基于改进浣熊算法并行极限学习机机械装备 故障预测

黄载东

广西华昇新材料有限公司, 广西 防城港

收稿日期: 2025年2月15日; 录用日期: 2025年3月9日; 发布日期: 2025年3月18日

摘要

本研究提出了一种基于改进浣熊优化算法的并行极限学习机机械装备故障诊断与预测方法。针对并行极限学习机在故障诊断中存在的收敛速度慢、易陷入局部最优等问题,提出一种改进浣熊算法方案,并对并行极限学习机参数进行优化。通过多组对比实验,从诊断准确率、预测精度、收敛速度和鲁棒性等方面验证了所提出方法的优越性。实验结果表明,ICOA优化后的并行极限学习机模型在CWRU轴承数据集上的诊断准确率达到99.6%,在加入不同程度的干扰的情况下,ICOA优化后的并行极限学习具备较强的 鲁棒性,显著优于传统优化方法。

关键词

机械装备,浣熊优化算法,并行极限学习机,预测,故障诊断

Fault Prognosis of Mechanical Equipment Using Improved Raccoon-Optimized Parallel Extreme Learning Machine

Zaidong Huang

Guangxi Huasheng New Materials Co., Ltd., Fangchenggang Guangxi

Received: Feb. 15th, 2025; accepted: Mar. 9th, 2025; published: Mar. 18th, 2025

Abstract

This study proposes a mechanical equipment fault diagnosis and prediction method based on an improved Coati Optimization Algorithm (ICOA)-enhanced parallel extreme learning machine (PELM).

To address issues such as slow convergence and susceptibility to local optima in fault diagnosis using parallel ELM, an improved Coati Optimization Algorithm scheme is introduced to optimize the parameters of the parallel ELM. Through multiple comparative experiments, the superiority of the proposed method is validated in terms of diagnostic accuracy, prediction precision, convergence speed, and robustness. Experimental results demonstrate that the ICOA-optimized parallel ELM model achieves a diagnostic accuracy of 99.6% on the CWRU bearing dataset. Furthermore, under varying levels of interference, the ICOA-optimized parallel ELM exhibits strong robustness, significantly outperforming traditional optimization methods.

Keywords

Mechanical Equipment, Coati Optimization Algorithm, Parallel Extreme Learning Machine, Prediction, Fault Detection and Diagnosis

Copyright © 2025 by author(s) and Hans Publishers Inc. This work is licensed under the Creative Commons Attribution International License (CC BY 4.0). <u>http://creativecommons.org/licenses/by/4.0/</u> CO Open Access

1. 引言

材料生产所需要的机械装备在工业生产中扮演着关键角色,其故障诊断与预测对于保障生产的连续 性和安全性至关重要。黄如意等提出一种基于多任务学习的故障诊断策略[1],通过在原有预测模型的基 础上加入多任务学习策略,使得预测模型对任意一类的模型进行训练后,可同时获得此类模型的故障信 息和退化寿命。胡奎提出一种基于融合双向循环机制的深度学习集成预测模型[2],通过多个维度寻找训 练集各序列的相关性,并依次求导出新的代价函数,对装备的故障信息和寿命进行预测。雷亚国等利用 大数据采集获取各实验室的数据样本[3],并提取样本中的全部的故障特征,丰富样本的多样性,建立深 度残差网络,对装备的故障信息进行预测。任玲辉等提出一种基于图像处理的装备故障信息预测模型[4], 通过图像处理提取采样样本中的故障信息特征,对装备故障信息进行预测。徐志军等提出一种基于 LS 的 最小二乘向量机的故障诊断模型[5],该模型可对样本中原始信号序列两端进行扩展,延伸出 N 个有限的 数据点,并通过镜像的方式对延伸出的数据点进行反向扩展,使得原始信号序列形成圆形系列,避免了 在预测过程中由于端点效用导致预测精度降低的问题。朱可恒等提出一种基于希尔伯特振动分解的机械 故障诊断方法[6],利用希尔伯特振动分解故障信号,提取故障特征并进行模式识别。此外还有许多有效 的预测模型,例如图神经网络预测模型[7]、基于小波分析的神经网络预测模型[8]、长短期记忆网络预测 模型[9]等。

传统的诊断方法往往依赖于专家经验和简单的统计分析,难以满足复杂装备的诊断需求。但神经 网络虽然具有较强的非线性拟合能力,但在训练过程中容易陷入局部最优。浣熊算法[10]作为一种新 兴的群智能优化算法,具有良好的全局搜索能力,能够有效优化并行极限学习机的阈值参数和权重参 数。

2. 并行极限学习机数学模型

并行极限学习机(Parallel Extreme Learning Machine, PELM)通过并行技术,加速了传统极限学习机的 训练过程,将 ELM 的隐层节点分配到多个计算节点上,对数据进行并行处理。同时将采样的数据集分成 多个子集进行预处理,并分配到多个线程上进行并行处理。并行极限学习机的结构图如图1所示。



Figure 1. Structural diagram of parallel extreme learning machine 图 1. 并行极端学习机结构图

设样本个数为 N 的采样数据样本为 (x_i, y_i) $i = 1, 2, \dots, N$, x_i 和 y_i 分别表示输入向量和输出向量。设 每个隐含层存在 m 个神经元,存在线性 1 的矩阵 p 为线性网络学习部分的输入权值,随机数矩阵 q 非线 性网络学习部分的输入权值。 W_{oh} 为输出权值矩阵。yl 和 yn 分别为线性隐含层输出值和非线性隐含层输 出值,设极限学习及的隐含层激励函数 g(x)为 sigmoid 函数,因此及其数学模型如下所示:

$$\begin{cases} y_{j} = \sum_{k=1}^{m} W_{oh_{k}} \cdot yl_{k} \cdot yn_{k} \\ yl_{k} = \sum_{i=1}^{n} g\left(p_{k,i}x_{k,i} + b_{l,k}\right) \\ yn_{k} = \sum_{i=1}^{n} g\left(q_{k,i}x_{k,i} + b_{n,k}\right) \end{cases}$$
(1)

式中, $p_{k,i}$ 为线性隐含层输入值到第 k 个隐含层神经元之间的权值, $b_{l,k}$ 为第 k 个线性隐含层中阈值。 $q_{k,i}$ 为非线性隐含层输入值到第 k 个隐含层神经元之间的权值。 $b_{n,k}$ 为第 k 个非线性隐含层中的阈值。 W_{oh_k} 为 第 k 个隐含层神经元到输出层 y_i 之间的连接权值。

3. 改进浣熊优化算法(Improve Coati Optimization Algorithm, ICOA)

3.1. 基本浣熊优化算法

COA 是 2021 年提出的一类群智能优化算法,算法迭代过程模仿了浣熊在自然界的捕食行为,COA 算法的寻优过程可分为以下三种方法。

3.1.1. 种群初始化

设第 i 个浣熊个体在第 j 维的位置为 $s_{i,j}$,种群个数为 NP,维度为 D,解空间上下边界分别为 $Limit_{High}$ 和 $Limit_{Low}$,也表示浣熊个体的捕猎范围的上下边界。因此在有效的解空间中,随机初始化浣熊群的位置:

$$X_{i,j} = Limit_{Low} - rand\left(\right) \cdot \left(Limit_{High} - Limit_{Low}\right)$$
⁽²⁾

3.1.2. 探索阶段

在浣熊狩猎和攻击过程中,假设浣熊种群中最好成员的位置就是猎物的位置,则种群中除最优成员 外的一半的浣熊会爬上树,种群中另一半的浣熊会在树下等待猎物掉到地上。 对于爬上树的浣熊,其位置更新公式为:

$$X_{i,i}(t+1) = X_{i,j}(t) + rand() \cdot (X_{best}(t) - z \cdot X_{i,j}(t))$$
(3)

式中, $t = 1, 2, \dots, T_{max}$ 表示迭代次数, $X_{best}(t)$ 表示在当前迭代过程中猎物的位置, $X_{i,j}(t+1)$ 表示浣熊更新后的位置。z表示[1,2]之间的随机数。

对于等在树下的浣熊,其位置更新公式为:

$$\begin{cases} X_{best}'(t) = Limit_{Low} - rand() \cdot (Limit_{High} - Limit_{Low}) \\ X_{i,l}^{\alpha}(t+1) = X_{i,j}(t) + rand() \cdot (X_{best}'(t) - z \cdot X_{i,j}(t)) \\ X_{i,l}^{\beta}(t+1) = X_{i,j}(t) + rand() \cdot (X_{i,j}(t) - X_{best}'(t)) \end{cases}$$

$$\tag{4}$$

式中,当 $fitness(X_{i,j}(t)) > fitness(X'_{best}(t))$ 时浣熊的位置更新公式由 $X^{\alpha}_{i,l}(t+1)$ 表示。当 $fitness(X_{i,j}(t)) < fitness(X'_{best}(t))$ 时浣熊的位置更新公式由 $X^{\beta}_{i,l}(t+1)$ 表示。 $X'_{best}(t)$ 表示猎物掉落地面后 的位置。

3.1.3. 开发阶段

在浣熊狩猎和攻击过程中,猎物也会攻击浣熊,浣熊受到攻击时会自动逃离猎物直到到达安全位置。 此类位置更新的过程表现为在当前浣熊位置的周围随机生成一个新的位置,判断新位置和猎物的位置距 离,若远离了猎物的位置,则浣熊跑到新的位置处。若靠近了猎物的位置,则浣熊停留在当前位置保持 不变。此位置更新的数学表达式如下所示:

$$\begin{aligned} Limit_{Low}^{New} &= \frac{Limit_{Low}}{t} \\ Limit_{High}^{New} &= \frac{Limit_{High}}{t} \\ X_{i,j}\left(t+1\right) &= X_{i,j}\left(t\right) + \left(1-2rand\left(\right)\right) \cdot \left(Limit_{Low}^{New} + rand\left(\right) \cdot \left(Limit_{High}^{New} - Limit_{Low}^{New}\right)\right) \end{aligned}$$
(5)

3.2. 种群透镜反向学习初始化

大量实验研究表明,种群初始化质量对算法的求解精度有着及其重要的影响。浣熊优化算法的种群 初始化位置基于解空间的上下限进行随机初始化,其优点在于种群中个体间的个体影响较小,其缺点在 于初始解质量不稳定,群体多样性难以保证等。针对上述问题,本文提出一种种群透镜反向学习初始化 策略,其初始化流程如下所示:

Setp1: 对浣熊种群进行随机初始化,初始化位置为 $X = [x_{i,1}, x_{i,2}, \dots, x_{i,j}]$ 。设定 X 的反向点为 $X' = [x'_{i,1}, x'_{i,2}, \dots, x'_{i,j}]$ 。其中 $x'_{i,1}$ 与 $x_{i,1}$ 的关系为 $x'_{i,j} = \alpha_j + \beta_j - x_{i,j}$ 。 α_j 和 β_j 为解空间上下边界的第 j 维分量。

Setp2: 设在解空间内存在若干点 $\lambda_i = [\lambda_1, \lambda_2, \dots, \lambda_{NP}]$ 。 *X* 和 *X*' 到 λ 的欧式距离可表示为 d_i 和 d'_i 。设 $k = d_i/d'_i$ 。则点 λ_i 为 *X* 和 *X*' 的基点。

Setp3: 通过透镜形成新的位置点的数学表达式如下:

$$X_{i,j}'' = \frac{\alpha_j + \beta_j}{2} + \frac{\alpha_j + \beta_j}{2k_i} - \frac{X_{i,j}}{k_i}$$
(6)

3.3. 基于螺旋围捕猎物的位置更新策略

由于在猎物掉落地下后会逃跑和攻击,因此对于等在树下的浣熊在围捕猎物时通常采用包围的方式,

形成一个圆形,企图将猎物围在中间。但由于猎物掉落的位置是随机的,因此为提高算法的求解精度和 求解速度,使得浣熊个体可以尽快靠近猎物,因此引入一种螺旋包围方式[11],该方式在以猎物为中心进 行随机小范围的邻域搜索。其数学表达式如下所示:

$$X_{i}(t+1) = |X'_{best}(t) - X_{i}(t)|e^{cl} \times \cos(2\pi l) + X'_{best}(t)$$
(7)

式中, c用于调整螺旋包围范围, l为[-1, 1]之间的随机数, $X'_{hest}(t)$ 表示猎物掉落地面后的位置。

3.4. 改进灰狼优化算法的寻优过程

Step1: 根据式(2)和式(6)对浣熊种群进行位置初始化,将透镜反向学习形成的新的候选解和原始的初始位置进行贪婪选择,将适应度较小的个体保存,将适应度较大的个体剔除,完成种群初始化流程;

Step2: 根据式(3)和式(4)对浣熊个体进行位置更新,进行大范围全局寻优;

Step3: 根据式(5)对浣熊位置进行更新,进行小范围的局部搜索;

Step4:调整螺旋包围范围,命令树下的浣熊对掉落的猎物进行螺旋包围搜索,更新树下浣熊的位置; Step5: 判断是否到达最大迭代次数,若是则停止搜索,否则返回 Step2。

4. 实验与结果分析

4.1. 基于 ICOA 算法的 PELM 预测模型





为在预测过程中,提高 PELM 预测模型的预测精度和泛化能力,本文将通过 ICOA 算法对 PELM 预测模型中的输入权值和隐层阈值进行在线整定,以训练集样本为基础进行迭代计算后,将整定后的 PELM 模型对测试集样本进行预测,得到预测结果。

ICOA-PLEM 的预测流程如图 2 所示。

4.2. 基于 CWRU 采集样本的预测实验结果分析

实验采用 CWRU 轴承数据集用于故障诊断,数据集包含多种故障类型和不同等级的故障类型(正常 状态、内圈故障数据、外圈故障数据、滚动体故障数据)。4 种数据分别在振动过程中采集,包含了振动 信号的时间序列。数据采集完成后,对数据进行预处理,消除数据中的噪声信号和异常数据。

通过本文所提 ICOA-PELM 算法分别对 CWRU 轴承进行故障预测,并将实验结果与基本浣熊算法 (COA-PELM)的预测结果、基于量子自适应鸟群算法的 PELM (QBSA-PELM)预测结果、基于混沌鲸鱼算 法的 PELM 预测结果(CAWOA-PELM)以及基于改进粒子群算法的 PELM (ILPSO-PELM)预测结果进行对 比,以准确率 Accuracy、精确率 Precision、召回率 Recall、以及 F1 分数作为评价函数。

Table 1. Training results based on the training set 表 1. 基于训练集的训练结果

模型	Accuracy	Precision	Recall	F1
ICOA-PELM	97.6%	97.6%	97.4%	97.5%
COA-PELM	91.5%	91.5%	90.6%	91.2%
CAWOA-PELM	93.8%	93.8%	92.3%	93.5%
QBSA-PELM	93.4%	93.2%	92.8%	92.9%
ILPSO-PELM	94.7%	94.7%	94.2%	94.4%

Table 2. Prediction results based on the test set

表 2. 基于测试集的预测结果

模型	Accuracy	Precision	Recall	F1
ICOA-PELM	99.6%	99.6%	99.2%	99.4%
COA-PELM	92.5%	92.3%	91.8%	92.0%
CAWOA-PELM	94.6%	94.6%	94.0%	94.2%
QBSA-PELM	94.4%	94.4%	93.6%	94.0%
ILPSO-PELM	95.4%	95.4%	94.8%	95.0%

从表1和表2可知,对比五种预测模型的预测预测精度,本文所提ICOA-PELM预测模型在训练集下的训练精度分别高于COA-PELM、CAWOA-PELM、QBSA-PELM、ILPSO-PELM预测模型6.1%、3.8%、4.2%、2.9%。在测试集下的预测精度分别高于COA-PELM、CAWOA-PELM、QBSA-PELM、ILPSO-PELM预测模型7.3%、5.0%、5.2%、4.2%。对比训练集的训练精度和测试集的预测精度也可看出,通过ICOA算法在线整定后PELM的输入权值和隐层阈值后,PELM的预测精度得到有效的提升,对比其他四种算法的PELM参数整定效果,ICOA整定后的PELM具有更高的预测精度和泛化能力,说明本文所提ICOA的全局局部搜索能力更加平衡,算法全局搜索精度更高。

4.3. 不同噪声下的实验对比

为验证本文所提 ICOA-PELM 预测模型的稳定性,本文在数据样本中加入不同程度的噪声信号,模

式实际工况下噪声信号对预测模型的影响,并将实验结果与其他四种预测模型进行对比,辅助验证 ICOA-PELM 预测模型的鲁棒性(表 3 和表 4, 图 3 和图 4)。



Figure 3. Prediction results of five forecasting models under low noise 图 3. 低噪声下五种预测模型的预测结果





 Table 3. Prediction results of five prediction models under low noise

 表 3. 低噪声下五种预测模型的预测结果

模型	4 dB	8 dB	10 dB	12 dB	14 dB
ICOA-PELM	98.2%	98.4%	98.6%	99.0%	99.2%
COA-PELM	90.2%	90.6%	90.8%	91.0%	91.4%
CAWOA-PELM	92.2%	92.8%	93.4%	93.6%	94.0%
QBSA-PELM	92.0%	92.6%	93.2%	93.4%	93.8%
ILPSO-PELM	92.6%	93.2%	93.8%	94.2%	94.8%

模型	-4 dB	-8 dB	-10 dB	-12 dB	-14 dB
ICOA-PELM	97.4%	96.4%	94.2%	92.6%	91.8%
COA-PELM	85.4%	83.4%	81.8%	80.2%	78.4%
CAWOA-PELM	90.8%	87.4%	85.4%	84.4%	81.8%
QBSA-PELM	90.2%	87.2%	85.2%	84.0%	81.4%
ILPSO-PELM	91.0%	88.8%	87.0%	85.4%	82.6%

Table	e 4. Predi	ction results	of five p	rediction	models	under	high r	noise
表 4.	高噪声	下五种预测	模型的预	·测结果				

4.4. 考虑工况迁移的实验对比

轴承作为材料生产机械装备的主要零件,在实际工况下,转速,负载均会随时间的变化发生改变,因此固定样本的数据集难以完全包含全部工况下的实验数据。为避免 ICOA-PELM 预测模型在实际工况中由于训练样本缺失全部特性导致预测模型失效的问题,本文引入三种不同程度的工况迁移工况,对ICOA-PELM 预测模型进行测试,CWRU 轴承数据集包含以下四种工况[12] (表 5)。

Table 5. Four different operating conditions 表 5. 四种不同运行工况

状态	径向力/N	负载扭矩/Nm	转速/rpm
N15-M07-F10	1000	0.7	1500
N09-M07-F10	1000	0.7	900
N15-M01-F10	1000	0.1	1500
N15-M07-F04	400	0.7	1500

在数据集中,包括三种不同难以程度的数据迁移情况,具体情况如表 6 所示,五种算法的预测结果如表 7 所示:

Table 6. Three migration scenarios 表 6. 三种迁移工况

工况	迁移前	迁移后
工况1(迁移难度高)	N09-M07-F10	N15-M01-F10
工况2(迁移难度中)	N15-M01-F10	N09-M07-F10
工况3(迁移难度低)	N15-M01-F10	N15-M07-F04

 Table 7. Prediction results of five prediction models under different migration conditions

 表 7. 不同迁移工况下五种预测模型的预测结果

模型	工况 1	工况 2	工况 3
ICOA-PELM	96.4%	97.8%	98.5%
COA-PELM	68.4%	75.6%	89.7%
CAWOA-PELM	76.8%	88.5%	92.8%
QBSA-PELM	78.2%	80.4%	91.7%
ILPSO-PELM	83.4%	92.1%	94.1%

从表 7 中可知,对于复杂程度较低的工况迁移情况而言,五种算法求解的 Accuracy 均大于或接近 90%。但 ICOA-PELM 预测模型的求解精度接近理想工况下的求解精度,说明预测模型 ICOA-PELM 具 备较高的求解速度,可以在短时间求解到最优值。对于复杂程度较高的工况迁移情况而言,只有 ICOA-PELM 预测模型的求解精度大于 95%,而其他四种预测模型的预测程度均低于 90%, COA-PELM 预测模型的求解精度仅为 68.4%。因此验证了 ICOA 算法改进的有效性,很大程度提高了 COA 算法的全局搜索 精度,优化后的 PELM 输入权值和隐层阈值更加适用当前工况,很大程度提高了 PELM 预测模型的预测 精度和泛化能力。

5. 结束语

本文针对材料生产机械装备故障预测提出一种改进浣熊算法的 PELM 预测模型。针对传统浣熊算法 在迭代寻优过程中的缺陷,提出一种基于透镜反向学习的位置初始化策略,并通过引入螺旋寻优状态对 浣熊捕猎行为进行改进,提高算法的初始解精度以及算法的全局收敛精度以及收敛速度。将改进后的浣 熊算法对 PELM 模型的控制参数进行在线整定,建立 ICOA-PELM 预测模型。通过 ICOA-PELM 预测模 型的机械设备故障进行预测。通过从三个不同方面进行实验对比,结果表明,ICOA-PELM 预测模型具有 较强的预测能力和泛化能力,同时具备较强的鲁棒性。

参考文献

- [1] 黄如意,李霁蒲,王震,等. 基于多任务学习的装备智能诊断与寿命预测方法[J]. 中国科学: 技术科学, 2022, 52(1): 123-137.
- [2] 胡奎. 基于深度学习的机械装备寿命预测与故障诊断技术研究[D]: [硕士学位论文]. 武汉: 华中科技大学, 2021.
- [3] 雷亚国,杨彬,杜兆钧,等.大数据下机械装备故障的深度迁移诊断方法[J].机械工程学报,2019,55(7):1-8.
- [4] 任玲辉, 刘凯, 张海燕. 基于图像处理技术的机械故障诊断研究进展[J]. 机械设计与研究, 2011, 27(5): 21-24.
- [5] 徐志军, 旷欢, 王如龙, 等. 改进的 LS-SVM 方法在 EMD 端点效应问题中的应用[J]. 计算机工程与应用, 2015, 51(3): 222-228.
- [6] 朱可恒, 宋希庚, 薛冬新. 希尔伯特振动分解在滚动轴承故障诊断中应用[J]. 振动与冲击, 2014, 33(14): 160-164.
- [7] 李浩情,余点,潘常春,等.基于模型知识融合的图神经网络多雷达协同任务调度算法[J]. 雷达学报, 2025, 1-16.
- [8] 何田素,李玮,盖京明,等. 基于小波去噪神经网络在数字岩心的应用[J]. 科学技术与工程, 2025, 25(1): 270-277.
- [9] 吐尔逊·买买提, 成思怡, 刘亚楼. 基于 VMD-SSA-LSSVM 模型的汽油车 CO₂ 排放预测[J]. 交通科技与经济, 2025, 27(1): 43
- [10] Dehghani, M., Montazeri, Z., Trojovská, E. and Trojovský, P. (2023) Coati Optimization Algorithm: A New Bio-Inspired Metaheuristic Algorithm for Solving Optimization Problems. *Knowledge Based Systems*, 259, Article ID: 110011. <u>https://doi.org/10.1016/j.knosys.2022.110011</u>
- [11] 孟小燕. 融入自学习与多领导者策略的改进鲸鱼优化算法及多阈值图像分割[J]. 计算机应用与软件, 2025, 42(1): 205-212, 233.
- [12] 范小婷. 基于深度学习的滚动轴承故障诊断方法研究[D]: [硕士学位论文]. 南京: 南京信息工程大学, 2024.