

基于 WOA-GRNN 的球磨机负荷参数预测研究

孟 静¹ 胡 勇²
MENG Jing HU Yong

摘 要

针对球磨机的工作环境复杂、非线性因素多,且传统的球磨机负荷检测技术具有操作难度高、检测效率低等问题,提出了一种基于鲸鱼算法(whale optimization algorithm, WOA)优化广义回归神经网络(generalized regression neural network, GRNN)参数的球磨机负荷软测量模型。该模型选取给矿量、给水量、泵池液位高度、补加水量、泵出口浓度、磨机功率和磨机筒体磨音信号的时域频域特征量作为输入,采用多因素法建立球磨机负荷参数的预测模型。通过与选矿企业的实测数据实验对比,该模型泛化能力较强,提高了磨机负荷参数预测准确率,对球磨机磨矿效率的提高及其优化具有较大的应用价值。

关键词

球磨机负荷; 软测量; 广义回归神经网络; 鲸鱼算法; 磨机功率; 振动信号

doi: 10.3969/j.issn.1672-9528.2025.02.021

0 引言

在磨矿生产中,球磨机常常作为一种关键的矿山粉磨设备,用于将原矿石磨成生产所需的粒度。但球磨机属于能耗极高的设备,往往选矿厂的球磨机所消耗的材料成本以及电耗能达到总能耗的 50% 左右,用电量占据整个工厂的 15%~25%^[1],且其容易发生过负荷和欠负荷的现象,过负荷时会造成矿石研磨不充分,发生“涨肚”现象^[2],极易发生安全事故;欠负荷会产生电能浪费,增加钢材消耗,使磨机处于或接近空砸状态,严重甚至破坏磨机设备。由于矿山作业环境复杂,在磨矿过程自动控制中,球磨机负荷的检测和控制是球磨机自动控制最重要的内容,但是其负荷参数难以直接采集与控制,能否准确地检测出球磨机的负荷是球磨机优化控制成败的关键。实际上大多选矿企业是根据现场操作工的观察和经验去判断,并不能保证磨矿的最佳状态。因此,研究更加合理、高效的球磨机负荷参数检测方法显得尤为重要^[3]。

一般情况下,对于不易测量的变量,或无法直接测量的变量,通常是将难以直接测量的变量与其相关的可测变量建立数学模型的方式来估计其值的方法^[4],即建立软测量模型的数学方法,从而实现实时在线测量。文献[5]通过分解不同域的信号,提取频域特征,提出了基于核偏最小二乘建模的软测量方法。文献[6]对振动信号的功率谱特征值进行

提取,提出了基于振动信号和云推理的球磨机负荷软测量模型。文献[7]将筒体振动与振动信号的特征信息作为输入,磨机负荷参数作为输出,构建了基于 ASOS-EML 的球磨机负荷软测量模型。以上方法可有效实现球磨机负荷参数的准确检测,为磨矿优化控制和效率提高提供准确、可靠的依据。由于球磨机是一个复杂的非线性系统,上述方法只采用单因素法建立外部因素与负荷参数的数学模型,虽然能够在一定程度上对负荷参数进行预测,但仍存在预测精度低、泛化能力差等缺点。

为克服上述缺陷,本文针对球磨机负荷状态特征提取困难、诊断准确度低的问题,结合领域专家研究经验,采用多因素法建立 WOA-GRNN 的球磨机负荷参数软测量模型。该方法选取球磨机运行时的给矿量、给水量、泵池液位高度、补加水量、泵出口浓度、磨机功率和磨机筒体磨音信号作为输入变量,球磨机负荷参数(浓度,料球比,介质充填率)作为模型输出,建立鲸鱼算法(WOA)优化广义回归神经网络(GRNN)的软测量模型。

1 研究方法

1.1 广义回归神经网络

广义回归神经网络(generalized regression neural network, GRNN)具有高非线性问题求解的能力,与传统的 BP 神经网络相比,有更强的学习能力和求解速度^[8]。本研究根据实际需求选取广义回归神经网络作为球磨机负荷参数检测的软测量模型。其网络结构如图 1 所示。

1. 无锡机电高等职业技术学校 江苏无锡 214215

2. 荣托昆普(无锡)科技有限公司 江苏无锡 214215




图 1 GRNN 网络结构

输入层：网络输入为 $X=[x_1, x_2, \dots, x_n]^T$ ，该层的神经元数目与 X 的维数 n 相等，且各神经元之间互不关联，输入变量从输入层直接被传递到模式层。

模式层：该层传递函数为：

$$P_i = \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \quad i=1, 2, \dots, n \quad (1)$$

式中： X 是 GRNN 的输入变量； X_i 为第 i 个神经元的学习样本； T 为广义回归神经网络输入数据的维数； σ 为光滑因子。

加和层：该层中使用两类神经元对应的计算公式进行计算。

一类的计算公式为：

$$\sum_{i=1}^n \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \quad (2)$$

传递函数为：

$$S_D = \sum_{i=1}^n P_i \quad (3)$$

另一类传递函数为：

$$S_{Nj} = \sum_{i=1}^n y_{ij} P_i \quad j=1, 2, \dots, k \quad (4)$$

输出层：求和层传递函数 S_{Nj} 除以 S_D 作为神经元输出，其对应输入条件下的条件均值 $Y_{(X)}$ 的第 j 个元素，即：

$$y_i = \frac{S_{Nj}}{S_D} \quad j=1, 2, \dots, k \quad (5)$$

1.2 鲸鱼算法

鲸鱼算法 (whale optimization algorithm, WOA) 是 Mirjalil 等人^[9]根据座头鲸利用起泡网追捕食物的过程而提出的群智能优化算法，能够实现在全局范围内寻找最优解。其捕食行为分为收缩包围、气泡释放和随机搜索 3 种^[10]。

(1) 收缩包围

鲸鱼种群在捕食时，会向先发现食物的鲸鱼游去达到争抢食物的目的，实现收缩包围。其位置更新公式分别为：

$$X(t+1) = X^*(t) - AD \quad (6)$$

$$A = 2a \cdot r_1 - a \quad (7)$$

$$D = |C \cdot X^*(t) - X^*(t)| \quad (8)$$

$$C = 2r_2 \quad (9)$$

$$a = 2 - \frac{2t}{T_{\max}} \quad (10)$$

式中： $X^*(t)$ 为当前迭代次数 t 时，鲸鱼种群中最优个体的位置； r_1 和 r_2 是 0~1 内的随机数； $T_{\max}$ 为最大迭代次数。

(2) 气泡释放

气泡释放是鲸鱼独有的捕食行为，有收缩包围和螺旋式运动两种位置更新方式。

引入随机概率 p ，当 $p < 0.5$ 时，按照收缩包围机制来进行捕食，即按照式 (6) 更新鲸鱼个体位置；当 $p \geq 0.5$ 时，鲸鱼以螺旋运动方式游向食物：

$$X(t+1) = X^*(t) - D_p e^{bl} \cos(2\pi l) \quad (11)$$

$$D_p = |X^*(t) - X(t)| \quad (12)$$

式中： l 为 $[-1, 1]$ 内的随机数； b 为控制常数。

(3) 随机搜索

当 $A < 1$ 时，以收缩包围和释放气泡的方式捕获食物；当 $A \geq 1$ 时，以随机搜索方式捕获食物。

$$D_r = |C \cdot X_r(t) - X(t)| \quad (13)$$

$$X(t+1) = X_r(t) - A \cdot D_r \quad (14)$$

式中： $X_r(t)$ 为随机产生的鲸鱼位置。

1.3 基于立方混沌算子的种群初始化

鲸鱼算法在初始化种群时具有随机性、种群位置更新固定性的缺点，这样容易导致算法陷入局部最优，为了使鲸鱼种群保持多样性，提高算法的寻优能力，利用混沌算子具有伪随机性和遍历性的特点，采用映射更加均匀的 Logistic-Tent 混沌映射来初始化种群^[11]。

$$y_{i+1} = \begin{cases} \text{mod} \left[ry_i(1 - y_i) + \frac{4-r}{2} y_i, 1 \right], & y_i \in [-1, 0.5] \\ \text{mod} \left[ry_i(1 - y_i) + \frac{(4-r)(1 - y_i)}{2}, 1 \right], & y_i \in [0.5, 1] \end{cases} \quad (15)$$

$$-1 < y_i < 1, y_i \neq 0, i = 0, 1, \dots, N \quad (16)$$

$$x_i = lb + \frac{(ub - lb) \times (y_i + 1)}{2} \quad (17)$$

式中： x_i 表示映射后的鲸鱼个体；ub、lb 表示初始鲸鱼种群的上下边界。立方混沌算子初始化种群的步骤为：

(1) 在 $[-1, 1]$ 内随机生成一个 d 维向量作为初始种群个体。

(2) 代入式 (15) 生成 $N-1$ 个混沌值。

(3) 代入式 (17) 将混沌值映射到种群个体上。

1.4 WOA-GRNN 模型

GRNN 网络模型具有高非线性问题的求解能力，且对数据规模要求不严格，不需要迭代学习过程。但是 σ 的选择将影响网络模型的输出效果， σ 过大将导致欠拟合现象，过小

则导致过拟合现象。WOA 算法具有良好的复杂参数的寻优效果, 将鲸鱼算法 WOA 对 GRNN 的 σ 进行优化, 寻找最佳的光滑因子, 从而提高 GRNN 的网络输出精度, 如图 2 所示。

WOA-GRNN 模型实现步骤如下:

- (1) 确定 GRNN 神经网络结构, 初始光滑因子值。
- (2) 使用训练集训练 GRNN 网络。
- (3) 使用测试集测试 GRNN 网络。
- (4) 利用式 (17) 初始化鲸鱼种群, 产生混沌映射种群个体位置, 其中种群个体位置代表光滑因子值。
- (5) 以 GRNN 神经网络的均方误差函数作为鲸鱼算法适应度函数。
- (6) 计算种群个体适应度值, 找出最优适应度值个体, 记录当前最优个体位置。
- (7) 根据式 (7) 计算 A 值, 确定鲸鱼种群位置更新策略。
- (8) 使用当前最优光滑因子值重新训练 GRNN, 直到 WOA 算法达到最大迭代次数为止。




图 2 WOA-GRNN 流程

2 应用

2.1 数据来源与 WOA-GRNN 模型输入

河北某铁矿山厂工艺采用的是三段一闭路破碎系统，磁选后的精矿经二段磨矿，1次筛分，3次磁选，1次淘洗磁选，最终的精矿质量达到65%以上。本项目所需要的模型输入数

据都是采用此选厂一段球磨机 MQY3645 相关数据, 其中, 给矿量、给水量、泵池液位高度、补加水量、泵出口浓度、磨机功率等可在生产过程控制系统数据库中直接读取, 磨机筒体磨音信号需要进行时域、频域特征提取, 将处理后的特征值一并作为模型输入, 该选厂一段磨矿分级相关工艺流程图如图 3 所示。




图3 磨矿分级过程工艺流程图

2.2 评价标准

本文采用平均绝对误差 (MAE)、均方误差 (RMSE) 作为模型预测的评价标准。其公式为:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (18)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (19)$$

式中： y_i 表示样本实际值； y_i' 表示预测值。

2.3 实验结果与分析

过程数据给矿量、给水量、泵池液位高度、补加水量、泵出口浓度、磨机功率和磨机筒体振动信号作为输入变量，浓度、料球比、介质充填率作为输出变量，提取 2000 组有效样本数据，样本数据的 90% 用于模型训练，10% 用于测试实验。通过实验验证 WOA-GRNN 在球磨机负荷预测中的准确性和稳定性。

WOA-GRNN 模型的初始参数设置如下:

初始种群规模为 40, 迭代次数为 500, 光滑因子 $\sigma_{\min}$ 为 0.02, $\sigma_{\max}$ 为 1, σ 初始值为 0.1。同时为了验证 WOA-GRNN 模型的有效性, 将其与 GA-GRNN 进行对比, 首先分别对球磨机的充填率, 浓度与料球比进行预测, 测试样本 100 个, 选取其中的 15 个样本进行拟合曲线的对比, 图 4 ~ 图 6 分别为充填率, 浓度与料球比的拟合对比曲线。




图4 充填率拟合对比曲线




图5 浓度拟合对比曲线




图6 料球比拟合对比曲线

从图4~图6中可以看出,无论充填率、料球比还是浓度,WOA-GRNN模型的软测量值(预测值)和样本值(目标值)非常逼近,明显优于GA-GRNN。

为了进一步验证WOA-GRNN模型的有效性,计算其预测的平均绝对误差(MAE)和均方误差(RMSE)以及预测精度(ACC),如表1所示。

表1 预测实验结果

预测模型	MAE	RMSE	Acc
GA-GRNN- 充填率	3.998 7e-03	5.352 2e-03	83.52%
WOA-GRNN- 充填率	2.352 4e-05	3.453 2e-06	95.42%
GA-GRNN- 料球比	3.462 7e-03	7.231 9e-03	82.87%
WOA-GRNN- 料球比	3.543 2e-05	5.887 6e-05	95.89%
GA-GRNN- 浓度	3.557 8e-03	6.018 7e-03	83.66%
WOA-GRNN- 浓度	2.104 7e-05	5.887 6e-05	96.31%

从表1可以看出,WOA-GRNN在充填率、料球比、浓度上的平均绝对误差(MAE)与均方误差(RMSE)均小于

GA-GRNN模型,且在预测精度上优于GA-GRNN,预测准确率在95%以上。由此可以证明,WOA-GRNN在球磨机负荷预测中具有较高的准确性。

3 结论

本文采用多因素法建立基于WOA-GRNN的球磨机负荷参数软测量模型,使用鲸鱼算法来优化GRNN网络的光滑因子,提出WOA-GRNN模型。将本文建立的软测量模型与GA-GRNN相比,数据结果表明,该模型在球磨机负荷参数的预测上具有较高的准确性,在预测精度和稳定性上均高于GA-GRNN,为选矿厂磨矿效率提高和过程优化控制提供准确、可靠的依据,在实际生产应用中有较好的指导意义。

参考文献:

- [1] 周伟. 关于湿式球磨机特性探讨[J]. 化工设计通讯, 2016, 42(4): 253-255.
- [2] 李艳姣. 磨机负荷优化计算与专家控制[D]. 唐山: 河北联合大学, 2014.
- [3] 王廷, 赵建军, 陶乐, 等. 磨机负荷检测及建模方法研究进展[J]. 矿产综合利用, 2023(3): 107-111.
- [4] 单显明, 那崇正, 汤健, 等. 基于CEEMDAN-GPR的球磨机负荷软测量[J]. 电子测量技术, 2022, 45(17): 127-133.
- [5] 汤健, 赵立杰, 岳恒, 等. 基于多源数据特征融合的球磨机负荷软测量[J]. 浙江大学学报(工学版), 2010, 44(7): 1406-1413.
- [6] 阎高伟, 龚杏雄, 李国勇. 基于振动信号和云推理的球磨机负荷软测量[J]. 控制与决策, 2014, 29(6): 1109-1114.
- [7] 蔡改贫, 赵小涛, 张丹荣, 等. 基于ASOS-ELM的湿式球磨机负荷软测量方法[J]. 振动. 测试与诊断, 2020, 40(1): 184-192.
- [8] 孔颜芳, 南新元, 石跃飞, 等. 基于果蝇算法优化GRNN的生物氧化预处理温度预测[J]. 有色金属工程, 2021, 11(3): 69-74.
- [9] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in engineering software, 2016, 95: 51-67.
- [10] 蔡赛男, 宋卫星, 班利明, 等. 基于鲸鱼算法优化LSSVM的滚动轴承故障诊断[J]. 控制与决策, 2022, 37(1): 230-236.
- [11] 钱建国, 徐志文, 赵玉国, 等. 基于改进鲸鱼算法优化神经网络的GPS高程拟合方法[J]. 大地测量与地球动力学, 2024, 44(2): 122-127.

【作者简介】

孟静(1988—), 女, 江苏无锡人, 硕士研究生, 讲师, 研究方向: 智能控制、机器学习。

胡勇(1986—), 男, 江苏无锡人, 硕士, 高级工程师, 研究方向: 智能控制理论与研究。

(收稿日期: 2024-10-30)