), \\ v = (k + m_k) \times R_s + v_{in}, \end{cases} \tag{15}$$

其中 v 为逆运算结果.

如果 SISO-FCMAC 的权值 W 对应非线性函数 $f(\bullet)$, 则通过逆运算得到的函数为 $F(\bullet)$, 它是 $f(\bullet)$ 的反函数 $f^{-1}(\bullet)$, 即有: $F(p) = F[f(v)] = f^{-1}[f(v)] = v$. 所以, 先通过静态标定得到传感器的实验数据; 再由神经网络的学习, 建立传感器的静态逆模型; 最后, 由 SISO-FCMAC 的逆运算, 实现传感器的静态逆模型, 消除静态非线性误差.

3 仿真分析

为验证 SISO-FCMAC 学习收敛和泛化能力, 作者用 SISO-FCMAC 对 $\cos(x)$ 函数在 $[0 \sim \pi]$ 之间的逼近能力进行了仿真试验. 在实验中, $R_s = \pi/10$ 随机抽取 $l = 40$ 个样本点对网络进行了训练. 作者按下列公式进行了误差分析: $e_i = |y_i - y_{di}|$, $aver = \sum e_i / l$, $max = \text{MAX}\{e_i\}$, 其中, y_{di} 希望输出, y_i 实际输出. 经过 150 次训练后, 网络收敛, $max = 0.00234$, $aver = 0.0003475$. 为了验证网络的泛化能力, 在 $[0 \sim \pi]$ 之间任意选取了 200 个点, 经过网络泛化后, 误差分析的结果是: $max = 0.00298$, $aver = 0.0005347$. 泛化误差如图 2 所示. 所以, 通过仿真试验表明, SISO-FCMAC 具有学习简单、收敛速度快和泛化能力强的特点.

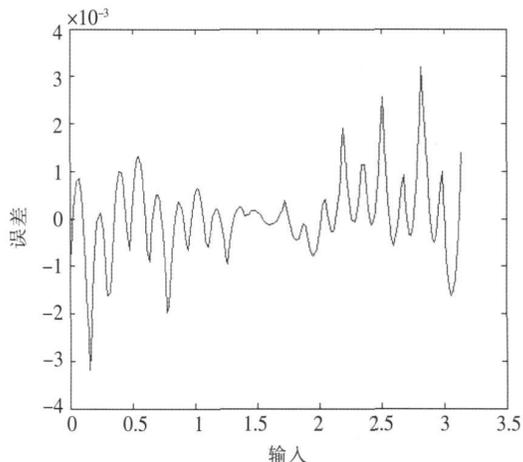


图 2 泛化误差
Fig.2 Generalized error

4 实验和结果

热敏电阻作为测温传感器, 在自动测温系统得到了广泛应用. 但是, 热敏电阻温度的传感特性存在严重的静态非线性, 热敏电阻的阻值与温度之间的关系可表示为

$$y = R_t = f(t) = R_0 \exp \left[B \left(\frac{1}{T} - \frac{1}{T_0} \right) \right]. \quad (16)$$

目前, 有许多人研究了采用神经网络作为补偿环节, 进行热敏电阻传感器的非线性补偿^[8], 但是, 这些方法都是直接建立传感特性的反函数, 由于在实验装置中, 通过输出电压值确定输入温度值十分困难, 这就使学习样本点选取受到一定的限制. 为此本文提出了通过 SISO-FCMAC 直接建立热敏电阻非线性函数, 再通过 SISO-FCMAC 的逆运算建立反函数的误差补偿方法.

选取某国产北陆热敏电阻传感器 (150-202-97006) 进行了实验. 该传感器在 $-50^\circ\text{C} \sim 50^\circ\text{C}$ 的传感特性存在严重的非线性误差. 采用 SISO-FCMAC 进行补偿实验. 将传感器的温度测量范围 $[-50^\circ\text{C}, 50^\circ\text{C}]$ 等分成 40 个小区, 得到热敏电阻传感器的输入量化表 $S = \{S_0, S_1, \dots, S_{39}\}$, 在每个小区间随机抽取 1 个点, 得到输入样本点 $T = \{t_0, t_1, \dots, t_{39}\}$; 通过恒温箱设定温度 t_k 并通过测量电路得到热敏电阻的输出电压 $U = \{u_0, u_1, \dots, u_{39}\}$; 将 $T = \{t_0, t_1, \dots, t_{39}\}$ 作为 SISO-FCMAC 学习的输入样本点集合, $U = \{u_0, u_1, \dots, u_{39}\}$ 作为 SISO-FCMAC 学习的希望输出样本点集合. 通过式 (7) 的学习, 得到传感器非线性函数所对应的 SISO-FCMAC 的权值 W . 将 $S = \{S_0, S_1, \dots, S_{39}\}$ 中每一个 S_i 作为 v_i 由公式 (3) 和 (4) 的计算, 建立起 S 所对应的输出表 $Y = f(S) = \{y_0, \dots, y_{39}\}$. 在补偿非线性误差时, 将传感器测量输出的电压 u 作为式 (15) 的 p , 先通过查输出表 Y , 确定 p 在表中的位置 k , 再通过式 (15) 的计算, 得到逆运算结果 v_k 将其作为测量温度的真值 t . 由于 SISO-FCMAC 的权值 W 对应热敏电阻传感特性的非线性函数 $f(\bullet)$, 则通过逆运算得到的函数为 $F(\bullet)$, 它是 $f(\bullet)$ 的反函数 $f^{-1}(\bullet)$, 即有:

$$F(u) = F(p) = F[f(v)] = f^{-1}[f(v)] = v = t$$

可以消除热敏电阻的非线性误差. 作者对采用该方法对传感特性线性化后的测温系统误差进行了分析. 设 $e_i = |t_i - t|$, 平均误差 $E = \sum e_i / m$, 其中 t_i 是希望测量的温度值, t 是实际测量的温度值, m 是测量点的数量. 随机选择 60 个测量点, 线性化后测温系统的分辨率为 0.1°C , 测温系统误差如图 3 所示, 最大误差为 0.075°C , 平均误差 $E = 0.035^\circ\text{C}$.

5 结语

为了实现高精度的传感器非线性误差补偿, 本文提出了采用一种单输入/单输出的小脑神经网络(SISO-CMAC)逆运算补偿传感器非线性误差的方法, 分析并证明了 SISO-CMAC 算法在增量学习方式下的收敛性. 最后, 将 SISO-CMAC 算法应用到一个热敏电阻传感器的非线性误差中, 实验结果表明, 采用 SISO-CMAC 算法可以有效地减小测量系统的非线性误差, 提高传感器的测量精度.

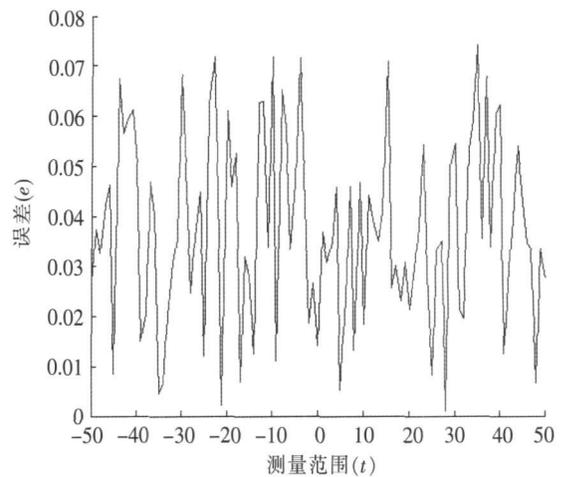


图 3 测温系统误差

Fig.3 Temperature measurement system error

[参考文献]

- [1] Stubbenud S C, Kramer K A, Geramian J A. Online sensor modeling using a neural Kalman filter[J]. IEEE Trans Instrum Meas 2007, 56(4): 1451-1458
- [2] Marconato A, Hu M Q, Boni A. Dynamic compensation of nonlinear sensors by a learning-from-examples approach[J]. IEEE Trans Instrum Meas 2008, 57(8): 1689-1694
- [3] Wang J S, Chen Y P. A hammerstein recurrent neurofuzzy network with an online minimal realization learning algorithm[J]. IEEE Trans Fuz Sys 2008, 16(6): 1597-1612
- [4] Yu D H, Li F, Lai P Y. Nonlinear dynamic compensation of sensors using inverse model based neural network[J]. IEEE Trans Instrum Meas 2008, 57(10): 2364-2376
- [5] Rao Y N, Erdogmus D, Rao G Y, et al. Fast error whitening algorithms for system identification and control with noisy data[J]. Neurocomputing 2005, 69(1): 158-181.
- [6] 丁丽娟. 数值计算方法[M]. 北京: 北京理工大学出版社, 1997.
- [7] 刘清. 人工神经网络算法的改进及其在水利测量技术中的应用[D]. 南京: 河海大学水利水电工程学院, 2005
- [8] 俞阿龙. 基于 RBF 神经网络的热敏电阻温度传感器非线性补偿方法[J]. 仪器仪表学报, 2007, 28(5): 899-902

[责任编辑: 顾晓天]