

文章编号:1671-7333(2015)02-0144-05

DOI:10.3969/j.issn.1671-7333.2015.02.009

基于并联逆的超声波液位传感器故障误差补偿方法

李 炜, 黄 超, 申富媛

(兰州理工大学 电气工程与信息工程学院, 兰州 730050)

摘 要: 针对过程控制系统(PCS)液位控制单元中超声波液位传感器故障引起的非线性误差,基于神经网络建模方法设计了一种并联逆补偿环节,有效地补偿了故障误差对系统的影响。通过实验分别获得故障传感器与正常传感器测得的液位值,并进行相应的预处理;基于上述离线数据,分别利用 LM-BP、径向基函数(RBF)神经网络的非线性逼近特性,设计逆映射中的并联补偿环节;为验证传感器故障误差的补偿效果,基于 OPC 技术与 Matlab 搭建了 PCS 半实体实验平台,将设计的并联补偿环节置于搭建的 PCS 液位控制单元中进行闭环实验。结果表明,所建方法能有效补偿传感器故障产生的非线性误差,抑制了故障影响在系统中的传播,实体实验也显现了方法的工程可用性。

关键词: 传感器; 并联补偿; 径向基函数神经网络; LM-BP 神经网络

中图分类号: TP 212.9

文献标志码: A

Ultrasonic Level Sensor Fault Error Compensation Based on Parallel Inverse Method

LI Wei, HUANG Chao, SHEN Fuyuan

(College of Electrical and Information Engineering, Lanzhou University of Technology,
Lanzhou 730050, China)

Abstract: Considering the nonlinearity error caused by the ultrasonic level sensor fault in process control system (PCS) level control, a parallel inverse link of compensation was presented based on the method of neural network modeling, which could compensate the effect of fault error. Firstly, the measurement of fault error and actual level were obtained through experiments, and the corresponding pretreatment was done. Then based on the above offline data, the parallel compensation link of the inverse mapping was designed by using the nonlinear approximation properties of Levenberg-Marquardt back propagation (LM-BP) and radial basis function (RBF) neural network. In order to verify the validity and the actual availability of the compensation method, a PCS semi-entity experimental platform was established based on OPC and Matlab technology, etc. The parallel compensation link designed in this paper was placed in level control unit of PCS and closed-loop experiments were implemented. The results showed that the method was effective to compensate the failure nonlinear error for ultrasonic level sensor that inhibited the influence on the system propagation, and suitable to apply in practical engineering.

Key words: sensor; parallel compensation; radial basis function neural network; LM-BP neural network

收稿日期:2015-01-14

基金项目:国家自然科学基金资助项目(61364011);甘肃省自然科学基金资助项目(1212RJZA002);兰州理工大学基金(03-0099)

第一作者:李 炜(1963-),女,教授,博士生导师,主要研究方向为动态系统故障诊断与容错控制、工业过程先进控制等。

E-mail: hc2097@126.com

液位是石油、化工、气象等诸多领域应用最为广泛的观测量之一,随着技术的发展,无接触、智能化测量已成为当前液位测量的主流。而超声波液位传感器由于对被测介质不产生干扰,无污染、无泄漏、无腐蚀,同时具有成本低、安装维护方便、可靠性高、技术难度相对较低等优点,更是广泛应用于工业生产中。但是,此类传感器在工业中常处于温度与湿度多变的恶劣环境下,较易出现各种故障,尤其当其参与闭环控制时,故障产生的错误数据会经反馈通道通过操纵控制器变量迅速传播至整个控制系统,使系统性能下降甚至崩溃^[1];此外,已产生故障的传感器更换中断也会给企业带来经济损失。因此,针对超声波液位传感器故障引起的误差进行补偿与修正就成为亟待解决的问题。

当今,传感器已是无处不在,各类误差也无法避免,基于硬件补偿的传统方法^[2]由于成本高,灵活性差已非主流;基于模型的补偿方法^[3-4]也因难以建立精确的机理模型在实际应用中受到了限制;基于数据驱动的智能方法^[5-8]却因可逼近任一连续函数以及现代工业数据的丰富储备,在传感器非线性误差补偿中受到了青睐。近年来,无论是针对单一传感器^[9-12],还是多传感器^[13-14]误差,无论是静态^[15]亦或动态^[16]误差,不难看出,借助各类神经网络设计补偿环节应是最为普遍和热宠的。鉴于此,本文针对超声波液位传感器故障引起的非线性误差,基于逆系统方法,分别将 LM-BP 与径向基函数(RBF)神经网络用于误差并联补偿环节的设计,并通过搭建过程控制系统(PCS)半实体液位控制实验平台,对方法的有效性与可用性进行了实验研究。

1 超声波液位传感器故障误差逆补偿设计

1.1 超声波液位传感器故障误差并联逆补偿原理

超声波液位传感器故障误差并联逆补偿原理见图 1。图中, u 为执行器输出; h_a 为被控对象实际液位值; w 为传感器所处工作环境产生的外部输入; $h=f(h_a)$ 为故障传感器测得的液位值; \hat{h} 为补偿后实际液位估计值; e 为已测得的 h_a 与 h 差,即故障传感器引起的误差; \hat{e} 为补偿环节液位误差估计值。




图 1 传感器故障误差并联逆补偿原理图

Fig. 1 Sensor fault error of parallel inverse compensation principle diagram

考虑故障传感器产生的误差与实际液位值之间的映射很多情况下是非线性的,因此,若能通过设计图 1 中虚线框内系统构成式(1)的映射,便可得到液位的估计值

$$\hat{h}_a = f^{-1}[f(h)] \quad (1)$$

式中, f^{-1} 为 f 的逆映射。

由式(1)可知,补偿环节设计的实质是寻求 f 的精确逆映射 f^{-1} ,即建立 h_a-h 的逆系统模型。而结合图 1 易得,式(1)还可表示为并联形式,即

$$\hat{h}_a = f^{-1}[f(h)] = h + \hat{e} = h_a - e + \hat{e} \quad (2)$$

由于 h 为故障传感器的输出,为已知量,故只需构建虚线框内补偿部分,即为建立非线性映射(3),便可实现超声波液位传感器故障引起误差的补偿

$$\hat{e} = g(h) \quad (3)$$

由此可知,并联逆补偿实际是为寻求非线性映射 g ,只要使 \hat{e} 以足够精度逼近 e ,也就确保了 \hat{h}_a 。以足够精度逼近 h_a ,从而实现超声波液位传感器故障引起误差的补偿。

由于实际工程中,超声波传感器故障产生的误差与测量值之间机理很难分析,这就使得传统的机理建模法很难建立起 $h-e$ 之间精确表达式,故应用中常常受限。近年来,由于计算机与数据驱动技术的飞速发展,以数据为基础的建模方法已使任意非线性关系的逼近变得不再困难,也就使基于图 1 所示的并联逆补偿方法有了更广泛的应用价值。

1.2 基于神经网络的并联逆补偿环节设计

1.2.1 并联逆补偿环节设计流程

由于超声波液位传感器故障时的测量值与故障引起的误差 e 往往表现为非线性的映射关系,而在数据驱动技术中神经网络是最常用的建模方法^[15]。考虑到反向传播(BP)神经网络存在易陷入局部极小值、收敛速度慢等缺陷,本文分别采用 LM-BP、RBF 神经网络,建立 $h-e$ 之间的非线性模型,并用于并联逆补偿的设计。设计步骤如下:

(1) 在 PCS 液位控制系统开环情形下,考虑到 LM-BP 与 RBF 模型的泛化能力,在受控对象较为宽泛的液位区域,分别用正常与故障传感器采集正常传感器测得的实际液位值 h_a 与故障传感器测得的液位值 h ;

(2) 对 h_a 、 h 进行剔除野值等预处理,计算 $e = h_a - h$,组成样本集 $[h, e]$;

(3) 采用 LM-BP 与 RBF 神经网络分别建立 $h-e$ 的非线性映射 g ,完成并联逆补偿环节的设计。

1.2.2 LM-BP 算法

由于 RBF 网络的使用已极为广泛,只对 LM-BP 作简单介绍. LM 算法的突出特点是能够根据迭代的结果动态调整阻尼因子,从而动态地调整其迭代的收敛方向,因此可使每次的迭代误差函数值都有所下降,而且不用计算海森矩阵却有着二阶导数的训练速度. 该算法的核心思想是对高斯-牛顿法添加了一个非负的对角矩阵使其强迫正定. 具体算法可描述如下:

通常神经网络连接权的调整为

$$\omega_{k+1} = \omega_k + \Delta\omega \quad (4)$$

BP 算法的训练目的是希望训练样本与网络的输出之间的误差平方和最小,即将误差平方和作为要优化的目标函数

$$E(\omega) = \frac{1}{2} \sum_i^N (d_i - y_i)^2 = \frac{1}{2} e^T(\omega) e(\omega) \quad (5)$$

式中, d_i 与 y_i 分别是网络期望输出与实际输出.

根据牛顿算法可得

$$\Delta\omega = -H_k^{-1} g_k \quad (6)$$

式中,误差函数的海森矩阵为

$$H = J^T(\omega)J(\omega) + S(\omega) \quad (7)$$

$$S(\omega) = \sum_{k=1}^N e_i(\omega) \nabla^2 e_i(\omega) \quad (8)$$

式中, J 为误差对权值的雅可比矩阵,其计算公式为

$$J = \begin{bmatrix} \frac{\partial e_1(\omega)}{\partial \omega_1} & \frac{\partial e_1(\omega)}{\partial \omega_2} & \dots & \frac{\partial e_1(\omega)}{\partial \omega_n} \\ \frac{\partial e_2(\omega)}{\partial \omega_1} & \frac{\partial e_2(\omega)}{\partial \omega_2} & \dots & \frac{\partial e_2(\omega)}{\partial \omega_n} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial e_N(\omega)}{\partial \omega_1} & \frac{\partial e_N(\omega)}{\partial \omega_2} & \dots & \frac{\partial e_N(\omega)}{\partial \omega_n} \end{bmatrix} \quad (9)$$

高斯-牛顿法中的 $S(\omega)$ 通常很小,可忽略不计,此时 Hessian 矩阵可近似为

$$H \approx J^T(\omega)J(\omega) \quad (10)$$

同时,梯度可表示为

$$g = J^T(\omega)e(\omega) \quad (11)$$

由于雅可比矩阵的计算相比通过 Hessian 矩阵的计算简单,因此高斯-牛顿算法的权值更新简化为

$$\Delta\omega = -[J^T(\omega)J(\omega)]^{-1} J^T(\omega)e(\omega) \quad (12)$$

为使式(12)均有意义,式(10)必须非奇异,即 H 可逆,LM 算法正是通过添加修正量使海森矩阵可逆的,新的海森矩阵 H_n 可表示为

$$H_n = J^T(\omega)J(\omega) + \mu I \quad (13)$$

LM 算法近似的权值更新可表示为

$$\omega_{k+1} = \omega_k - [J^T(\omega)J(\omega) + \mu I]^{-1} J^T(\omega)e(\omega) \quad (14)$$

当 μ 为 0 时,算法用 Hessian 矩阵的牛顿法;当

μ 很大时,则变成了小步长的梯度下降法. LM 算法正是通过增加 μI ,使得 $[J^T(\omega)J(\omega) + \mu I]$ 必可逆,网络收敛.

2 PCS 半实体实验系统的搭建

2.1 PCS 平台结构及液位控制实体单元选择

PCS 是德国 FESTO 公司研制的一套连续生产过程实验装置. 该装置由液位控制、流量控制、压力控制和温度控制 4 个工作单元组成,并以西门子 S7-300 作为下位机进行各站的配置. 各单元可独立运行,也可与其他单元柔性连接,并以模块化的结构近似模拟实际工业生产的控制过程.

本文选取 PCS 装置中的液位控制单元作为实验被控对象的原因为:由于该装置长期使用,超声波液位传感器已出现乘性与加性故障,使得系统已无法正常工作;考虑到液位是工业生产过程中较为常见的被控参数,而 PCS 装置上水箱容积小、管道短,对应的时间常数与滞后性均较小,便于观察并易于测量;选择实体液位受控对象,并对真实的超声波液位传感器故障误差设计相应的并联逆补偿环节,进行方法的有效性与可用性研究,其结果会更有价值.

2.2 液位传感器故障误差补偿闭环半实体系统架构及其实现

液位传感器故障误差补偿闭环半实体系统架构的搭建^[17]如图 2 所示. 图中,PC 机作为 OPC Client,并配置有 MATLAB R2010b,利用该软件实现 PID 及 LM-BP、RBF 并联逆补偿算法设计、液位实时监控分析等;西门子 S7-300 PLC、Simatic Net 作为 OPC Server,实现 PC 机 MATLAB 中控制量发送与液位控制单元液位检测量的接收;Ethernet 作为 PLC 与 PC 机的通信媒介. 通过相应的硬件、软件及网络设置与编程,即可构建起液位传感器故障误差补偿闭环半实体系统架构图.

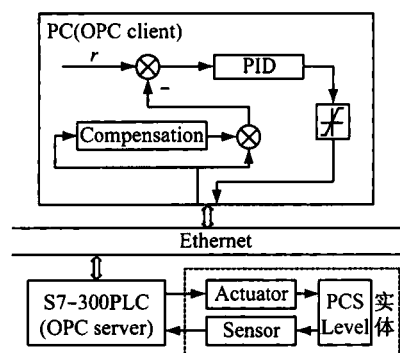


图 2 液位传感器故障误差补偿闭环半实体系统架构图
Fig. 2 Architecture diagram of level sensor fault error compensation loop semi-entity system

半实体液位控制系统 MATLAB 如图 3 所示. 具体实现过程是:OPC Read1 与 OPC Read2 模块分别读取的是 S7-300 PLC 存储单元 MREAL80 与 MREAL82 中的数据,即故障与正常传感器所测得的液位值,故障传感器的输出送入 Compensation 模块,经补偿后获得实际液位估计值,需将所读取的液位值与时间截存储到工作空间中. 经 PID 的控制量由 OPC Write 输出,送至 PLC 模拟变量模块输出端口 QW0 中;由于水泵正常工作电压范围为 0~10 V,故需对 PLC 输出的 0~5 V 模拟量电压转换成 0~10 V 电压,从而控制水泵的抽水速度;在仿真回路中还加入了 Saturation 非线性饱和模块限幅,防止水泵长时间工作处于过载状态.

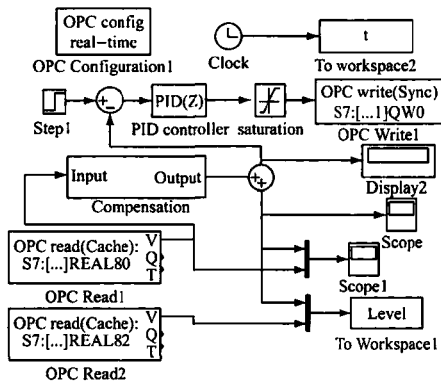


图 3 半实体液位控制系统 MATLAB 实现


Fig. 3 MATLAB implementation of semi-entity level control system

3 实验研究


3.1 逆补偿环节建模

因工艺技术限制,PCS 实验平台水箱实际液位的可控范围是 20~300 mm,考虑到模型的泛化能力,在此区间内开环采集离线数据. 先将水泵关闭,水箱底部排水管道阀门保持适当开度,通过正常传感器与故障传感器分别测得水箱液位值 h_a 与 h ,并存储到 MATLAB 工作空间中;之后需对所采集的数据进行剔除野值、求偏差等预处理. 考虑到数据可能具有的规律性,将数据随机排序进行训练、测试. 采集数据样本的 75% 作为训练,25% 作为测试. 利用 MATLAB 仿真软件分别采用 LM-BP 神经网络、RBF 神经网络进行离线建模,模型的输入为 h 、输出为 e ,上述两种神经网络隐含层节点均为 3,不同模型的预测结果如图 4 与表 1 所示.

由图 4 和表 1 可见,经 RBF 与 LM-BP 神经网络补偿之后,超声波液位传感器误差修正值偏差 $e - \hat{e}$ 均可控制在 ± 0.5 mm 内;补偿的均方误差



(a) LM-BP



(b) RBF

图 4 LM-BP 和 RBF 神经网络预测

Fig. 4 LM-BP and RBF neural network prediction

表 1 不同补偿模型的性能比较

Tab. 1 Performance comparison of different compensated ways


补偿误差	LM-BP 网络	RBF 网络
MSE	0.032 9	0.029 6
MAXE	0.455 6	0.443 2

(MSE)、最大绝对误差 (MAXE) 均较小,都表现出较高的补偿精度与泛化能力.


3.2 传感器故障误差补偿闭环实验

由前述实验分析可知,LM-BP 与 RBF 神经网络对于超声波液位传感器故障产生的误差均具有较好的非线性逼近能力,故将其分别置入图 2 的 Compensation 模块. 给系统施加 100 mm 的阶跃给定,

采用 PI 控制, 整定参数 $K_P=277, K_I=6$, 取采样周期为 0.5 s、实验时间为 300 s。超声波液位传感器补偿前后系统阶跃响应曲线如图 5 所示。图中曲线为故障传感器引入两种神经网络补偿环节前后, PCS 闭环系统的正常传感器所指示的实际液位值, 即图 3 中 OPC Read2 所读出的数据。由图可见, 补偿前系统阶跃响应不仅动态性能差, 且最终平衡于 140 mm 处; 而经两种神经网络分别补偿后, 系统响应的动态性能明显改善, 最终输出稳定于给定值 100 mm 处。由此说明, LM-BP 与 RBF 神经网络针对超声波液位传感器故障误差进行的逆补偿均是有效可行的, 由于实验结果来自实体系统, 说明方法在实际中是可用的。



(a) LM-BP



(b) RBF

图 5 LM-BP 和 RBF 补偿前后系统阶跃响应

Fig. 5 System response without compensation and with LM-BP and RBF compensation

4 结 语

本文针对过程控制系统中超声波液位传感器故障引起的非线性误差, 分别设计了基于 LM-BP、RBF 神经网络的并联逆补偿环节。MATLAB 离线仿真训练得到的 LM-BP、RBF 神经网络均适合于超声波液位传感器故障的非线性特性; 将训练的 LM-BP、RBF 神经网络置入 PCS 半实体平台的并

联逆补偿环节中, 实验表明, 文中设计的补偿环节可使液位的最大绝对误差由 65.7 mm 降低到 0.5 mm, 很好地补偿了传感器故障引起的非线性误差, 抑制了故障非线性误差在闭环系统中的蔓延, 提高了系统控制性能, 确保了系统的安全性。

参考文献:

- [1] Wan Y, Ye H. Data-driven diagnosis of sensor precision degradation in the presence of control [J]. *Journal of Process Control*, 2012, 22(1): 26-40.
- [2] 余向东, 张在宣, 祝海忠, 等. 一种应用于分布式光纤拉曼温度传感器的温度补偿电路[J]. *中国激光*, 2010, 37(6): 1440-1444.
- [3] Jafaripana M, Al-Hashimi B M, White N M. Application of analog adaptive filters for dynamic sensor compensation[J]. *IEEE Transactions on Instrumentation and Measurement*, 2005, 54(1): 245-251.
- [4] Zhang Y, Wu Y, Xu Y, et al. Research of dynamic compensation method based on Hammerstein model for Wiener model sensor [C]//Control Conference (CCC). Xi'an China: IEEE, 2013: 1935-1939.
- [5] Patra J C, Meher P K, Chakraborty G. Development of Laguerre neural-network-based intelligent sensors for wireless sensor networks[J]. *IEEE Transactions on Instrumentation and Measurement*, 2011, 60(3): 725-734.
- [6] 景婧, 卢文科, 左锋, 等. 基于反馈调节器的应变式位移传感器非线性校正[J]. *东华大学学报: 自然科学版*, 2013, 39(3): 349-355.
- [7] 栗鹏飞, 杨永平. 提高太阳能热泵系统温度传感器测量准确性的研究[J]. *传感技术学报*, 2014, 27(8): 1017-1021.
- [8] Patra J C, Chakraborty G, Meher P K. Neural-network-based robust linearization and compensation technique for sensors under nonlinear environmental influences [J]. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2008, 55(5): 1316-1327.
- [9] Marconato A, Hu M, Boni A, et al. Dynamic compensation of nonlinear sensors by a learning-from-examples approach [J]. *Instrumentation and Measurement, IEEE Transactions on*, 2008, 57(8): 1689-1694.
- [10] Santhosh K V, Roy B K. An intelligent pressure measurement technique by capacitance pressure sensor using optimized ANN[J]. *ACEEE International Journal of Electrical and Power Engineering*, 2013, 4(1): 28-33.

(下转第 172 页)

参考文献:

- [1] 许域菲. 近空间飞行器非线性容错控制技术研究[D]. 南京:南京航空航天大学, 2011.
- [2] 高志峰. 复杂系统的容错控制技术及其在近空间飞行器中的应用研究[D]. 南京:南京航空航天大学, 2011.
- [3] 李怡勇, 沈怀荣, 李岩. 先进控制方法在飞行控制系统设计中的应用[J]. 飞航导弹, 2006, 35(12): 50-54.
- [4] 张新国, 张汝麟, 陈宗基. 飞行控制系统设计方法研究[J]. 航空科学技术, 1997, 8(1): 17-19, 31.
- [5] Kung C. Nonlinear H_∞ robust control applied to F-16 aircraft with mass uncertainty using control surface inverse algorithm[J]. Journal of the Franklin Institute, 2008, 345(6): 851-876.
- [6] 苗德乃. 飞机建模与控制仿真[D]. 北京:北京航空航天大学, 2003.
- [7] 黄书鹏, 王诗宓. 带状态观测器系统的鲁棒容错控制[J]. 控制理论与应用, 2001, 18(2): 249-252.
- [8] 谭珍珍. 大型民机飞行控制系统建模仿真研究[D]. 南京:南京航空航天大学, 2014.
- [9] 张剑, 谢刚涛, 余圣晖, 等. 民用飞机线性化仿真分析[J]. 航空科学技术, 2014, 25(5): 63-66.

(编辑 俞红卫)

(上接第 148 页)

- [11] 李亮, 杜利东, 赵湛, 等. 数字气压传感器的一种高效标定和补偿方法[J]. 传感器与微系统, 2014, 33(11): 44-47.
- [12] 高贯斌, 王文, 林铿, 等. 圆光栅角度传感器的误差补偿及参数辨识[J]. 光学精密工程, 2010, 18(8): 1766-1772.
- [13] 林海军, 滕召胜, 迟海, 等. 基于多传感器信息融合的汽车衡误差补偿[J]. 仪器仪表学报, 2009, 30(6): 1245-1250.
- [14] Arpaia P, Daponte P, Grimaldi D, et al. ANN-based error reduction for experimentally modeled sensors [J]. IEEE Transactions on Instrumentation and Measurement, 2002, 51(1): 23-30.
- [15] 黄世震, 林淑玲. 基于 GSA-BP 神经网络的压力传感器温度补偿[J]. 电子器件, 2013, 36(5): 680-684.
- [16] Schoen M P. Dynamic compensation of intelligent sensors[J]. IEEE Transactions on Instrumentation and Measurement, 2007, 56(5): 1992-2001.
- [17] 李二超, 李炜, 李战明, 等. 基于 OPC 技术的网络控制系统仿真平台设计[J]. 实验技术与管理, 2012, 29(6): 90-93.

(编辑 吕丹)

(上接第 166 页)

- [10] 叶世伟. 神经网络原理[M]. 北京:机械工业出版社, 2004.
- [11] 赵慧. 人工神经网络原理[M]. 北京:机械工业出版社, 2013.
- [12] 王兆安. 电力电子技术[M]. 北京:机械工业出版社, 2009.
- [13] 洪乃刚. 电力电子基础[M]. 北京:清华大学出版社, 2008.
- [14] Chen Y M, Chou H W, LEE Kungyen. Online failure prediction of the electrolytic capacitor for LC filter of switching-mode power converters[J]. IEEE Transactions on Industrial Electronics, 2008, 55(1): 400-406.
- [15] Chen S, Wang X X, Brown D J. Sparse incremental regression modeling using correlation criterion with boosting search[J]. IEEE Signal Processing Letters, 2005, 12(3): 198-201.
- [16] Feng H M. Self-generation RBFNs using evolutionary PSO learning[J]. Neurocomputing, 2006, 70: 241-251.

(编辑 俞红卫)