

文章编号: 1671-7848(2006)06-0536-04

RBFNN 软测量的嵌入式系统仿真与实现

王亮, 邵惠鹤

(上海交通大学自动化系, 上海 200030)



摘 要: 在基于 WinCE 操作系统的嵌入式平台上, 实现基于 RBF 神经网络的工业过程软仪表。应用无监督 K 均值聚类确定聚类中心, 用可避免矩阵求逆运算的递推最小二乘法训练网络权值的两阶段学习算法训练网络。进一步构造双重 RBF 网络结构, 用一个 RBF 神经网络训练样本, 用另一个独立的 RBF 神经网络训练误差提高精度。以嵌入式工业计算机作为硬件平台, 在基于 WinCE 的嵌入式系统上用 EVC 编程实现。在某炼油厂轻柴油凝固点的工业现场, 用该软仪表实测数据进行仿真测试, 取得了较好的效果。

关键词: RBF 神经网络; 软测量; 嵌入式系统; WinCE

中图分类号: TP 273

文献标识码: A

Simulation and Implement of RBFNN Soft Sensor Based on Embedded System

WANG Liang, SHAO Hui-he

(Department of Automation, Shanghai Jiaotong University, Shanghai 200030, China)

Abstract: Implement problem of the RBF neural network soft sensor on WinCE embedded system is discussed. By using K -means procedure, the cluster center is established and recursion algorithm is given to train the network weight value. A Double network structure is built to improve the network accuracy. One is used to train sample data and the other is used to train network error. To implement this soft sensor instrument, industrial embedded computer is used for hardware platform, and the software is programmed with Embedded visual C++. This method is used to estimate the freeze point of diesel oil in modeling data and good results are obtained.

Key words: RBF neural network, soft sensor, embedded system, WinCE

1 引言

软仪表技术^[1](也称为软测量技术)是工业过程控制领域中一项重要技术, 在石油、化工、医药等领域广泛应用。在现代流程工业中, 由于工艺技术的限制, 有许多重要的过程量都难以在线测量。软仪表通过统计回归、神经网络等方法建立一定的预报模型, 用软件方法在线估计难以用硬仪表测量的过程变量。

软仪表技术所涉及的研究内容主要有: 选择与主导变量最相关又易于测量的辅助变量作为输入; 构建数学模型; 输入数据预处理; 模型的在线校正等。由于工业过程, 尤其是化工过程的现场干扰大、灰尘多、温度高, 运行环境往往非常恶劣, 软测量技术实现的关键问题, 是软硬件运行平台的选择与构架。

本文在综合考虑系统的负载能力和测量估算精

度后, 采用一种双重 RBF 神经网络的模型作为测量的数学模型; 并选择具有优良的系统稳定性和抗干扰能力的, 基于微软 WinCE 操作系统的嵌入式计算机作为硬件平台, 开发环境为普通 PC 上的嵌入式应用软件开发包 Embedded VC++; 并将这一软仪表用石化工业中轻柴油凝固点模型进行仿真。

2 双重 RBFNN 模型及学习算法

1) 基本 RBF 模型 RBFNN, 即径向基函数神经网络^[2]。它有一个隐层的前向网络, 与其他前向神经网络相比, 收敛速度快, 具有较好的局部逼近能力。

基本映射关系为

$$F: \mathbf{R}^n \rightarrow \mathbf{R}$$

$$F(\mathbf{X}) = \omega_0 + \sum_{i=1}^n \omega_i \times \Phi(\|\mathbf{X} - \mathbf{C}_i\|)$$

式中, ω 为输出权值; ω_0 为输出层的阈值; \mathbf{C}_i 为

每一个隐层节点的聚类中心； ϕ 表示隐层的非线性径向基函数。

一般地，基函数的选择对网络性能影响不大，本文用高斯函数作为基函数：

$$\phi(X) = \exp\left(-\frac{\|X - C_i\|^2}{\sigma_i^2}\right), i = 1, 2, \dots, n$$

基本 RBF 模型的结构，如图 1 所示。

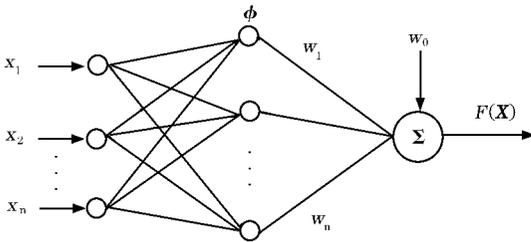


图 1 RBF 基本结构

2) 学习算法 采用基本的非监督学习确定聚类中心和有监督学习训练网络权值的两阶段学习算法^[3]，并在此基础上根据本文所涉及问题的特点作相应修改，来训练 RBF 网络。

① K 均值聚类

a) 初值设置，由于 K 均值聚类对初值敏感，有把全部输入数据往初始聚类中心聚集的趋势。为了避免这种趋势，本文在样本中随机选取数据作为初始中心，并用多次计算取最佳值的方法，消除由此带来的随机误差；b) 把所有输入数据按和聚类中心欧氏距离最近的原则分类；c) 重新计算每一类的中心；d) 重复以上步骤，直至分类不再有变化为止，由此得到的中心，即为聚类中心；e) 计算方差 σ^2 。由于 $\exp(-0.6932) = 0.5$ ，所以本文对每一类取：

$\sigma^2 =$ 该类数据和中心的平均欧氏距离/0.6932

则有：当输入数据和中心的距离等于上述平均距离时，输出为 0.5；输入数据正好等于聚类中心时，输出为 1，使网络输出平滑，并有较好的局部逼近性能。

② 递推最小二乘法 有了上述的聚类中心和方差后，第②阶段用有监督学习的方式训练网络权值 ω 。这是一个线性最小二乘问题，即把每一个样本数据经网络的变换看成一个线性方程，有 p 组样本就有 p 个方程；把权值看成方程的未知数，求一组未知数，使得方程组的输出和样本输出的差最小。

通常的最小二乘算法涉及规模庞大的矩阵求逆运算，不利于在嵌入式系统上编程实现。本文应用一种递推式的最小二乘算法^[4]，不涉及矩阵求逆，并且递推的方式可以用循环语句很方便的软件实现。不失一般性，本文只考虑多输入单输出、没有

阈值的情况。

设有 p 组样本，隐层节点数为 n ，隐层的输出矩阵为 $X_{p \times n}$ （注意，这不是输入样本，而是样本经隐层的高斯函数作用后的输出，为了推导的简便，记为 X ），网络的输出实测值为 y ，权值 ω ，则整个网络的输出可写成方程组：

$$\begin{bmatrix} y_1 \\ \vdots \\ y_p \end{bmatrix} = \begin{bmatrix} x_{11} & \dots & x_{1n} \\ \vdots & & \vdots \\ x_{p1} & \dots & x_{pn} \end{bmatrix}_{p \times n} \times \begin{bmatrix} \omega_1 \\ \vdots \\ \omega_n \end{bmatrix}$$

简记为

$$Y_{p \times 1} = X_{p \times n} \times \omega_{n \times 1} \quad (1)$$

如 $p > n$ 则该方程组无解。用通常求导并令导数为零的方法，可得 ω 的最小二乘估计为

$$\hat{\omega} = (X^T X)^{-1} X^T Y \quad (2)$$

现在假设又得到一个新的方程（一组新的样本），它是第 $p + 1$ 个：

$$y_{p+1} = \omega_1 x_{p+1,1} + \dots + \omega_n x_{p+1,n}$$

并记列向量：

$$x(p+1) = [x_{p+1,1} \dots x_{p+1,n}]^T$$

则全部的 $p + 1$ 个方程可以写为

$$Y_{(p+1) \times 1} = X_{(p+1) \times n} \times \omega_{n \times 1}$$

简记为

$$Y(p+1) = X(p+1) \times \omega$$

新的最小二乘估计为

$$\hat{\omega}(p+1) = (X^T(p+1)X(p+1))^{-1} \cdot X^T(p+1)Y(p+1) \quad (3)$$

引理 1（在此不加证明）若 $A, C, A + BCD$ 都是非奇异方阵，有：

$$(A + BCD)^{-1} = A^{-1} - A^{-1}B(C^{-1} + DA^{-1}B)^{-1}DA^{-1}$$

定义：

$$F(p) = (X^T X)^{-1}$$

运用上述引理 1，并由 $F(p)$ 和 $F(p+1)$ 的关系有：

$$F(p+1) = (X^T(p+1)X(p+1))^{-1} = [F(p)^{-1} + x(p+1)x^T(p+1)]^{-1} = F(p) - F(p)x(p+1)[1 + x^T(p+1)F(p)x(p+1)]^{-1}x^T(p+1)F(p) \quad (4)$$

将式(4)代入式(3)并整理，有：

$$\hat{\omega}(p+1) = F(p+1)[X^T Y + x(p+1)y(p+1)] = \hat{\omega}(p) + F(p)x(p+1)[1 + x^T(p+1)F(p)x(p+1)]^{-1}[y(p+1) - x^T(p+1)\hat{\omega}(p)]$$

这样就得到一个从 p 个方程（样本）到 $p + 1$ 个方程（样本）的权值 ω 最小二乘估计的递推关系式。由于 $[\]^{-1}$ 里是一个实数，不涉及矩阵求逆。

只要设定 $\omega(0)$ 和 $F(0)$ 的初值 ($\omega(0)$ 可任意设定; $F(0)$ 可取为 $a \times I$, a 为较大的实数, I 为 $p \times n$ 的单位矩阵) 就可以不断递推计算, 得到最后结果。软件实现时, 只需一个循环就可完成。

3) 隐层节点数的确定 上述的两阶段学习算法的一个重要问题, 是隐层单元数 n 的确定。仅从算法本身是无法得出 n 的最佳取值的。

考虑到上述算法本身不涉及大规模的优化计算, 收敛速度很快, 本文使用试凑的方法, 在一定取值范围内, 用不同 n 建立网络, 训练完后计算网络输出和样本输出的平均绝对误差, 取误差最小的 n 为最佳的 n_0 。直观地, n 太小, 则网络中储存的信息太少, 不可能有效逼近; n 太大, 则没有必要。经实际测试, 样本数为 100 左右时, n 的取值大约在 10 ~ 25 之间搜索就可满足要求了。而且, 多次计算整个网络, 使得 K 均值聚类也被多次计算, 这样由于随机初值带来的随机波动也可以被消除, K 均值聚类的可靠性提高。

4) 双重网络提高精度 为了提高网络的逼近精度, 本文采用一种双重网络的模型^[2], 其结构如图 2 所示。

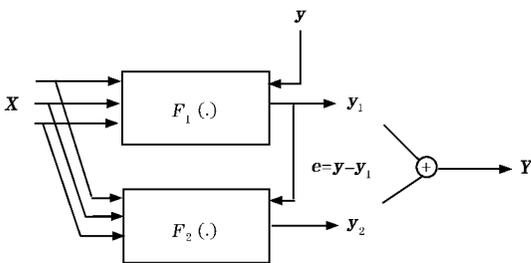


图 2 双重神经网络模型

F_1 和 F_2 分别表示两个性质相同, 但各自独立的 RBF 网络。 F_1 用样本的输入输出数据 x , y 作为网络的输入和目标输出, 训练后得到 F_1 网络输出 y_1 。

记 $e = y - y_1$, 即样本输出和 F_1 网络输出的差值。再对 F_2 进行另一次独立的训练 (隐层节点数 n 也另行确定)。 F_2 的输入是样本输入 x , 目标输出取为 e , 即用 F_2 对 F_1 的误差进行逼近。训练后得到 F_2 网络输出 y_2 。

整个结构最终的输出为两个网络输出的叠加, 即 $Y = y_1 + y_2$ 。理想情况下, 假设每一个网络的精度都只有 80%, 则整个结构的精度能达到:

$$80\% + 20\% \times 80\% = 96\%$$

使得整体性能有明显提升, 而付出的代价却是有限的, 网络复杂度只是单纯地增加了一倍。

3 软硬件实现

1) 硬件平台 本文使用嵌入式工业计算机作为硬件平台。嵌入式系统的特点是: 以应用为中心, 采用模块化设计软、硬件可裁剪、能适应具体应用环境对其功能、可靠性、功耗等严格要求的专用计算机。相对于普通 PC, 它的抗干扰、抗震、防尘散热等性能都比较高, 能适应恶劣的工业环境; 相对于工业计算机, 它又具有体积小、功耗少、成本低的优点。因此, 嵌入式计算机适合作为软仪表的硬件平台。主要技术参数为:

① CPU NS Geode GX1-300 MHz, 64 MB SDRAM 2 个标准 RS-232 口, 2 个隔离 RS232/422/485, 自动流量控制; ② 速度 RS-232: 50 ~ 115.2 Kbps; RS-422/485: 50 ~ 921.6 Kbps; ③ 8 通道隔离数字输入、输出 70 VDC 过压保护, 0 ~ 50 VDC 电压输入范围, 5 ~ 40 VDC 电压输出范围, 速度 10 kHz; ④ 网口 两个 10/100M Base-R RJ-45 接口; ⑤ 操作系统 Windows CE.NET, 支持超过 1 000 个常用的 Win32 API, 具有良好的硬件兼容性。

2) 开发机的连接与调试 开发机使用普通 PC 机即可, 安装 Embedded VC 4.0 开发包。和普通的 VC 编程不同, 由于嵌入式系统的开放性, 使得应用软件的可移植性、通用性比较差。一个嵌入式系统的应用程序, 一般不可能在另一个系统下正常的运行。

解决方法是, 在开发机上安装对应的嵌入式系统的 SDK (Software Develop Kit 软件开发包), 使 EVC 能编译生成该嵌入式系统的应用程序。源代码编写完成后, 只要 EVC 下有嵌入式系统的 SDK, 生成可执行程序就只是一次 EVC 编译过程。

正常安装完 SDK 后, 需要把开发机与嵌入式系统连接起来, 才能运行与调试。连接的方式有:

① 通过网线连接, 以 TCP/IP 协议通讯, 两机需要设置适当的 IP 地址; ② 通过串口 (COM) 的连接, 以动态同步 ActiveSync 通讯, 这需要相应的通讯软件。

连接后, 在 EVC 的平台管理器 Plat Manager 中设置相应的参数, 测试成功, 就完成了连接。这样开发机就能把程序下载到嵌入式系统的内存中, 在嵌入式系统的环境中运行调试。有了准备工作, 具体编程调试和 VC 编程就很相似了。

3) 程序流程图 基于上述算法的程序流程图分为两部分, 离线的训练建模部分和在线的估算测量部分, 如图 3 所示。

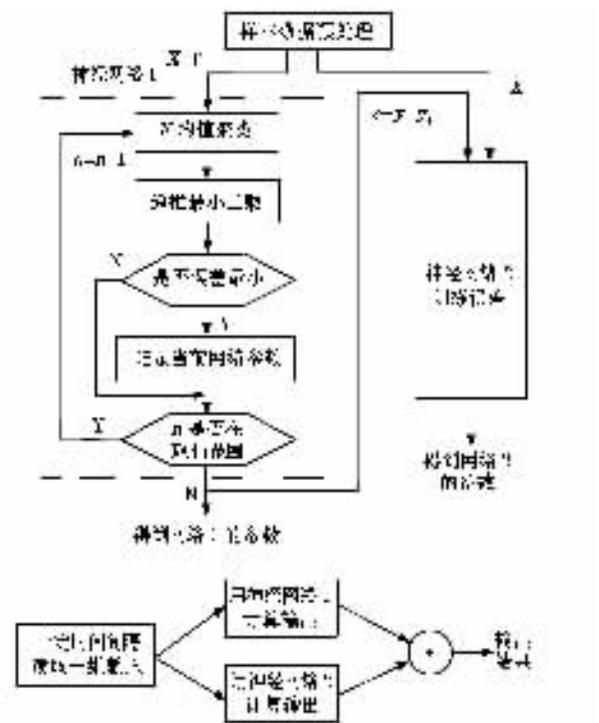


图 3 程序流程图

4 实例仿真

以某炼油厂在轻柴油凝固点相关变量的实测数据为样本,用本软测量仪表仿真。该模型为 5 输入 1 输出结构,输入为:一中循环量、一中抽温、一中返温、轻下抽油、19 层汽相温度;输出为:轻柴

(上接第 524 页)

6 非线性模型实验

对于上述的三容水箱非线性模型,根据式(6)~式(10)及式(12),在 SIMULINK 环境下建立仿真模型,可以得出模型的阶跃响应。同时,对实际被控对象进行动态特性测试实验。电磁阀打开,作为阶跃输入,液位高度经 A/D 送入计算机,利用组态软件历史报表画面记录响应过程。实验曲线和模型计算结果,如图 5 所示。

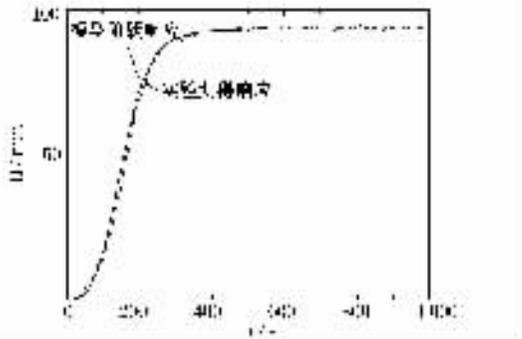


图 5 非线性模型阶跃响应

油凝固点(5~14℃)。共有 144 组数据,用其中 100 组训练神经网络,44 组测试。经实际计算,隐层节点数:网络 1 为 23,网络 2 为 24。

用均方根误差 RMSE 和最大绝对误差 MAXE 表征软仪表性能。双重神经网络和普通单一神经网络的测量精度误差比较,见表 1。

表 1 误差比较

	RMSE	MAXE
单一神经网络	2.64	4.16
双重神经网络	2.29	3.62

由表中可见,采用双重神经网络的软仪表精度较高。

5 结 语

本文应用双重 RBF 神经网络进行软测量建模,使用 K 均值聚类确定聚类中心和递推最小二乘训练网络权值的学习算法。经轻柴油凝固点数据的仿真测试,有较好的效果。

参考文献:

[1] 冯瑞. 支持向量机及其在工业过程软测量中的应用研究[D]. 上海:上海交通大学,2003.
 [2] 王旭东. 用径向基函数神经网络进行非线性系统的建模与控制[D]. 上海:上海交通大学,1995.
 [3] 徐秉铮,等. 神经网络理论与应用[M]. 广州:华南理工大学出版社,1994.
 [4] 王学仁,王松桂. 实用多元统计分析[M]. 上海:上海科学技术出版社,1996.

从图中可以看出,两条曲线存在一定误差,但误差总体较小,模型阶跃响应和实验结果相吻合,表明机理建模方法是正确的和可行的。

7 结 语

本文通过机理建模的方法,推导出三容水箱的一般数学模型,分析了线性和非线性阻力板流量特性,实验测得阻力板的流量系数,给出了较有代表性的线性模型和线性化模型。非线性模型的阶跃响应和实验测得的响应曲线相吻合,验证了机理建模方法的正确性和可行性。本文的工作为三容水箱先进控制策略的研究奠定了良好基础。

参考文献:

[1] 谢启,杨马英,余主正. 基于预测函数控制算法的水槽液位控制系统[J]. 控制工程,2003,10(6):510-511.
 [2] 方康玲. 过程控制系统[M]. 武汉:武汉理工大学出版社,2002.
 [3] 李炜,徐孝平. 水力学[M]. 武汉:武汉水利电力大学出版社,2000.
 [4] 李延新,李文,李光宇. 一种基于 RBF 网络提取模糊规则的算法实现[J]. 控制工程,2005,12(1):47-49.