

文章编号: 1001-0920(2015)12-2187-06

DOI: 10.13195/j.kzyjc.2014.1770

基于多目标分层遗传模糊建模的磨矿过程溢流粒度软测量

赵 珺, 崔庆磊, 刘 颖, 王 伟

(大连理工大学 控制科学与工程学院, 辽宁 大连 116023)

摘要: 提出一种基于多目标分层遗传算法的模糊系统对溢流粒度进行软测量, 该方法将模糊系统分为4层, 即输入层、隶属度层、规则库层和系统集成层. 为了达到各层共同进化的目的, 设计遗传算法各层编码策略, 构建基于平均绝对百分误差和均方根误差的优化目标函数, 并采用该函数计算各层个体的适应度. 鉴于模糊模型训练过程中可能出现异常解, 将L-M贝叶斯正则化方法融入训练过程. 对磨矿生产数据的仿真实验验证了所提出方法的有效性.

关键词: 溢流粒度; 软测量; 多目标分层遗传算法; L-M贝叶斯正则化

中图分类号: TP206

文献标志码: A

Multi-objective hierarchical genetic fuzzy modeling for soft-sensor of overflow particle size in grinding process

ZHAO Jun, CUI Qing-lei, LIU Ying, WANG Wei

(School of Control Science and Engineering, Dalian University of Technology, Dalian 116023, China. Correspondent: ZHAO Jun, E-mail: zhaoj@dlut.edu.cn)

Abstract: A fuzzy system based on multi-objective hierarchical genetic method is proposed to measure the overflow particle size. The fuzzy system are divided into four layers: the input layer, the membership layer, the rule base layer and the system layer. In order to achieve the purpose of co-evolution for each layer, a coding strategy for each layer is designed here. The mean absolute percentage error(MAPE) and root mean square error(RMSE) are considered as the optimization target to calculate the fitness value of each individual. A L-M Bayesian regularization algorithm is used for training the fuzzy system to avoid the ill-conditioned solution. The experimental results using a series of practical production data coming from a grinding plant show the effectiveness of the proposed method.

Keywords: overflow particle size; soft-sensor; multi-objective hierarchical genetic algorithms; L-M Bayesian regularization algorithms

0 引言

旋流器溢流粒度是选矿工业中判断磨矿分级作业生产状况和后续产品质量的重要指标, 现场工作人员往往根据溢流粒度大小来调节给矿量和给水量, 使整个系统得以平稳高效运行. 因此, 对溢流粒度及时准确地获取成为控制选矿工业高效安全生产的重要环节. 然而, 由于工业现场粒度监测仪抗干扰能力差, 磨矿溢流粒度难以通过仪表进行直接在线测量, 采用科学的软测量方法对溢流粒度进行在线估计是获取溢流粒度的有效方法, 该方法可为磨矿生产的监控和决策提供重要信息^[1].

软测量建模方法可分为机理建模和基于过程数

据建模两种. 对于复杂的磨矿工业环境, 机理模型的构建比较困难, 而且单纯的机理建模应用较少. 近年来, 基于数据的过程建模方法被越来越多地应用于溢流粒度估计. 借助实际生产过程的大量历史数据建立旋流器溢流粒度软测量模型, 常用的方法有神经网络和支持向量机等. 文献[2]通过人工挑选与溢流粒度相关的输入变量, 采用RBF神经网络建立软测量模型对溢流粒度进行在线检测; 文献[3]将混合核支持向量机作为非线性建模工具, 通过遗传算法对支持向量机参数进行优化来建立软测量模型. 然而, 基于神经网络和支持向量机的建模方法对数据要求较高, 对于含噪声水平较高的工业数据存在着泛化能力差、易陷

收稿日期: 2014-11-20; **修回日期:** 2015-02-04.

基金项目: 国家自然科学基金项目(61273037, 61304213, 61473056); 国家863计划项目(2013AA040703); 中央高校基本科研业务费专项资金项目(DUT13RC203).

作者简介: 赵珺(1981—), 男, 副教授, 博士生导师, 从事生产计划与调度、现代集成制造系统、工业生产一体化优化技术等研究; 崔庆磊(1989—), 男, 硕士生, 从事流程工业建模与优化的研究.

入局部最优等问题.

对于复杂的工业系统往往难以采用准确的数学模型来描述,而模糊系统建模为描述复杂非线性系统提供了新手段^[4].模糊系统建模涉及到模糊规则制定问题,文献[5]采用遗传算法解决了该问题,但设计单一的遗传算法只能制定模糊规则,而忽略了模型整体的构建;为此,文献[6]提出了一种基于分层遗传算法的模糊系统,将模糊系统划分为4个层次,即模糊子集集合层、模糊规则层、规则库层和系统层,采用遗传算法对每一层进行优化,通过适应度函数的设置将各层关联起来,达到共同进化的效果.但上述文献中的模糊系统缺少输入层设置,多数采用了手动选择的方法为模型确定输入.文献[7]在已有研究的基础上建立了5层结构的模糊系统,增加了输入变量层,将输入变量的选择过程引入到分层遗传算法中进行优化,可自动获取与模型相关的输入变量.但文献[7]所述的5层结构具有一定的冗余性,其中的模糊规则层和规则库层是可以合并处理的.此外,磨矿工业应用要求所建模型具有稳定性,单纯以模型精度为优化目标是不全面的,还需考虑所建模型的稳定性.

本文针对磨矿过程溢流粒度软测量问题,提出一种基于多目标分层遗传算法的模糊建模方法.该方法将模糊系统划分为输入层、隶属度层、规则库层和系统集成层.为了达到各层共同进化的目的,文中设计了遗传算法各层编码策略,并构建了基于平均绝对百分误差和均方根误差的优化目标函数用于计算各层个体的适应度.鉴于模糊模型训练过程中可能出现异常解,将L-M贝叶斯正则化方法融入训练过程.为了验证本文方法的有效性,分别选取标准数据集和磨矿生产过程实际数据进行实验,并与已有多种方法进行对比实验.实验结果表明,本文方法较其他方法具有较高的预测精度,同时可为制定磨矿控制策略提供科学的决策支持.

1 溢流粒度软测量问题描述

我国某一选矿厂选矿分级系统如图1所示.由图1可以看出,溢流粒度的大小对下级浮选作业会产生重要影响,是现场工作人员确定给矿量和给水量的重要依据.然而,由于磨矿工业生产工艺复杂,难以用仪表在线实时监测溢流粒度,工业现场一般采用人工化验的方法对溢流粒度进行测量,人工化验虽然准确,但化验时间较长,无法满足工业生产实时性的要求.本文借助实际生产过程的大量历史数据建立一种基于多目标分层遗传模糊算法的旋流器溢流粒度软测量模型来解决上述问题.

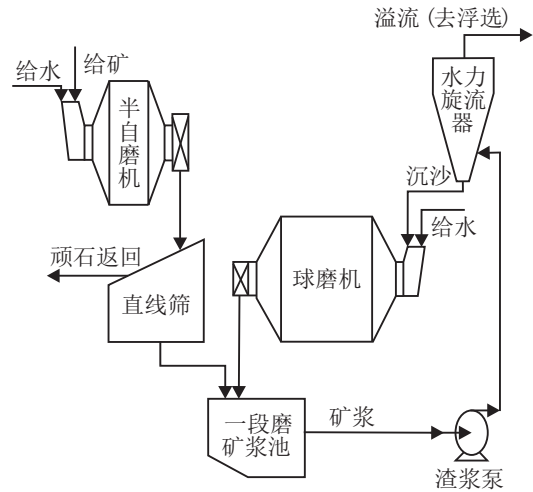


图1 工艺流程图

根据磨矿系统的运行特点建立如下溢流粒度软测量模糊模型:

$$R_i: \text{If } x_1 \text{ is } A_1^i, \text{ and } x_2 \text{ is } A_2^i, \dots, \text{ and } x_n \text{ is } A_n^i,$$

$$\text{Then } Y \text{ is } y_i(c_i, x), \quad i = 1, 2, \dots, k. \quad (1)$$

其中: R_i 为第 i 条溢流粒度模糊规则; x_1, x_2, \dots, x_n 为软测量模型 n 个输入变量, 例如旋流器给矿压力、给矿流量、溢流浓度等; $A_1^i, A_2^i, \dots, A_n^i$ 为每个输入变量的对应模糊子集, 如给矿压力的高、中、低; $y_i(c_i, x)$ 为第 i 条模糊规则的溢流粒度输出值, 即

$$y_i(c_i, x) = c_{i0} + c_{i1}x_1 + \dots + c_{in}x_n + c_{i(n+1)}x_1^2 + \dots + c_{i(2n)}x_n^2 + c_{i(2n+1)}x_1 \times \dots \times x_n, \quad (2)$$

其中向量 $c_i = [c_{i0}, c_{i1}, \dots, c_{i(2n+1)}]^T$ 为第 i 条规则的后件参数. 设有 m 条与粒度相关的样本数据, 每条样本的输入变量 x_q 对应的粒度实际输出为 y_q , 软测量模型输出为 \hat{y}_q ($q = 1, 2, \dots, m$), 则 m 条样本的实际输出为

$$y = [y_1, y_2, \dots, y_m]^T = \Psi C. \quad (3)$$

其中: Ψ 为前件参数矩阵, $C = [c_1^T, c_2^T, \dots, c_k^T]$ 为所有规则的后件参数.

2 基于多目标分层遗传算法的模糊建模

2.1 分层遗传算法结构

模糊模型的建立需要确定模型输入、模糊划分隶属度、模糊规则库等参数, 直接对各部分基于遗传算法进行集成编码很难实现, 因此本文提出采用分层结构的遗传算法对整个模糊系统进行求解. 根据模糊系统的结构将遗传算法的求解过程分为4层: 输入层、隶属度层、规则库层、系统集成层, 其结构如图2所示. 本文提出的分层遗传算法可以实现分别对各层进行编码和计算.

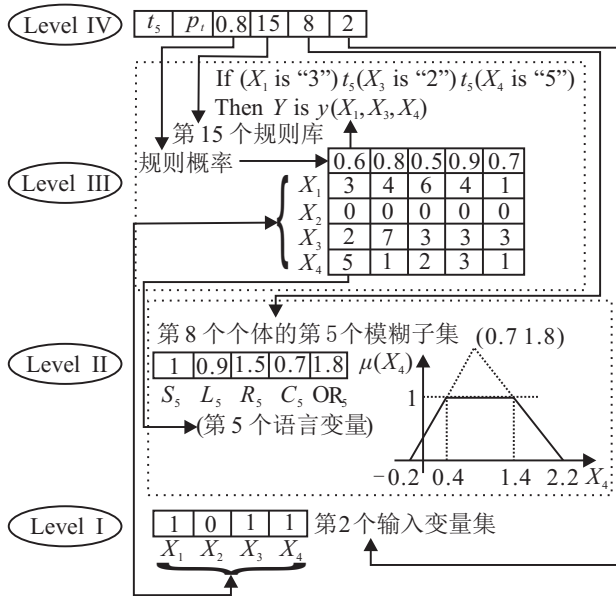


图 2 分层遗传模糊系统结构

在图 2 中: 第 1 层为输入变量确定层, 通过遗传算法的优化可以确定模糊模型的输入; 第 2 层为隶属度层, 指定各条模糊规则中输入变量的隶属度函数; 第 3 层为规则库层, 包含整个模糊系统的规则; 第 4 层为系统集成层, 代表整个溢流粒度软测量模型。

2.2 分层遗传操作

2.2.1 编码方式

第 1 层: 采用二进制编码, 如图 2 中的 Level I 所示。 $X_1 \sim X_4$ 为与溢流粒度相关的输入变量, 分别设为给矿压力、泵池液位、给矿流量、给矿浓度。基因值为 1 的给矿压力、给矿流量、给矿浓度为软测量模型的输入变量, 而基因值为 0 的泵池液位不是模型输入变量。该层编码的长度与溢流粒度的所有相关输入有关。如果某些输入变量有延迟, 则也可对延迟的输入变量进行编码。

第 2 层: 采用实数编码, 代表输入变量的模糊子集集合, 每一个编码个体由若干个如 Level II 所示的模糊子集编码组成。图 2 中的 Level II 展示了第 8 个编码个体的第 5 个模糊子集的编码过程。基因 S_5 代表模糊子集隶属度函数的类型, 其值为 1、2 和 3 时分别代表梯形隶属度函数、三角形隶属度函数和高斯隶属度函数, 0 代表无用的模糊子集编码; 基因 L_5 代表三角形左边点的横坐标与顶点横坐标的距离; 基因 R_5 代表三角形右边点横坐标与顶点横坐标的距离; 编码的最后两个基因 (C_5, OR_5) 分别代表顶点的横坐标和纵坐标。当隶属度函数类型为三角形或高斯型时, 顶点的纵坐标 OR_5 恒为 1; 当 S_5 代表高斯隶属度函数时, 其参数 $\sigma = (L_5 + R_5)/6$ 。通过以上编码可以唯一确定某一隶属度函数及其相关参数。

第 3 层: 采用实数编码, 代表溢流粒度软测量模型的规则库, 其中的每个个体采用一个矩阵表示, 矩

阵的每一列代表一条模糊规则, 如 Level III 所示。以矩阵的第 1 列为例, 第 1 个编码基因代表是否采用此模糊规则的概率, 当规则概率小于某一值时, 此条模糊规则将被采用, 规则概率的使用可有效防止模糊系统出现规则冗余的问题。编码的后 4 位分别代表第 2 层编码的模糊子集序号, 例如当给矿浓度 $X_4 = 5$ 时, 代表给矿浓度对应第 2 层编码的第 5 个语言变量, 当泵池液位 $X_2 = 0$ 时, 代表此输入没有对应的语言变量。本文采用 t_5 模糊算子^[6]进行模糊计算, 其公式为

$$x_1 \ t_5 \ x_2 = \frac{x_1 x_2}{p_t + (1 - p_t)(x_1 + x_2 - x_1 x_2)}. \quad (4)$$

根据编码的后 4 位和模糊算子可以确定一条模糊规则, 以第 1 列为例, 其规则为

$$\begin{aligned} &\text{If } (X_1 \text{ is "3"})_{t_5}(X_3 \text{ is "2"})_{t_5}(X_4 \text{ is "5"}), \\ &\text{Then } Y \text{ is } y(X_1, X_3, X_4). \end{aligned} \quad (5)$$

第 4 层: 采用实数编码, 代表整个软测量模型。编码的前两个基因分别代表模糊控制中的模糊算子和式 (4) 中的参数 p_t , 其中 $p_t \in [0, 10]$ 。编码的第 3 个基因代表第 3 层的规则概率, 其值越大, 系统的规则越多; 编码的第 4 个基因代表第 3 层的规则库序号; 编码的第 5 个基因代表第 2 层的个体序号; 编码的最后一个基因代表第 1 层的输入编码个体序号。

2.2.2 适应度求取

为了保证模型预测的准确性和稳定性, 本文以平均绝对百分误差 (MAPE) 和均方根误差 (RMSE) 为两个优化目标对模糊系统各层进行优化。其中: MAPE 为模型预测的精度指标, 下文用 M 表示; RMSE 为模型预测的平稳性指标, 下文用 R 表示。分别对 MAPE 和 RMSE 作如下定义:

$$MAPE = \frac{1}{S} \sum_{k=1}^S \frac{|y(k) - \hat{y}(k)|}{y(k)}, \quad (6)$$

$$RMSE = \sqrt{\frac{1}{S} \sum_{k=1}^S (y(k) - \hat{y}(k))^2}. \quad (7)$$

其中: S 为测试样本数量, $\hat{y}(k)$ 为第 k 个样本的模型输出, $y(k)$ 为第 k 个样本的溢流粒度实际值。

为了实现各层个体的共同进化, 定义各层个体的适应度为

$$\begin{aligned} f_{si}^i &= (M, R) (i = 1, 2, \dots, n, n \text{ 为种群规模}), \\ f_{rb}^k (M_{rb}^k, R_{rb}^k) &= MR_{\min}(f_{si}^b, \dots, f_{si}^d), \\ f_{ps}^k (M_{ps}^k, R_{ps}^k) &= MR_{\min}(f_{si}^b, \dots, f_{si}^d), \\ f_{is}^k (M_{is}^k, R_{is}^k) &= MR_{\min}(f_{si}^b, \dots, f_{si}^d). \end{aligned} \quad (8)$$

其中: f_{is}, f_{ps}, f_{rb} 和 f_{si} 分别为第 1~4 层个体的适应度; $b \cdots d$ 为各层包含个体 k 的第 4 层个体; $f_{si}^b, \dots, f_{si}^d$ 为第 4 层中包含个体 k 的适应度值; $MR_{\min}(f_{si}^b, \dots, f_{si}^d)$ 为 $f_{si}^b, \dots, f_{si}^d$ 中 MR 最小的适应度值, MR 可以定义为

$$MR = R(1 + \gamma(\text{accuracy} \times e^{-\eta(\text{accuracy} - \mu)})). \quad (9)$$

其中

$$\gamma = \begin{cases} 0, & \text{accuracy} \geq \mu; \\ 1, & \text{accuracy} < \mu. \end{cases}$$

其中: η 用于放大 accuracy 和 μ 的差值,可依据人工经验进行选取,本文实验选取 $\eta = 10$; μ 为人为设定的预测精度值,本文实验选取 $\mu = 0.985$; $\text{accuracy} = 1 - M$ 为训练精度,当 $\text{accuracy} \geq \mu$ 时,MR只与 R 有关,MR越小,个体越好,当 $\text{accuracy} < \mu$ 时,MR越小,个体越好.该公式可以解决在最优个体选取过程中个体之间存在的非支配关系^[8]问题,并可实现模型训练精度达到 μ 之前以提高精度为主,模型精度达到 μ 之后以减少 R 值为主的效果.

2.2.3 各层遗传操作

本文各层种群的选择操作采用锦标赛方法,第1、2、4层个体采用两点交叉操作和单点变异操作^[9].由于采用实数矩阵编码,系统的第3层个体采用区域交叉和区域变异的方法,即对父代的个体随机确定两个点作为矩形的两个对角顶点来确定交叉或变异的矩形区域,对该矩形区域进行交叉操作或对矩形区域里的每个基因在合理的范围内进行变异操作,以获得新的子代个体.第3层个体的区域交叉变异方法可有效地增加种群个体的多样性,减少遗传算法陷入局部最优的情况.

2.3 基于L-M贝叶斯正则化的模型参数确定

传统的求取模糊模型后件参数的方法是最小二乘法,但采用该方法对系数矩阵求逆可能产生奇异解^[10].因此,可采用贝叶斯正则化方法对模型的后件参数 C 进行求解,该方法求解模型后件参数问题的本质是通过最大化后件参数的后验分布来求取后件参数 C 的最优值^[4]

$$p(C|D) \propto \exp\left(-\frac{\beta}{2} \sum_{p=1}^K (\varphi(x_p)C - y_p)^2 - \frac{\alpha}{2} \|C\|^2\right). \quad (10)$$

令 $E_D = \frac{1}{2} \sum_{p=1}^K (\varphi(x_p)C - y_p)^2$ 为模型输出与观察输出的误差, $E_W = \frac{1}{2} \|C\|^2$ 为模型后件参数的平方和,则要求对应后验分布最大的 C 值可以转换为求使 E 最小的 C 值,即

$$E = \alpha E_W + \beta E_D, \quad (11)$$

其中 α 和 β 为超参数.

为了避免参数求解过程中的雅可比矩阵奇异现象,本文将L-M算法与贝叶斯正则化方法相结合,将 E_D 和 E_W 分别改写为

$$\begin{cases} E_D = \frac{1}{2} \|\varepsilon(C^k) + Z(\Delta C)\|^2 + \lambda \|\Delta C\|^2, \\ E_W = \frac{1}{N} \|C\|^2. \end{cases} \quad (12)$$

其中: $\Delta C = C^{k+1} - C^k$, N 为后件参数的个数, λ 可在迭代过程中依据误差 E 的大小取值.

超参数 α 和 β 可通过迭代更新的方式获取,其更新公式为

$$\begin{aligned} \alpha^{k+1} &= \frac{\gamma^{k+1} E_W^{k+1}}{2}, \\ \beta^{k+1} &= \frac{(N - \gamma^{k+1}) E_D^{k+1}}{2}, \\ \gamma^{k+1} &= N - 2\alpha^k \text{tr}(H)^{-1}. \end{aligned} \quad (13)$$

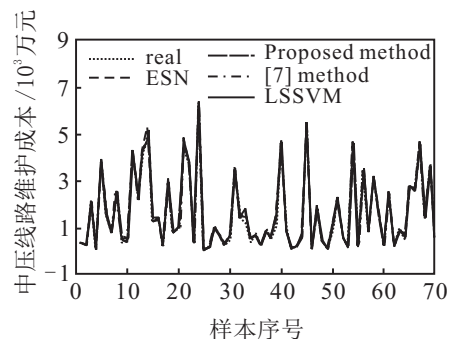
其中: k 为迭代次数, H 为目标函数的Hessian矩阵^[11].通过采用新的目标函数能保证在模型训练误差尽可能小的情况下使模型具有较小的值,可以有效避免模型训练过程中可能产生的异常解现象,提高模型的泛化能力.

3 实验及运行效果

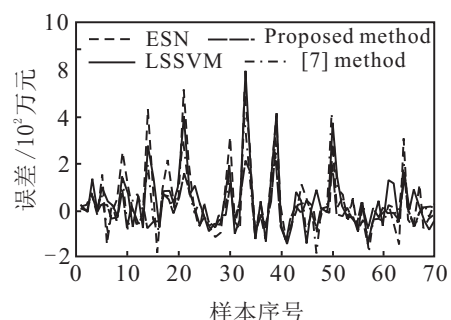
为了验证本文所提方法的有效性,本文选取两组数据进行验证,一组为中压线路维护成本标准数据集^[12],另一组为某选矿厂的工业数据.由于LSSVM、ESN和文献[7]中的方法是常用的溢流粒度软测量方法,实验过程中会将本文方法与其进行比较.

3.1 中压线路维护成本软测量

该标准数据集是一组4输入1输出的数据集,共分为训练数据集和测试数据集两部分,本文从训练数据集中随机选取300条训练数据来建立软测量模型,从测试数据集中随机抽取8组样本验证模型的正确性,每组样本包含70条数据,实验取8组测试结果的均值作为总的测试结果,其中一组实验的预测结果和误差对比如图3所示.



(a) 预测结果对比



(b) 误差对比

图3 标准数据集下4种方法的预测结果和误差对比

表 1 标准数据集软测量对比实验参数和结果

方法	输入变量	实验参数	实验结果
本文	4	训练数据: 300	MAPE = 0.067 6
		规则数量: 28	RMSE = 72.523 2
文献 [7]	4	训练数据: 300	MAPE = 0.096 9
		规则数量: 32	RMSE = 115.026 6
LSSVM	4	训练数据: 300	MAPE = 0.118 3 RMSE = 139.892 0
		嵌入维数: 4	
		核函数: RBF	
		惩罚系数: $\gamma = 92.95$ 核参数: $\sigma^2 = 40.17$	
ESN	4	训练数据: 300	MAPE = 0.128 1 RMSE = 155.958 9
		嵌入维数: 4	
		神经元个数: 360	
		谱半径: 0.99	

4 种方法的模型训练参数和预测结果详见表 1。由实验结果可以看出, 本文方法较其他方法预测更精确, 误差波动较少, 误差绝对值基本维持在 100 以内, 而其他 3 种方法会出现个别点波动较大的情况, 模型预测的稳定性较差。

3.2 磨矿溢流粒度软测量

为了验证本文方法的实际应用价值, 选取某选矿场真实数据进行磨矿溢流粒度软测量实验。通过图 1 的工艺分析可以确定, 与旋流器溢流粒度相关的输入为 9 个, 分别为 u_1, u_2, \dots, u_9, y 为软测量模型的输出, 模型相关的输入输出各变量代表的具体含义如表 2 所示。

表 2 模型输入输出各变量代表的含义

变量	变量描述
u_1	旋流器给矿压力
u_2	旋流器给矿流量
u_3	旋流器给矿浓度
u_4	泵池液位
u_5	渣浆泵频率
u_6	溢流流量
u_7	溢流浓度
u_8	旋流器组数
u_9	沉沙量
y	溢流粒度


所有的输入输出数据的时间间隔均为 1 min, 由于工业实际生产过程中各输入变量对输出溢流粒度的延迟较短, 故可忽略不计。

实验在 6 月 6 日~6 月 17 日的磨矿数据中选取 204 条具有代表性的样本数据作为训练数据, 在 9 月份的磨矿数据中随机抽取 8 组样本来验证模型的正确性, 每组样本包含 70 条数据, 实验取 8 组测试结果的均值作为总的测试结果。


在实验中: 本文方法模型训练完成后, 经算法第 1 层优化选取 u_1, u_2, u_3, u_7, u_8 作为模型的实际输入, 并构建了 31 条模糊规则; 文献 [7] 方法模型训练完成

后, 经算法第 1 层优化选取 $u_1, u_2, u_3, u_6, u_7, u_8$ 作为模型的实际输入, 并构建了 35 条模糊规则。为了使实验结果更具可比性, LSSVM 方法和 ESN 方法采用与本文方法相同的模型输入。

4 种方法对溢流粒度软测量的预测结果和误差对比如图 4 所示。



(a) 预测结果对比



(b) 误差对比

图 4 磨矿数据下 4 种方法的预测结果和误差对比

由图 4 可以看出: LSSVM 方法对于某些突变点预测效果较差; ESN 方法预测结果波动较大, 预测误差较大; 文献 [7] 方法也会出现个别点预测误差较大的情况; 本文方法预测结果较好。

4 种方法的溢流粒度软测量对比实验参数和结果如表 3 所示。在上述实验结果的基础上, 表 3 进一步给出了多次溢流粒度软测量对比实验的统计结果, 该结果充分说明了本文方法在解决溢流粒度软测量问题上的优势。

表 3 溢流粒度软测量对比实验参数和结果

方法	输入变量	实验参数	实验结果
本文	u_1, u_2, u_3, u_7, u_8	训练数据: 240 规则数量: 31	MAPE = 0.022 0 RMSE = 1.854 3
文献 [7]	$u_1, u_2, u_3, u_6, u_7, u_8$	训练数据: 240 规则数量: 35	MAPE = 0.045 4 RMSE = 3.593 5
LSSVM	u_1, u_2, u_3, u_7, u_8	训练数据: 240 嵌入维数: 5 核函数: RBF 惩罚系数: $\gamma = 100.56$ 核参数: $\sigma^2 = 95.23$	MAPE = 0.059 7 RMSE = 4.101 0
ESN	u_1, u_2, u_3, u_7, u_8	训练数据: 240 嵌入维数: 5 神经元个数: 280 谱半径: 0.98	MAPE = 0.056 7 RMSE = 4.339 7

4 结 论

本文提出了一种基于模糊建模的软测量方法, 采用多目标分层遗传算法对模糊模型的参数进行调整和优化, 可用于选矿工艺溢流粒度的实时监测. 该方法可以基于历史数据自动获取软测量模型, 无需人工经验干预. 在多目标分层遗传算法的作用下, 可自动获取模糊模型的输入、模糊子集、模糊规则等系统参数. 而模糊模型后件参数则是通过基于 L-M 的贝叶斯正则化方法获取, 该方法可避免模糊模型训练过程中可能产生的异常解现象. 仿真实验表明, 所提方法在对含有噪声的磨矿数据建模方面具有一定优势, 并且可以保证所建立的软测量模型具有准确性和稳定性, 模型预测结果是现场工作人员确定给矿量和给水量的重要依据, 可以为制定磨矿控制策略提供科学的决策支持.

参考文献(References)

- [1] Garcia O, Cobos J A, Prieto R, et al. Single phase power factor correction: A survey[J]. IEEE Trans on Power Electronics, 2003, 18(3): 749-755.
- [2] 张晓东, 王伟, 王小刚. 选矿过程神经网络粒度软测量方法的研究[J]. 控制理论与应用, 2002, 19(1): 85-88. (Zhang X D, Wang W, Wang X G. Research of the particle size neural network soft sensor for concentration process[J]. Control Theory & Applications, 2002, 19(1): 85-88.)
- [3] 王新华, 桂卫华, 王雅琳, 等. 混合核函数支持向量机的磨矿粒度预测模型[J]. 计算机工程与应用, 2010, 46(12): 207-209. (Wang X H, Gui W H, Wang Y L, et al. Prediction modeling for particle size of grinding circuit of mixture kernels SVM[J]. Computer Engineering and Applications, 2010, 46(12): 207-209.)
- [4] 盛春阳, 赵珺, 王伟, 等. 基于 T-S 模型的高炉煤气系统模糊建模[J]. 上海交通大学学报, 2012(12): 1907-1913. (Sheng C Y, Zhao J, Wang W, et al. a Fuzzy modeling method based on T-S model for blast furnace gas system[J]. J of Shanghai Jiaotong University, 2012(12): 1907-1913.)
- [5] Yusof R, Rahman R Z A, Khalid M, et al. Optimization of fuzzy model using genetic algorithm for process control application[J]. J of the Franklin Institute, 2011, 348(7): 1717-1737.
- [6] Delgado M R, Von Zuben F, Gomide F. Hierarchical genetic fuzzy systems[J]. Information Sciences, 2001, 136(1): 29-52.
- [7] Mendes J, Souza F, Araújo R, et al. Genetic fuzzy system for data-driven soft sensors design[J]. Applied Soft Computing, 2012, 12(10): 3237-3245.
- [8] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Trans on Evolutionary Computation, 2002, 6(2): 182-197.
- [9] Grefenstette J J. Multilevel credit assignment in a genetic learning system[C]. Proc of the 2nd Int Conf on Genetic Algorithms and Their Applications. London: Psychology Press, 2013: 705-706.
- [10] 蒋强, 肖建, 何都益, 等. 基于 T-S 模型的模糊系统辨识方法综述[J]. 计算机应用研究, 2009, 26(6): 2008-2012. (Jiang Q, Xiao J, He D Y, et al. Overview of methods of fuzzy system identification on T-S model[J]. Application Research of Computers, 2009, 26(6): 2008-2012.)
- [11] Lauret P, Fock E, Randrianarivony R N, et al. Bayesian neural network approach to short time load forecasting[J]. Energy Conversion and Management, 2008, 49(5): 1156-1166.
- [12] Rezaee B, Zarandi M H. Data-driven fuzzy modeling for Takagi-Sugeno-Kang fuzzy system[J]. Information Sciences, 2010, 180(2): 241-255.

(责任编辑: 闫 妍)