

文章编号 1004-924X(2011)07-1588-08

基于遗传优化小波神经网络逆模型的油水测量

张冬至^{1,2*}, 胡国清²

- (1. 中国石油大学(华东) 信息与控制工程学院, 山东 青岛 266555;
2. 华南理工大学 机械与汽车工程学院, 广东 广州 510641)

摘要:考虑基于传统的介电常数法动态测量原油含水率时存在多变量交叉敏感性,检测精度无法满足石油生产实时优化控制的需要,研究了利用多传感技术对存在交叉耦合的多敏感参量进行测量,提出了一种基于多维数据驱动的遗传优化小波神经网络逆模型及其辨识方法。该模型克服了传统神经网络初始参数随机选取的盲目性,具有全局优化和复杂非线性自学习性能,摒弃了多影响因素之间的交叉敏感性。仿真和实验结果表明了该模型的有效性,其模型预测值与实验标定值之间的相关系数为0.999 6,优于BP-NN模型。该方法具有较强的泛化能力和鲁棒性,有效抑制了温度、矿化度等多参量交叉敏感性及传感器自身非线性对测量精度的影响,改善了多传感器系统的非线性动态特性和检测精度。

关键词:小波神经网络;逆模型;模型辨识;遗传优化;油水测量

中图分类号:TP183;TP274 **文献标识码:**A **doi:**10.3788/OPE.20111907.1588

Measurement of oil-water flow based on inverse model of wavelet neural network with genetic optimization

ZHANG Dong-zhi^{1,2*}, HU Guo-qing²

- (1. College of Information and Control Engineering, China University of Petroleum (East China), Qingdao 266555, China; 2. School of Mechanical and Automotive Engineering, South China University of Technology, Guangzhou 510641, China)
- * Corresponding author, E-mail: dz.z@mail.scut.edu.cn

Abstract: As the traditional measuring method based on dielectric coefficients shows cross-sensitivity for multi-parameters in the measurement of oil/water two-phase flows, it can not meet the requirements of real-time optimization control for petroleum production. Therefore, this paper investigates a method to measure multi-parameters with cross-sensitivity by using multi-sensing technology. It presents an inverse model of wavelet neural network with genetic optimization and also researches its identification method. The model overcomes the blindness of initialization weight-value choice in traditional neural networks, provides the abilities of global optimization and nonlinear self-learning, and eliminates the cross-sensitivity of multi-factors. The simulation and experimental results demonstrate the validity and effectiveness of the proposed model and show that the correlation coefficient between the predicted values and calibration values is 0.999 6, which is better than that of BP-NN model. The

收稿日期:2010-07-01;修订日期:2010-11-26.

基金项目:华南理工大学优秀博士学位论文创新基金资助项目(No. 200903023)

method has strong generalized capability and robust convergence rate, and can effectively eliminate the influence of the cross-sensitivity of multi-factors and the nonlinearity of sensor self on the measuring precision, and improve the dynamic characteristics and measurement accuracy of sensor systems.

Key words: wavelet neural network; inverse model; model identification; genetic optimization; oil-water measurement

1 引言

原油含水率检测是油田生产、脱水、储运过程中的重要环节,对生产过程工艺优化、流量测量及控制决策具有重要意义^[1]。由于油水两相流系统是一个复杂的双组分非线性耗散动力系统,表现出一系列混沌特性,动态检测过程含有时变、非线性及随机干扰噪声等不确定性因素,难以通过建立一个精确的传感器测量模型加以描述。当前石油工业领域正大力发展数字化油田和智能井技术,原油含水率在线检测技术的研究及应用得到广泛关注,而且对检测精度和性价比的要求越来越高。目前,应用较为普遍的原油含水率测量仪多基于油水混合物的介电特性差异反映混合物的各相含量,其存在多种敏感参量的交叉影响,如油水混合流体的温度变化导致其介电常数改变,矿化度变化致使流体的密度、导电性、黏度等物性发生变化等,这些影响使含水率检测精度难以满足石油生产实时优化控制的需要^[2]。

提高该类传感器检测精度通常从两个方面入手:一是改变传感器的结构、参数和设计;二是基于模型的误差补偿^[3-6]。随着计算机信息处理技术的普及,后一种方法得到了广泛应用。交叉敏感情况下的模型误差补偿旨在从多源传感器观测信号中融合复现出被测信息,同时摒弃非目标敏感参量的交叉影响,即建立传感器系统逆模型^[7]。针对交叉敏感性的油水两相流系统中存在多因素影响检测精度的问题,本文提出一种基于遗传算法优化的小波神经网络传感器逆模型及其辨识方法。研究表明,该方法具有较强的泛化能力和鲁棒性,有效抑制了温度、矿化度等多参量交叉敏感性及传感器非线性对测量精度的影响,改善了多传感器系统的非线性动态特性和检测精度。

2 实验装置与数据采集

油水混合物含水率测量方法大多集中在表征油和水极化强度差异的介电常数上,但该参数与混合物的温度、矿化度等参量有复杂的非线性关系^[8-11]。单变量模型一般不能充分体现原油含水率测量中的多因素交叉耦合作用,因此,文中采用调速电机、齿轮油泵、油水混合装置、可调加热器、温度传感器、电容测量仪、稳压电源、温控仪、PC机等组成油水两相流实验室模拟系统,实验装置如图1所示。实验试剂为纯油、去离子水及干燥氯化钠。被测油样由人工配比制取标定,其含水率配制为0~100%,水矿化度(NaCl含量)标定在0~50 g/L,流体温度为20~75℃。基于电磁波谐振技术的电容测量仪,在极化电场下能充分体现油、水分子对油水乳化液介电特性的贡献,其电容值变化反映油水混合物等效介电常数的变化。



图1 测量实验装置

Fig. 1 Experimental setup for measurement system

实验中,首先采用标准容器人工配备具有不同含水率的 n 组标定油样,其次将标定油样采用温控加热器加热到 m 组不同的预设温度,而后按照比例加入一定量的氯化钠(矿化度当量),进而

模拟油田现场开采混合流体的温度、含水及矿化程度差异。采用调速电机驱动齿轮油泵使被测流体在油水混合装置中充分混合,利用多传感器技术对流体温度、电容(含水)、电导(矿化度)等多敏感参数进行实时测定,实验方案如图 2 所示。为提高存在交叉敏感性的传感器系统检测精度,引入基于多维数据驱动的遗传优化小波神经网络逆模型进行误差补偿。

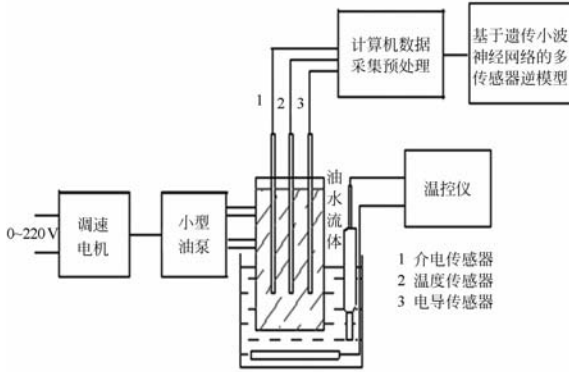


图 2 实验方案示意图

Fig. 2 Sketch of experimental scheme

3 交叉敏感多传感器系统逆模型

考虑一个存在多参量交叉敏感性的多传感器单目标检测系统 Σ ,其静态输入输出特性描述为

$$\begin{cases} x_{1(k)} = f_1(u_{1(k)}, u_{2(k)}, \dots, u_{n(k)}) \\ x_{2(k)} = f_2(u_{1(k)}, u_{2(k)}, \dots, u_{n(k)}) \\ \vdots \\ x_{m(k)} = f_m(u_{1(k)}, u_{2(k)}, \dots, u_{n(k)}) \\ y_{(k)} = f(x_{1(k)}, x_{2(k)}, \dots, x_{m(k)}) + \varepsilon_{(k)} \end{cases} \quad (1)$$

简记为

$$\begin{cases} \mathbf{X}_{(k)} = \mathbf{F}(\mathbf{U}_{(k)}) \\ y_{(k)} = f(\mathbf{X}_{(k)}) + \varepsilon_{(k)} \end{cases} \quad (2)$$

式中 $\mathbf{U}_{(k)} = [u_{1(k)}, u_{2(k)}, \dots, u_{n(k)}]^T$ 为传感器的输入信号,包含传感器所交叉敏感的多个非目标参量; $\mathbf{X}_{(k)} = [x_{1(k)}, x_{2(k)}, \dots, x_{m(k)}]^T$ 为传感器的输出向量; $\mathbf{F} = [f_1, f_2, \dots, f_m]^T$,分量 f_i 为传感器 i 的固有静态特性,由传感器的物理性质决定。 $y_{(k)}$ 为被测目标参量; $f(\cdot)$ 为信息融合算子; $\varepsilon_{(k)}$ 为信息融合白噪声。

交叉敏感情况下的多传感器系统动态输入输出特性描述为

$$\begin{cases} \Delta \mathbf{X}_{(k)} = \frac{\partial \mathbf{F}(\mathbf{U}_{(k)})}{\partial \mathbf{U}_{(k)}} \mathbf{U}_{(k)} = \begin{bmatrix} \frac{\partial f_1}{\partial u_1} & \frac{\partial f_1}{\partial u_2} & \dots & \frac{\partial f_1}{\partial u_n} \\ \frac{\partial f_2}{\partial u_1} & \frac{\partial f_2}{\partial u_2} & \dots & \frac{\partial f_2}{\partial u_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_m}{\partial u_1} & \frac{\partial f_m}{\partial u_2} & \dots & \frac{\partial f_m}{\partial u_n} \end{bmatrix} \begin{bmatrix} u_{1(k)} \\ u_{2(k)} \\ \vdots \\ u_{n(k)} \end{bmatrix} \\ \Delta y_{(k)} = \frac{\partial f(\mathbf{X}_{(k)})}{\partial \mathbf{X}_{(k)}} \mathbf{X}_{(k)} \end{cases} \quad (3)$$

所谓多传感器系统 Σ 的逆系统 Π 是指能实现由系统 Σ 的输出到输入映射关系的系统,即将系统 Σ 的输出 $X_{(k)}$ 作为逆系统 Π 的输入,则逆系统 Π 的输出正是驱动系统 Σ 产生期望输出 $X_{(k)}$ 所需的目标激励量 $y_{(k)}$ [12]。基于神经网络函数逼近理论,该多传感器系统可由一个线性滤波器 $\phi(z^{-1})$ 和一个无记忆非线性映射函数 $F(\cdot)$ 串联组成的 Wiener 模型表示。而对于它的逆系统可用一个无记忆非线性映射函数 $G(\cdot)$ 和一个线性滤波器 $\varphi(z^{-1})$ 串联组成的 Hammerstein 模型表示 [7]。 $G(\cdot)$ 和 $\varphi(z^{-1})$ 满足

$$G(\cdot) = F^{-1}(\cdot) \quad (4)$$

$$\varphi(z^{-1})\phi(z^{-1}) = z^{-d}I \quad (5)$$

式中 d 为系统的时延因子, $G(\cdot)$ 由静态标定确定。构造传感器逆模型的关键是如何确定 $\varphi(z^{-1})$,使得动态补偿后的系统误差 E 最小。

为突破传统解析逆模型对精确数学模型和具体参数的依赖,文中构造一种遗传优化的小波神经网络逆模型用于多传感器系统动态建模,其结构如图 3 所示。小波神经网络(WNN)是基于小波变换而构造的一类新型前馈神经网络模型,同 BP 网络相比,WNN 具有更强的信息提取和非线性逼近、容错能力,但仍存在 BP 网络算法初始权值敏感等问题 [13-15]。为此,采用遗传优化小波神经网络(GW-NN)模型,克服了传统神经网络初始参数随机选取的盲目性,提高了模型的鲁棒性和泛化能力。传感器逆模型的建模问题转化为遗传小波神经网络权值的辨识与优化问题,其输出特性的数学描述可表示为:

$$y = \sigma \sum_{i=1}^h \tau_i \Phi_{a_i, b_i} \left(\sum_{j=1}^l \tau_{ij} x_j \right) + \theta \quad (6)$$

其中 $x_j (j=1, 2, \dots, m)$ 为网络输入, $\{\tau_{ij}\}$ 为输入层与隐层的连接权值, $\{\tau_i\}$ 为隐层与输出层的连接权值, $\Phi(\cdot)$ 为小波基函数, $\{a_i\}$ 、 $\{b_i\}$ 分别为第

i 个隐层节点的尺度因子和平移因子, σ 为输出层激励函数决定的线性因子, θ 为输出的均值估计, h, l 分别为隐层和输入层的神经元数。

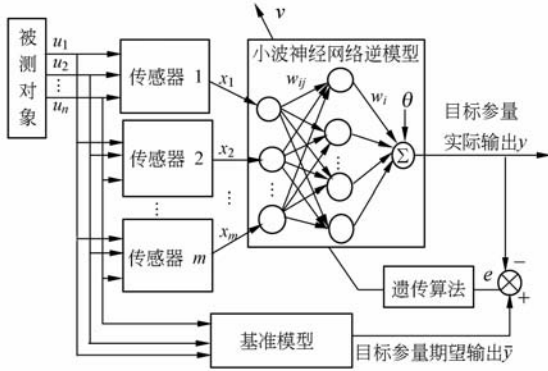


图 3 遗传优化小波神经网络多传感器系统逆模型结构

Fig. 3 Structure sketch of multi-sensor system inverse model of wavelet neural network with genetic optimization

基准模型是采用高精度传感器或实验标定数据建立的理想输入输出模型,为网络训练模式提供目标期望输出值。传感器逆模型的预测输出 $y_{(k)}$ 与期望目标输出 $\bar{y}_{(k)}$ 相比较得到辨识误差 $e_{(k)}$,作为逆模型训练的指导信号,监督网络模型参数不断调整,并通过最小化误差能量函数而优化确定,即

$$E = \frac{1}{2} \sum_{k=1}^p e_{(k)}^2 = \frac{1}{2} \sum_{k=1}^p (\bar{y}_{(k)} - y_{(k)})^2, \quad (7)$$

其中 p 为训练模式个数。

4 遗传小波神经网络逆模型辨识

小波神经网络通过将非线性小波基与信号向量的内积进行加权可实现信号的特征提取,兼有全局优化和复杂非线性自学习性能。常用的小波神经网络训练方法有共轭梯度法和随机梯度法,理论上可实现任意线性或非线性函数映射,但通常存在结构参数混合优化时计算规模巨大、过拟合和网络初始参数盲目等问题。为了提高多传感器系统 WNN 模型的鲁棒性和泛化能力,文中采用的 GW-NN 模型算法设计如下:

(1) 对多传感器系统进行动态标定实验,即在允许工作量程内输入各标定信号 $U_{(k)}$,充分激励传感器的动态响应 $X_{(k)}$,获取系统输入输出数据样本。

(2) 设计神经网络结构及小波基函数 $\Phi(\cdot)$ 。若 $\Phi(x) \in L^2(R)$ 且 $\Phi(x)$ 的傅里叶变换 $\psi(\omega)$ 满足

$$C_\psi = \int_{-\infty}^{+\infty} \frac{|\psi(\omega)|^2}{|\omega|} d\omega < \infty, \psi(0) = 0, \quad (8)$$

则 $\Phi(x)$ 为小波基函数。由 $\Phi(x)$ 作位移 b 后,在不同尺度 a 下伸缩生成小波函数族 $\{\Phi_{a,b}(x)\}$,即

$$\Phi_{a,b}(x) = |a|^{-\frac{1}{2}} \Phi\left(\frac{x-b}{a}\right), \quad (9)$$

式中尺度因子 $a \in \mathbf{R}$ 且 $a \neq 0$, 平移因子 $b \in \mathbf{R}$ 。文中采用余弦调制 Morlet 小波函数,即

$$\Phi(x) = \cos(1.75x) e^{-x^2/2}, \quad (10)$$

则 m 维输入网络的隐层小波神经元 i 的输出可表示为

$$\Phi_{a_i,b_i}(X_m) = |a_i|^{-\frac{1}{2}} \cos\left(1.75 \frac{\sum_{j=1}^m \omega_{ij} x_j - b_i}{a_i}\right) e^{-\left(\frac{\sum_{j=1}^m \omega_{ij} x_j - b_i}{a_i}\right)^2/2}. \quad (11)$$

(3) 网络参数实数编码。对网络模型参数 $\{a_i\}, \{b_i\}, \{\omega_{ij}\}, \{\omega_i\}, \{\theta\}$ 的解空间进行实数编码,每条遗传染色体对应于一组待定模型参数的解,编码形式为

$$v_i = [a_1, a_2, \dots, a_p, b_1, b_2, \dots, b_p, \omega_{11}, \omega_{12}, \dots, \omega_{pm}, \omega_1, \omega_2, \dots, \omega_p, \sigma, \theta]. \quad (12)$$

该染色体串长度(基因数目)为

$$S = (m+3)p + 2. \quad (13)$$

初始种群由随机生成的 N 条染色体构成,即

$$Q_{N \times S} = [v_1, v_2, \dots, v_i, \dots, v_N]^T. \quad (14)$$

(4) 计算个体适应度。将染色体上各基因分配到 BP 网络结构中,以训练样本正向运行网络,计算网络的输出值 y 与期望目标值 \bar{y} 之间的误差平方和 E ,得到第 h 代进化个体的适应度为

$$f(v_i^{(h)}) = \frac{M}{E(v_i^{(h)})} = \frac{2M}{\sum_{k=1}^R (\bar{y}_{(k)}^{(h)} - y_{(k)}^{(h)})^2}, \quad (15)$$

其中 $y = \sum_{i=1}^p [\omega_i \Phi_{i,a,b}(X_m) + \theta]$, M 为调节系数,进化代数 $h=1, 2, \dots, h_{\max}$ 。适应度 $f(v_i^{(h)})$ 越大,表明在网络参数 $v_i^{(h)}$ 下,网络训练误差平方和越小,越接近性能要求。

(5) 优选个体进行遗传操作。对种群中的所有个体按适应度大小进行排序,并基于此排序采用轮盘赌法计算个体被选中的概率为:

$$p_i^{(h)} = f(v_i^{(h)}) / \sum_{i=1}^N f(v_i^{(h)}), \quad (16)$$

交叉操作采用改进的自适应交叉算子, 设 $v_i^{(h)}$ 和 $v_j^{(h)}$ 为 h 代的两个个体, 则交叉运算后产生的两个新个体构造如下:

$$\begin{cases} v_i^{(h+1)} = \frac{1}{1+c/f(v_i^{(h)})} \left[\frac{c}{f(v_j^{(h)})} \alpha v_i^{(h)} + (1-\alpha) v_j^{(h)} \right] \\ v_j^{(h+1)} = \frac{1}{1+c/f(v_j^{(h)})} \left[\alpha v_i^{(h)} + \frac{c}{f(v_i^{(h)})} (1-\alpha) v_j^{(h)} \right] \end{cases}, \quad (17)$$

式中 c 为可调系数, α 为 $(0, 1)$ 区间均匀分布随机数。设父代个体的适应度函数 $f(v_i^{(h)}) \gg f(v_j^{(h)})$,

则有 $\frac{1}{1+c/f(v_i^{(h)})} \rightarrow 1$, 且 $\frac{1}{1+c/f(v_j^{(h)})} \rightarrow 0$, 式

(17) 充分表明适应度值大的父代个体 $v_i^{(h)}$ 具有高的概率将其基因遗传给下一代, 适应度值小的父代个体 $v_j^{(h)}$ 具有小的遗传概率。改进的交叉算子不仅具有自适应性, 而且保留了随机性, 有助于提高收敛速度。

变异操作采用非一致变异算子, 即

$$v_i^{(h)} = \begin{cases} v_i^{(h)} + \Delta(h, h_{\max}, U_{\max}^i - v_i^{(h)}), \text{rand}(0, 1) = 0 \\ v_i^{(h)} + \Delta(h, h_{\max}, v_i^{(h)} - U_{\min}^i), \text{rand}(0, 1) = 0 \end{cases}, \quad (18)$$

其中 $v_i^{(h)}$ 为个体 $v_i^{(h)}$ 的变异后的结果, $[U_{\min}^i, U_{\max}^i]$ 为变异点 $v_i^{(h)}$ 的取值范围。函数 $\Delta(h, h_{\max}, d)$ 返回 $[0, d]$ 范围内非均匀分布的一个随机数, 且随进化代数 h 增大而接近于 0 的概率逐渐增加。

(6) 保留当前群体中的最优个体进行繁殖, 产生下一代个体, 并对新生个体进行评价, 直至满足误差精度或达到终止代数结束, 否则转(3)。

(7) 将得到的最优个体作为网络初始权值进行网络计算和自调整。误差能量函数 E 采用基于 LMS 的共轭梯度算法实现极小化, 各网络参数的梯度为

$$\frac{\partial E}{\partial w_{ij}} = -\sigma \sum_{k=1}^R (\bar{y}^{(k)} - y^{(k)}) \sum_{i=1}^p \omega_i \Phi'_{a_i, b_i} \left(\sum_{j=1}^m \omega_{ij} x_{j(k)} \right) x_{j(k)} / a_i, \quad (19)$$

$$\frac{\partial E}{\partial w_i} = -\sigma \sum_{k=1}^R (\bar{y}^{(k)} - y^{(k)}) \Phi_{a_i, b_i} \left(\sum_{j=1}^m \omega_{ij} x_{j(k)} \right), \quad (20)$$

$$\frac{\partial E}{\partial a_i} = \sigma \sum_{k=1}^R (\bar{y}^{(k)} - y^{(k)}) \sum_{i=1}^p \omega_i \Phi'_{a_i, b_i} \left(\sum_{j=1}^m \omega_{ij} x_{j(k)} \right) \times \left(\sum_{j=1}^m \omega_{ij} x_{j(k)} - b_i \right) / a_i^2, \quad (21)$$

$$\frac{\partial E}{\partial b_i} = \sigma \sum_{k=1}^R (\bar{y}^{(k)} - y^{(k)}) \sum_{i=1}^p \omega_i \Phi'_{a_i, b_i} \left(\sum_{j=1}^m \omega_{ij} x_{j(k)} \right) / a_i, \quad (22)$$

为保证网络参数平稳调整, 引入学习率 η 和动量因子 μ , 设 t 为迭代次数, 则网络参数修正公式为

$$w_{ij}(t+1) = w_{ij}(t) - \eta \frac{\partial E}{\partial w_{ij}} + \mu [w_{ij}(t) - w_{ij}(t-1)], \quad (23)$$

$$w_i(t+1) = w_i(t) - \eta \frac{\partial E}{\partial w_i} + \mu [w_i(t) - w_i(t-1)], \quad (24)$$

$$a_i(t+1) = a_i(t) - \eta \frac{\partial E}{\partial a_i} + \mu [a_i(t) - a_i(t-1)], \quad (25)$$

$$b_i(t+1) = b_i(t) - \eta \frac{\partial E}{\partial b_i} + \mu [b_i(t) - b_i(t-1)]. \quad (26)$$

(8) 当网络误差小于设定的 E_{\max} , 或网络训练达到最大次数 t_{\max} , 则终止训练, 得到最佳的模型参数。

5 仿真实验及分析

对于文中提出的遗传优化小波神经网络逆模型方法, 通过油水两相流实验测试数据验证其有效性。配制具有不同油水比、温度及矿化程度的油水混合物样本 150 组, 采用多传感器对油样进行标定实验, 获取样本数据, 其中取 130 组数据作为训练样本, 其余数据作为测试样本。测定参量经归一化处理, 作为 GW-NN 模型的输入量, 标定含水比率作为模型的目标输出, 并采用期望与目标输出之间的最小均方差误差 (MMSE) 作为模型优化的指导准则。进行仿真实验时, 采用三层网络拓扑结构, 隐层神经元激励函数采用式 (10) 所示的 Morlet 小波函数, 输出层采用饱和线性函数。遗传算法控制参数选取种群规模 $N = 60$, 终止进化代数 $h_{\max} = 100$, 交叉概率 $p_c = 0.5$, 变异概率 $p_v = 0.01$, 适应度评价函数采用式 (15)。神经网络控制参数选取学习率 $\eta = 0.3$, 动量因子 $\mu = 0.15$, 训练误差设定值 $E_{\max} = 0.0025$, 最大训练次数 $t_{\max} = 10000$ 。利用学习样本进行训练, 确定最佳网络模型结构为 3-13-1。为比较 GW-NN 逆模型与传统 BP 神经网络 (BP-NN) 模

型的训练效果和泛化性能,文中采用相同的训练样本对具有相同网络结构的两种模型进行建模仿真研究,其中 BP-NN 网络权值调整采用附加动量最速下降法。两模型的预测值与目标真值之间的关系如图 4 和 5 所示,两模型误差对比结果如图 6 所示,并采用式(27)所示的相关系数(CC)法对两模型的预测效果进行评价。

$$R = \frac{(y^{(k)} - \frac{1}{p} \sum_{k=1}^p y^{(k)})^T (\hat{y}^{(k)} - \frac{1}{p} \sum_{k=1}^p \hat{y}^{(k)})}{\left\| y^{(k)} - \frac{1}{p} \sum_{k=1}^p y^{(k)} \right\| \cdot \left\| \hat{y}^{(k)} - \frac{1}{p} \sum_{k=1}^p \hat{y}^{(k)} \right\|} \quad (27)$$

实验仿真结果及预测评价表明了两模型的有效性,但在同等实验条件下, GW-NN 模型的预测精度明显优于 BP-NN 模型,预测值与标定值之间的相关系数分别为 0.999 6 和 0.996 7。

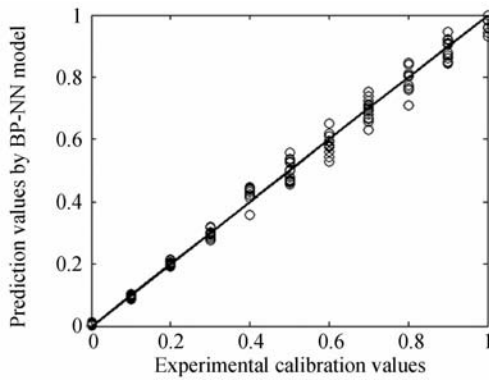


图 4 BP-NN 模型的训练结果

Fig. 4 Training results for BP-NN model

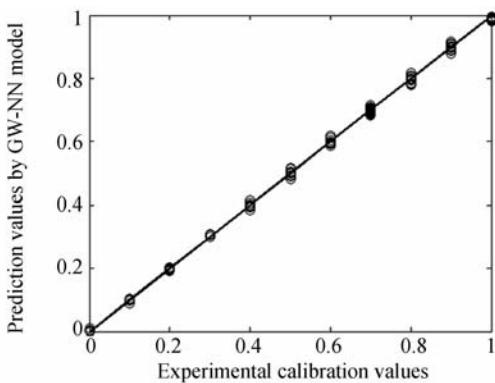


图 5 GW-NN 模型的训练结果

Fig. 5 Training results for GW-NN model

为验证所建模型的泛化能力,以误差均值和均方误差为性能指标,对 BP-NN 和 GW-NN 模

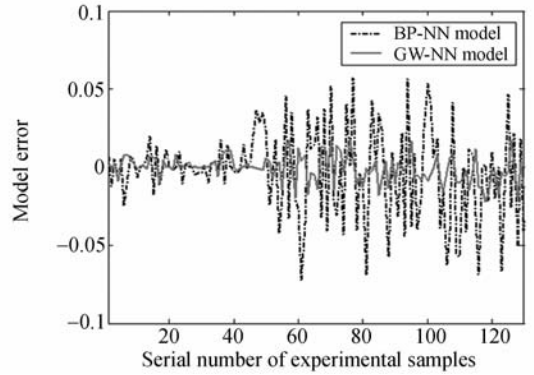


图 6 BP-NN 和 GW-NN 模型的误差对比

Fig. 6 Error comparison between BP-NN and GW-NN models

型的训练误差和测试误差进行评价,结果如表 1 所示。

表 1 BP-NN 和 GW-NN 模型的误差结果

Tab. 1 Error results for BP-NN and GW-NN models

模型	误差均值($\times 10^{-2}$)		均方误差($\times 10^{-4}$)	
	训练值	测试值	训练值	测试值
BP-NN	2.07	1.67	4.38	5.42
GW-NN	0.68	0.56	0.371	0.843

由表 1 可见, GW-NN 模型对油水混合物含水率的测量精度优于 BP-NN 模型,获得较为满意的训练误差和测试误差,具有稳健的泛化能力和鲁棒性。因此,基于数据驱动建立的 GW-NN 模型是与未知的非线性交叉敏感特性等价的一种描述,有效地抑制了动态测量过程中多敏感因素对含水率测量精度的影响。

6 结 论

油水两相流是一个复杂的双组分非线性时变系统,基于介电常数法的原油含水率动态测量过程存在多变量交叉敏感性,检测精度难以满足石油生产实时优化控制的需要。本文利用多传感器技术对存在交叉耦合的多敏感参量进行测定,提出一种基于遗传优化的小波神经网络逆模型及其辨识方法,仿真和实验结果均表明了该模型的有效性,其模型预测值与标定值之间的相关系数为 0.999 6, 优于 BP-NN 模型。该方法有效抑制了多参量交叉敏感性及传感器自身非线性对测量精

度的影响,改善了传感器的非线性动态特性及检测精度。文中提出的传感器逆模型也适用于其他

存在交叉敏感性的多传感器系统及多源信息融合系统。

参考文献:

- [1] HEWITT G F. *Measurement for Two-Phase Flow Parameters* [M]. London: Academic Press, 1978.
- [2] 张冬至, 夏伯锴, 宋永强. 原油含水率测量多因素影响的数值模拟与实验研究[J]. 计算机与应用化学, 2008, 25(8): 947-950.
ZHANG D ZH, XIA B K, SONG Y Q. Numerical simulation and experimental research of multi-factor influence on the measurement of water content in crude oil [J]. *Computers and Applied Chemistry*, 2008, 25(8): 947-950. (in Chinese)
- [3] ZHANG Y, LIU J H, ZHANG Y H, *et al.*. Cross sensitivity reduction of gas sensors using genetic algorithm neural network[J]. *Optical Engineering*, 2002, 41(3): 615-625.
- [4] 金靖, 张忠钢, 王峥, 等. 基于 RBF 神经网络的数字闭环光纤陀螺温度误差补偿[J]. 光学精密工程, 2008, 16(2): 235-240.
JIN J, ZHANG ZH G, WANG ZH, *et al.*. Temperature error compensation for digital closed-loop fiber optic gyroscope based on RBF neural network [J]. *Opt. Precision Eng.*, 2008, 16(2): 235-240. (in Chinese)
- [5] 洪喜, 续志军, 杨宁. 基于径向基函数网络的光电编码器误差补偿法[J]. 光学精密工程, 2008, 16(4): 598-604.
HONG X, XU ZH J, YANG N. Error compensation of optical encoder based on RBF network [J]. *Opt. Precision Eng.*, 2008, 16(4): 598-604. (in Chinese)
- [6] 高贵斌, 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.
GAO G B, WANG W, LIN K, *et al.*. Error compensation and parameter identification of circular grating angle sensors [J]. *Opt. Precision Eng.*, 2010, 18(8): 1766-1772. (in Chinese)
- [7] 汤晓君, 刘君华. 交叉敏感情况下多传感器系统的动态特性研究[J]. 中国科学 E 辑, 2005, 35(1): 85-105.
TANG X J, LIU J H. Research on dynamic characteristics for multi-sensor system with cross sensitivity [J]. *Science in China (Series E)*, 2005, 35(1): 85-105. (in Chinese)
- [8] TUNCER E, SERDYUK Y V, GUBANSKI S M. Dielectric mixtures; electrical properties and modeling [J]. *IEEE Transactions on Dielectrics and Electrical Insulation*, 2002, 9(5): 809-828.
- [9] MOHAMED A M O, ELAMAL M, ZEKRI A Y. Effect of salinity and temperature on water cut determination in oil reservoirs [J]. *Journal of Petroleum Science and Engineering*, 2003, 40(3-4): 177-188.
- [10] AL-OTAIBI M B, ELKAMEL A, NASSEHI V, *et al.*. A computational intelligence based approach for the analysis and optimization of a crude oil desalting and dehydration process [J]. *Energy & Fuels*, 2005, 19(6): 2526-2534.
- [11] 任磊, 王天婧, 陈祥光. 基于小波变换的油水混合物时域介电谱分析[J]. 兵工学报, 2008, 29(1): 47-51.
REN L, WANG T J, CHEN X G. Analysis of oil-water mixture using time domain dielectric spectroscopy based on wavelet transform [J]. *Acta Armamentarii*, 2008, 29(1): 47-51. (in Chinese)
- [12] 戴先中, 殷铭, 王勤. 传感器动态补偿的神经网络逆系统方法[J]. 仪器仪表学报, 2004, 25(5): 593-596.
DAI X ZH, YIN M, WANG Q. A novel dynamic compensating method based on ANN inverse system [J]. *Chinese Journal of Scientific Instrument*, 2004, 25(5): 593-596. (in Chinese)
- [13] 于丽丽, 刘永红, 蔡宝平, 等. 基于小波神经网络的双电极同步伺服放电加工工艺效果预测[J]. 中国石油大学学报(自然科学版), 2008, 32(4): 87-90.
YU L L, LIU Y H, CAI B P, *et al.*. Prediction for electrical discharge machining process with synchronous servo double electrodes based on wavelet neural network [J]. *Journal of China University of Petroleum (Natural Science Edition)*, 2008, 32(4): 87-90. (in Chinese)
- [14] 俞阿龙, 黄惟一. 力觉临场感系统中操作环境动力学的小波神经网络模型[J]. 仪器仪表学报, 2006, 27(1): 14-18.
YU A L, HUANG W Y. Research on the dynamic model of operating environment in force telepres-

ence system[J]. *Chinese Journal of Scientific Instrument*, 2006, 27(1):14-18. (in Chinese)

- [15] 高美静, 赵勇, 谈爱玲. 基于遗传小波神经网络的多传感器信息融合技术的研究[J]. *仪器仪表学报*, 2007, 28(11):2103-2104.

GAO M J, ZHAO Y, TAN A L. Study on genetic wavelet neural network based multi-sensor information fusion technique[J]. *Chinese Journal of Scientific Instrument*, 2007, 28(11):2103-2104. (in Chinese)

作者简介:



张冬至(1981—),男,山东聊城人,博士研究生,2004年于山东理工大学获得学士学位,2007年于中国石油大学(华东)获得硕士学位,2011年于华南理工大学获得博士学位,主要从事工业生产过程建模仿真控制与优化、智能信息处理、聚合物 MEMS 等方面的研究。E-mail: dz. z@mail. scut. edu. cn



胡国清(1964—),男,四川人,教授,博士生导师,1987年、1990年于西北工业大学分别获得学士和硕士学位,1993年于成都科技大学获得博士学位,现为华南理工大学机械与汽车工程学院机械电子工程研究所副所长,主要从事机电系统与先进传感器技术、自动化装备与控制工程等方面的研究。E-mail: gqhu@scut. edu. cn

●下期预告

应用地球椭球的三线阵立体测绘相机像移补偿

武星星,刘金国

(中国科学院 长春光学精密机械与物理研究所,吉林 长春 130033)

在三线阵立体测绘相机对地成像过程中,正视相机对星下点成像,前视相机和后视相机在沿轨方向分别向前和向后倾斜一定角度成像,而地球实际为椭球体,这些因素都导致了前视、正视和后视相机像移速度和偏流角的差异。在分析三线阵立体测绘相机成像原理的基础上,推导了基于地球椭球的前视、正视和后视相机像移速度和偏流角计算公式,并以某三线阵立体测绘相机为例,选取 WGS84 地球椭球模型,分析了前视相机和后视相机都以正视相机为准调整行周期和偏流角时,像移速度匹配残差和偏流角残差对像质的影响。分析及实验结果表明,以调制传递函数下降 5% 为约束,当积分级数大于 2 时应分别调整前视、正视和后视相机的行周期。按正视相机调整前视相机和后视相机的偏流角时,积分级数应取 40 级以内。