

神经网络数据融合在位移传感系统中的应用

朱海梅

(扬州大学 物理科学与技术学院, 江苏 扬州 225002)

[摘要] 温度漂移误差是位移传感系统的主要误差之一. 为了提高位移传感器输出的精度与稳定性, 可以把位移传感器的输出与温度传感器的输出进行数据融合. 提出一种基于 RBF 网络 (径向基函数神经网络) 的多传感器数据融合方法, 把位移传感器和温度传感器的输出送入融合中心, 通过 RBF 网络的学习训练, 得到稳定的位移输出. 实验表明: 在相同的温度波动情况下, 位移传感器的输出稳定性比原来提高了约 4 倍. 该方法在位移传感系统减小温度漂移的应用中十分有效.

[关键词] 数据融合, BP 神经网络, RBF 神经网络, 温度漂移

[中图分类号] TP212.6 [文献标识码] A [文章编号] 1672-1292(2006)01-0028-05

Application of Data Fusion Based on Neural Network for Displacement Sensing System

ZHU Haimei

(College of Physical Science and Technology, Yangzhou University, Yangzhou 225002, China)

Abstract The temperature drift error is one of the major errors of the displacement sensor system. In order to improve the accuracy and stability, the output from the displacement sensor and the one from the temperature sensor can be fused. At present, neural network has been widely applied to the area of data fusion, in which data from multiple sensors are mostly fused by BP neural network. The low training speed of BP network leads to the poor practicability, therefore in this paper, a data fusion method based on RBF neural network is proposed for reducing temperature drift error. The outputs from the displacement sensor and those from the temperature sensor are sent to the fusion center, where the RBF neural network is trained and as a result the stable output is obtained. Experiments show that the output stability of the displacement sensor is improved by 4 times under the same temperature fluctuation. It is obvious that the proposed method in this paper is effective for reducing the drift error of displacement sensor system.

Key words data fusion, BP neural network, RBF neural network, temperature drift

0 引言

多传感器数据融合技术是当前智能信息处理领域的一种重要方法. 单一的传感器数据采集量不足, 且易受到周围环境等干扰因素的影响, 因此很难保证其准确性和可靠性, 从而给系统决策的正确性造成影响. 而采用多传感器数据融合技术, 利用各种传感器在性能上的差异和互补可以弥补单一传感器的缺陷, 从而得到更为精确的结果. 很多学者从不同角度出发提出了多种数据融合技术方案, 常用的数据融合方法是多维回归分析法, 通过建立包括待消除的非目标参量在内的函数解析式, 来消除非目标参量对传感器的影响. 这种方法存在两个局限性: 第一, 该方法需建立严格的包括非目标参量在内的函数解析式; 第二, 该方法在求解时, 方程为多维矩阵, 方程可能为病态方程^[1, 2], 从而使求解受阻. 神经网络技术是模拟人类大脑而产生的一种处理技术, 它使用大量的神经元处理信息, 而神经元按层次结构的形式组织, 每层上的神经元以加权的方式与其它层上的神经元联接, 采用并行结构和并行处理机制, 因而网络具有很强的容错性以及自学习、自组织及自适应能力, 能够模拟复杂的非线性映射. 神经网络的这些特性和强大的非线性处

收稿日期: 2005-07-28
基金项目: 江苏省教育厅自然科学基金资助项目 (01KJB520007).
作者简介: 朱海梅 (1973-), 女, 讲师, 主要从事智能控制方面的教学与研究. E-mail: littlezhu@yzu.net

理能力, 恰好满足了多传感器数据融合技术处理的要求, 因而近年来得到了较快的发展和一定的应用^[3~5]. 然而, 已有的这些方法都是用 BP 神经网络对多传感器数据进行融合, 由于 BP 网络训练速度慢, 实时性比较差, 效果受到一定的局限性. 为此, 本文提出了一种 RBF (Radial Basis Function 径向基函数神经网络) 实现的多传感器数据融合方法, 并在减小位移传感器温度漂移问题的应用中取得了很好的效果. 实验结果表明, 位移传感器输出电压的最大相对波动值由原来的 5.52% 减为 1.4%. 可见, 在相同的温度波动情况下, 位移传感器的输出稳定性比原来提高了约 4 倍.

1 位移检测中的传感器数据融合基本原理

在实际应用中, 其准确度要求不高的场合, 通常认为位移传感器的输出仅仅是输入位移量的单值函数. 实际上, 在输入数值不变的情况下, 工作温度 t 的变化将引起传感器输出电压 u 发生变化, 即传感器除受目标参量的影响外, 还受到非目标参量 t 的影响, 若不考虑温度因素仍然根据单个传感器的输入计算系统的输出就会引入较大的温度漂移误差. 因此, 需消除非目标参量 t 对传感器输入输出特性的影响, 使传感器的输出是输入的单值函数. 这可用多传感器数据融合技术来解决.

为了校正位移传感器的温度漂移特性, 再增加一个温度传感器, 位移和温度传感器的输出接到神经网络的输入端, 神经网络的输出节点即可直接输出被测的位移量. 基于神经网络数据融合的位移传感器系统示意图如图 1 所示 (图 1 中, 神经网络是用微机模拟实现的, 微机没有画出). 其中 U_s 为被测位移 S 的电压输出信号, U_t 为非目标参量 (温度 t) 的检测电压信号.




图 1 基于神经网络数据融合的位移传感系统

U_s 和 U_t 经过 A/D 转换器进行模/数转换后, 再送入计算机进行处理, 计算机接收到 A/D 转换器送来的数字信号后, 按预先设置好的软件算法进行运算, 在这里, 采用了 RBF 算法 (即径向基函数神经网络算法). RBF 网络即可输出经温度校正后的位移值.

图 1 中的神经网络就是融合中心. 神经网络的输入为目标参量 S 的检测电压信号 U_s 和非目标参量 t 的检测电压信号 U_t . 输出量即为融合后的总输出, 其特点是: 它为被测位移的单值函数. 这样可以消除工作温度的影响. 为实现上述要求, 需要对神经网络进行训练, 网络训练样本由二维标定实验的数据提供.

2 RBF 神经网络模型及训练方法

2.1 神经网络模型及算法

RBF 网络结构示意图如图 2 所示.

输入变量的维数为 2 其中 U_s 为位移传感器的输出电压; U_t 为温度传感器的输出电压. 设 m 为隐层节点数, q 为样本数. $W_{1 \times m}$ 为隐层所有节点的中心向量组成的矩阵, $W_{m \times 1}$ 为隐层到输出层的权值. 取隐层的非线性激励函数为高斯函数, 输出层为线性层, SC 为中心点集的宽度, \exp 为自然指数, $\| \cdot \|$ 为欧氏范数. 基于以上符号, RBF 网络的输入输出的关系表达式为:

$$Z = \exp \left[- \frac{\| X - W_1 \|^2}{SC^2} \right] \text{ 非线性层 (隐含层)}$$
$$Y = Z \times W_2 + E = \exp \left[- \frac{\| X - W_1 \|^2}{SC^2} \right] \times W_2 + E$$

线性层 (输出层)

式中:

$$X = [X_1, X_2]^T, X_i = [X_i(1), X_i(2), \dots, X_i(q)],$$
$$i = 1, 2$$
$$Y_i = [Y_i(1), Y_i(2), \dots, Y_i(q)];$$
$$Z = [Z_1, Z_2, \dots, Z_m];$$
$$Z_i = [Z_i(1), Z_i(2), \dots, Z_i(q)]^T, i = 1, 2, \dots, m;$$




图 2 径向基函数神经网络结构示意图

$$W2 = [W2_1, W2_2, \dots, W2_m]^T;$$
$$E = [E(1), E(2), \dots, E(q)]^T$$

网络隐含层节点数的选取没有统一的标准. 隐含层节点数太少, 融合的效果不好; 节点数太多, 会增加训练的复杂性. 当训练样本总和不大时, 一种简单的方法是: 用训练样本数作为隐层节点数. 实验的样本数为 45 因而隐含层的节点数就确定为 45

中心向量可以从训练集中随机选取, 也可以通过 K-均值聚类法或正交最小二乘法获得. 由于网络隐含层节点数已经确定为训练样本数 45 故直接将隐含层传输函数的中心向量逐个设置为训练样本向量.

中心点集宽度参数决定感受野的范围. SC 越大, 感受野越宽, 融合能力越好, 收敛速度越慢; 反之亦然. 在这里, 中心点集宽度的确定采用 Stokbro 等^[6] 人给出的经验公式:

$$SC_i^2 = \frac{1}{m\sqrt{2}} \sum_h \|C_i - C_h\| \quad i = 0, 1, 2, \dots, m \text{ (} m \text{ 为隐含层节点数)}$$

即任一隐含节点的宽度参数用该节点的中心向量与隐含层所有节点中心向量的欧氏距离的均值来表示.

2.2 RBF 神经网络的训练流程与算法

- RBF 网络训练算法的流程图如图 3 所示.
- 在确定了网络的隐含层节点数、中心向量、宽度参数后便可训练网络. 网络的训练步骤如下:
- step 1 将样本归一化;
 - step 2 初始化隐层与输出层间的权值为 $[-1, 1]$ 间的随机数;
 - step 3 设置训练样本的目标向量, 即: 教师信号;
 - step 4 将训练样本逐个输入网络进行学习. 根据权值更新公式修改权值, 并计算网络误差 E_k ;
 - step 5 全体样本学习完毕后, 计算总体误差:

$$E = \sum_k E_k$$

step 6 用训练样本多次重复学习, 直到迭代次数超过预定的最大值或者总体误差小于预定的最小值, 训练结束.

3 计算机数值实验及融合结果

一般地, 常规位移检测系统的工作温度在 $0 \sim 40^{\circ}\text{C}$ 的范围内变化, 因此在不同的工作温度下 (t 分别取 $0, 10, 20, 30, 40^{\circ}\text{C}$) 对位移传感器的输入输出特性进行标定, 由于实验室条件的限制, 本文只能得到温度范围为 $6 \sim 30^{\circ}\text{C}$ 的实验标定数据, 标定数据列于表 1.

由于 RBF 网络一般要求输入输出是归一化的数值, 可以依据下面公式^[7] 将实验标定数据进行归一化处理:

$$X'_m = \frac{X_m - X_{m\min}}{X_{m\max} - X_{m\min}} \tag{1}$$

$$P'_m = \frac{0.9(P_m - P_{m\min})}{P_{m\max} - P_{m\min}} \tag{2}$$

式中, X'_m, P'_m 为第 m 个样本神经网络输入、输出归一化值; X_m, P_m 为第 m 个样本输入、输出标定值; $X_{m\max}, X_{m\min}$ 为神经网络输入最大、最小标定值; $P_{m\max}, P_{m\min}$ 为神经网络输出最大、最小标定值.

传感器样本库归一化后的数据如表 2 所示.

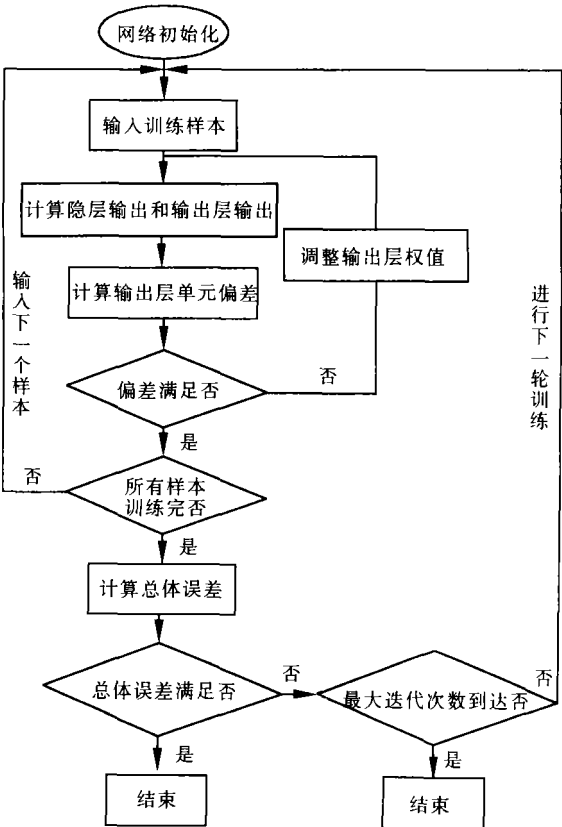


图 3 RBF 网络训练流程图

表 1 不同工作温度下位移传感器输入输出标定值

温度标 定值 S	$t = 6^{\circ}\text{C}$		$t = 12^{\circ}\text{C}$		$t = 18^{\circ}\text{C}$		$t = 24^{\circ}\text{C}$		$t = 30^{\circ}\text{C}$	
	U_s	U_t	U_s	U_t	U_s	U_t	U_s	U_t	U_s	U_t
0	0.005	0.300	0.004	0.604	0.003	0.900	0.002	1.196	0.001	1.498
50	0.632	0.298	0.628	0.600	0.600	0.892	0.580	1.194	0.548	1.496
100	1.258	0.292	1.250	0.596	1.242	0.890	1.228	1.190	1.200	1.492
150	1.878	0.290	1.800	0.594	1.788	0.886	1.776	1.188	1.746	1.488
200	2.500	0.288	2.478	0.590	2.466	0.882	2.450	1.182	2.418	1.482
250	3.125	0.284	3.102	0.586	3.078	0.880	3.052	1.174	3.022	1.476
300	3.752	0.282	3.738	0.582	3.702	0.876	3.688	1.170	3.652	1.470
350	4.478	0.278	4.402	0.580	4.336	0.870	4.274	1.166	4.202	1.462
400	4.980	0.272	4.958	0.570	4.950	0.862	4.938	1.160	4.912	1.456

表 2 传感器样本库归一化后的数据

温度标 定值 S	$t = 6^{\circ}\text{C}$		$t = 12^{\circ}\text{C}$		$t = 18^{\circ}\text{C}$		$t = 24^{\circ}\text{C}$		$t = 30^{\circ}\text{C}$	
	U_s	U_t	U_s	U_t	U_s	U_t	U_s	U_t	U_s	U_t
0.0000	0.000 8	0.022 8	0.000 6	0.270 8	0.000 4	0.512 2	0.000 2	0.753 7	0.000	1.00 0
0.1125	0.126 7	0.021 2	0.125 9	0.267 5	0.120 3	0.505 7	0.116 3	0.752 0	0.109 9	0.998 4
0.2250	0.252 5	0.016 3	0.250 9	0.264 3	0.249 2	0.504 1	0.246 4	0.748 8	0.224 7	0.995 1
0.3375	0.377 0	0.014 7	0.361 3	0.262 6	0.358 9	0.500 8	0.356 5	0.747 1	0.350 5	0.991 8
0.4500	0.501 9	0.013 1	0.497 5	0.259 4	0.495 1	0.497 6	0.491 9	0.742 3	0.485 4	0.986 9
0.5625	0.627 4	0.009 8	0.622 8	0.256 1	0.618 0	0.495 9	0.612 8	0.735 7	0.606 7	0.982 1
0.6750	0.753 4	0.008 2	0.750 6	0.252 9	0.743 3	0.492 7	0.740 5	0.732 5	0.733 3	0.977 2
0.7875	0.899 4	0.004 9	0.883 9	0.251 2	0.870 7	0.487 8	0.858 2	0.729 2	0.843 9	0.970 6
0.9000	1.000 0	0.000 0	0.995 6	0.241 3	0.994 0	0.481 2	0.991 6	0.724 3	0.986 3	0.965 7

由实验可以得出,当隐含层节点数为 45 时,训练能够在 77 步很快达到预先设定的误差要求 $1e-3$ 训练的误差收敛曲线如图 4 所示.

为了验证 RBF 神经网络进行多传感器数据融合的有效性,另给出 5 组实验标定值 (不是训练的样本点),利用训练好的 RBF 神经网络计算出被测位移的融合值.计算结果如表 3 所示.

表 3 RBF 神经网络融合处理结果

温度 T (非目标参量)		被测位移 (目标参量) / μm			
$T/^{\circ}\text{C}$	标定值	融合值	标定值	融合值	标定值
6	145	145.15	285	285.09	365.18
12		145.16		285.13	365.19
18		145.17		285.14	365.21
24		145.18		285.15	365.23
30		145.20		285.15	365.25

而使用 BP 网络、采用附加动量法和自适应学习速率法相结合的方法^[8]进行训练时,误差收敛曲线如图 5 所示.可见,即使是采用多种改进算法相结合,使用 BP 网络的收敛性能远远不及本文算法.




图 4 RBF 网络误差收敛曲线




图 5 改进的 BP 网络误差收敛曲线

由表 1 可见, 对于同一被测位移 S , 位移传感器的输出 U_s 随工作温度的变化而变化. 由工作温度的变化产生的位移传感器输出电压的相对波动值定义为:

$$\alpha = \frac{|y|_{\max}}{y_{F_s}} \quad (3)$$

式中, α 为位移传感器输出电压波动的相对值; $|y|_{\max}$ 为位移传感器输出电压的最大绝对波动值; y_{F_s} 为位移传感器满量程时的输出电压 (即在温度为 20°C , 传感器的输出电压值). 计算出位移传感器输出电压的最大相对波动值 α 为 5.52% . 可见, 该位移传感器受工作温度的影响较大. 采用 RBF 神经网络对传感器数据进行融合处理后, 用公式 (3) 求得 α 为 1.4% . 可见, 在相同的温度波动情况下, 位移传感器的输出稳定性比原来提高了约 4 倍. 因此, 采用 RBF 神经网络融合技术消除传感器在工作过程中受非目标参量的影响十分有效.

4 结语

提出了一种减小位移测量温度漂移的基于 RBF 神经网络的数据融合方法. 与 BP 网络数据融合相比, 收敛速度大幅提高, 有效解决了用 BP 神经网络训练速度慢的问题, 使其用于实时的传感系统成为可能. 本文虽以减小位移传感系统温度漂移问题为例, 但其思想方法可用于其他类似问题. 需要说明的是, 本文的 RBF 网络的训练算法只适用于训练样本数较少的情况, 不适用于大训练样本集.

然而, RBF 网络隐含层节点数、中心向量以及中心点集宽度参数的选取可以有多种方案, 但还没有形成系统分析的方法, 各种方法的选择也没有理论指导. 此外, 目前诸多研究成果还都是基于不同的传感系统, 对于不同的传感系统缺乏统一有效的方法. 因此, 还有许多问题有待进一步研究. 但可以推断, 随着研究的深入, 基于神经网络的数据融合算法也将同其它算法一样, 获得越来越多的应用.

[参考文献] (References)

- [1] 孙涛, 张宏建. 目标识别中的信息融合技术 [J]. 自动化仪表, 2001, 22(2): 1-3
SUN Tao, ZHANG Hongjian. Information fusion technology for object recognition [J]. Automatic Instruments, 2001, 22(2): 1-3 (in Chinese)
- [2] 刘君华. 采用压力传感器同时测量压力和温度 [J]. 微电子学与计算机, 1990(2): 8-11.
LIU Junhua. Measuring pressure and temperature simultaneously by pressure sensor [J]. Micro-Electronics and Computers, 1990(2): 8-11 (in Chinese)
- [3] 赵敏, 潘卫明, 杨灿军. 基于神经网络的数据融合技术在谐振式密度传感器中的运用 [J]. 传感技术学报, 2000(3): 187-192
ZHAO Min, PAN Weiming, YANG Canjun. Application of data fusion technology based on neural network for density sensor with harmonic vibration [J]. Journal of Sensor Technology, 2000(3): 187-192 (in Chinese)
- [4] 张铁壁. 多传感器数据融合技术在智能压力检测中的应用 [J]. 河北工程技术高等专科学校学报, 2003(2): 26-29.
ZHANG Tiebi. Application of data fusion technology about multiple sensors for pressure test with intelligence [J]. Journal of Hebei Engineering and Technical College, 2003(2): 26-29. (in Chinese)
- [5] 蔡兵. 基于神经网络的半导体压力传感器数据融合技术 [J]. 襄樊学院学报, 2002, 23(2): 16-18
CAI Bin. Data fusion technology based on neural network for semiconductor pressure sensor [J]. Journal of Xiangfan College, 2002, 23(2): 16-18 (in Chinese)
- [6] STOKBRO, UMBERGER, HERTZ. Exploiting neurons with localized receptive fields to learn chaos [J]. Complex Systems, 1990(4): 603-622
- [7] 刘君华. 智能传感器系统 [M]. 西安: 西安电子科技大学出版社, 1999. 388-400
LIU Junhua. Sensor System with Intelligence [M]. Xi'an: Xidian University Press, 1999. 388-400 (in Chinese)
- [8] 寇雪芹, 师帅兵. BP 人工神经网络在二传感器数据融合处理中的应用 [J]. 计量技术, 2003(2): 26-28
KOU Xueqin, SHI Shuaibing. Application of BP artificial neural network for data fusion about two sensors [J]. Measurement Technique, 2003(2): 26-28 (in Chinese)

[责任编辑: 刘健]