

文章编号: 1000-8152(2005)05-0825-04

基于混沌混合优化的回转干燥窑出料含水量软测量

秦斌^{1,2}, 王欣², 吴敏², 阳春华²

(1. 株洲工学院 电气工程系, 湖南 株洲 412008; 2. 中南大学 信息科学与工程学院, 湖南 长沙 410083)

摘要: 回转干燥窑由于出料含水量难以在线测量, 其过程控制一直是一大难题. 本文在分析回转干燥窑干燥过程的基础上, 提出了基于分布式 RBF 网络的出料含水量软测量模型及其优化学习算法, 首先根据先验知识和聚类将输入空间划分成多个子空间, 对于每个子空间的 RBF 网络, 由 FCM 算法和分区校验熵确定隐含节点数, 中心向量的学习采用混沌优化与 FCM 相结合的混合算法. 设计了获取样本数据的实验, 得到了出料含水量软测量模型, 此模型已成功应用于干燥窑的推断控制中.

关键词: 软测量; RBF 网络; 模糊聚类; 混沌优化; 回转干燥窑出料含水量

中图分类号: TP274, TP183 **文献标识码:** A

Soft-sensor for the water content of dregs in rotary dryer kiln based on hybrid chaos optimization algorithm

QIN Bin^{1,2}, WANG Xin^{1,2}, WU Min², YANG Chun-hua²

(1. Department of Electrical Engineering, Zhuzhou Institute of Technology, zhuzhou Hunan 412008, China;

2. College of Information Science & Engineering, Central South University, Changsha Hunan 410083, China)

Abstract: It is difficult to control the process for rotary dryer kiln because the reliable online measurement for the water content of dregs is hardly available. Based on analysis of the drying process of rotary dryer kiln, this paper proposes a distributed RBF neural network soft-sensor model for water content of dregs and a new hybrid optimal algorithm. The input space is divided into multi-subspace by using prior knowledge and fuzzy clustering. For the RBF network with each subspace, the number of hidden nodes is determined by using the fuzzy c-mean (FCM) clustering algorithm and clustering validity criteria, the learning of center vector adopts the hybrid optimization algorithm combining the chaos optimization with FCM. Experiments of acquiring the sample data are designed. The model has been built and successfully used in the inference control of rotary dryer kiln.

Key words: soft-sensor; radial basis function network; fuzzy clustering; chaos optimization; water content of the dregs of rotary dryer kiln

1 引言 (Introduction)

在复杂工业过程控制系统中, 由于检测元件、工艺和技术等方面条件的限制, 一些关键变量难以在线检测, 如回转干燥窑过程出料含水量等, 给过程控制和监测带来很大困难. 软测量技术是解决这类变量估计问题的有效方法^[1], 它克服人工分析和使用在线分析仪表的许多不足, 是实现推断控制的前提和基础. RBF 网络是一种品质优良的网络, 具有网络结构简单、非线性逼近能力强、收敛速度快以及全局收敛等优点^[2], 因而在软测量建模中得到广泛地应用. 但在实际工业过程中, 常常需面对有限的过程数据, 良好的建模效果一般依赖网络的泛化能力^[1]. RBF 网络的性能严重依赖于基函数的个数、位置 (即

中心向量) 和它的形状, 中心向量的学习是网络性能好坏的关键.

本文在分析回转干燥窑干燥过程的基础上, 提出了一种基于分布式 RBF 模糊神经网络的出料含水量软测量模型, 首先根据先验知识和聚类将输入空间划分成多个子空间, 对于每个子空间的 RBF 网络, 由 FCM 和分区校验熵确定隐含节点数, 中心向量的学习规则采用 FCM 与混沌优化的混合算法, 采用最小二乘法算法优化权值. 设计了在测量困难的情况下获取样本的实验, 得到了出料含水量软测量模型, 并成功地应用于回转干燥窑出料含水量推断控制中, 运行结果表明了该方法的有效性.

2 回转干燥窑工艺流程 (Scheme of the rotary dryer kiln)

在锌湿法冶炼过程中,浸出渣回转干燥窑工艺过程是锌综合回收的重要一环,它将含水量为 35%~40% 的锌焙烧矿浸出渣在回转干燥窑内,通过燃烧煤气产生的烟气与渣的热交换过程,使浸出渣的含水量将降至 15%~17%,然后送到下一步继续回收锌,如图 1 所示.由于粒状固体物料的含水量检测一直是一个尚未解决的难题,因此出料含水量的软测量成为控制系统能否成功的关键.




图 1 回转干燥窑工艺示意图

Fig. 1 Schematic diagram of the rotary dryer kiln

根据 Keyy 等人的研究以及 Krevelen 试验证实物料温度对干燥速率有重要影响,通过一系列合理简化后,逆流型回转干燥窑可由具有分裂边界条件的四联立非线性双曲型偏微分方程来描述,数字仿真表明^[3]:物料在窑内的状态呈现 3 个典型区域:预热带、干燥带、加热带,并且过程响应的非线性相当明显.

3 模型结构 (Architecture of model)

采用多个局部 RBF 网络来构成出料含水量软测量模型^[4],首先利用聚类的思想将学习样本分解成主要工作区间和其他异常工作区间.然后针对每个区间利用本文提出的算法构造并学习 RBF 神经网络.RBF 神经网络由单隐层前向网络组成,如图 2 所示,其中 C 为隐层单元个数,隐层单元输出 $R_i(x)$ 定义为

$$R_i(x) = \exp\left(-\frac{\|x - c_i\|^2}{\sigma_i^2}\right). \quad (1)$$

其网络输出:

$$y = \sum_{i=1}^C R_i(x) * w_i. \quad (2)$$

根据机理分析和实验,将输入空间分成高、低含水量和主工作区间,主取窑中部温度 $T_M(t-2)$, $T_M(t-3)$, $T_M(t-4)$,窑头窑尾温度差 $\Delta T_a(t)$, $\Delta T_a(t-1)$, $\Delta T_a(t-3)$,燃料流量 $Q_f(t)$, $Q_f(t-1)$, $Q_f(t-2)$,烟气流量 Q_a ,窑转速 $V(t-1)$, $V(t-2)$,构成出料含水量模型输入向量 x ,模型输出 y 为出料含水量 M_a .




图 2 RBF 神经网络模型结构

Fig. 2 Architecture of RBF neural network model

4 RBF 网络混沌混合学习算法 (Chaos hybrid learning algorithm of RBF neural network)

4.1 模糊聚类 (Fuzzy clustering)

模糊 C 均值聚类是用隶属度确定每个数据点属于某个聚类的方法.构造样本集 $P_j = \{x_{1,j}, x_{2,j}, \dots, x_{m,j}, y_j\}$, FCM 把 n 个向量 $P_j (j = 1, 2, \dots, n)$ 分为 C 个模糊组,设样本 P_j 属于模糊集合的隶属度为 u_{ij} ,按归一化规定有

$$\sum_{i=1}^C u_{ij} = 1, \quad \forall j = 1, 2, \dots, n. \quad (3)$$

为了衡量聚类的质量,常采用非相似性能指标为聚类准则函数:

$$J(P, C) = \sum_{i=1}^C J_i = \sum_{i=1}^C \sum_{j=1}^n u_{ij}^m d_{ij}^2, \quad (4)$$

式中 d_{ik} 表示第 k 个样本到第 i 个中心点之间的欧氏距离.因为式(4)是有关 C 的单调函数,引入改进 Bezdek 分区熵^[2]来衡量 FCM 聚类数指标:

$$H(U, C) = -\frac{1}{n} \sum_{j=1}^n \max_{i \in C} (u_{ij}) \lg(\max_{i \in C} (u_{ij})). \quad (5)$$

一旦聚类中心向量确定,宽度 σ_i 可通过最接近的 p 个中心距离的平均值计算,使与 σ_i 有关的目标函数极小化

$$E_\sigma = \frac{1}{2} \sum_{i=1}^p \left[\sum_{v_j \in P_{\text{nearest}}} \left(\frac{v_i - v_j}{\sigma_i} \right) - r \right]^2. \quad (6)$$

式中 r 为超调常数.

由 FCM 的算法^[5],通过计算 c 取不同值时的 $H(U, c)$,如果 $H(c-1) \leq H(c)$,并且 $H(c-1) \leq H(c-2)$ 确定隐含节点数为 $(c-1)$,从而确定初步聚类中心向量.将聚类中心向量 V 分成两部分 X 和 Y ,则 X 为输入聚类权向量 Y 为输出权向量.由该方法可确定输入空间划分和输出合成,对于工作点附近子空间,由该方法确定 RBF 网络的隐含节点数和初步聚类中心向量.由于 FCM 算法由取极值的必要条件而非充分条件推出,不能确保 FCM 收敛于一个最优解,算法的性能依赖初始聚类中心,因此有必要进一步优化.

4.2 混沌混合优化 (Chaos hybrid optimization)

对 $J(X, V)$ 连续对象的全局优化问题, 选择 logistic 映射产生的混沌变量:

$$\begin{aligned} z_{i,t+1} &= 4z_{i,t}(1.0 - z_{i,t}), \\ z_{i,t} &\in [0, 1], \quad i = 1, 2, \dots, m + 1. \end{aligned} \quad (7)$$

由于 Logistic 映射落入中心区间的概率密度较小, 而在边缘密度较大, 单纯提高迭代步数并不能显著提高映射的遍历程度, 因此本文提出一种基于混沌混合优化方法, 通过变换或多个变量组合将混沌变量映射到另一区间, 产生基于混沌序列, 概率密度分布满足在优化点处局部寻优的要求, 如取变换:

$$z'_i = z_{i1} + z_{i2}. \quad (8)$$

其概率密度呈中心大两边小, 然后将序列放大到寻优区间上进行混沌初步优化, 得到初始优化值群, 最后与 FCM 方法相结合得到最优点. 混沌混合优化步骤如下:

Step 1 根据前一步确定聚类类别数 C , 预置允许误差 ϵ ; 初始化混沌初值 $z_{i,0}$ 为 $[0, 1]$ 区间 $2C$ 个相异的初值, 且 $z_{i,0}$ 不等于映射不动点; 按式 (8) 生成 $z'_{i,0}$, 预置最优混沌参数初值 $z_i^* C = z'_{i,0}$, 预置进化种群个数 $s (s \leq 5)$, $z_{i,s}^* C$ 为当前得到的最优混沌变量群, 对应的当前最优解指标群队列 $J^* C$ 通常初始化为一个较大的数组; 取前一步得到的模型参数为优化参数 $v_i^* C \sigma_i^* C w_i^* C$ 初值.

Step 2 把 $z'_{i,t}$ 以前一步得到的初值为中心, 线性映射到优化变量取值区间:

$$v_{i,t} = v_i^* C + \beta \sigma_i^* C (z'_{i,t} - 0.5), \quad (9)$$

$i = 1, 2, \dots, C, \beta$ 为宽度系数, 一般取值 $0.5 - 1.0$.

Step 3 若 $J(p, v_{i,t}) < J_s^* C$, 则将 $J(p, v_{i,t})$ 按大小插入 $J_s^* C$ 队列中, $J_s^* C = J(p, v_{i,t}), z_i^* C = z_{i,t}$, 比较此点与队列中前一点和后一点的距离, 若与前点距离小于某预定的正数, 则删除本点, 若与后点距离小于某预定的正数, 则删除后点; 否则继续.

Step 4 $t = t + 1$; 混沌变量迭代: 按式 (7) (8) 计算 $z'_{i,t+1}$.

Step 5 重复 Step 2, 3, 4, 直到一定步数内 $J_s^* C$ 保持不变或达到最大迭代上限为止. 得到的最优 $v_{i,s}^* C$, 即为混沌算法得到的最优聚类中心解群, $J_1^* C$ 为算法得到的最优解.

Step 6 以候选优化群为初值, 分别执行 FCM 算法求得新的最优化聚类中心 v^* , 计算 σ^* .

聚类后权值训练算法运用一组输入向量 $\{x_t | x_t \in \mathbb{R}^m, t = 1, 2, \dots, n\}$ 及其输出 y_t 进行迭代的 LSM 使误差函数

$$E = \sum_{i=1}^n \|\Phi(x_i)w_i - y_i\|^2 \quad (10)$$

最小, 从而达到调节权 w_i 的目的. w_i 的调整公式为^[6]

$$w_{i,t+1} = w_i + \eta_i \Phi(x_i)(y_i - F(x_i)). \quad (11)$$

上式中 t 表示迭代次数往复训练直到误差满足要求为止. 对于一个新的数据输入 x , 先根据区间聚类中心确定子空间隶属度和子空间 RBF 输出, 然后根据隶属度对输出进行加权合成得到估计值.


5 获取样本实验与出料含水量实际模型 (Experiments for sample data and model of the water content of dregs)

5.1 实验 (Experiments)


由于现场出料含水量检测仪表基本不能使用, 故采用离线测量获取实验数据. 考虑到数据样本有限性, 设计了在多个工作区间的出料含水量实验.

在实验中, 实验信号选择为伪随机二位式序列 (PRBS). 通过调整序列的长度 N_p 和码宽, 可以使信号自相关函数逼近白噪声的自相关函数.

将系统稳定在工作点附近后, 分别用煤气和进料输入 PRBS 信号激励这个系统, 部分实验曲线如图 3 所示.



(a) 温度响应曲线



(b) 煤气激励曲线

图 3 实验曲线

Fig. 3 Curves of experiment

5.2 数据处理 (Data processing)

考虑到外部干扰等因素, 输入数据不能直接作为软测量仪表输入, 必须进行预处理. 预处理主要有数据变换和误差处理. 首先对测量数据进行归一化处理, 设输入数据 X 的最大值、最小值分别为 X_{max} , X_{min} , 则归一化值为 $X' = (X - X_{min}) / (X_{max} - X_{min})$, 误差分为随机误差和过失误

差,对于随机误差,采用移动平均值数字滤波.对于过失误差,采用数据协调技术^[7].

输入变量的等级校验,其主要思想是^[8]:在规则前提部分除需校验的变量外,将所有其他变量去除,然后计算有关这个变量的模糊输出,通过计算 m 个输入-输出曲线来校验,将影响较小的输入变量删除.在这个系统中,经过校验,删除了影响较小的输入变量 $Q_r(t)$ 和 $V(t-1)$.

将样本数据由模糊聚类方法分成相应的子空间,将实验数据分成拟合数据和测试数据两部分,应用本文改进的 RBF 神经网络学习算法,按采用 FCM 和 FCM 加混沌混合优化两种方法,在自行编制的软测量模型软件上运行,得到系统的软测量模型.在实际运行中模型可在线校正:

经过一段时间后,如果软测量模型的输出与实际值偏差较大,可以将这组新的数据加入学习样本,剔除与这组新的样本矛盾的样本,重新训练新样本所属的 RBF 神经网络.

主工作区间出料含水量模型训练误差及检验误差数据如表 1 所示,部分模型测试数据输出相应于实际曲线的拟合见图 4.由此可见用本文提出的混沌混合优化方法优于单纯用 FCM 方法,模型较好的反映了过程的变化和趋势,能应用于控制系统的分析和设计.

表 1 模型训练误差及检验误差(误差均方根)

Table 1 Train error and test error of model(RMSE)

| 模型 | 训练误差 | 检验误差 | 隐含节点个数 | 训练数据规模 | 检验数据规模 |
|--------|-------|-------|--------|--------|--------|
| 本文方法 | 0.11% | 1.25% | 8 | 120 | 65 |
| FCM 方法 | 0.21% | 4.24% | 8 | 120 | 65 |




图 4 出料含水量软测量模型输出与实际曲线
Fig. 4 Output of soft-sensor model and field data

6 模型应用及结论 (Application of model and conclusions)

以该模型为中心的出料含水量推断控制系统方案最终在工业控制计算机与单回路控制器组成的两级集散型系统上实现,工业控制计算机完成出料含水量软测量和推断控制,计算结果作为单回路控制

器给定值,单回路控制器完成燃料等回路控制.当进料有一扰动时,出料含水量均能保持在工艺要求范围以内.实现了各热工参数的动态控制和多参数的综合最优化.从而降低了能源消耗,提高了产品质量和产量,获得了显著经济效益.

本文将混沌优化与 FCM 算法相结合,提出了 RBF 模糊神经网络一种新的混沌混合优化方法,解决了神经网络模型复杂性和逼近精度和泛化性能的矛盾,增强了模型的预测能力,实际应用结果表明,采用该方法能达到较好的建模效果.

参考文献 (References):

- [1] THAM M T, MORRIS A J, MONTAGUE G A. Soft-sensors for process estimation and inferential control [J]. *J Proc Control*, 1991, 1(1):3-14.
- [2] BIANCHINI M, FRASCONI P, GORI M. Learning without local minima in radial basis function networks [J]. *IEEE Trans on Neural Networks*, 1995, 6(3):749-756.
- [3] 吴惕华. 回旋烘干过程的数学模型与过程辨识[J]. 化工自动化及仪表, 1985, 12(5):5-12.
(WU Tihua. The mathematical model and identification of rotary dryer process [J]. *Control and Instruments in Chemical Industry*, 1985, 12(5):5-12.)
- [4] 王旭东, 邵惠鹤, 罗荣富. 分布式 RBF 神经网络及其在软测量方面的应用[J]. 控制理论与应用, 1998, 15(4):558-563.
(WANG Xudong, SHAO Huihe, LUO Rongfu. The distributed RBF neural network and its application in soft sensor [J]. *Control Theory & Applications*, 1998, 15(4):558-563.)
- [5] BEZDEK J C. Convergence theory for fuzzy c -means: counterexamples and repairs [J]. *IEEE Trans on Systems, Man and Cybernetics*, 1987, 17(2):873-877.
- [6] SCHWENKER F, KESTLER H A, PALM G. Three learning phases for radial-basis-function networks [J]. *Neural Network*, 2001, 14(4, 5):439-458.
- [7] 李红军, 秦永胜, 徐用懋. 化工过程中的数据协调及显著误差检测[J]. 化工自动化及仪表, 1997, 24(2):25-32.
(LI Hongjun, QIN Yongsheng, XU Yongmao. Data Reconciliation and Gross Error Detection in Chemical Process [J]. *Control and Instruments in Chemical Industry*, 1997, 24(2):25-32.)
- [8] LIN Y, CUNNINGHAM G A. A new approach to fuzzy-neural system modeling [J]. *IEEE Trans on Fuzzy System*, 1995, 3(2):190-198.

作者简介:

秦斌 (1963—), 男, 教授, 中南大学在职博士研究生, 主要从事复杂工业过程建模与智能控制, E-mail: qinbin99@163.com;

王欣 (1971—), 女, 副教授, 博士研究生, 主要研究方向为复杂工业过程建模与智能控制, 实时智能调度系统;

吴敏 (1963—), 男, 教授, 博士生导师, 1986 年于中南工业大学自动化专业获硕士学位, 1999 年获日本东京工业大学博士学位, 研究领域: 鲁棒控制、非线性控制和过程控制, E-mail: min@mail.csu.edu.cn;

阳春华 (1965—), 女, 教授, 博士生导师, 主要研究方向为智能控制、实时优化调度.