



基于WOA-RF算法的船舶柴发电系统故障诊断

李维波 高峰 肖朋 黄康政 阮道杰 高俊卓

Fault diagnosis of ship diesel power distribution system based on WOA-RF algorithm

LI Weibo, GAO Feng, XIAO Peng, HUANG Kangzheng, RUAN Daojie, GAO Junzhuo

在线阅读 View online: <https://doi.org/10.19693/j.issn.1673-3185.04193>

您可能感兴趣的其他文章

Articles you may be interested in

基于动态特征融合的船舶柴油机进排气系统故障诊断

Fault diagnosis of marine diesel engine intake and exhaust system based on dynamic feature fusion

中国舰船研究. 2022, 17(6): 103-110 <https://doi.org/10.19693/j.issn.1673-3185.02443>

船舶动力装置智能故障诊断技术的应用与展望

Application and prospects of intelligent fault diagnosis technology for marine power system

中国舰船研究. 2020, 15(1): 56-67 <https://doi.org/10.19693/j.issn.1673-3185.01679>

基于随机森林的离心泵滚动轴承故障诊断

Fault diagnosis of antifriction bearing of centrifugal pump based on random forest

中国舰船研究. 2020, 15(3): 129-135 <https://doi.org/10.19693/j.issn.1673-3185.01646>

基于卷积神经网络的蒸汽动力系统故障诊断

Fault diagnosis of steam power system based on convolutional neural network

中国舰船研究. 2022, 17(6): 96-102 <https://doi.org/10.19693/j.issn.1673-3185.02616>

基于粗糙集和优化DAG-SVM的船舶主机故障诊断方法

Main marine engine fault diagnosis method based on rough set theory and optimized DAG-SVM

中国舰船研究. 2020, 15(1): 68-73 <https://doi.org/10.19693/j.issn.1673-3185.01650>

不平衡数据下船舶主机在线故障诊断研究

Study on fault diagnosis of marine main engine's online imbalanced data

中国舰船研究. 2023, 18(5): 269-275 <https://doi.org/10.19693/j.issn.1673-3185.02977>



扫码关注微信公众号, 获得更多资讯信息

本文网址: <http://www.ship-research.com/cn/article/doi/10.19693/j.issn.1673-3185.04193>

期刊网址: www.ship-research.com

引用格式: 李维波, 高峰, 肖朋, 等. 基于 WOA-RF 算法的船舶柴发配电系统故障诊断 [J]. 中国舰船研究, 2025, 20(X): 1-12.
LI W B, GAO F, XIAO P, et al. Fault diagnosis of ship diesel power distribution system based on WOA-RF algorithm [J]. Chinese Journal of Ship Research, 2025, 20(X): 1-12 (in Chinese).

基于 WOA-RF 算法的船舶柴发配电系统故障诊断



扫码阅读全文

李维波^{*1,2}, 高峰¹, 肖朋¹, 黄康政¹, 阮道杰¹, 高俊卓¹

1 武汉理工大学 自动化学院, 湖北 武汉 430070

2 西北民族大学 电气工程学院, 甘肃 兰州 730124

摘要: [目的] 船舶柴发配电系统对航行稳定性至关重要, 海洋工作环境的严苛性致使其故障频发, 为此提出一种基于鲸鱼优化算法的优化随机森林(WOA-RF)算法, 用以开展船舶柴发配电系统故障诊断。[方法] 首先, 基于 Matlab/Simulink 仿真软件搭建船舶柴发配电系统模型, 采集其故障工况和正常工况的数据; 然后, 对收集的数据进行预处理以提取时域特征, 并使用随机森林提取重要特征, 从而减少数据维度; 最后, 使用 WOA 优化后的随机森林模型对船舶柴发配电系统运行数据进行故障识别、诊断和分类。[结果] 仿真模拟试验表明: WOA-RF 方法识别故障状态和正常状态的准确率为 100%, 区分 12 种故障类型的准确率为 98.26%; 在原始数据集中, 与 9 种不同算法对比, WOA-RF 的准确率最低提升了 4.86%, 最高提升了 34.37%; 在添加 10 dB 噪声数据后, 与 6 种不同算法对比, WOA-RF 的准确率最低提升了 2.43%, 最高提升了 18.40%。[结论] 基于 WOA-RF 的故障诊断方法在复杂海洋环境中展示了优异的准确性和鲁棒性, 可为船舶电力系统故障的可靠识别提供参考。

关键词: 船舶柴发配电系统; Simulink 模型; 故障诊断; 鲸鱼优化算法(WOA); 随机森林(RF); 特征提取

中图分类号: U665.14

文献标志码: A

DOI: 10.19693/j.issn.1673-3185.04193

0 引言

船舶柴发配电系统是现代船舶的核心组成部分^[1], 其可为推进系统、导航设备、通信系统、自动化控制系统及生活区等提供电力支持。随着船舶的主尺度增加和功能复杂化, 柴发配电系统也日趋复杂, 一旦发生故障, 可能导致船舶失去动力或其他关键功能, 甚至为船员、货物及航行安全带来风险^[2-3]。由于船舶柴发配电系统包含大量的子系统, 且各子系统之间具有强耦合性和非线性特征, 仅依靠操作人员的经验难以快速准确地定位故障, 可能错过最佳排除时机而导致故障加剧, 最终影响船舶的机动性和操控性。与陆地发配电系统有所不同^[4,5], 船舶柴发配电系统的容量较小且独立性强, 任何设备故障都可能引发整个电网的不稳定, 尤其在施加或移除较大负荷时,

而母线电压波动容易导致严重故障。因此, 船舶柴发配电系统对故障诊断和快速响应的要求更高, 能否准确定位故障设备并分析原因至关重要。随着技术发展, 可实现全船能量整体协调的船舶柴发配电系统将成为未来趋势, 为保障航行安全, 有必要深入开展故障诊断技术研究^[6]。

故障诊断方法分为基于模型和无模型两类: 基于模型的方法包括状态估计、参数估计和等价空间法, 但船舶电力系统的数学模型一般难以获取, 故其应用范围有限; 随着计算机技术的发展, 无模型故障诊断方法应运而生, 例如模糊理论、专家系统、机器学习和深度学习, 其无需依赖精确的数学模型, 仅利用船舶电网的运行数据即可进行故障诊断^[7], 在船舶故障的快速识别、诊断定位等方面具有明显优势。船舶配电系统的数据量庞大, 其数据处理设备的计算负荷较高, 所以实时

收稿日期: 2024-09-18 修回日期: 2024-11-07 网络首发时间: 20xx-xx-xx xx:xx

基金项目: 国家重点研发计划项目(2020YFB1506802); 国家自然科学基金面上项目(51977164); 湖北省科技计划项目(2024BAB067)

作者简介: 李维波, 男, 1973 年生, 博士, 教授, 博士生导师。研究方向: 电力电子技术能源系统中的应用。E-mail: liweibo@whut.edu.cn

高峰, 男, 2001 年生, 硕士生。研究方向: 电气工程。E-mail: 1251985390@qq.com

*通信作者: 李维波

故障诊断的难度也较高,因此,迫切需要开发一种不依赖数学模型、可嵌入任何设备和操作系统的算法,不仅可以快速检测故障,还具备区分多种故障类别和故障程度的能力。

目前,在船舶配电系统的故障诊断领域,已开展了大量的研究工作。Zhong等^[8]将深度学习应用于船舶柴油机故障诊断,提出了基于相关分布和深度置信网络的方法,并取得了良好的效果。Yu等^[9]提出了一种基于改进卷积神经网络的船舶电力系统故障诊断方法。Liu等^[10]针对永磁同步电机定子绕组的故障诊断问题,提出了一种改进的粒子群算法,优化了参数选择方式。Li等^[11]提出了一种基于电网数据的风电机组故障诊断方法,其利用残差发生器和自主决策建立了长短期记忆网络,可以较好地处理风电机组的时间序列数据。Zhang等^[12]针对发电机终端短路故障诊断,提出了一种结合多级小波分解、门控递归神经网络和卷积网络的混合模型,并通过高斯随机变量的合成过采样技术解决了数据不平衡问题。Xie等^[13]基于残差网络和双向长短期记忆网络,提出了高阻连接故障的深度学习诊断模型,实现了高性能诊断。Liu等^[14]提出了一种基于噪声辅助多元经验模态分解和互信息-轻梯度提升算法的舰船中压直流电力系统故障诊断方法,不仅显著减少了训练时间,还实现了优异的诊断功能。然而,现有的研究成果在以下方面仍有待改进:模型在处理数据类别不平衡时的训练效果欠佳,影响了实际应用效果;高复杂度模型的计算成本较高,限制了其实际应用范围;部分深度学习模型对噪声较为敏感,且在解释性方面存在不足,尤其在标签数据有限的情况下,模型表现将受到明显的制约;此外,在长序列数据建模中,部分方法的处理速度较为缓慢。

针对以上问题,本文拟提出一种鲸鱼优化算法结合随机森林的船舶柴发配电系统故障诊断方法,通过将智能算法与机器学习相结合,从而优化故障诊断过程。首先,通过Simulink仿真软件建立船舶柴发配电系统模型,以模拟正常状态与故障状态,从而生成故障响应曲线并获取数据集;然后,对原始数据进行清洗和归一化处理,进行特征提取,并使用随机森林模型提取重要特征,以减少数据维度;其次,利用鲸鱼优化算法(whale optimization algorithm, WOA)来优化随机森林的关键参数,避免过拟合或欠拟合,以提高模型性能;最后,通过分类准确率、精确率、召回率、F1得分(F1 score,即精确率和召回率的调和平均数)和混淆矩阵对模型性能进行评估,并与

其他算法进行对比,从而验证该方法的故障诊断准确率以及处理噪声数据时的鲁棒性。

1 船舶电力系统

相较于陆地电网而言,船舶电力系统非常特殊,其本质上是一个处于孤岛运行状态的微电网,具有极强的独立性。船舶电网主要分为辐射型、环型和区域配电网络三类,本文的研究对象为环状区域配电网络的柴发配电系统。

环状区域结构结合了辐射型供电和环型供电的特点,发电机通过配电板形成环状连接。在船舶左舷和右舷分别布置2条母线,艏部和艉部均通过断路器相连,从而将船舶电网划分为多个区域。每个区域均与这2条母线连接,当一侧母线发生故障时,区域内的重要负载将自动切换至另一侧母线,以确保冗余供电,从而提高全船供电的连续性和可靠性,保障船舶的生存力和生命力。图1所示为环状区域配电结构^[15],其中MTG表示主发电机,ATG表示辅发电机,ESS表示能量存储单元。

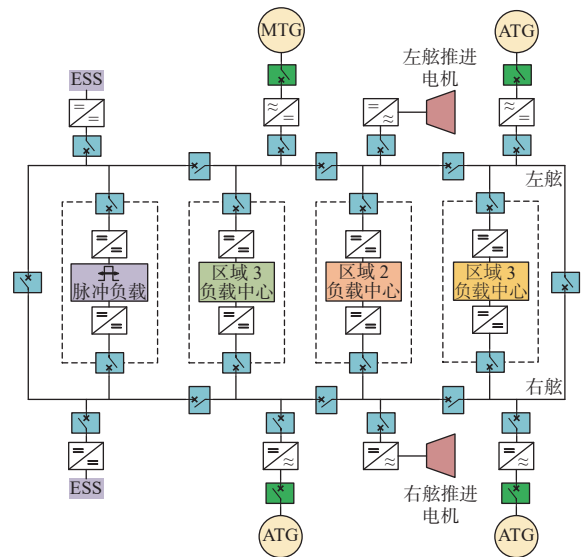


图1 船舶区域配电结构示意图

Fig. 1 Schematic diagram of ship regional power distribution structure

2 算法理论基础

2.1 随机森林

随机森林(random forest, RF)是一种集成学习算法^[16],其将多棵分类回归树(classification and regression tree, CART)集成在一起,每棵树均针对相同输入进行分类,并通过多数投票确定最终的分类结果。

2.1.1 CART决策树

CART决策树是构成随机森林的基础单元,

其使用基尼指数作为属性选择的度量标准。基尼指数可用于衡量数据集的纯度, 基尼指数越小, 数据集越纯, 模型的构建效果也更好。假设数据集 D 包含 n 个类别, 则基尼指数 $T(D)$ 的计算公式为

$$T(D) = 1 - \sum_{i=1}^n p_i^2 \quad (1)$$

式中, p_i 为第 i 类元素出现的频率, 其中 $i=1, 2, \dots, n$ 。

根据属性 B 将数据集 D 划分为 D_1 和 D_2 , 则此时 D 的基尼系数 $G_B(D)$ 为

$$G_B(D) = \frac{|D_1|}{|D|} G_B(D_1) + \frac{|D_2|}{|D|} G_B(D_2) \quad (2)$$

式中, $G_B(D_1), G_B(D_2)$ 分别为 D_1, D_2 的基尼系数。

2.1.2 Bagging 算法

Bagging 算法, 也称为引导聚集 (bootstrap aggregating) 算法, 是一种并行的集成学习方法, 其核心思想是从原始的 M 个训练样本中反复进行可放回的抽样, 每次选取 m 个样本, 从而生成多个不同的训练集, 接着训练多个弱学习器。通过对这些弱学习器的结果进行综合, 例如投票或平均, 来构建一个强学习器, 从而提升模型的整体性能和稳定性。图 2 所示为 Bagging 算法的原理图

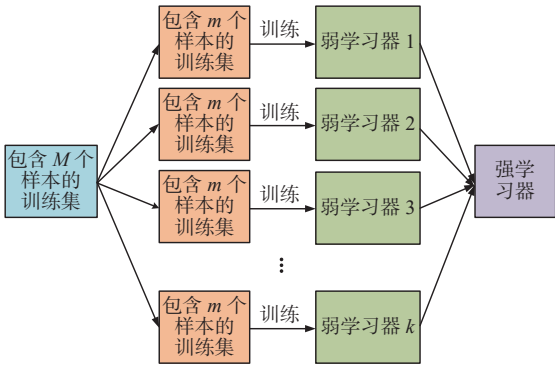


图 2 Bagging 算法的原理图

Fig. 2 Schematic diagram of Bagging algorithm

2.1.3 随机森林的计算步骤

随机森林的计算步骤包括 Bagging 抽样、决策树基本分类器的构建、决策树投票, 如图 3 所示, 其中 N 表示通过抽样后所生成的数据集总数。

2.2 鲸鱼优化算法 (WOA)

鲸鱼优化算法 (WOA) 是 Mirjalili 等^[7] 于 2016 年提出的一种新型群体智能优化算法。WOA 算法属于元启发式算法, 主要通过随机或最佳搜索代理的方式来模拟座头鲸的捕猎行为, 并采用螺旋攻击来模拟气泡网的攻击机制。与其他优化算法相比, WOA 算法的优化机制简单、寻优能力强且收敛速度快。WOA 算法主要包括 3 个优化求解

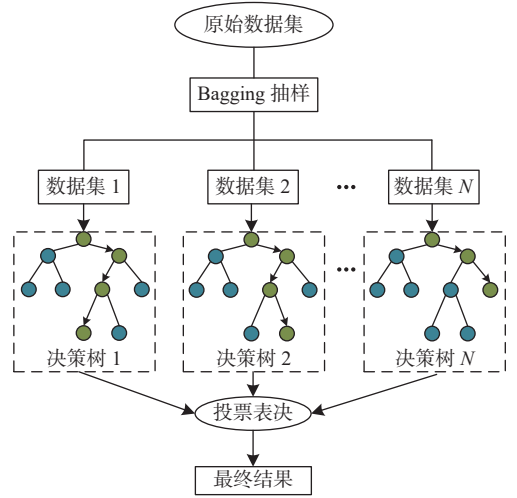


图 3 随机森林计算的步骤图

Fig. 3 Step by step diagram of random forest calculation

过程, 即包围猎物、气泡网攻击和随机搜索^[8], 具体如下:

1) 过程 1: 包围猎物。

在 WOA 算法中, 鲸鱼群体之间将互相交流信息, 并随机游走搜索猎物的位置。每只鲸鱼代表 1 个个体, 每个个体在搜索空间的位置代表 1 个解。假设当前的最优位置是目标猎物, 当群体中其他鲸鱼个体向当前最优个体位置移动时, 可利用如下公式来更新位置:

$$P = |C \cdot x_{\text{best}}(t) - x(t)| \quad (3)$$

$$x(t+1) = x_{\text{best}}(t) - A \cdot P \quad (4)$$

式中: P 为目标位置; C 和 A 均为系数向量, 且 $A \cdot P$ 为包围步长; $x(t)$ 为鲸鱼当前位置, 其中 t 为当前迭代次数, $x(t+1)$ 为通过更新规则得到的新位置; $x_{\text{best}}(t)$ 为当前全局最优位置。其中

$$A = 2ar_1 - a \quad (5)$$

$$C = 2r_2 \quad (6)$$

式中: r_1, r_2 为 $[0, 1]$ 范围内均匀分布的随机数; a 为随着迭代次数的增加, 从 2 线性递减至 0 的收敛因子, 即

$$a = 2 - 2t/t_{\text{max}} \quad (7)$$

式中, t_{max} 为最大迭代次数。

2) 过程 2: 气泡网攻击。

在 WOA 中, 鲸鱼通过向上螺旋运动并不断收缩包围圈来攻击猎物, 可以采用 2 种方法来表示鲸鱼的捕食行为, 即收缩包围机制和螺旋更新机制。

(1) 收缩包围机制: 通过减小式 (5) 和 (7) 中的

收敛因子 a 即可实现。

(2)螺旋更新位置:鲸鱼以螺线运动轨迹向猎物游动,朝向不同的气泡进行捕食,其数学模型为

$$x(t+1) = P_2 e^{\beta l} \cos(2\pi l) + x_{\text{best}}(t) \quad (8)$$

式中: $P_2 = |x_{\text{best}}(t) - x(t)|$, 为鲸鱼与当前全局最优个体之间的距离; β 为限定对数螺旋形式的常数; l 为 $[-1, 1]$ 区间内的随机数。

当鲸鱼在猎物收缩圈的周围沿着螺旋路径进行游动时,可以选择相同概率的随机变量 q 进行收缩包围,并通过螺旋更新机制来更新鲸鱼的位置,其数学模型为

$$x(t+1) = \begin{cases} x_{\text{best}}(t) - A \cdot |C \cdot x_{\text{best}}(t) - x(t)|, & q < 0.5 \\ P_2 e^{\beta l} \cos(2\pi l) + x_{\text{best}}(t), & q \geq 0.5 \end{cases} \quad (9)$$

3)过程3:随机搜索。

在此阶段,随机选择种群的某个鲸鱼个体位置作为目标方向来寻找猎物。当 $|A| \geq 1$ 时,表示

鲸鱼在收缩圈外游动,则可根据彼此位置进行随机搜索,其数学表达式如下:

$$P = |C \cdot x_{\text{rand}}(t) - x(t)| \quad (10)$$

$$x(t+1) = x_{\text{rand}}(t) - A \cdot P \quad (11)$$

式中, $x_{\text{rand}}(t)$ 为种群中随机选取鲸鱼的位置。

在 WOA 算法中,当控制参数 $|A| < 1$ 时,进行局部最优解搜索,此时鲸鱼以概率 0.5 进行猎物包围,以概率 0.5 进行螺线运动;当控制参数 $|A| \geq 1$ 时,进行全局最优解搜索。

2.3 鲸鱼优化的随机森林算法

基于鲸鱼优化算法的优化随机森林 (whale optimization algorithm-optimized random forest, WOA-RF) 算法中,包含了数据收集、数据预处理、特征提取与选择、数据集划分、选择随机森林参数、故障分类、故障评估和故障决策等过程,如图 4 所示。

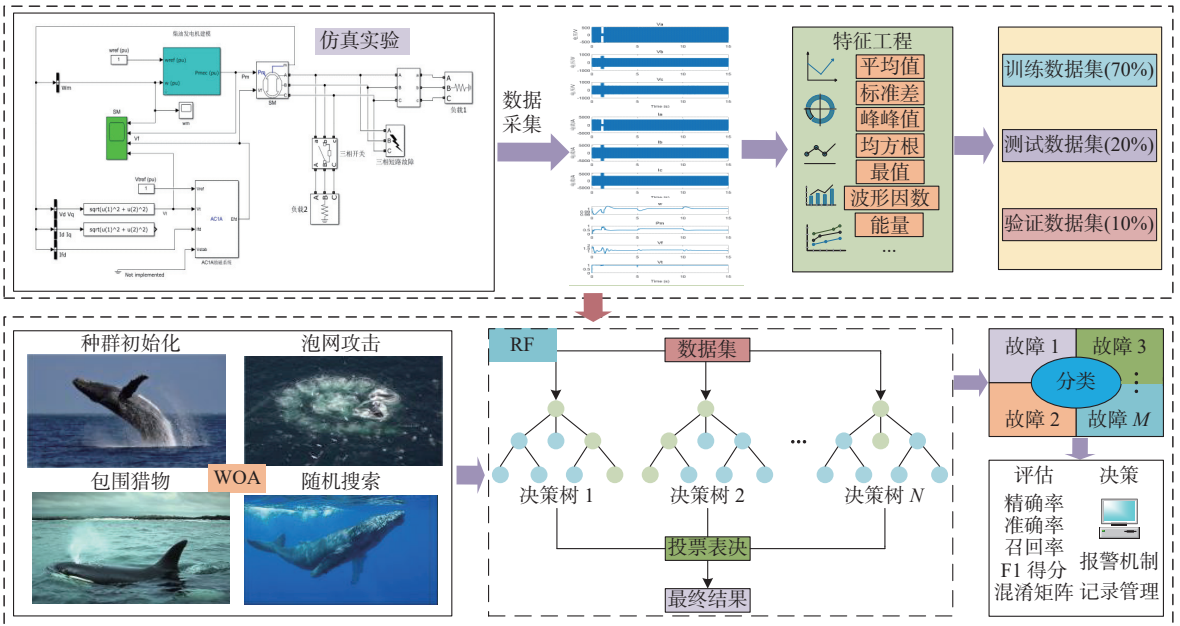


图 4 WOA-RF 算法处理的过程框图

Fig. 4 Block diagram of the process handled by the WOA-RF algorithm

WOA-RF 算法的分析步骤具体如下:

1)数据收集:收集船舶柴发配电系统在不同短路故障和正常工况下的数据,包括三相电压、三相电流,以及柴油发电机侧的转速、输出功率、励磁电压和电压幅值等 10 个信号,其中转速、输出功率、励磁电压和电压幅值均以标么值表示。

2)数据预处理:首先,对原始数据进行清洗和预处理,包括处理缺失值、噪声、异常值;然后,将数据归一化缩放至标准范围(0~1),以防止数据奇异性并提高故障诊断率。

$$X^* = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (12)$$

式中: X^* 为归一化之后的数据; X 为原始数据; X_{\min} , X_{\max} 分别为原始数据中的最小值和最大值。

3)特征提取与选择:首先,从原始数据中提取有意义的时域特征,例如平均值、标准差、最大值、最小值、峰峰值、均方根、振幅因数、波形因数和能量;然后,利用随机森林的重要评估指标来选择具有代表性的特征,以减少数据维度,从而提高模型的性能。

4)数据集划分: 将预处理后的数据集划分为 70% 训练集、20% 测试集和 10% 验证集。

5)选择随机森林参数: 在 WOA 中, 每条鲸鱼代表一组随机森林超参数。在适应度评估中, 最小误差率作为适应度值, 适应度值越低即说明参数组合越优。鲸鱼行为包括包围猎物、螺旋攻击和

随机搜索, 经过多次迭代来逐步优化超参数, 最终输出最佳决策树的数量和深度。图 5 所示为 WOA 优化 RF 参数的寻优流程图。

6)故障分类: 采用 WOA 优化后的随机森林模型对数据进行分类, 通过集成多个决策树的预测结果, 即可输出最终的分类结果。

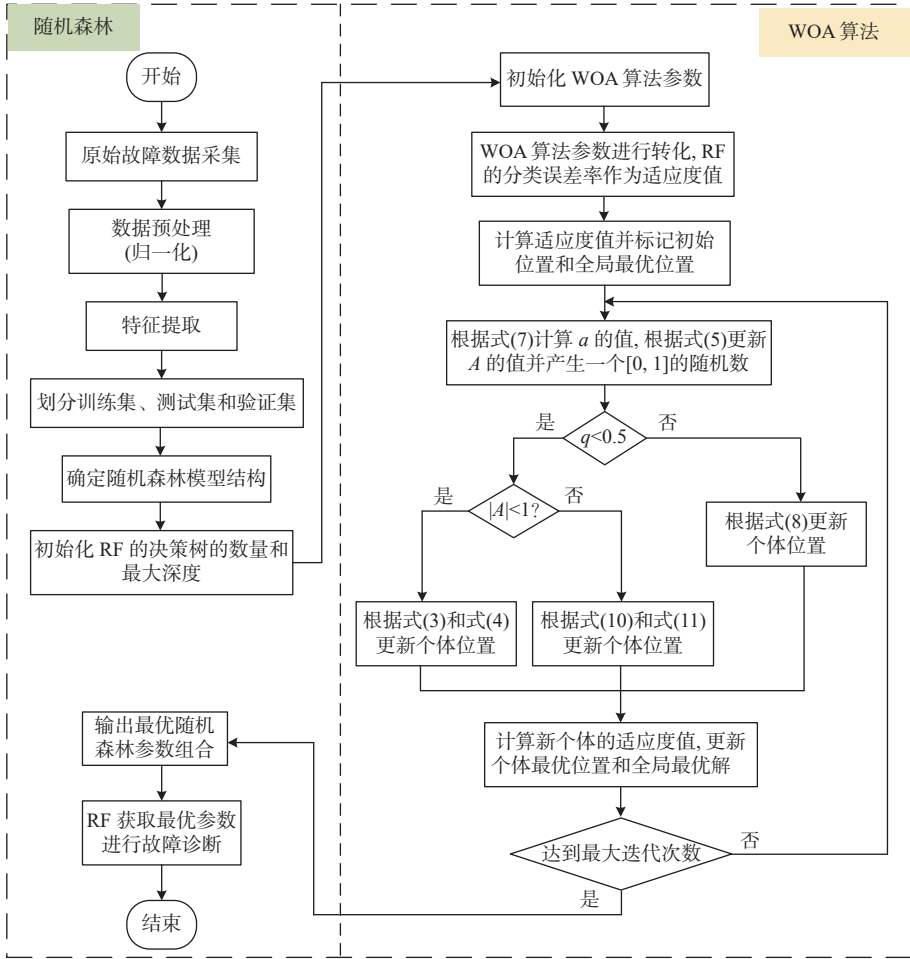


图 5 WOA 优化 RF 参数流程图

Fig. 5 WOA optimized RF parameters flowchart

7)故障评估: 使用验证集评估模型的性能, 评估指标包括: 准确率、精确率、召回率、F1 得分和混淆矩阵。

8)故障决策: 根据分类结果和评估指标, 做出相应的故障诊断决策 (报警机制、维护建议和记录管理)。

2.4 评估指标

在故障分类问题中, 需要根据准确率、精确率、召回率和 F1 得分等指标来评估分类器的性能。根据混淆矩阵, 即可计算得出评估指标。混淆矩阵是在机器学习和统计学中用于评估和分类模型的一种表格, 如表 1 所示, 混淆矩阵的行和列分别表示实际的类和预测的类。

准确率 (accuracy) A_c 、精确率 (precision) P_r 、召

回率 (recall) R_c 的定义为

表 1 混淆矩阵

Table 1 Confusion matrix

	预测为正类别	预测为负类别
实际为正类别	True positive (TP)	False negative (FN)
实际为负类别	False positive (FP)	True negative (TN)

$$A_c = \frac{TP + TN}{TP + TN + FP + FN} \quad (13)$$

$$P_r = \frac{TP}{TP + FP} \quad (14)$$

$$R_c = \frac{TP}{TP + FN} \quad (15)$$

作为精确率和召回率的调和平均数, F1 得分

的表达式为

$$F1 = \frac{2P_r \cdot R_e}{PP_r + R_e} \quad (16)$$

3 实验和结果分析

3.1 故障数据获取

本文以 Matlab 2023b 作为仿真软件, 操作系统为 Windows11, 计算机为 i5-13400F, 2.5 GHz, 内存

32 GB。在 Matlab/Simulink 中搭建船舶柴发电系统模型^[19], 如图 6 所示, 具体参数如表 2 所示。

通过改变故障发生器的类型, 即可模拟不同种类的故障类型, 最终得到 11 类故障工况和 1 种正常工况下的仿真数据(共计 12 种), 故障类型所对应的标签如表 3 所示。设定本文的故障点均为负载侧发生的故障, 故需采集负载侧的三相电压、三相电流以及柴油同步发电机侧的转速、功率、励磁电压和电压幅值并进行特征提取, 其中转速、功率、励磁电压和电压幅值均采用标么值表示。

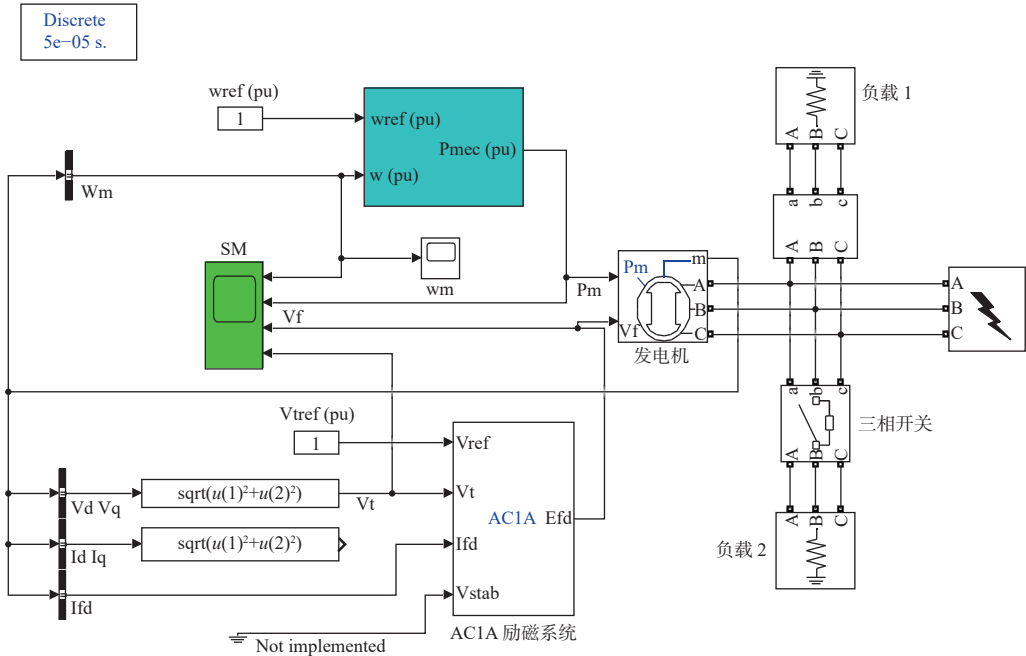


图 6 船舶柴油发电机模型

Fig. 6 Ship diesel generator model

表 2 模型参数
Table 2 Model parameter

参数名称	数值
额定功率 P_n /MW	6
额定电压 U_n /V	660
定子电阻 R_s /Ω	0.003 6
额定频率 f_n /Hz	50
惯性系数 H (s)/s	1.07
极对数 P	4
d轴同步电抗 X_d /pu	1.26
d轴暂态同步电抗 X'_d /pu	0.213
d轴次暂态同步电抗 X''_d /pu	0.111
q轴同步电抗 X_q /pu	0.70
q轴次暂态同步电抗 X'_q /pu	0.122
漏电抗 X_l /pu	0.067
d轴暂态时间常数 T'_d /s	0.32
d轴次暂态时间常数 T''_d /s	0.015
q轴次暂态时间常数 T''_q /s	0.30

表 3 故障类型所对应的标签
Table 3 Fault categories and labels

故障类别	标签
A相接地故障	1
B相接地故障	2
C相接地故障	3
AB相相间短路故障	4
BC相相间短路故障	5
CA相相间短路故障	6
AB相两相接地故障	7
BC相两相接地故障	8
CA相两相接地故障	9
ABC三相短路故障	10
ABC三相接地故障	11
正常工况	12

假设每个工况的运行时间为 15 s, 采样频率为 20 kHz, 每组数据有 300 000 个采样点。本文

接入的负载共有 3 种组合, 如表 4 所示: 组合 1 为 1 MW 和 0 MW; 组合 2 为 3 MW 和 1 MW; 组合 3 为 0.5 MW 和 5.5 MW。负载接入的时间为分别为第 5 s 和第 10 s, 持续时间为 5 s, 即第 1 种情况为负载第 5 s 时接入, 第 10 s 时断开; 第 2 种情况为负载第 10 s 时接入, 持续到仿真结束。设定故障发生的时间分别为第 1, 4, 7, 10 s, 故障的持续时间为 0.1, 0.2, 0.3, 0.4, 0.5 s。综合以上条件, 1 种故障类型有 120 组数据, 则 11 种故障工况和 1 种正常工况共有 1440 组数据。

图 7 表示 A 相接地故障中一组数据的 10 个信号的故障波形图。结合负载处电压、电流变化情况以及发电机输出端的变化情况可知, 第 1 s

表 4 负载接入表

Table 4 Load access table

组合序号	负载一/MW	负载二/MW
1	1	0
2	3	1
3	0.5	5.5

时, 发电机侧 A 相发生接地短路故障: 图 7(a)中, 负载处的 A 相电压 V_a 瞬间减小, 电压值接近于 0, 其余两相电压 (V_b 和 V_c) 均出现了相同幅度的增加; 图 7(b)中, A 相电流 I_a 瞬间减小, 其余两相电流 (I_b 和 I_c) 的增加幅度相同; 图 7(c)中, 发生故障后的转速 w 和功率 P_m 先突增尔后保持稳定, 励磁电压 V_f 和端电压 V_t 均保持稳定, 无明显变化。




图 7 A 相接地故障波形图
Fig. 7 Phase A ground fault waveform

3.2 故障诊断结果分析

为了确定最佳参数, 在提取特征之后, 采用 WOA 算法选择 RF 的超参数, 并将最大化准确率 (即最小化错误率) 作为适应度函数值。WOA 的参数设置为: 种群数量为 20, 最大迭代次数为 100, 上下限值为 [0, 100], 维度为 2。

WOA-RF 仿真计算结果如图 8 所示, 可知 WOA-RF 算法在迭代过程中表现了较好的收敛

性, 经过 48 次迭代后, 适应度值达到最优。当完成 100 次迭代后, 输出了优化所得的 2 个超参数, 即决策树的数量和最大深度, 以此作为随机森林的超参数。然后, 在船舶柴发电系统的故障原始数据集上进行 WOA-RF 故障诊断和故障分类, 验证集数据集的实验结果如图 9 所示, WOA-RF 的准确率为 98.26%, 精确率为 98.61%, 召回率为 98.78%, F1 得分为 98.69%。

为了进一步验证 WOA-RF 算法的有效性, 将




图 8 适应度迭代曲线
Fig. 8 Fitness iteration curve




图 9 WOA-RF 实验结果
Fig. 9 WOA-RF experimental result

WOA-RF 与 9 种算法进行比较,包括 K 近邻算法(K-nearest neighbors, KNN)、支持向量机(support vector machine, SVM)、反向传播算法(back-propagation, BP)、随机森林(random forest, RF)、学习向量量化(learning vector quantization, LVQ)、决策树(decision tree, DT)、集成学习(ensemble learning, EL)、极限学习机(extreme learning machine, ELM)和卷积神经网络(convolutional neural network, CNN)。表 5 所示为以准确率、精确率、召回率和 F1 得分(F1_Score)作为评估指标的不同算法对比结果。

表 5 WOA-RF 与其他算法的 4 种指标对比

Table 5 Comparison of four indicators between WOA-RF and other algorithms

算法	评估指标			
	准确率	精确率	召回率	F1得分
KNN	86.11%	85.52%	84.57%	84.45%
SVM	72.57%	73.38%	84.31%	76.28%
BP	63.89%	66.19%	66.23%	63.94%
RF	90.36%	90.17%	90.25%	90.02%
LVQ	74.65%	73.38%	73.20%	71.92%
EL	93.40%	92.82%	92.80%	92.81%
ELM	86.84%	86.31%	87.26%	86.78%
CNN	91.67%	92.07%	91.88%	91.98%
DT	94.44%	94.20%	94.18%	94.19%
WOA-RF	98.26%	98.61%	98.78%	98.69%

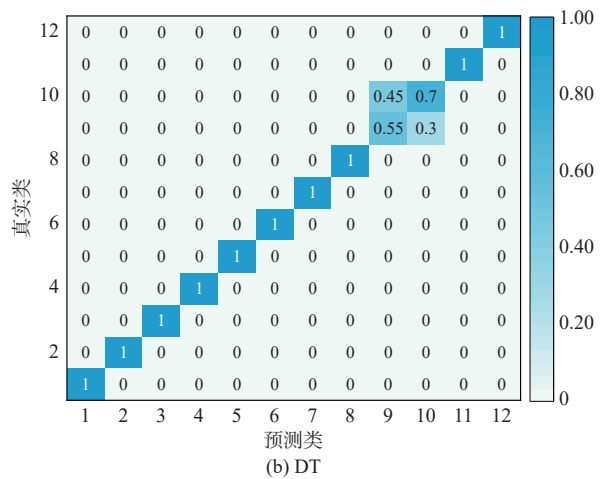

由表 5 得知,本文 WOA-RF 算法的准确率为 98.26%,与 KNN(86.11%)相比,提高了 12.15%;与 SVM(72.57%)相比,提高了 25.69%;与 BP(63.89%)相比,提高了 34.37%;与 RF(90.36%)相比,提高了 7.9%;与 LVQ(74.65%)相比,提高了 23.61%;与 ELM(86.84%)相比,提高了 11.42%;与 CNN(91.67%)相比,提高了 6.59%;与 EL(93.40%)相比,提高了

4.86%;与准确率最高的 DT(94.44%)相比,提高了 3.82%,由此可见,WOA-RF 算法的准确率平均提高了 14.55%。同样,在精确率方面,WOA-RF 算法最少提高了 4.41%(相较于 DT),最多提高了 32.42%(相较于 BP),平均提高了 14.83%;在召回率方面,WOA-RF 最少提高了 4.60%(相较于 DT),最多提高了 32.55%(相较于 BP),平均提高了 13.82%;在 F1 得分方面,WOA-RF 最少提高了 4.5%(相较于 DT),最多提高了 34.75%(相较于 BP),平均提高了 15.09%。

图 10 所示为不同算法验证集的混淆矩阵,其中坐标轴数字 1~12 分别表示故障类型所对应的标签,右侧 0~1 标尺表示混淆矩阵数值经归一化处理后,反映模型在各个类别上的准确率和错误率。由图 10(a)可知,标签 10 和标签 11 的诊断率分别为 60% 和 66.7%,而其他标签的诊断率均为 100%;由图 10(b)可知,标签 9 和标签 10 的诊断率分别为 55% 和 70%,而其他标签的诊断率均为 100%;由图 10(c)可知,标签 1、标签 2 和标签 3 的诊断率分别为 47.8%、71% 和 43.9%,其他标签的诊断率均为 100%;由图 10(d)得知,标签 1 的诊断率为 84%,标签 2 的诊断率为 95.7%,而标签 3 至标签 12 的诊断率为 100%。

由此可见,WOA-RF 算法的故障诊断准确率很高,明显优于 RF 算法、EL 算法和 DT 算法,不仅可以区分正常工况和故障工况,还能识别不同的故障类别。

在船舶电力系统中,故障诊断是保障系统安全运行的关键环节。然而,在实际操作环境中存在各种复杂的干扰因素,例如传感器精度限制、环境噪声和信号传输误差等,这些因素可能导致系统获取的数据带有不同程度的噪声,从而影响故障诊断的准确性和可靠性。为了模拟这些实际工况,评估诊断模型在噪声条件下的鲁棒性,有






图 10 原始数据验证集的混淆矩阵

Fig. 10 Confusion matrix of original data validation set

必要开展引入噪声的实验。

当完成对船舶柴发配电系统故障数据的基础分析之后,为进一步验证诊断模型的鲁棒性和实际应用效果,下一步将开展噪声添加实验。通过在船舶柴发配电系统故障数据中添加不同水平的噪声,可以有效模拟现实环境中可能出现的各种干扰情况。该实验不仅有助于揭示噪声对诊断结果

的影响,还可为优化及提升故障诊断模型的抗干扰能力提供依据,从而为确保船舶柴发配电系统在复杂和多变的实际运行环境中保持高效、可靠的故障诊断能力奠定基础。

通过对原始数据添加 10 dB 噪声,并采用与上文相同的处理方式,即可得到如图 11 所示的不同算法验证集的混淆矩阵。

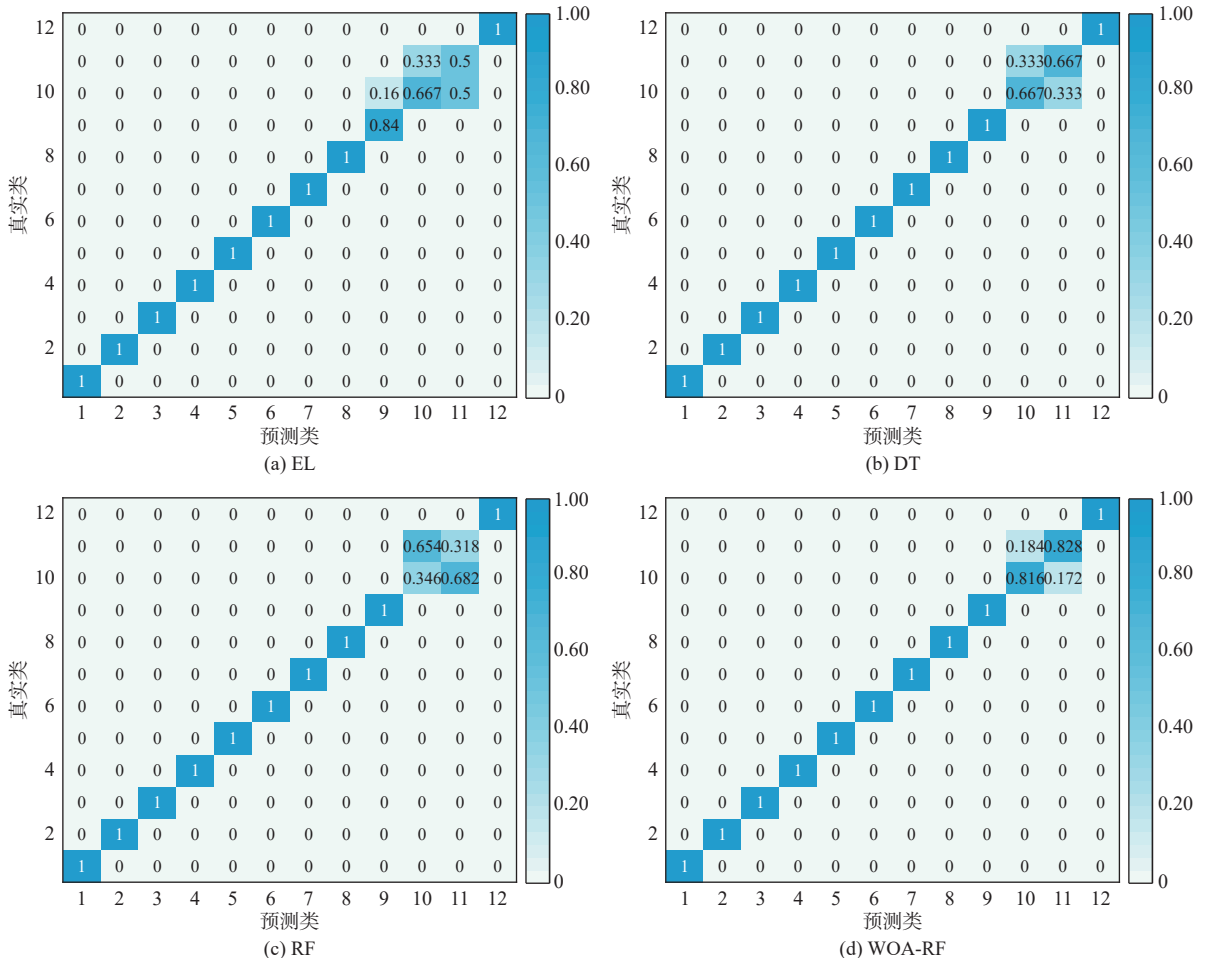


图 11 添加噪声条件下的验证数据集混淆矩阵

Fig. 11 Confusion matrix of validation data set under added noise

由图 11(a) 得知, 标签 9、标签 10 和标签 11 的诊断率分别为 84%, 66.7%, 50%, 而其他标签的诊断率均为 100%; 由图 11(b) 得知, 标签 10 和标签 11 的诊断率均为 66.7%, 其他标签的诊断率均为 100%; 由图 11(c) 得知, 标签 10 和标签 11 的诊断率分别为 34.6% 和 31.8%, 其他标签的诊断率均为 100%; 由图 11(d) 得知, WOA-RF 算法已经达到 100% 的故障识别率, 在具体故障类别的识别过程中, 仅标签 10 和标签 11 的诊断率分别为 81.6% 和 82.8%。因此, 添加噪声后的 WOA-RF 算法在故障诊断方面仍然具有很高的准确率, 明显优于 RF 算法、EL 算法和 DT 算法, 不仅可区分正常工况和故障状态, 还能识别不同的故障类别。

为了进一步验证 WOA-RF 算法的有效性, 本节将 WOA-RF 与 KNN 算法、BP 算法、RF 算法、ELM 算法、EL 算法、DT 算法进行对比分析, 根据准确率、精确率、召回率和 F1 得分进行验证和评估, 结果如表 6 所示。

表 6 WOA-RF 与其他算法的 4 种指标对比(添加噪声后)
Table 6 Comparison of four indicators between WOA-RF and other algorithms(after adding noise)

算法	评估指标			
	准确率	精确率	召回率	F1 得分
KNN	78.47%	78.37%	77.99%	76.88%
BP	76.74%	77.30%	76.94%	76.18%
RF	88.89%	90.83%	88.88%	88.87%
ELM	89.61%	86.64%	86.82%	86.73%
EL	92.01%	91.56%	91.57%	91.56%
DT	92.71%	92.51%	92.48%	92.36%
WOA-RF	95.14%	95.36%	95.30%	95.28%

分析表 6 可知, 添加噪声后的数据准确率略低于原始数据(表 5), 但下降幅度较小, WOA-RF 算法的准确率为 95.14%, 与 KNN(78.47%) 相比, 提高了 16.67%; 与 BP(76.74%) 相比, 提高了 18.40%; 与 RF(88.89%) 相比, 提高了 6.25%; 与 ELM(89.61%) 相比, 提高了 5.53%; 与 EL(92.01%) 相比, 提高了 3.13%; 与准确率最高的 DT(92.71%) 相比, 提高了 2.43%, 即 WOA-RF 算法的平均准确率提高了 8.735%。在精确率方面, WOA-RF 算法至少提高了 2.85%(相较于 DT), 最多提高了 18.06%(相较于 BP), 平均提高了 9.16%; 在召回率方面, WOA-RF 算法最少提高了 2.82%(相较于 DT), 最多提高了 18.36%(相较于 BP), 平均提高了 9.58%; 在 F1 得分方面, WOA-RF 最少提高了 2.92%(相较于 DT), 最多提高了 19.1%(相较于

BP), 平均提高了 9.85%。

4 结 论

传统的故障诊断方法依赖于先验知识和专家经验, 需要构建精确的数学模型, 故难以应对系统设备的新变化和未知故障, 其扩展性和适应性有限。相比之下, 基于数据驱动的故障诊断采用机器学习与深度学习, 能够处理复杂系统以及非线性关系, 具有较好的泛化能力, 但存在样本难获取、训练时间长等问题, 难以满足实时性要求。为此, 本文提出了一种基于鲸鱼优化算法与随机森林结合的船舶柴发配电系统故障诊断方法, 并通过 Matlab/Simulink 仿真平台建立了船舶电力系统模型, 进而提取故障特征, 并利用鲸鱼优化算法对随机森林超参数进行优化, 仿真结果表明: WOA-RF 方法可以有效识别系统的故障工况和正常工况, 故障识别率高达 100%; 在原始数据集下对 12 种故障类型的诊断准确率为 98.26%, 在噪声数据集下的准确率为 95.14%; 与其他算法相比, WOA-RF 在准确率、精确率、召回率和 F1 得分等指标方面均有显著的提升效果。这表明该算法不仅具备较高的故障诊断准确率, 还在噪声环境下保持了良好的鲁棒性, 所以具备良好的应用潜力。

需注意的是, 虽然 WOA-RF 算法在船舶柴发配电系统故障诊断中表现优异, 但该方法仍存在一定的优化空间:

1) 计算复杂度高: 由于 WOA 在迭代过程中涉及多次全局搜索和适应度评估, 尤其在处理大规模数据集时, WOA-RF 算法的计算复杂度较高, 故导致训练时间较长, 难以满足实时性要求。

2) 收敛性问题: 虽然 WOA 在大多数情况下表现了良好的优化效果, 但仍可能存在收敛速度较慢或陷入局部最优解的问题, 所以其在复杂环境下的诊断效果有限。

在未来的研究工作中, 可以通过降低 WOA-RF 的计算复杂度来优化算法效率, 具体方法包括改进 WOA 的搜索机制或引入并行计算技术, 从而加快大规模数据集的处理速度, 以更好地满足实时性需求。同时, 可以结合其他优化算法的局部优化能力与 WOA 的全局搜索优势来形成混合优化策略, 以加快收敛速度, 从而提升算法在复杂故障诊断中的鲁棒性与全局搜索能力。此外, WOA-RF 算法还可以进一步增强其在实际工程中的实用性与适应性, 例如扩展到其他电力系统, 为其提供新的故障诊断思路。

参考文献:

- [1] KJONG S, RØDSKAR E, MOLINAS M, et al. The marine vessel's electrical power system: from its birth to present day[J]. *Proceedings of the IEEE*, 2015, 103(12): 2410–2424.
- [2] 李维波, 郝春昊, 高佳俊, 等. 舰船综合电力系统发展综述 [J]. *中国舰船研究*, 2020, 15(6): 1–11.
LI W B, HAO C H, GAO J J, et al. Overview of the development of shipboard integrated power system[J]. *Chinese Journal of Ship Research*, 2020, 15(6): 1–11 (in Chinese).
- [3] BARROS J, DIEGO R I. A review of measurement and analysis of electric power quality on shipboard power system networks[J]. *Renewable and Sustainable Energy Reviews*, 2016, 62: 665–672.
- [4] 孙光甦, 原宗, 关静. 舰船综合保障体系综述 [J]. *中国舰船研究*, 2020, 15(1): 89–94.
SUN G S, YUAN Z, GUAN J. A review of integrated logistics support systems for ships[J]. *Chinese Journal of Ship Research*, 2020, 15(1): 89–94 (in Chinese).
- [5] ZHANG Z, HE X. Fault-structure-based active fault diagnosis: a geometric observer approach[J]. *Energies*, 2020, 13(17): 4475.
- [6] WANG Z, XIA L, WANG Y J, et al. Fault diagnosis system based on multiagent technique for ship power system[J]. *Mathematical Problems in Engineering*, 2014, 2014(1): 370246.
- [7] GAO Z W, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques—Part I: fault diagnosis with model-based and signal-based approaches[J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(6): 3757–3767.
- [8] ZHONG G Q, WANG H Y, ZHANG K Y, et al. Fault diagnosis of marine diesel engine based on deep belief network[C]//Proceedings of 2019 Chinese Automation Congress. Hangzhou, China: IEEE, 2019: 3415–3419. doi: 10.1109/CAC48633.2019.8997060.
- [9] YU C C, QI L, SUN J, et al. Fault diagnosis technology for ship electrical power system[J]. *Energies*, 2022, 15(4): 1287.
- [10] LIU W X, LIU L, CHUNG I Y, et al. Modeling and detecting the stator winding fault of permanent magnet synchronous motors[J]. *Simulation Modelling Practice and Theory*, 2012, 27: 1–16.
- [11] LI M S, YU D, CHEN Z M, et al. A data-driven residual-based method for fault diagnosis and isolation in wind turbines[J]. *IEEE Transactions on Sustainable Energy*, 2019, 10(2): 895–904.
- [12] ZHANG L Y, ZHANG Z Q, PENG H M. Diagnostic method for short circuit faults at the generator end of ship power systems based on MWDN and deep-gated RNN-FCN[J]. *Journal of Marine Science and Engineering*, 2023, 11(9): 1806.
- [13] XIE J L, SHI W F, XUE T, et al. High-resistance connection fault diagnosis in ship electric propulsion system using res-CBDNN[J]. *Journal of Marine Science and Engineering*, 2024, 12(4): 583.
- [14] LIU S, SUN Y, ZHANG L Y, et al. Fault diagnosis of shipboard medium-voltage DC power system based on machine learning[J]. *International Journal of Electrical Power & Energy Systems*, 2021, 124: 106399.
- [15] AMY J V. Considerations in the design of naval electric power systems[C]//Proceedings of the IEEE Power Engineering Society Summer Meeting. Chicago: IEEE, 2002: 331–335. doi: 10.1109/PSS.2002.1043244.
- [16] 周海军, 王超伟, 周国敬, 等. 基于随机森林的离心泵滚动轴承故障诊断 [J]. *中国舰船研究*, 2020, 15(3): 129–135.
ZHOU H J, WANG C W, ZHOU G J, et al. Fault diagnosis of antifriction bearing of centrifugal pump based on random forest[J]. *Chinese Journal of Ship Research*, 2020, 15(3): 129–135 (in Chinese).
- [17] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. *Advances in Engineering Software*, 2016, 95: 51–67.
- [18] 王喜莲, 秦嘉翼, 耿民. 基于 d-q 变换及 WOA-LSTM 的异步电机定子匝间短路故障诊断方法 [J]. *电机与控制学报*, 2024, 28(6): 56–65.
WANG X L, QIN J Y, GENG M. Asynchronous motor stator turn-to-turn short circuit fault diagnosis based on d-q transform and WOA-LSTM[J]. *Electric Machines and Control*, 2024, 28(6): 56–65 (in Chinese).
- [19] 张峰. 船舶电力系统故障分析及诊断技术研究 [D]. 哈尔滨: 哈尔滨工程大学, 2022.
ZHANG F. Research on fault analysis and diagnosis technology of ship power system[D]. Harbin: Harbin Engineering University, 2022 (in Chinese).

Fault diagnosis of ship diesel power distribution system based on WOA-RF algorithm

LI Weibo^{*1,2}, GAO Feng¹, XIAO Peng¹, HUANG Kangzheng¹, RUAN Daojie¹, GAO Junzhuo¹

¹ School of Automation, Wuhan University of Technology, Wuhan 430070, China

² College of Electrical Engineering, Northwest Minzu University, Lanzhou 730124, China

Abstract: [**Objectives**] The marine diesel generator (DG) power distribution system is crucial for ship navigation. However, due to the harsh marine environment, frequent failures occur. Therefore, a fault diagnosis method based on whale optimization algorithm-optimized random forest (WOA-RF) is proposed for the marine DG power distribution system. [**Methods**] The marine DG power distribution system model is built using Matlab/Simulink simulation software. First, fault and normal condition data are collected. Then, the collected data is normalized, time-domain features are extracted, and important features are selected using random forest to reduce data dimensionality. Finally, the WOA-optimized random forest model is used for fault identification, diagnosis and classification. [**Results**] Simulation results show that the WOA-RF method can identify fault and normal states with 100% accuracy. It can classify 12 different fault types with an accuracy of 98.26%. In the original dataset, the accuracy of WOA-RF improved by at least 4.86% and by up to 34.37% compared to nine different algorithms. In the dataset with 10 dB noise, the accuracy of WOA-RF improved by at least 2.43% and by up to 18.40% compared to six different algorithms. [**Conclusions**] The WOA-RF-based fault diagnosis method demonstrates superior accuracy and robustness in complex marine environments, providing a reliable solution for fault identification in marine power systems.

Key words: marine diesel power distribution system; Simulink model; fault diagnosis; whale optimization algorithm (WOA); random forest (RF); feature extraction