

DOI: 10.19650/j.cnki.cjsi.J2210107

基于时频特征融合与 GWO-ELM 的棒控电源早期故障状态辨识方法*

唐圣学, 马晨阳, 勾泽

(河北工业大学省部共建电工装备可靠性与智能化国家重点实验室 天津 300130)

摘要:针对核电棒控系统电源(PWE)早期故障状态辨识问题,提出一种基于融合时域与时频域的故障特征和灰狼优化算法(GWO)的极限学习机(ELM)辨识方法。首先,根据棒控电源 PWE 工作原理和控制棒驱动机构的驱动电流,利用电流上升时间分析了早期波形形态与早期故障模式。然后,构建融合电流上升时间、均方根-差分和小波包奇异熵的故障时频特征,分析了特征的可区分性。进而,采用 GWO 算法进行 ELM 分类器参数择优,建立 GWO-ELM 模型实现 PWE 早期故障状态的辨识,以提高辨识精度。最后,通过开展不同特征组合和辨识模型比对试验,结果表明所提方法能有效实现棒控电源早期故障识别诊断,且平均辨识准确度可达 98.86%。

关键词:棒控电源;早期故障;状态辨识;时域特征;小波包奇异熵;GWO-ELM 模型

中图分类号: TH86 TL362 **文献标识码:** A **国家标准学科分类代码:** 470.40

Early fault state identification method of the rod control system power equipment based on time-frequency characteristics fusion and GWO-ELM

Tang Shengxue, Ma Chenyang, Gou Ze

(State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300130, China)

Abstract: To address the problem of early fault state identification of the nuclear rod control system and rod position system power equipment (PWE), this article proposes an identification method based on the fusion of fault features in time domain and time-frequency domain and extreme learning machine (ELM) of grey wolf optimizer (GWO). Firstly, according to the working principle of PWE and the driving current of control rod drive mechanism, the early waveform shape and early fault mode are analyzed by using the current rise time. Then, the fault time-frequency features are constructed, which are fused with current rise time, root mean square difference summation and wavelet packet singular entropy. The discriminability of the features is analyzed. Then, the GWO algorithm can optimize parameters of the ELM classifier. The GWO-ELM model is formulated to realize the identification of early fault states of PWE, which can improve the identification accuracy. Finally, through the comparison test of different feature combinations and identification models, the results show that the proposed method can effectively realize the early fault identification and diagnosis of rod control system power supply, and the average identification accuracy can reach 98.86%.

Keywords: rod control system power equipment; early fault; state identification; time domain characters; wavelet packet singular entropy; GWO-ELM

0 引言

核电棒控系统(rod control system, RCS)作为核电最重要的仪控系统之一,用于驱动燃料棒提升或插入,

来实现反应堆发电功率调节,对保证核电站安全运行和提高负荷率具有重要作用。其中电源装置作为控制棒驱动机构的直接控制设备,其安全可靠运行是实现棒束驱动的基本保证^[1]。同时,国内许多核电站仍配备进口棒控电源(power equipment, PWE),已服役十余

收稿日期:2022-07-09 Received Date: 2022-07-09

* 基金项目:河北省自然科学基金(E2021202068)项目资助

年,其内部关键器件出现老化,严重影响反应堆功率自动调节,提高了计划外检修的可能性。如2013年某核电站控制棒下插失效而触发双保持,造成停堆检修事件;2019年某核电站大修期间控制棒意外掉落,但未发出预警信号。这些故障均由棒控电源故障导致的输出电流错位所导致^[2-3]。PWE早期故障状态检测与辨识能为PWE安全状态提供信息描述,能为维修策略制定提供技术支持,可提升核电站可用性和安全经济可行性^[4]。

核电设备故障检测包括机械设备故障检测、电设备检测等^[5-6]。目前,机械故障检测成果较多,如汽轮机、轴承故障检测等^[7-8]。核电棒控系统RCS故障主要包括电气故障和执行机构故障。电气故障主要成果有棒位检测位置故障、功率器件开路 and 短路故障、可编程逻辑控制器(programmable logic controller, PLC)控制器故障等,机械故障主要有钩爪脱口等^[9-11]。目前,PWE软故障或早期故障检测成果较少,尤其是因电容、器件老化引起的早期故障缺乏深入研究。

核电故障诊断方法主要有基于模型的方法、基于知识的方法和基于数据驱动的方法等。基于模型的方法需要建立精确数学模型^[12],RCS系统涉及机械、电气、控制学科,建立精确模型以及退化模型比较困难,难以用于电源早期故障检测。基于知识的方法依赖于经验知识,具有一定局限性^[13]。基于数据驱动的方法中,传统神经网络模型存在收敛速度慢和局部最优解等问题,需大量历史数据^[14-15]。然而,由于核电站高安全性要求,棒控电源采用定期维护,各种故障数据相对较少。支持向量机(support vector machine, SVM)学习泛化能力较传统神经网络有较大提升,但核函数及参数的选择限制着其辨识精度^[16]。

极限学习机(extreme learning machine, ELM)是一种新型非线性分类算法,比传统神经网络法和SVM模型表现出了更优越的诊断性能^[17]。ELM具有易建模,泛化能力强等优点,对于小样本、高维度问题能够有效解决。但由于ELM采用随机生成权重初值方法,会影响辨识精度与稳定性。灰狼优化算法(grey wolf optimizer, GWO)作为一种种群优化算法,模拟狼群等级层次和狩猎行为,具有原理简单、参数需求少、搜索能力强等优势^[18]。采用GWO对ELM进行参数寻优,能够有效提高其辨识能力。

本文针对PWE电源早期故障,通过分析故障波形和早期故障信息,融合时域与时频域特征,提出采用上升时间、均方根-差分和小波包奇异熵的多维融合特征向量。利用GWO算法优化ELM,构建早期故障GWO-ELM分类模型,以融合特征向量为输入,对PWE早期故障状态进行检测与辨识。

1 核电电源早期故障波形与模式分析

1.1 电路原理

核电RCS电源PWE由电源与相位参考模块(power supply and phase ref module, ALSYN)和电源模块(power module, MDP)组成,其中ALSYN模块由220V交流电供电,内部包含6、24、±15V稳压模块,能够向其他控制部分电路提供稳压电源。MDP模块能够输出一个CRDM线圈电流来直接控制一个CRDM线圈,此线圈电流值与当前电平、模块配置和电流值参数有关。输出电流由发电机260Vac通过整流桥整流产生,ALSYN从260Vac提取相位参考信号,转化为逻辑电平控制MDP晶闸管关断,进而输出特殊序列电流控制CRDM运动。

RCS电源PWE装置主要由1个三相半波可控整流电路、脉冲生成电路、驱动电路等组成。发电机发出260Vac交流电经过电阻电容组成的微分电路滤波后,经三相晶闸管半桥整流,整流后电流序列驱动CRDM线圈控制CRDM驱动棒动作。同时,电流传感器实时监测输出电流大小与相位质量,与ALSYN模块的参考相位进行比较,如出现缺相等相位故障,MDP模块相位管理模块会发出双保持命令。

随着服役时间增长,电源元器件不断老化,PWE电源容易发生故障。发生功率器件短路、断路等故障,电源PWE没有输出或者变化显著,容易检测。目前,这类故障成果较多。其实,在电源老化过程中,会出现输出电流幅值、频率等波形畸变,影响CRDM驱动机构抓举效果,如有输出无动作、抓举振动。像这种故障状态,本文称之为早期故障。

引入欧几里得距离(Euclidean distance, ED)度量电流波形畸变程度,即是否发生早期故障。欧几里得距离为:

$$D_E(F_i, F_0) = \frac{1}{n} \sum_k^n \sqrt{\sum_{m=1}^p (a_k^m - b_k^m)^2} \quad (1)$$

式中: a_k^m 和 b_k^m 分别为两曲线第 m 维第 k 个波形数据, p 为维数, n 为数据采样个数。 $D_E(F_i, F_0)$ 表示各故障电流波形和无故障电流波形的欧式距离, $i=1,2,3$ 。早期故障阈值可通过现场或仿真数据统计分析确定。

文中考虑工况变化和噪声对数据的干扰,经过统计分析后发现,选取早期故障状态阈值 $D_{E,th} = 0.2$,即电流数据与基准值的欧氏距离大于0.2时,能比较有效的发现早期故障。

1.2 早期故障模式与特性分析

核电电源PWE正常工况下,驱动机构提升一步的电流波形如图1所示。电源PWE为插入线圈、提升线圈和

保持线圈供电。在 3 种线圈中,保持线圈工作状态只有啮合棒和非啮合棒两种状态,分析阐述容易,为此选取保持线圈电流作为分析对象。为了分析故障模式,根据波形不同阶段特点,可将输出电流波形分为全电流区、半电流区、零电流区和电流上升区。由图 1 可知,上升时间 t_r 定义为:电流从零电流区增加到出现动作点后全电流区所需的时间。设零电流区结束时间为 t_z ,全电流区开始时间为 t_f ,则上升时间 t_r 为:

$$t_r = t_f - t_z \quad (2)$$




图 1 退出动作电流时序

Fig. 1 Withdrawal current sequence

在电流上升至动作临界点时,线圈磁力带动衔铁、衔铁带动钩爪将棒啮合。此时在钩爪动作后磁通量减小,导致线圈电感增大、电流减小。电流全电流区会产生一个小幅凹陷,即出现动作点。分析表明,利用电流变化可监测电源早期故障状态。

经过统计分析表明,棒控电源 PWE 早期常见故障模式如表 1 所列。下面对 3 种早期故障状态外在现象和产生原因进行分析。

表 1 PWE 故障类型

Table 1 PWE fault category

故障类型	故障现象	故障原因
F_0	无故障	-
F_1	动作点滞后	钩爪卡涩
F_2	动作点缺失	驱动机构失效
F_3	上升时间延迟	电源模块老化

1) 动作点滞后故障

当电流从零电流区上升至全电流区后,电流衔铁无法按时吸合,导致钩爪未能及时啮合燃料棒,出现一定的滞后现象,此时波形如图 2 所示。从图 2 可知,正常情况下电流在上升到全电流值之前动作点会出现,而发生动作点滞后情况下电流出现动作点前的电流峰值明显大于正常情况。根据式(1)和图 2,计算 F_1 的欧式距离为 $D_E(F_1, F_0) = 0.432$,大于 0.2,可判定发生早期故障。




图 2 动作点滞后故障电流波形

Fig. 2 Current waveform of action point lag fault

2) 动作点缺失故障

当电流上升至全电流区时,动作点未出现,表现为动作点缺失故障,此时电流波形如图 3 所示。动作缺失原因是电磁线圈断路导致驱动机构失效,钩爪未作出相应啮合动作。从图 3 可知,因未出现动作点,电流持续爬升至全电流区,上升时间较无故障情况明显缩短。除电流上升区外,零电流区和全电流区和无故障电流基本一致。根据式(1)和图 3,计算 F_2 的欧式距离为 $D_E(F_2, F_0) = 0.415$,大于 0.2,可判定发生早期故障。




图 3 动作点缺失故障电流波形

Fig. 3 Current waveform of action point missing fault

3) 上升时间延迟故障

当电源电路出现明显老化,如脆弱器件降质或结温过高等现象时,输出电流上升时间明显延长,但幅值以及均值未出现大幅波动,此时电流波形如图 4 所示。当发生上升时间延长时,动作点存在延迟,全电流区缩短。根据式(1)和图 4,计算 F_3 的欧式距离为 $D_E(F_3, F_0) = 0.582$,大于 0.2,可判定发生早期故障。




图 4 上升时间延迟故障电流波形

Fig. 4 Current waveform of rise time delay fault

综上所述,PWE电源早期故障会增加钩爪误操作风险,降低了反应堆功率调节的可靠性。根据电流波形特征,可表征早期故障状态。

2 核电电源早期故障特征提取

2.1 时域特征分析与提取

直接采用电流辨识早期故障状态,数据量大。文中经过分析,采用故障电流曲线分区时域特征表征PWE电源故障状态。前述电流波形分析可知,故障状态表现在动作点所在前后波形区间,包含电流上升区和全电流区。

以接受动作指令开始,不同状态下电流上升区波形典型数据如表2所示。由表2可知,不同状态上升开始时间基本保持在384~385 ms之间,因此选取385~565 ms波形数据进行分析计算。根据式(2)计算每种状态上升时间 t_r ,即: F_0 (无故障)情况下 $t_{r0} = 140.64$ ms, F_1 (动作点滞后)故障 $t_{r1} = 152.01$ ms, F_2 (动作点缺失)故障 $t_{r2} = 96.1$ ms, F_3 (上升时间延迟)故障 $t_{r3} = 162.52$ ms。

表2 电流上升区波形原始数据

Table 2 Raw data of current rising area waveform

故障类型	上升开始时间/ms	上升结束时间/ms	动作点波谷时间/ms	动作点前电流峰值/A
F_0	384.30	524.94	474.49	7.005
F_1	384.24	536.25	502.70	8.214
F_2	384.09	480.19	-	-
F_3	384.89	547.41	495.66	6.871

分析由表2可知,动作点滞后故障和上升时间延迟故障的上升时间均明显大于无故障状态,动作点缺失故障因未出现动作点,导致电流提前上升至全电流区,上升时间大幅缩短;动作点滞后故障和上升时间延迟故障均存在一定的时延;无故障状态和上升时间延迟故障的电流峰值基本相同,但动作点滞后故障电流峰值大于其他3种故障。

当故障程度不同或受外界噪声干扰时,不同早期故障状态存在一定的重叠或模糊性,根据上述三种特征无法明确区分故障类型(如 F_1 、 F_3),上升时间易混淆且难以直接提取,因此只能作为故障的初步判据,进一步辨识早期故障状态还需结合其他特征参量。

经过分析,文中采用电流均方根值、差分和对等特征描述早期故障状态。均方根值能反应区段电流的波动情况,差分 and 能在无需滤波情况下反应区段电流整体变化趋势、能检测奇异点。此外,在电流上升区,均方根值和差分和对不同早期故障状态差异明显。

设电流时间序列数据 $I_s = [x_1, x_2, \dots, x_m]$,其中 $x_j (j = 1, 2, \dots, m)$ 为电流采样点数据值。均方根值表达式为:

$$RMS_j = \sqrt{\frac{1}{N} \sum_{n=1}^N [I_{s,j}(n)]^2} \quad (3)$$

差分和表达式为:

$$D_j = \sum_{r=1}^R [I_{s,j}(n+r) - I_{s,j}(n) + I_{s,j}(n-r) - I_{s,j}(n)] \quad (4)$$

其中, $I_{s,j}(n)$ 表示第 j 段数据采样区间中的第 n 个数据, $n = 1, 2, \dots, N$; r 为以 n 时刻数据为中心的差分半径, $r = 1, 2, \dots, R$ 。

本文中取数据区间宽度 $n = 101$,取最大差分半径 $R = 50$,即选取385~565 ms波形数据中的共758组数据区间。不同早期故障状态典型的均方根值和差分和波形分别如图5和6所示。其中图6(a)为无故障类型,图6(b)为动作点滞后故障,图6(c)为动作点缺失故障,图6(d)为上升时间延迟故障。




图5 故障波形均方根值

Fig. 5 Root-mean-square value of fault waveforms

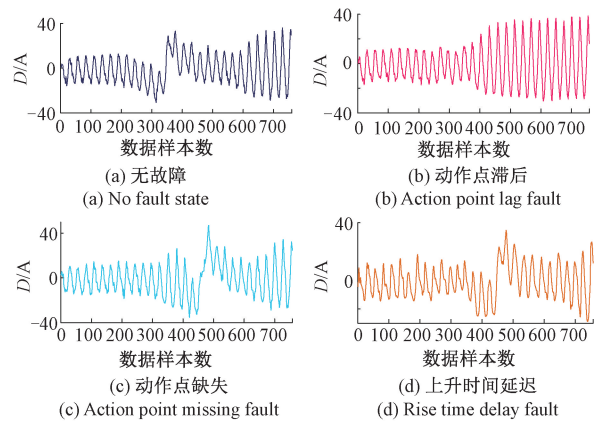


图6 故障波形差分和对

Fig. 6 Difference summation of fault waveforms

由图5可知,3种早期故障状态电流均方根值波形与正常波形形状区别明显,均方根值比较平滑,可准确从中提取电流上升区部分特征,如上升时间、动作点时间等。

图6为未经滤波处理的电流差分。由图6可知,正常、动作点缺失和上升延迟差分数值波动跳跃性较大,适合区分状态,但时间点容易受到噪声干扰。

为了更好的电流波形中提取电流上升和动作点出现时间,定义均方根-差分 $D_{RMS,j}$,表达式如下:

$$D_{RMS,j} = \sum_{r=1}^R [RMS_j(n+r) - RMS_j(n) + RMS_j(n-r) - RMS_j(n)] \quad (5)$$

其中, $RMS_j(n)$ 表示第 j 段数据采样区间中的第 n 个RMS数据, $n=1,2,\dots,N$ 。 D_{RMS} 值越接近0,代表波形越平缓。

经过均方根-差分和处理后,电流波形如图7所示。比较图7(a)~(d)可知,图7(a)、(b)、(d)均出现了奇异峰值,表示动作点出现时刻,图7(c)未出现奇异点且 D_{RMS} 值波动幅度较小,代表电流出现了动作点缺失故障。由图7(b)、(d)可见,二者均出现了奇异点滞后,但图7(b)第198~358组 D_{RMS} 呈连续较快下降趋势,对应458ms时开始出现动作点;图7(d)在198~249组 D_{RMS} 呈一定的上升趋势,再继续下降,且下降幅度较为平缓。因此,均方根-差分 D_{RMS} 二者区分性好。

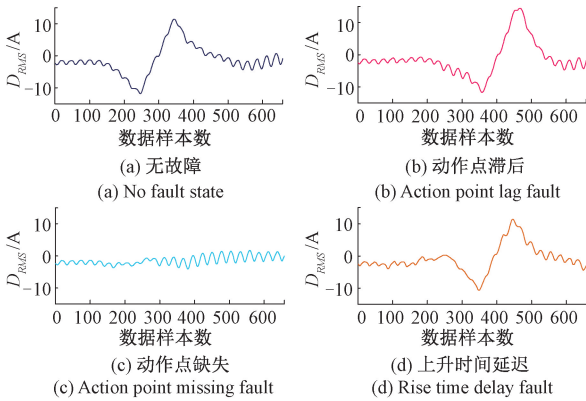


图7 故障波形均方根-差分

Fig. 7 D_{RMS} of fault waveforms

然而,在电源PWE早期故障程度较轻状态下,只根据均方根-差分和有时不能将动作点滞后和上升时间延迟两种故障进行明确区分,易混淆造成误判。

综上,电流特征如上升时间、均方根值和差分只能作为故障初步判据,无法明确对每种早期故障状态进行明确有效辨识区分。为了进一步提高特征识别准确度,提出采用小波分析对电流信号进行多尺度特征提取来表征早期故障状态。

2.2 小波包奇异熵特征提取

小波变换(wavelet transform, WT)能提取电流信号的时频信息。小波变换容易忽略信号高频部分,错过一些重要信

息^[19-20]。小波包分解(wavelet packet transform, WPT)可同时对低频信号和高频信号进行分解,实现有用数据信息提取。

设原始时域信号为 $\Psi(t)$,小波包分解公式如下:

$$w_0^0(t) = \psi(t) \quad (6)$$

$$w_n^{2i}(t) = \sum_k g(k-2t)w_{n-1}^i(t) \quad (7)$$

$$w_n^{2i-1}(t) = \sum_k h(k-2t)w_{n-1}^i(t) \quad (8)$$

其中, n 为小波包分解层数; $w_n^i(t)$ 表示经分解后第 n 层第 i 个分解系数; g 和 h 为小波分解滤波器。

然后对分解系数进行重构,信号重构公式如下:

$$w_n^i(t) = \sum_k g(k-2t)w_{n+1}^{2i}(t) + \sum_k h(k-2t)w_{n+1}^{2i-1}(t) \quad (9)$$

设矩阵 W_p 由小波包分解后各节点重构信号构成,即:

$$W_p^T = \begin{pmatrix} w_1^1 & w_2^1 & \dots & w_{2^n}^1 \\ w_1^2 & w_2^2 & \dots & w_{2^n}^2 \\ \dots & \dots & \ddots & \dots \\ w_1^{2^n} & w_2^{2^n} & \dots & w_{2^n}^{2^n} \end{pmatrix} \quad (10)$$

其中, w_p^t 表示由式(9)重构后的小波包第 p 个尺度空间中第 t 个重构信号, t 为重构信号长度, $t=1,2,\dots,T$, p 为小波包树节点个数, $p=1,2,\dots,2^n$ 。

根据奇异值分解理论(singular value decomposition, SVD),将 $2^n \times T$ 阶矩阵 W 分解为:

$$W = UAV^T \quad (11)$$

其中, U 、 V 为正交矩阵, A 为对角矩阵,其主对角元素 $\lambda_j(j=1,2,\dots,a, a \leq \min(2^n, T))$ 为 W 的奇异值且非负降序排列。则小波包奇异熵 E_s 为:

$$E_s = - \sum_{j=1}^a \left[\left(\lambda_j / \sum_{j=1}^a \lambda_j \right) \ln \left(\lambda_j / \sum_{j=1}^a \lambda_j \right) \right] \quad (12)$$

利用上述算法,对2.2节中385~565ms区间内电流信号采用MATLAB平台编程提取小波包熵,其中采样频率为47kHz,选用db4小波基函数,分解4层小波包。经计算,不同早期故障状态下电流小波包奇异熵数据如表3所示。

表3 电流小波包奇异熵分析结果

Table 3 Results analysis of current wavelet packet singular entropy

故障类型	E_s	相对变化率/%
F_0	0.176 5	-
F_1	0.173 9	-1.474
F_2	0.188 3	+6.686
F_3	0.162 1	-8.159

由表3可知,动作点缺失故障 F_2 小波包奇异熵值大于无故障 F_0 小波包奇异熵值,动作点滞后故障 F_1 的小波包奇异熵值和无故障 F_0 相差较小,故障 F_3 小波包奇异熵值相对变化率大于 F_1 小波包奇异熵值相对变化率,区别明显。因此,在2.2节中用上升时间和差分和作为特征参量难以辨识 F_1 和 F_3 情况下,利用小波包奇异熵值可进一步有效辨识 F_1 和 F_3 两种故障。但 F_1 故障小波包奇异熵值在不同故障程度下,存在与无故障 F_0 的小波包奇异熵值相对变化率接近于0的情况,这将导致仅以 E_s 作为特征进行状态区分时,将会出现 F_0 和 F_1 误辨,无法保证辨识精度。

3 基于GWO-ELM的PWE系统早期故障辨识方法

3.1 GWO-ELM模型

1) 极限学习机模型

ELM是一种针对单隐层前馈神经网络的机器学习分类算法,本质上将输入数据映射到随机空间,并进行最小二乘线性回归算法,具有学习速度快,泛化能力强等优点^[21]。

ELM算法主要分为以下3个步骤:

(1) 随机生成输入权重 W_i 和隐含层阈值 b_i ;

(2) 计算隐含层输出矩阵 H ;

(3) 计算输出权重矩阵 β 。输出权重矩阵计算公式为:

$$\beta = H^+ Y \quad (13)$$

其中, H^+ 为隐含层输出矩阵 H 的Moore-Penrose广义逆; Y 为ELM网络输出,由故障类型组成。

2) 灰狼优化算法

GWO是Mirjalili等^[22]提出的一种种群优化算法,是受灰狼捕食猎物活动的启发而开发的一种优化搜索方法,具有较强的收敛性、参数少、易实现等特点。

该算法寻优过程模仿灰狼到达猎物位置的行为。寻优模型包含3个向量,即 α 、 β 和 δ ,来模拟3种类型的灰狼,它们按适应度的高低评估猎物位置,引导狼群中其余灰狼计算猎物距离,完成捕获猎物。寻优过程如下:

$$D = |C \cdot X_p(t) - X(t)| \quad (14)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (15)$$

$$A = 2a \cdot r_1 - a \quad (16)$$

$$C = 2r_2 \quad (17)$$

式中: D 为灰狼个体间的距离; t 为迭代次数; A 、 C 为包围猎物随机产生的系数; a 在迭代过程中由2线性减小到0; r_1 和 r_2 是 $[0, 1]$ 的随机向量; $X_p(t)$ 是猎物位置向量; $X(t+1)$ 为灰狼位置向量。灰狼狩猎行为为:

$$D_n = |C_i \cdot X_n(t) - X(t)| \quad (18)$$

$$X_i = X_n(t) - A_i \cdot D_n \quad (19)$$

$$X_p(t+1) = (X_1 + X_2 + X_3)/3 \quad (20)$$

其中, D_n 为灰狼 α 、 β 、 δ 和其他个体间的距离, $X_n(t)$ 为当前第 t 次迭代后灰狼 α 、 β 、 δ 的位置, $n = \alpha, \beta, \delta$; $i = 1, 2, 3$; X_i 为第 i 个个体在3个最优个体指导下的更新位置向量, $X_p(t+1)$ 为适应度最好的最优解更新位置。

3.2 基于GWO-ELM的早期故障辨识流程

采集385~565 ms区段内电流数据,计算上升时间 t_r 和小波包奇异熵 E_s ;同时,以第200组数据为起点,间隔100个数据点采样,提取均方根-差分 and 特征 D_{RMS1} 、 D_{RMS2} 、 D_{RMS3} 、 D_{RMS4} ;利用上述特征,设计6维故障特征向量,作为GWO-ELM模型数据输入,即:

$$x = [t_r, D_{RMS1}, D_{RMS2}, D_{RMS3}, D_{RMS4}, E_s] \quad (21)$$

进而采用数据库数据训练和测试后获取辨识模型,输出诊断结果。故障辨识流程如图8所示,具体流程如下:

1) 获取电流历史早期故障数据,计算电流 t_r ,比较 t_r 和上升时间阈值 t_{rth} (阈值选取 $t_{rth} = 120$ ms)。

2) 根据式(2)、(5)和(12)分别计算上升时间 t_r 、均方根-差分 D_{RMS} 和小波包奇异熵 E_s ,构建故障特征向量,进而构建训练数据库和测试数据库。

3) 采用训练数据训练ELM模型,进而利用GWO对ELM模型进行参数寻优,计算适应度并更新ELM参数 W_i 、 b_i 、 β ,构建最优GWO-ELM模型。

4) 在线测试数据库提取特征,根据最优GWO-ELM模型,识别早期故障状态。

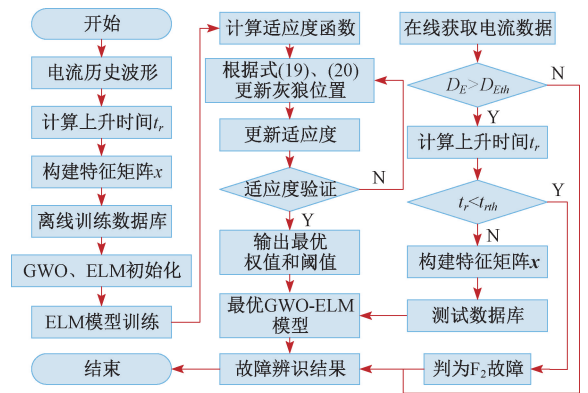


图8 故障辨识流程

Fig. 8 Fault identification process

4 实验数据验证

提取某核电站2014年12月~2020年12月RCS系统中某PWE电源柜采集的电流数据作为验证数据,所采数据均为一步385~565 ms区间内电流波形,采样频率为47.62 kHz,总计310组电流波形数据(共4种状态,包括

无故障和 3 种故障)。随机选取 240 组为训练数据集, 剩余 70 组为测试数据集, 输出故障类别序号 1~4, 对应 $F_0 \sim F_3$ 。典型的某次电流状态数据波形如图 9 所示。

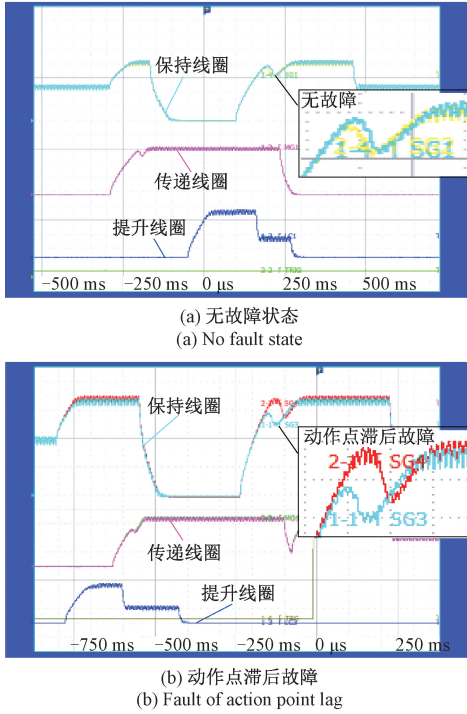


图 9 不同故障状态下的数据波形

Fig. 9 Data waveforms under different fault states

随机选取故障状态测试数据集的特征分布如图 10 所示。从图 10 可以看出, 在不同退化状态下, F_1 和 F_3 的 t_r 和 D_{RMS} 特征较为接近, 但 E_s 特征较远, 可区分。不同故障状态下的状态特征重叠性低, 可分性较好。




图 10 不同故障状态在三维坐标系中的特征分布

Fig. 10 Characteristic distribution of different fault states in three-dimensional coordinate system

在主频 2.60 GHz、内存 8 GB 的 PC 上, 基于 MATLAB2020a 平台, 进行 GWO-ELM 模型辨识训练与测试。模型参数设置为: 激励函数为 Sigmoid, 种群数量为

20, 最大迭代次数为 200。经统计, GWO-ELM 模型辨识测试结果如图 11 所示, 准确率为 98.57%。70 组测试样本中 69 组识别正确, 其中第 56 组数据应为故障 F_3 , GWO-ELM 模型识别为故障 F_1 。




图 11 故障波形测试集诊断结果

Fig. 11 Diagnosis results of fault waveform test set

经分析发现, GWO-ELM 模型误辨识主要原因为第 56 号样本数据 F_3 特征 D_{RMS3} 、 D_{RMS4} 和 t_r 与 F_1 在早期故障较轻微情况下存在一定相似, 以及在噪声干扰下测试时间点定位引起的。

为了进一步分析第 56 号样本误辨识情况, 表 4 给出了与其他 F_1 典型故障特征向量的比较。由表 4 可见, 第 38 号样本与 56 号样本特征一致, 实现了正确辨识。

表 4 特征向量数据比较

Table 4 Comparison of feature vectors data

组号	特征向量数据			实际标签	辨识结果	结论
	t_r	D_{RMS3}	D_{RMS4}			
56	0.152 01	0.543 67	6.443 3	4	2	错误
38	0.151 33	0.550 7	6.440 2	2	2	正确

为了验证 GWO-ELM 模型有效性, 减少诊断模型随机性, 随机重复选取训练集和测试集, 测试 50 次, 测试结果如图 12 所示。在 50 次随机测试中, 共有 23 次准确率为 100%, 14 次准确率为 98.57%, 13 次准确率为 97.14%, 平均准确率为 98.86%。因此, 模型故障识别效果较好。

图 13 给出了 50 次随机测试的混淆矩阵。由图 13 可见, 无故障状态 F_0 和动作点缺失故障 F_2 的识别率为 100%。发生误判情况为动作点滞后故障 F_1 和上升延迟故障 F_3 , 错判样本数分别为 26 个和 14 个, 误判原因是轻度早期故障状态下特征区别较小, 以及在噪声干扰下测试时间点定位精度较低。

为了验证 GWO-ELM 模型和用所提出特征的分类识别效果, 分别选用单独特征与不同特征量组合, 构建 GWO-ELM 模型进行测试, 测试结果如表 5 所示。从表 5




图 12 50 次随机测试结果

Fig. 12 Results of 50 random tests




图 13 故障辨识混淆矩阵

Fig. 13 Confusion matrix of fault tests

可知,3 种单个特征测试结果中, t_r 和 D_{RMS} 的训练精度较高,但测试精度较低; E_s 特征测试精度较高,但训练精度较低,说明 t_r 、 D_{RMS} 和 E_s 分别作为单个特征时,辨识故障准确度和效果较差。采用 4 种不同特征组合的早期故障状态的训练精度和测试精度均在 90% 以上,辨识效果较好。采用多特征融合精度达 98.86%,精度最高。因此,文中所提特征及其辨识方法效果最好。

表 5 不同特征组合测试结果

Table 5 Test results of different vectors

故障向量	训练集 样本数	测试集 样本数	训练精 度/%	测试精 度/%
t_r	240	70	95.28	82.57
D_{RMS}	240	70	89.27	85.69
E_s	240	70	85.80	88.75
$t_r + D_{RMS}$	240	70	91.55	93.31
$t_r + E_s$	240	70	96.63	92.71
$D_{RMS} + E_s$	240	70	95.04	94.23
$t_r + D_{RMS} + E_s$	240	70	100.00	98.86

为了进一步验证本文所提故障辨识模型的可行性,进行不同辨识模型下的故障辨识对比实验。以多特征融合作为模型输入,选取 ELM、SVM、BP 神经网络作为辨识模型,分别利用粒子群优化 (particle swarm optimization, PSO) 和 GWO 对模型进行优化,对 PWE 故障状态进行辨识。

基于 MATLAB2020a 平台、神经网络工具箱和 Libsvm 等方法,对 6 种不同故障辨识模型进行建立与测试。其中,设置 PSO 算法粒子数为 30,惯性权重上下限为 0.9 和 0.3,加速系数为 1.5; SVM 核函数为径向基函数,惩罚因子 c 和核参数 g 的寻优空间分别为 $[0.1, 100]$ 和 $[0.01, 1000]$; BP 神经网络层数为 3,隐含层神经元个数为 50,权值和阈值通过优化算法寻优得到。50 次随机测试结果如表 6 所示。从表 6 可知, GWO-ELM 训练精度和测试精度均高于其他方法。在不同优化算法下, GWO-ELM 的测试精度增加了 10.91%, GWO-SVM 增加了 10.71%, GWO-BP 增加了 2.91%,且训练精度均有所提高;在相同优化算法下, GWO-ELM 较其他两种方法精度分别提高 7.55% 和 24.57%,说明基于 GWO 优化可以有效提高 ELM 模型准确度,性能较好。GWO-ELM 的辨识时间为 0.0027 s,远小于动作电流步长,能够实现快速辨识。

表 6 不同辨识模型下故障辨识结果

Table 6 Fault identification results of different identification models

辨识模型	训练集 样本数	测试集 样本数	训练精 度/%	测试精 度/%
PSO-BP	240	70	71.87	71.37
GWO-BP	240	70	73.02	74.29
PSO-SVM	240	70	89.01	80.60
PSO-ELM	240	70	91.73	87.94
GWO-SVM	240	70	94.98	91.31
GWO-ELM	240	70	100.00	98.86

5 结 论

针对核电棒控电源 PWE 故障,提出早期故障状态辨识方法。主要成果如下:

- 1) 分析了棒控电源 PWE 早期故障状态下工电流波形特点,指明了故障原因,提出了采用时域上升时间、均方根-差分和小波包奇异熵特征表征早期故障状态的方法。
- 2) 提出了灰狼优化算法优化 ELM 模型的核电电源

PWE 早期故障状态智能识别方法, 识别精度达到了 98.86%。

3) 完成了核电棒控电源 PWE 早期故障状态特征可分性分析、识别方法测试与验证。

参考文献

- [1] MASOOD M S, HAQUE N, HASAN R, et al. Fabrication of a control rod drive mechanism emulator for nuclear reactors [C]. 2021 International Conference on Automation, Control and Mechatronics for Industry 4.0 (ACMI), 2021: 1-5.
- [2] 姬海波, 荆茂林, 张恒. CPR1000 机组 RGL 系统双夹持故障分析 [J]. 南方能源建设, 2022, 9(2): 101-106.
- JI H B, JING M L, ZHANG H. Analysis of double-hold fault in RGL system of CPR1000 unit [J]. Southern Energy Construction, 2022, 9(2): 101-106.
- [3] 李袁鹏, 马奔, 冷凌锋, 等. 核电站控制棒意外下落事件分析与处理 [J]. 电工技术, 2020(7): 97-98.
- LI Y P, MA B, LENG L F, et al. Analysis and processing of accidental drop of control rod in nuclear power plant [J]. Electric Engineering, 2020(7): 97-98.
- [4] LEE C, KWON G, SHIN Y. Condition assessment of I&C cables in nuclear power plants via stepped-frequency waveform reflectometry [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(1): 215-224.
- [5] HU G, ZHOU T, LIU Q. Data-driven machine learning for fault detection and diagnosis in nuclear power plants: A review [J]. Frontiers in Energy Research, 2021, 9: 185.
- [6] YIN S, LI X, GAO H, et al. Data-based techniques focused on modern industry: An overview [J]. IEEE Transactions on Industrial Electronics, 2015, 62(1): 657-667.
- [7] LIU G J, GU H X, SHEN X C, et al. Bayesian long short-term memory model for fault early warning of nuclear power turbine [J]. IEEE Access, 2020, 8: 50801-50813.
- [8] LIU Z L, LI T X, HUANG Y P, et al. Research on fault diagnosis of nuclear gate valve based on analysis of energy variation characteristics of vibration signal [J]. 2022 IEEE International Conference on Prognostics and Health Management (ICPHM), 2022: 198-202.
- [9] 曾杰, 彭翠云, 何攀, 等. 控制棒驱动机构电流监测与故障诊断技术研究 [J]. 核动力工程, 2019, 40(1): 172-175.
- ZENG J, PENG C Y, HE P, et al. Research on current monitoring and fault diagnosis technology for control rod drive mechanism [J]. Nuclear Power Engineering, 2019, 40(1): 172-175.
- [10] 张建军, 青先国, 蔡晨, 等. 基于电流特征处理的 CRDM 逆变器故障诊断方法研究 [J]. 核动力工程, 2020, 41(S2): 36-40.
- ZHANG J J, QING X G, CAI CH, et al. Research on fault diagnosis of inverter in CRDM based on current characteristic processing [J]. Nuclear Power Engineering, 2020, 41(S2): 36-40.
- [11] OU D H, LU G L. Pit detection in current monitoring of control rod drive mechanism based on daubechies wavelet analysis [J]. 2022 Prognostics and Health Management Conference (PHM-2022 London), 2022: 549-552.
- [12] MUSTAFA E, AFIA R S A, TAMUS Z A. Application of non-destructive condition monitoring techniques on irradiated low voltage unshielded nuclear power cables [J]. IEEE Access, 2020, 38: 166024-166033.
- [13] HOSEYNI S M, DI M F, ZIO E. Condition-based probabilistic safety assessment for maintenance decision making regarding a nuclear power plant steam generator undergoing multiple degradation mechanisms [J]. Reliability Engineering & System Safety, 2019, 191: 106583.
- [14] PENG B, XIA H, MA X, et al. A mixed intelligent condition monitoring method for nuclear power plant [J]. Annals of Nuclear Energy, 2020, 140: 107307.
- [15] LI W, PENG M J, WANG Q Z. Fault identification in PCA method during sensor condition monitoring in a nuclear power plant [J]. Annals of Nuclear Energy, 2018, 121: 135-145.
- [16] SAID A, HASHIMA S, FOUADA M M, et al. Deep learning-based fault classification and location for underground power cable of nuclear facilities [J]. IEEE Access, 2022, 10: 70126-70142.
- [17] 张淑清, 苑世钰, 姚玉永, 等. 基于 ICEEMD 及

- AWOA 优化 ELM 的机械故障诊断方法[J]. 仪器仪表学报, 2019, 40(11): 172-180.
- ZHANG SH Q, YUAN SH Y, YAO Y Y, et al. Machinery fault diagnosis method based on ICEMMD and AWOA optimized ELM[J]. Chinese Journal of Scientific Instrument, 2019, 40(11): 172-180.
- [18] ZHANG S C, AN D Z, HE Z X. Research on load prediction based on improve GWO and ELM in cloud computing[J]. 2019 IEEE 5th International Conference on Computer and Communications (ICCC), 2019: 102-105.
- [19] 何正友, 蔡玉梅, 钱清泉. 小波熵理论及其在电力系统故障检测中的应用研究[J]. 中国电机工程学报, 2005(5): 40-45.
- HE ZH Y, CAI Y M, QIAN Q Q. A study of wavelet entropy theory and its application in electric power system fault detection[J]. Proceedings of the CSEE, 2005(5): 40-45.
- [20] 潘超, 陈祥, 蔡国伟, 等. 基于小波包尺度-能量占比的变压器三相不平衡绕组振动特征辨识[J]. 仪器仪表学报, 2020, 41(4): 129-137.
- PAN CH, CHEN X, CAI G W, et al. Identification of winding vibration characteristics of three-phase unbalanced transformer based on scale-energy ratio of wavelet packet [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 129-137.
- [21] HUANG G B, WANG D H, LAN Y. Extreme learning machine: A survey[J]. International Journal of Machine Learning & Cybernetics, 2011, 2(2): 107-122.
- [22] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.

作者简介



唐圣学(通信作者), 2001年于吉首大学获得学士学位, 2004年于湖南大学获硕士学位, 2008年于湖南大学获博士学位, 现为河北工业大学教授, 主要研究方向为电力电子技术、新能源发电技术。

E-mail: tsx@hebut.edu.cn

Tang Shengxue (Corresponding author) received his B. Sc. degree from Jishou University in 2001, received his M. Sc. degree from Hunan University in 2004, and received his Ph. D. degree from Hunan University in 2008. He is currently a professor at Hebei University of Technology. His main research interests include power electronics technology and new energy power generation technology.