

基于 ASOS-ELM 的湿式球磨机负荷软测量方法^{*}

蔡改贫, 赵小涛, 张丹荣, 宗路

(江西理工大学机电工程学院 赣州, 341000)

摘要 针对湿式球磨机在磨矿过程中内部负荷靠专家经验难以准确预测的问题, 提出一种基于改进的共生生物搜索 (ameliorated symbiotic organisms search, 简称 ASOS)-极限学习机 (extreme learning machine, 简称 ELM) 的磨机负荷软测量方法。首先, 利用 ELM 算法建立磨机负荷软测量模型, 运用 ASOS 算法优化软测量模型的隐含层参数; 其次, 以筒体振动与振声信号的特征信息构建磨机负荷特征向量, 并将其作为软测量模型的输入, 将磨机负荷参数作为输出; 最后, 通过磨矿负荷检测实验和对比分析表明, 磨机负荷软测量模型的负荷参数预测准确率较高, 泛化能力较强, 为磨机磨矿效率的提高及控制优化提供了有益的指导。

关键词 磨机负荷; 极限学习机; 共生生物搜索; 软测量

中图分类号 TD4; TH133.3; TH132.41

引言

研磨是选矿流程中的关键工序, 研磨过程是通过湿式球磨机将粉碎的矿石研磨成合格粒度的矿浆, 为选矿过程提供原料。磨机的运转率和效率决定了磨矿过程甚至选矿流程的生产效率及指标^[1-3]。在磨矿过程中, 由于磨机筒体内部环境恶劣且工况复杂, 其负荷参数难以准确检测^[4-5]。现有的湿磨负荷检测方法是通过对磨机轴承振动、磨矿过程的振声信号及磨机主电机的电流信号来确定磨机负荷。上述检测方法存在精度低、性能不稳定和难以在现场实施等缺点, 且只能判断磨机负荷状态和检测磨机内部的料球比^[6-8]。

文献[9]采用振声、磨尾矿提升机瞬时功率、粗粉回流量和物料的湿度等因素建立回归方程, 以此来检测磨机负荷参数。Yue 等^[10]提出了基于非线性算法 (partial least square, 简称 PLS) 磨机内部负荷的预测方法。文献[11]运用最小二乘支持向量机 (least squares support vector machines, 简称 LSSVM) 算法建立了筒体内部负荷参数的预测模型, 对该方法进行仿真分析, 同时与其他方法进行了对比, 结果得出该方法的泛化能力较强。汤健等^[12]利用分支定界选择性集成 (improved branch and bound based selective ensemble, 简称 IBBSEN) 算法建立筒体内部负荷参数

的预测模型, 采用现场数据对该方法进行了验证。王东风等^[13]针对干式球磨机采用模糊方法划分磨机工况为正常工况和接近堵磨工况, 以出口温度、出入口压差、入口负压、入料速度和热风热量作为神经网络的输入, 磨机筒体内的负荷参数作为输出, 利用前向负荷型神经网络建立磨机筒体内部负荷参数的预测模型。文献[14]针对模糊工况划分方法的人为性, 采用并行径向基函数 (radial basis function, 简称 RBF) 神经网络检测磨机筒体内部负荷, 该方法在网络结构中不断增加新的 RBF 函数, 直到学习误差满足要求为止, 并对该方法进行了仿真实验。

近年来, 一些学者对神经网络算法进行深入研究, 提出基于误差反向传播 V 神经网络改进算法的软测量方法等^[15]。由于上述研究没有对模型的输入变量进行相关分析和降维, 对变量的选择也具有较大的人为性, 因此笔者采用极限学习机算法建立磨机负荷软测量模型, 利用改进的共生生物搜索算法对软测量模型优化, 实现磨机负荷参数准确有效的预测。

1 磨机负荷软测量模型的建立

1.1 ELM 算法分析

ELM 是一种新的针对单隐层神经网络的学习算法, 该算法的训练过程快速简单, 泛化性能良好,

^{*} 国家自然科学基金资助项目 (51464017); 江西省教育厅科技重点资助项目 (GJJ150618)

收稿日期: 2019-06-27; 修回日期: 2019-08-09

因此该方法被广泛应用于各种复杂工业过程的软测量建模,其原理结构如图 1 所示。




图 1 ELM 算法的结构原理

Fig. 1 The structural principle of the ELM algorithm

分析图 1 可知,ELM 算法由输入层、隐含层和输出层组成,输入层与隐含层、隐含层与输出层通过神经元连接。其中: $x_{i_1}, x_{i_2}, \dots, x_{i_L}$ 为 L 个输入变量,对应输入层 L 个神经元; $y_{o_1}, y_{o_2}, \dots, y_{o_K}$ 为 K 个输出变量,对应输出层的 K 个神经元。给定一训练样本为 $P = \{(\mathbf{x}_l, \mathbf{y}_l) \mid \mathbf{x}_l \in \mathbf{R}^n, \mathbf{y}_l \in \mathbf{R}^m, l=1, 2, \dots, N\}$, 其中: \mathbf{x}_l 为磨机筒体振动和振声信号特征信息组成的特征向量; \mathbf{y}_l 为磨机内部负荷参数; N 为输入节点数。

设 L 为隐含层节点数,则激活函数为 $g(x)$ 的 ELM 可表示为

$$\sum_{i=1}^L \beta_i g_i(\mathbf{x}_j) = \sum_{i=1}^L \beta_i g(\omega_i \cdot \mathbf{x}_j + b_i) = y_j \quad (1)$$

其中: β_i 为第 i 个隐含层节点与输出层节点的权值向量; ω_i 为隐含层第 i 个节点与输入层节点的权值向量; b_i 为第 i 个隐含层节点的偏置参数; ω_i 和 b_i 可以随机生成; $j = 1, 2, \dots, M$; M 为输出节点数; $g(\cdot)$ 表示隐含层的激活函数; $\omega_i \cdot \mathbf{x}_j$ 为 ω_i 和 \mathbf{x}_j 的内积。

训练整个单层神经网络的目标是使输出值和实际值的误差最小,可表示为

$$\sum_{j=1}^M \|y_j - t_j\| = 0 \quad (2)$$

则问题的求解转化为求解最优权值,即存在 β_i, ω_i 和 b_i ,使得

$$\sum_{i=1}^L \beta_i g(\omega_i \cdot \mathbf{x}_j + b_i) = t_j \quad (j=1, 2, \dots, M) \quad (3)$$

式(3)的矩阵表达式如式(4)所示

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (4)$$

$$\mathbf{H} = \begin{bmatrix} g(\omega_1 \cdot \mathbf{x}_1 + b_1) & \cdots & g(\omega_L \cdot \mathbf{x}_1 + b_L) \\ \vdots & & \vdots \\ g(\omega_1 \cdot \mathbf{x}_M + b_1) & \cdots & g(\omega_L \cdot \mathbf{x}_M + b_L) \end{bmatrix}_{M \times L} \quad (5)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^o \\ \vdots \\ \beta_L^o \end{bmatrix} \quad (6a)$$

$$\mathbf{T} = \begin{bmatrix} T_1^o \\ \vdots \\ T_M^o \end{bmatrix} \quad (6b)$$

其中: \mathbf{H} 为 ELM 隐含层输出矩阵,其第 i 列为第 i 个隐含层节点对应于输入 x_1, x_2, \dots, x_N 的第 i 个隐含层神经元的输出向量; $\boldsymbol{\beta}$ 为 ELM 输出权重; \mathbf{T} 为期望输出,为了使 ELM 具有较好泛化能力,令 $L < M$ 。

ELM 算法的训练过程可以描述为非线性优化问题,当激活函数 $g(x)$ 无限可微时,网络输入权值 ω_i 和隐含层阈值 b_i 可以随机赋值,此时 \mathbf{H} 为一个常数矩阵,连接隐含层和输出节点的权值可以通过求解线性方程组 $\mathbf{H}\boldsymbol{\beta} = \mathbf{Y}$ 的最小二乘解得到,其解为

$$\hat{\boldsymbol{\beta}} = (\mathbf{H}^+ \mathbf{H})^{-1} \mathbf{H}^o \mathbf{Y} \quad (7)$$

其中: \mathbf{H}^+ 为输出矩阵 \mathbf{H} 的 Moore-Penrose 广义逆矩阵,同时求得 $\hat{\boldsymbol{\beta}}$ 为最小解且唯一。

1.2 磨机负荷特征向量的构建

利用 MEEMD 算法对磨机筒体振动信号和振声信号预处理,通过云模型提取不同负荷参数下筒体振动信号的特征信息,并采用 IMF 能量法提取振声信号的特征信息,以筒体振动信号的云模型特征和磨机振声信号的 IMF 能量占比构建特征向量,结果如表 1 所示,并将其作为训练及测试样本。

1.3 基于 ELM 的磨机负荷软测量模型建立

通过对 ELM 算法原理的研究分析可知,ELM 算法在计算性能和准确性等方面具有特定的优势,在缺乏高级经验知识的情况下,ELM 的输入权值和隐含层阈值一般是随机确定的,并求出输出权值,且在执行过程中不需要调整输入权值和阈值。以磨机筒体振动信号和振声信号的特征信息构成的特征向量为输入,填充率、料球比和磨矿浓度为输出,采用 ELM 算法建立湿式磨机负荷软测量模型,其建立步骤如下:

- 1) 确定训练样本和隐含层节点数;
- 2) 对输入权值矩阵 ω_m 和隐含层阈值 b 随机取值;
- 3) 计算隐含层输出矩阵;
- 4) 根据式(7)求得输出权值矩阵 $\hat{\boldsymbol{\beta}}$ 。

考虑到输入权值和隐含层阈值随机选择不当,会影响 ELM 模型的磨机负荷软测量精度和泛化能

表1 不同工况的筒体振动与振声信号的特征向量

Tab.1 Characteristic vector of cylinder vibration and vibration signal under different working conditions

序号	负荷参数 ($\varphi_{mbw}, \varphi_{mw}, \varphi_{mb}$)	筒体振动信号云模型特征 (E_x, E_n, H_c)	磨机振声信号 IMF 能量占比 T
1	(10%, 0.4, 0.5)	(-0.808 2, 105.181 7, 143.971 5)	(0.186 4, 0.352 7, 0.261 1, 0.113 6, 0.053 9, 0.032 3)
2	(10%, 0.6, 0.7)	(-0.753 9, 102.413 6, 131.156 4)	(0.175 8, 0.381 3, 0.236 2, 0.101 7, 0.062 7, 0.024 5)
3	(10%, 0.8, 0.9)	(-0.831 7, 100.852 7, 140.528 4)	(0.149 2, 0.360 8, 0.274 4, 0.098 3, 0.056 5, 0.029 4)
4	(10%, 1.0, 0.6)	(-0.850 2, 103.472 1, 156.257 1)	(0.163 4, 0.379 4, 0.296 1, 0.126 8, 0.041 2, 0.031 7)
5	(10%, 1.2, 0.8)	(-0.816 3, 107.147 9, 144.984)	(0.159 7, 0.349 1, 0.284 3, 0.108 6, 0.047 6, 0.038 4)
...
11	(20%, 0.4, 0.9)	(-0.924 8, 81.267 1, 114.583)	(0.218 7, 0.338 6, 0.246 7, 0.146 1, 0.098 4, 0.041 2)
12	(20%, 0.6, 0.6)	(-0.881 3, 82.364 7, 112.872 1)	(0.236 3, 0.321 8, 0.253 2, 0.168 4, 0.083 2, 0.035 6)
13	(20%, 0.8, 0.8)	(-0.893 2, 80.528 4, 115.548 1)	(0.241 8, 0.346 8, 0.261 9, 0.153 7, 0.104 7, 0.033 7)
14	(20%, 1.0, 0.5)	(-0.915 8, 84.918 7, 118.374)	(0.229 6, 0.350 8, 0.257 4, 0.183 6, 0.098 1, 0.043 8)
15	(20%, 1.2, 0.7)	(-0.938 7, 85.147 3, 116.158 6)	(0.253 7, 0.361 1, 0.231 7, 0.175 9, 0.093 5, 0.029 1)
...
21	(30%, 0.4, 0.8)	(-0.492 2, 69.285 7, 98.621 7)	(0.369 5, 0.286 2, 0.148 7, 0.071 3, 0.108 7, 0.019 5)
22	(30%, 0.6, 0.5)	(-0.513 7, 71.174 3, 85.485 9)	(0.358 4, 0.249 5, 0.162 8, 0.069 4, 0.097 4, 0.016 4)
23	(30%, 0.8, 0.7)	(-0.481 4, 66.890 2, 91.294 1)	(0.394 2, 0.254 3, 0.175 6, 0.039 4, 0.118 9, 0.017 6)
24	(30%, 1.0, 0.9)	(-0.458 1, 64.351 4, 74.351 5)	(0.386 1, 0.273 9, 0.182 7, 0.042 6, 0.105 8, 0.018 4)
25	(30%, 1.2, 0.6)	(-0.487 3, 62.531 9, 81.217 3)	(0.364 3, 0.268 3, 0.159 7, 0.034 6, 0.125 5, 0.020 6)
...
31	(40%, 0.4, 0.7)	(-0.431 5, 51.684 7, 79.368 4)	(0.318 5, 0.218 7, 0.270 6, 0.131 7, 0.075 1, 0.025 7)
32	(40%, 0.6, 0.9)	(-0.428 9, 53.584 1, 78.318 5)	(0.336 1, 0.241 6, 0.294 8, 0.125 8, 0.086 2, 0.023 8)
33	(40%, 0.8, 0.6)	(-0.419 7, 52.687 3, 76.359 1)	(0.327 4, 0.228 1, 0.265 5, 0.140 9, 0.063 4, 0.028 3)
34	(40%, 1.0, 0.8)	(-0.437 4, 55.981 4, 77.582 9)	(0.348 1, 0.239 4, 0.283 6, 0.157 2, 0.091 4, 0.030 3)
35	(40%, 1.2, 0.5)	(-0.401 9, 54.863 7, 80.731 7)	(0.339 5, 0.208 3, 0.274 2, 0.146 2, 0.081 3, 0.021 7)
...
41	(50%, 0.4, 0.6)	(-0.381 6, 36.259 4, 71.154 8)	(0.267 5, 0.401 8, 0.096 3, 0.193 7, 0.024 8, 0.038 4)
42	(50%, 0.6, 0.8)	(-0.375 7, 32.104 6, 75.379 1)	(0.284 3, 0.393 1, 0.108 4, 0.176 4, 0.025 1, 0.039 1)
43	(50%, 0.8, 0.5)	(-0.417 4, 30.384 2, 66.315 7)	(0.291 8, 0.373 9, 0.116 4, 0.204 7, 0.023 5, 0.032 7)
44	(50%, 1.0, 0.7)	(-0.351 7, 33.602 4, 64.683 1)	(0.278 2, 0.386 9, 0.128 7, 0.185 3, 0.026 4, 0.036 2)
45	(50%, 1.2, 0.9)	(-0.451 2, 34.831 4, 68.164 2)	(0.269 7, 0.365 1, 0.137 7, 0.193 1, 0.031 6, 0.040 5)
...

力。因此,为了提高模型的测量精度,通过混沌自适应鲸鱼优化算法搜索调整得到最佳输入权值和隐含层阈值,在隐含层节点尽可能少的情况下使得 ELM 算法的回归效果最好。

隐含层神经元数量和激活函数类型对磨机负荷参数软测量模型的预测结果的影响较为显著,其中,常用的激活函数类型有 Sin, Sig 和 Hardlim。为了进一步确定隐含层神经元的最佳数量和激活函数,以均方根误差 (root mean squared error, 简称 RMSE) 为磨机负荷软测量模型的评价指标,从表 1 中选取每种负荷状态的 10 组筒体振动与振声信号作为训练样本,每组样本的多特征参数构成输入矩阵,故输入矩阵的维度为 9,磨机筒体内部负荷参数 (填充率、料球比及磨矿浓度) 作为输出矩阵,则 ELM 模型的输出层有 3 个神经元,仿真得到不同激

活函数类型和隐含神经元数量的 ELM 训练的均方根误差如图 2 所示。

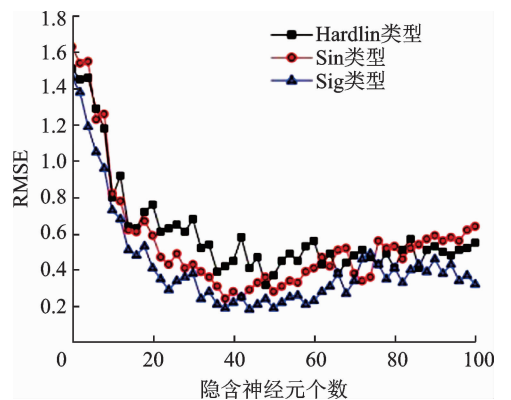


图2 不同激活函数的 RMSE 与隐含神经元个数关系曲线
Fig.2 Relationship between RMSE and number of hidden neurons in different activation functions

从图 2 可以看出,3 种激活函数的均方根误差随着隐含神经元数量的增加呈现先快速减小后再缓慢波动。其中:Hardlim 类型的整体均方根误差较大,稳定后达到 0.503 7;Sig 类型的整体均方根误差较小。进一步分析图 2 可知,对于不同的激活函数,隐含神经元数量在 30~60,ELM 磨机负荷软测量模型的均方根误差最小;当激活函数为 Sig 类型且隐含神经元数量为 44 时,磨机负荷软测量模型的均方根误差达到最小值 0.182 4。因此,选取 Sig 类型作为 ELM 磨机筒体内部负荷软测量模型的激活函数。

图 3 为磨机负荷参数的预测值与实际值对比。由图 3 可知,利用 ELM 磨机负荷软测量模型预测的填充率、料球比和磨矿浓度的预测值和实际值存在着较大的误差,因此需要对磨机负荷软测量模型进一步优化。




图 3 磨机负荷参数的预测值与实际值对比

Fig. 3 Comparison of predicted and actual values of mill load parameters

2 磨机负荷软测量模型的优化

2.1 改进的共生生物搜索算法

共生生物搜索算法 (symbiotic organisms search, 简称 SOS) 是由 Cheng 等于 2014 年提出的一种智能算法。该算法是源于物种在生态系统中生存的共生互动策略,并将共生关系主要概括为“互利”、“共栖”和“寄生”3 种^[16]。根据该算法原理依次建立搜索原则,具体步骤如下。

1) 随机初始化一个总数为 N 的“生物”种群,定义每个“生物”为一个初始解。根据式(8)初始化种群

$$X_i = L_b + \text{rand}(1, D)(U_b - L_b) \quad (8)$$

其中: X_i 为生态系统中第 i ($i=1, 2, \dots, N$) 个“生物”; D 为解的维数; $\text{rand}(1, D)$ 为 $1 \times D$ 维的缩放因子向量; U_b, L_b 为搜索空间的上界和上界。

2) 互利:在该阶段,随机从种群中选取一个“生物” X_i 和 X_j ,并相互产生互利作用,使 X_i 和 X_j 均向最优解学习。 X_j 与 X_i 按式(9)生成新的解 $X_{i\text{new}}, X_{j\text{new}}$ 。

$$\begin{cases} X_{i\text{new}} = X_i + \text{rand}(0, 1)(X_{\text{best}} - M_v B_1) \\ X_{j\text{new}} = X_j + \text{rand}(0, 1)(X_{\text{best}} - M_v B_2) \end{cases} \quad (9)$$

$$M_v = \frac{X_i + X_j}{2} \quad (10)$$

其中: $i, j \in \{1, 2, \dots, N\}, i \neq j$; 缩放因子 $\text{rand}(0, 1)$ 为 $[0, 1]$ 之间的随机数; X_{best} 为当前最优个体; B_1, B_2 为随机因子,是 $\{1, 2\}$ 中的随机数; M_v 为“互利向量”。

互利作用中的两个“生物”获得的收益由获益因子决定,获益因子大的生物收益越多,获益因子小则生物的收益越少。

3) 共栖:和“互利”阶段类似,随机选取一个“生物” X_i 与另一个“生物” X_j 相互作用,让 X_i 从该作用中受益,而 X_j 则不受该作用的影响, X_i 根据式(11)进行更新。

$$X_{i\text{new}} = X_i + \text{rand}(-1, 1)(X_{\text{best}} - X_j) \quad (11)$$

其中: $\text{rand}(-1, 1)$ 为 $[-1, 1]$ 之间的随机数; $X_{\text{best}} - X_j$ 表示 X_i 在 X_j 提供的帮助下不断向最优生物靠拢,并只留下最优的生物。

4) 寄生:首先,按照随机的规则修改 X_i 中的一个或多个元素,从而获得一个新生物,将其称为“寄生向量”,记作 X_{pv} ;其次,依据同样的规则在种群中随机选择一个生物 X_j ($i \neq j$) 作为 X_{pv} 的“宿主”,

计算并对比“寄生向量”和“寄主”的适应度值,如果“寄生向量”的适应度值优于“宿主”,则生物 X_j 会被替换,否则 X_j 将具有免疫性,因此被保留直至下一次“寄生”。

由于共生生物搜索算法在寻优过程中具有随机性,导致该算法的寻优时间较长。因此对该算法进行改进,使改进的共生生物搜索算法有更快的求解速度与更好的收敛精度。该方法具体描述如下。

1) 改善互利系数。由于互利系数对变量 M_v 的影响较大,但在共生生物搜索算法中,仅有 1 和 2 两个互利系数,极大地影响了共生生物搜索算法的收敛速度。根据文献[17]的研究可知,自适应因子能够提高搜索更新的速率。因此,在共生生物搜索算法的搜索过程中,运用自适应的互利系数能够加快收敛速度。

$$BE_1 = 2 - \frac{\text{iter}_1}{\text{iter}_{\max}} \quad (12)$$

$$BE_2 = 2 - \frac{\text{iter}_2}{\text{iter}_{\max}} \quad (13)$$

其中: iter 为当前迭代次数; iter_{\max} 为最大迭代次数。

2) 精英策略。为增大个体突变成功的概率,对其传统的寄生策略进行改进。首先,在整个种群更新开始时按适应度从大到小排序,把大于适应度均值的生物分为精英种群,其余小于适应度均值的生物分为普通种群。精英种群通过式(14)更新“寄生向量”,和普通种群相比,只留下较优的“生物”,普通种群则按照传统策略生成“寄生向量”。

$$\mathbf{V}_{\text{para}} = X_i + \alpha \text{rand}(-1, 1) \cdot X_j \quad (14)$$

其中: \mathbf{V}_{para} 为由个体 i 创建的寄生向量; α 为变化系数,取值为 0.01。

该策略既能加快算法的收敛精度,又可以很好地跳出局部最优。改进的共生生物搜索算法的具体步骤如下:

- 1) 初始化参数;
- 2) 计算出各种群的适应度值并排序;
- 3) 找出种群中的最优值 X_{best} 和最优“生物”;
- 4) 进入互利阶段,按式(8)进行更新;
- 5) 进入共栖阶段,按式(10)进行更新;
- 6) 进入寄生阶段,精英种群按式(13)产生“寄生向量”,普通种群按传统方式产生“寄生向量”;
- 7) 若整个种群完成更新操作,则执行步骤 8; 否则执行步骤 3;
- 8) 若达到终止条件,则终止; 否则执行步骤 2。

2.2 基于 ASOS 算法优化的 ELM 磨机负荷软测量模型建立

为了提高磨机负荷软测量模型的精度和泛化能力,利用 ASOS 算法对 ELM 磨机负荷软测量模型进行优化。在建立 ELM 磨机负荷软测模型时,已确定最佳激活函数为 Sig 类型,其表达式为

$$g(x, \lambda, \theta) = \frac{1}{1 + e^{[-\lambda(x-\theta)]}} \quad (15)$$

其中: x 为净输入值; λ 为坡度; θ 为函数中心。

一般情况下,参数 λ 和 θ 的取值为 1 和 0,考虑到该函数的输出会随着 λ 和 θ 的改变而发生较大的变化,因此需找到每个节点的最佳参数组合,使输出结果最优。

ASOS-ELM 模型是利用 ASOS 算法对 Sig 函数的参数进行优化,从而建立最优的磨机负荷预测模型。ASOS-ELM 的建模过程如图 4 所示。

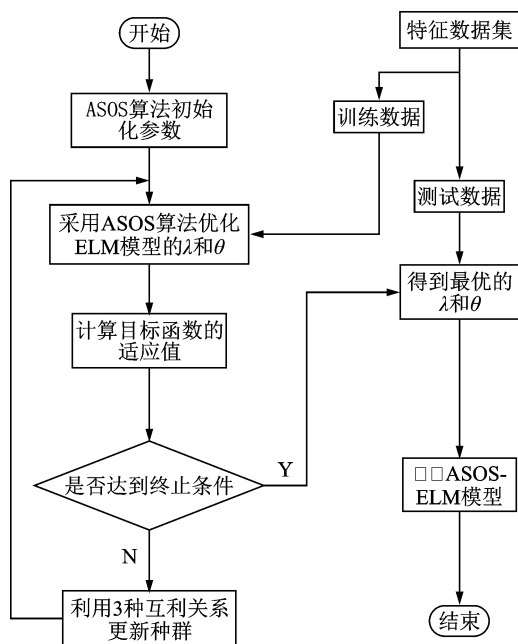


图4 ASOS算法优化ELM的流程图

Fig. 4 ASOS algorithm optimization ELM flow chart

3 磨机负荷软测量的实验分析

3.1 实验平台搭建

笔者采用 Bond 功指数球磨机开展湿式磨矿实验,实验样品使用赣州某矿山的钨矿脉石,其普氏硬度系数为 14~18,密度为 3 000 kg/m³。以磨机负荷参数作为磨矿实验的输入参数,排料量、能耗作为输出参数。同时,采集磨机筒体振动与振声信号作为

检测磨机负荷的外部响应信号,搭建湿式磨矿检测实验平台,采用 CHE100 变频器控制磨机的转速,每组实验的磨矿时间为 10min。湿式球磨机实验系统如图 5 所示。




图 5 湿式球磨机实验系统图

Fig. 5 Wet ball mill experimental system diagram

3.2 实验分析

利用 Matlab2016b 软件对建立的 ASOS-ELM 湿式磨机负荷软测量模型进行验证,其中,训练样本的磨机负荷参数预测值与实际值对比如图 6 所示。

对图 6 分析可知,训练样本的磨机负荷参数预测值与实际值的变化趋势相同,尤其是填充率的预测值和实际值基本一致,而对于料球比和磨矿浓度,虽然存在个别样本的预测值和实际值存在差异,但整体较为接近。

为进一步分析 ASOS-ELM 磨机负荷软测量模型的性能,分别采用 SOS-ELM 算法和粒子群算法

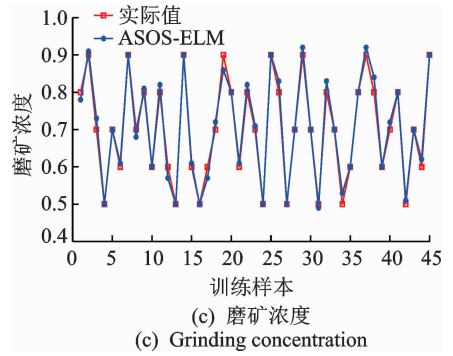



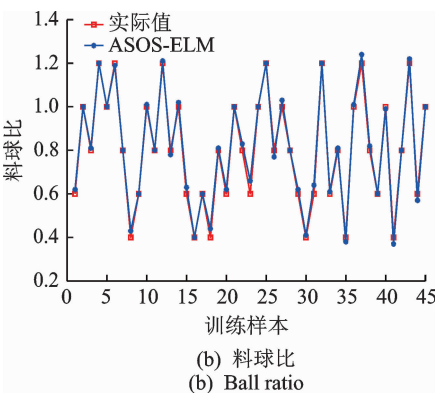
图 6 训练样本磨机负荷参数的预测值与实际值对比
Fig. 6 Comparison of predicted and actual values of training sample mill load parameters

(particle swarm optimization, 简称 PSO)-ELM 算法建立磨机负荷软测量模型,在 POS-ELM 和 PSO-ELM 模型中,每个模型独立运行 20 次,参数设置与 ASOS-ELM 模型相同,其中,PSO 算法的种群个数为 100,学习因子 c_1, c_2 均为 2。

图 7 为 3 种算法优化 ELM 的迭代过程。对图 7 分析可知,当迭代次数为 44 时,智能优化算法可以通过优化激活函数极大地提高磨机负荷参数软测量模型的训练精度。对比 ASOS 算法、PSO 算法和 SOS 算法的优化过程可知,ASOS 算法的收敛速度比另外两种算法更快,且在第 20 次迭代时收敛,说明 ASOS-ELM 磨机负荷软测量模型的学习能力最强。



(a) 填充率
(a) Fill rate



(b) 料球比
(b) Ball ratio

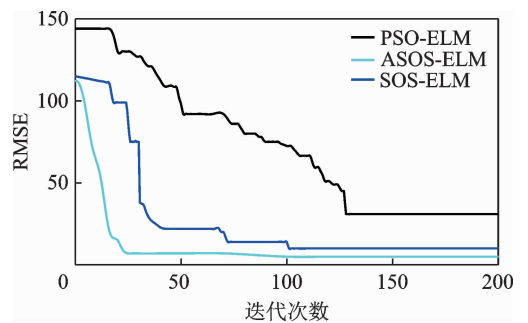


图 7 3 种算法优化 ELM 的迭代过程

Fig. 7 Three algorithms optimize the iterative process of ELM

图 8 为测试样本磨机负荷参数的预测值与实际值对比。可以看出,ASOS-ELM 磨机负荷软测量模型预测的料球比、填充率、磨矿浓度与真实值非常接近,磨机负荷参数的预测准确性较高。对图 8 进一步分析可知,SOS-ELM 和 PSO-ELM 磨机负荷软测量模型的预测结果与实际值存在一定的误差,特别是磨矿浓度的预测结果与 ASOS-ELM 模型的预

测结果有着明显的差别。

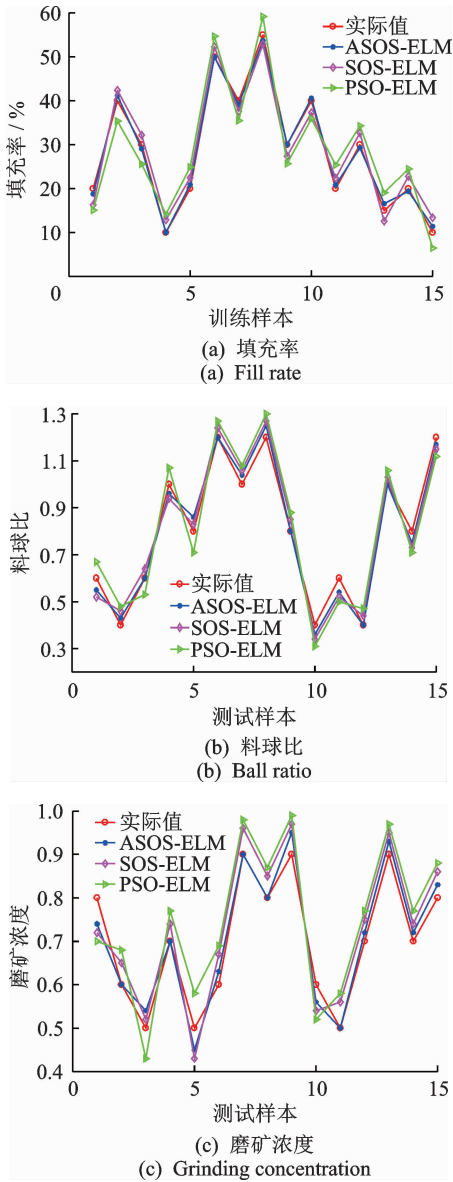


图8 测试样本磨机负荷参数的预测值与实际值对比
Fig.8 Comparison of predicted and actual values of test sample mill load parameters

图9为3种磨机负荷软测量模型预测结果的误差棒。对图9(a)分析可知, PSO-ELM软测量模型预测的填充率误差上限和下限分别为5.4%和4.9%; SOS-ELM模型预测的填充率误差上限和下限分别为3.4%和3.7%; ASOS-ELM模型预测的填充率误差上限和下限分别为1.4%和2.2%, 说明ASOS-ELM软测量模型预测填充率的准确率更高。对图9(b)分析可知, ASOS-ELM模型预测的料球比误差相较于 PSO-ELM, SOS-ELM模型明显减小。分析图9(c)可知, ASOS-ELM模型预测的磨矿浓度误差最小。

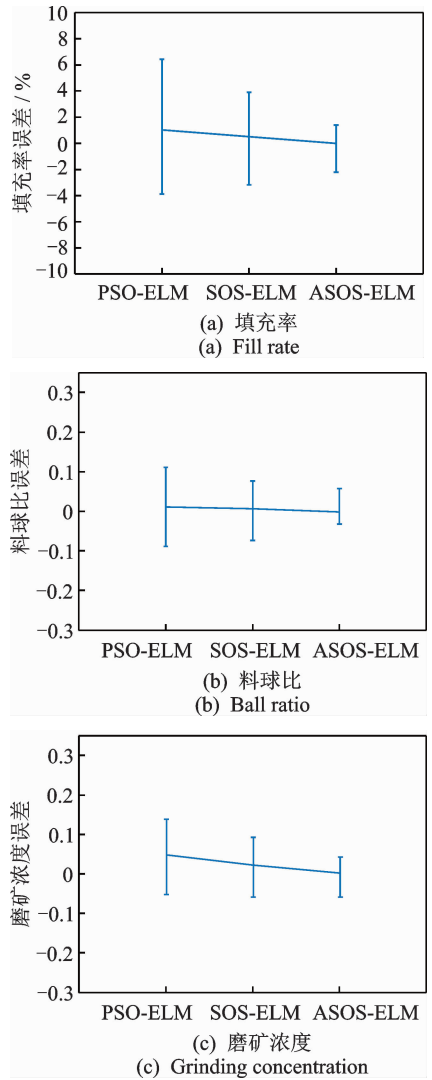


图9 3种磨机负荷软测量模型预测结果的误差棒
Fig.9 Comparison of error bars of prediction results of three kinds of mill load soft measurement models

为了进一步量化3种磨机负荷软测量模型预测的准确率和评价模型的泛化能力, 分别计算其平均绝对百分比误差(mean absolute percentage error, 简称 MAPE)、平均绝对误差(mean absolute error, 简称 MAE)和平均相对变动值(average relative variance, 简称 ARV)。3个指标分别按下式进行计算

$$MAPE = \frac{\sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i} \times 100\%}{N} \quad (16)$$

$$MAE = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)}{N} \quad (17)$$

$$ARV = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (18)$$

其中: y_i 为真实值; \hat{y}_i 为预测值; \bar{y}_i 为预测平均值。

表 2 为 3 种模型测试样本的预测误差和平均相对变动值。对表 2 分析可知,ASOS-ELM 磨机负荷软测量模型的平均绝对误差和平均绝对百分比误差最小,磨机负荷参数的预测准确率相较于 SOS-ELM 与 PSO-ELM 模型有明显提高。同时,ASOS-ELM 磨机负荷软测量模型的平均相对变动值小于 SOS-ELM 模型和 PSO-ELM 模型,表明采用 SOS-ELM 算法与 PSO-ELM 算法建立的磨机负荷软测量模型的泛化能力较差,ASOS-ELM 磨机负荷软测量模型的泛化能力最佳。

表 2 3 种模型测试样本的预测误差和平均相对变动值

Tab.2 Prediction error and average relative change value of three model test samples

模型-负荷参数	MAE	ARV	MAPE/%
PSO-ELM-填充率	4.44	0.109 5	19.74
SOS-ELM-填充率	2.58	0.037 6	13.27
ASOS-ELM-填充率	0.867	0.006 1	3.76
PSO-ELM-料球比	0.079	0.092 1	11.51
SOS-ELM-料球比	0.054	0.039 3	7.91
ASOS-ELM-料球比	0.030	0.017 1	4.28
PSO-ELM-磨矿浓度	0.079	0.287 1	11.68
SOS-ELM-磨矿浓度	0.055	0.157 9	8.16
ASOS-ELM-磨矿浓度	0.025	0.051 0	3.36

4 结 论

1) 为了准确快速地预测湿式球磨机内部负荷参数,采用 ELM 算法建立湿式磨机负荷软测量模型,确定了模型的最佳激活函数为 Sig,利用 ASOS 算法优化 ELM 隐含层激活函数的参数。通过实例验证发现,当隐含层神经元个数为 44 时,磨机负荷的软测量结果较好。

2) 通过对磨机负荷软测量模型的实验分析发现,ASOS-ELM 模型的平均绝对误差和平均绝对百分比误差最小,对磨机负荷参数的预测准确率明显高于 SOS-ELM 模型和 PSO-ELM 模型;ASOS-ELM 模型的平均相对变动值最小,表明 ASOS-ELM 磨机负荷软测量模型的泛化能力最佳,为检测磨机筒体内部的负荷参数提供了一种有效途径。

参 考 文 献

[1] 李景杰.我国选矿机械设备大型化研究现状及发展动向[J].金属矿山,2014,50(10):52-57.

LI Jingjie. Research status and development trend of large-scale research of mineral processing machinery in China [J]. Metal Mine, 2014, 50(10):52-57. (in Chinese)

[2] SHA Y, CHANG T, CHANG J. Measure methods of ball mill's load [J]. Modern Electric Power, 2006, 24 (35): 624-632.

[3] 罗小燕,邵凡,陈慧明,等.基于多源信号融合的球磨机负荷预测方法研究[J].振动与冲击,2019,38(8):232-237.

LUO Xiaoyan, SHAO Fan, CHEN Huiming, et al. A ball mill load prediction method based on multi-source signal fusion technology [J]. Journal of Vibration and Shock, 2019, 38(8): 232-237. (in Chinese)

[4] 张晓宏,唐贵基,尹增谦,等.钢球磨煤机轴振能量的测量及应用[J].测控技术,2002,21(4):58-59.

ZHANG Xiaohong, TANG Guiji, YIN Zengqian, et al. Measuring and application of the ball mill's axes vibration energy [J]. Measurement & Control Technology, 2002, 21(4): 58-59. (in Chinese)

[5] 李晓枫,吴惠雁,李勇.球磨机料位检测仪的开发及其在优化运行控制上的应用[J].仪表技术与传感器,2002(11):20-22.

LI Xiaofeng, WU Huiyan, LI Yong. Development of instrument to measure material level of ball mill and its application [J]. Instrument Technique and Sensor, 2002(11): 20-22. (in Chinese)

[6] 徐波,周凤星,马娅婕,等.基于 HLS-SVDR 和 SPPCS 的 CEEMD 的滚动轴承微故障特征提取[J].振动、测试与诊断,2019,39(1):136-146.

XU Bo, ZHOU Fengxing, MA Yajie, et al. Feature extraction of rolling bearing's slight fault of SPPCS CEEMD based on HLS-SVDR [J]. Journal of Vibration, Measurement & Diagnosis, 2019, 39(1): 136-146. (in Chinese)

[7] 段勇,崔宝侠,徐冰,等.基于多传感器信息融合双进双出磨煤机料位检测[J].机械工程学报,2010,46(24):61-66.

DUAN Yong, CUI Baoxia, XU Bing, et al. Material level detection of double-in double-out coal mill based

- on multi-sensor fusion [J]. Journal of Mechanical Engineering, 2010, 46(24):61-66. (in Chinese)
- [8] 刘晓璞. 面向磨机负荷识别的新型磨音检测装置研究[D]. 济南: 济南大学, 2012.
- [9] 向北平, 周建, 倪磊, 等. 基于样本熵的改进小波包阈值去噪算法[J]. 振动、测试与诊断, 2019, 39(2): 410-415.
XIANG Beiping, ZHOU Jian, NI Lei, et al. Research on improved wavelet packet threshold denosing algorithm based on sample entropy [J]. Journal of Vibration, Measurement & Diagnosis, 2019, 39(2): 410-415. (in Chinese)
- [10] YUE H, QIN S J. Reconstruction based fault detection using a confined index [J]. Industrial & Engineering Chemistry Research, 2001, 40(20):4403-4414.
- [11] 汤健, 赵立杰, 柴天佑, 等. 基于振动频谱的磨机负荷在线软测量建模[J]. 信息与控制, 2012, 41(1):123-128.
TANG Jian, ZHAO Lijie, CHAI Tianyou, et al. On-line soft-sensing modeling of mill load based on vibration spectrum [J]. Information and Control, 2012, 41(1): 123-128. (in Chinese)
- [12] 汤健, 柴天佑, 丛秋梅, 等. 选择性融合多尺度筒体振动频谱的磨机负荷参数建模[J]. 控制理论与应用, 2015, 32(12):1582-1591.
TANG Jian, CHAI Tianyou, CONG Qiumei, et al. Modeling mill load parameters based on selective fusion of multi-scale shell vibration frequency spectra [J]. Control Theory & Applications, 2015, 32(12): 1582-1591. (in Chinese)
- [13] 王东风, 宋之平. 基于神经网络的制粉系统球磨机负荷软测量[J]. 中国电机工程学报, 2001, 21(12):97-99.
WANG Dongfeng, SONG Zhiping. A study on the soft-sensing of coal load in ball mill tube of pulverized system based on neural networks [J]. Proceedings of the CSEE, 2001, 21(12):97-99. (in Chinese)
- [14] 王东风, 韩璞. 基于 RBF 神经网络的球磨机负荷软测量[J]. 仪器仪表学报, 2002, 23(S1):311-312.
WANG Dongfeng, HAN Pu. Soft-sensing of coal load in ball mill tube of pulverizing system [J]. Chinese Journal of Scientific Instrument, 2002, 23(S1):311-312. (in Chinese)
- [15] 司刚全, 曹晖, 王靖程, 等. 基于复合式神经网络的火电厂筒式钢球磨煤机负荷软测量[J]. 热力发电, 2007, 36(5):64-67.
SI Gangquan, CAO Hui, WANG Jingcheng, et al. Load softsenser for tube type ball mill based on composite neural network in thermal power plant [J]. Thermal Power Generation, 2007, 36(5):64-67. (in Chinese)
- [16] LIAO T W, KUO R J. Five discrete symbiotic organisms search algorithms for simultaneous optimization of feature subset and neighborhood size of KNN classification models [J]. Applied Soft Computing, 2018, 64: 581-595.
- [17] RAO R V, PATEL V. A multi-objective improved teaching-learning based optimization algorithm for unconstrained and constrained optimization problems [J]. International Journal of Industrial Engineering Computations, 2014, 5(1): 1-22.



第一作者简介:蔡改贫,男,1964年10月生,博士、教授、博士生导师。主要研究方向为散体-机械系统理论及智能装备、智能监控与工业机器人。曾发表《基于多尺度内聚颗粒模型的挤压分级破碎研究》(《岩石力学与工程学报》2018年第37卷)等文章。
E-mail: 1123615286@qq.com