

基于电流-振动特征自适应融合的 BWO-CNN-LSTM 断路器故障预测方法

李天汉^{1,2}, 李建兴^{1,2}, 杨秋玉^{1,2}, 许广坤^{1,2}

(1. 福建理工大学 电子电气与物理学院, 福建 福州 350118;

2. 福建省工业集中自动化行业技术开发基地, 福建 福州 350118)

摘要: 为了提高断路器故障预测结果的可靠性, 提出一种基于电流-振动信号特征自适应融合的 BWO-CNN-LSTM 故障预测方法。首先采用变分模态分解处理振动信号, 提取能量熵、样本熵和散布熵等特征; 同时提取线圈电流信号的关键特征, 通过特征自适应融合技术构建断路器完整动作过程的电流-振动联合信号特征集; 随后构建白鲸算法优化的 CNN-LSTM 故障预测模型, 对断路器的不同机械状态进行预测。与其他算法相比, BWO-CNN-LSTM 模型在故障预测准确率上显著提高, 有效解决了断路器故障预测中对人工经验过于依赖的问题。

关键词: 高压断路器; 自适应特征融合; 白鲸优化算法; CNN-LSTM; 故障预测

中图分类号: TM561

文献标志码: A

文章编号: 2097-3853(2025)03-0269-08

Adaptive fusion of current-vibration features based BWO-CNN-LSTM circuit breaker fault prediction approach

LI Tianhan^{1,2}, LI Jianxing^{1,2}, YANG Qiuyu^{1,2}, XU Guangkun^{1,2}

(1. School of Electronic, Electric Engineering and Physics, Fujian University of Technology, Fuzhou 350118, China;

2. Technical Development Base of Industrial Integration Automation of Fujian Province, Fuzhou 350118, China)

Abstract: In order to improve the reliability of circuit breaker fault prediction results, a BWO-CNN-LSTM fault prediction method based on adaptive fusion of current-vibration signal features is proposed. First, the vibration signal is processed by variational modal decomposition to extract features such as energy entropy, sample entropy and scatter entropy; and the key features of the coil current signal are also extracted, and the feature set of the current-vibration joint signal for the complete action process of the circuit breaker is constructed by feature adaptive fusion technology; subsequently, the CNN-LSTM fault prediction model optimized by the beluga whale optimization is constructed to predict the different mechanical states of the circuit breaker. Results show that compared with other algorithms, the BWO-CNN-LSTM model significantly improves the fault prediction accuracy, effectively solving the problem of manual experience dependence in circuit breaker fault prediction.

Keywords: high-voltage circuit breaker; adaptive feature fusion; beluga whale optimization; CNN-LSTM; fault prediction

高压断路器作为电力系统不可或缺的保护和控制设备, 在电网稳定安全运行中发挥着关键作用^[1]。根据国际大电网会议的报告, 约 70% 的断

路器故障源于机械问题^[2]。对高压断路器进行机械状态预测, 能够提前预测可能出现的机械故障, 从而避免事故的发生^[3]。

收稿日期: 2024-12-23

第一作者简介: 李天汉 (2000—), 男, 福建福州人, 硕士研究生, 研究方向: 断路器状态智能诊断、预测。

通信作者: 李建兴 (1968—), 男, 福建古田人, 教授, 硕士, 研究方向: 电力装备状态诊断、分布式控制、集成自动化、智能控制、机器视觉等。

近年来,专家学者提出了多种电力设备故障预测方法。高学金等^[4]利用随机森林算法筛选故障相关特征,实现实时故障状态预测。朱伏平等^[5]提出了基于信息融合技术的滚动轴承故障预测方法,显著提高了故障检测精度。Zheng 等^[6]通过计算关键机械特性参数并结合支持向量机模型,实现了机械状态的预测。

然而,上述故障预测方法主要依赖单一信息源的数据,在机械状态检测上缺乏综合性,易受环境干扰和噪声影响。综合不同来源的信息进行深入分析,不仅可以降低单个信息源的未知性,还可以增强识别系统的容错能力和自适应性,做出更准确的识别判断^[7-8]。张雅晖等^[9]基于定子电流和振动信号的频谱特点进行融合,引入一种基于小波包能量分析与信号融合的异步电机转子故障检测技术。Shi 等^[10]提出一种特征加权自适应融合多传感器信息的故障诊断方法,有效解决了故障信息的不足和冗余问题。为了更准确地检测电力设备状态,诸多混合模型还融合了集成学习、数据预处理技术以及元启发式算法^[11]。张荣升等^[12]提出了一种基于阈值反馈改进蝠鲼觅食优化算法的多电源配电网故障定位方法。万书亭等^[13]结合变分模态分解算法和支持向量机,对不同状态下的断路器进行模式识别。为了优化集成模型的权重和阈值,学者们还采用了多种启发式算法,包括灰狼算法(grey wolf optimizer, GWO)以及粒子群算法(particle swarm optimization, PSO)等。相比其他优化算法,白鲸优化算法(beluga whale optimization, BWO)展现了卓越的全局搜索性能、更强的稳定性和更高的收敛精度^[14]。

综上,本研究结合特征自适应融合技术、白鲸优化算法和 CNN-LSTM 神经网络,提出一种基于特征自适应融合技术的高压断路器机械状态预测方法。

1 理论基础

1.1 白鲸优化算法(BWO)

假设鲸类种群为 D , 同时扩展至 b 维, 第 d 只鲸类在 b 维空间中的搜索代理位置可表示为 $Z_d = [z_{d,1}, z_{d,2}, \dots, z_{d,b}]$ 。平衡因子 β_t 在全局搜索和局部搜索的转换中有决定性作用。该过程可以定义为:

$$\beta_t = \beta_0 (1 - \varepsilon / 2\varepsilon_{\max}) \quad (1)$$

式中, ε 为当前迭代次数; $\varepsilon_{\max}$ 为最大迭代次数; β_t 在 $(0 \sim 1)$ 区间随机变化。当平衡因子 β_t 大于 0.5 时, 种群中的每个个体进入全局搜索阶段, 否则进入局部搜索阶段。随着 T 的增加, β_t 的取值范围从 $(0, 1)$ 缩至 $(0, 0.5)$ 。

1.1.1 全局搜索阶段

BWO 基于白鲸的游泳行为更新白鲸的位置, 该过程可表示为:

$$\begin{cases} Z_{d,a}^{\varepsilon+1} = Z_{d,p_a}^{\varepsilon} + (Z_{r,p_1}^{\varepsilon} - Z_{d,p_a}^{\varepsilon}) (1 + r_1) \sin(2\pi r_2), \\ a = 2, 4, 6, \dots \\ Z_{d,a}^{\varepsilon+1} = Z_{d,p_a}^{\varepsilon} + (Z_{r,p_1}^{\varepsilon} - Z_{d,p_a}^{\varepsilon}) (1 + r_1) \cos(2\pi r_2), \\ a = 1, 3, 5, \dots \end{cases} \quad (2)$$

式中, $Z_{d,a}^{\varepsilon+1}$ 为第 $\varepsilon+1$ 次迭代时第 d 个白鲸在第 a 个维度的新位置; Z_{d,p_a}^{ε} 为白鲸中随机个体在 p_a 维度上的位置; Z_{r,p_1}^{ε} 表示从种群中随机选取的第 r 条白鲸; p_a 为 a 维中的随机维度; r_1 与 r_2 为 $(0, 1)$ 之间的随机数。

1.1.2 局部搜索阶段

在 BWO 的开发阶段引入莱维飞行以提升其收敛性, 可表示:

$$Z_d^{\varepsilon+1} = r_3 Z_{\text{best}}^{\varepsilon} - r_4 Z_d^{\varepsilon} + c_1 L_F (Z_r^{\varepsilon} - Z_d^{\varepsilon}) \quad (3)$$

式中, Z_r^{ε} 和 Z_d^{ε} 分别是随机白鲸和第 d 条白鲸的当前位置; $Z_d^{\varepsilon+1}$ 是第 d 条白鲸的新位置; $Z_{\text{best}}^{\varepsilon}$ 表示种群中的最佳个体; r_3 和 r_4 代表 $(0 \sim 1)$ 区间的随机数值; c_1 用于衡量随机跳跃强度。 L_F 为 Levy 飞行函数, 其计算公式为:

$$L_F = 0.05 (\vartheta \sigma / |v|^{1/\xi}) \quad (4)$$

其中, σ 为中间变量, 满足:

$$\sigma = \left(\frac{\Gamma(1+\beta) \times \sin(\pi\beta/2)}{\Gamma((1+\beta)/2) \times \beta \times 2^{(\beta-1)/2}} \right)^{1/\beta} \quad (5)$$

式中, Γ 是 Gamma 函数; ϑ 和 v 为满足正态分布的随机数, β 是常数, 取 1.5 ^[14]。

1.1.3 鲸落阶段

BWO 模拟了白鲸种群在鲸落过程中的行为模式, 以展示种群中的微小变动。为确保白鲸种群规模的稳定性, 鲸落阶段的位置更新公式为:

$$Z_{d,a}^{\varepsilon+1} = r_5 Z_{d,a}^{\varepsilon} - r_6 Z_{r,a}^{\varepsilon} + r_7 Z_{\text{step}} \quad (6)$$

式中, r_5 , r_6 和 r_7 是 $(0, 1)$ 之间的随机数; Z_{step} 用来描述鲸鱼坠落时的步长, 表达式为:

$$Z_{\text{step}} = (u_b - l_b) \exp\left(\frac{-c_2 \varepsilon}{\varepsilon_{\max}}\right) \quad (7)$$

式中, u_b 和 l_b 分别是变量的上下限。步长因子为 $c_2 = 2DW_i$ 。模型中, 种群个体的鲸鱼坠落概率 W_i 为:

$$W_i = 0.1 - \frac{0.05\varepsilon}{\varepsilon_{\max}} \tag{8}$$

式中, 鲸落概率从最初的 0.1 降至最终的 0.05, 这表明当白鲸抵达食物来源时, 其遇到的危险减少了。

1.2 CNN-LSTM 混合神经网络

在卷积神经网络层 (CNN) 后连接长短期神经网络 (LSTM) 的深度学习模型融合了两种神经网络的优势, 不仅拥有 CNN 强大的自主提炼抽象数据的能力, 同时具备了 LSTM 神经网络的长期记忆特性。

1.2.1 卷积神经网络

CNN 是一种深度学习模型, 包括输入层、卷积层、池化层、全连接层和输出层 5 个部分。卷积层是 CNN 的核心层, 其参数由可学习的滤波器集合构成, 主要用于特征提取。其数学表达式为:^[15]

$$u_j = f(x_i + b_i) \tag{9}$$

式中, u_j 为输出; $f(\cdot)$ 为 ReLU 函数; x_i 为输出; b_i 为偏置项。

在连续卷积层之间通常会定期插入池化层, 目的是减小特征数据的空间维度, 从而降低计算资源消耗, 并有效防止过拟合。其表达式为:

$$u_j = f(\beta_i \cdot \vartheta + b_i) \tag{10}$$

式中, β_i 为网络偏置, ϑ 为子采样函数。

全连接层用于对经过多层卷积和池化处理的特征进行分类。它根据各神经元的权重比例进行反馈, 最终通过优化权重和调整网络结构输出分

类结果。

1.2.2 长短期神经网络

长短期神经网络 (LSTM) 可解决传统 RNN 在反向传播环境中遇到的梯度消失以及爆炸的问题, 它引入了遗忘门、输入门、输出门和控制着细胞元状态, 目前在循环神经网络中广泛使用的架构^[16]。如式 (10) ~ (15) 所示。

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \tag{11}$$

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \tag{12}$$

$$\tilde{C}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \tag{13}$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \tag{14}$$

$$O_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \tag{15}$$

$$h_t = O_t \times \tanh(C_t) \tag{16}$$

式中, f_t 代表遗忘门的输出信号; W_f 代表遗忘门权重矩阵; h_{t-1} 代表前一时刻输出状态; x_t 代表当前时刻输入状态; b_f 代表遗忘门偏置值; i_t 代表输入门的输出信号; b_i 代表输入门偏置值; W_c 代表细胞状态权重矩阵; b_c 代表细胞状态偏置值; $\tilde{C}_t$ 代表候选细胞状态; C_t 代表当前时刻细胞状态; C_{t-1} 代表前一时刻细胞状态; O_t 代表输出门的输出信号; W_o 代表输出门权重矩阵; b_o 代表输出门偏置值; h_t 代表神经元细胞输出值。

2 融合电流-振动信号特征的 BWO-CNN-LSTM 故障预测方法

2.1 故障预测流程

基于 BWO-CNN-LSTM 和特征自适应融合技术的高压断路器故障预测流程的主要步骤如图 1 所示。




图 1 基于 BWO-CNN-LSTM 的高压断路器故障预测流程图

Fig.1 Flowchart of high-voltage circuit breaker fault prediction based on BWO-CNN-LSTM

2.2 振动信号特征提取

2.2.1 振动信号预处理

为了获取高压断路器在不同状态下的振动特征,首先需要对采集到的振动信号进行降噪处理。本研究采用自适应降噪方法消除振动信号中的噪声,同时保留信号的主要成分,不会引入额外的畸变,从而保持信号的原始特征^[17]。以正常分闸振动信号数据为例进行处理,波形如图 2 所示。




图 2 原始的振动信号波形图

Fig.2 Waveform of the original vibration signal

采用自适应阈值去噪算法对信号进行降噪处理,保留了更纯净的振动信号,振动信号波形如图 3 所示。




图 3 自适应阈值去噪法降噪效果图

Fig.3 Noise reduction effect diagram of adaptive threshold denoising method

2.2.2 特征熵提取

在故障诊断中,以能量熵、样本熵和散布熵作为特征向量,能够有效表征信号的复杂性和变化特性。本研究以高压断路器的正常分闸振动信号为例,通过变分模态分解 (variational mode decomposition, VMD) 算法提取这些熵值特征,从而提高故障识别的准确性^[18]。

首先,对振动信号实施了自适应阈值去噪处理,以消除噪声干扰。通过 VMD 处理的振动信号获得 6 个本征模态函数 (intrinsic mode functions, IMF)。对所有 IMF 分量都进行了 Hilbert 变换,并计算出 Hilbert 边际谱。接着,提取每个 IMF 分量的 Hilbert 边际谱能量熵, IMF Hilbert 边际谱的能量熵经过处理之后展现了显著的差异性,其冗余度相对较低。能量熵是一种衡量信号能量分布均匀性的指标,将这些能量熵

作为故障的特征量,能更精确地揭示高压断路器的机械状态。

将去噪后的振动信号进行 VMD 分解,得到 6 个 IMF 分量,分别计算每个 IMF 分量的样本熵,构建断路器故障特征向量。样本熵是一种用于度量时间序列复杂性的新型方法,能够有效解决近似熵算法中自身匹配引起的偏差问题,准确反映振动信号的复杂性和机械状态信息。

对去噪后的振动信号进行 VMD 分解,得到 6 个 IMF 分量,分别计算每个 IMF 分量的散布熵,构建用于故障预测的特征向量集。散布熵是一种描述时间序列不规则程度的物理量,可以更全面地描述信号的复杂性和变化特性。

2.3 线圈电流信号特征提取

分闸或合闸线圈的电流信号具有多峰特性,能够提供丰富的信息^[19],可以反映断路器在执行分闸或合闸操作时的动态行为及其机械特性。由于线圈电流信号中存在高频干扰,本研究采用 5 点 3 次平滑法对电流信号进行去噪处理,可以有效滤除高频噪声,使信号的主要特征更加明显。先确定电流波形的起始点 t_0 和终止点 t_7 ,再确定 $t_1 \sim t_6$,并获取相应的电流数值,从而确定电流波形的全部特征,去噪后提取的分 (合) 闸线圈电流波形如图 4 所示。




图 4 分 (合) 闸线圈电流波形

Fig.4 Split (close) coil current waveforms

在每个分合闸动作周期内,从线圈电流信号中按顺序提取了 6 个时间参数 $t_2, t_3, t_4, t_5, t_6, t_7$ 和 5 个电流参数 I_1, I_2, I_3, I_4, I_5 。对线圈电流信号进行综合分析后,构建了一个 11 维多源特征量 $T = [t_2, t_3, t_4, t_5, t_6, t_7, I_1, I_2, I_3, I_4, I_5]$ 作为线圈电流信号的特征描述。这些特征可以全面反映线圈电流波形的特性,为后续的故障预测提供了重要的依据。

2.4 特征自适应融合

本研究分别提取电流信号和振动信号特征,通过特征自适应加权融合技术,形成融合特征集,为系统提供更全面的分析视角,从而准确识别机械状态的各个类型。

高压断路器的多信号融合的特征集可以表示为 $F=(F_1,F_2)$,其中, F_1,F_2 分别表示电流信号特征矩阵、振动信号特征矩阵。假设样本容量为 m ,特征维度为 l 。设电流信号特征空间中的特征维度为 x ,振动信号特征空间中的特征维度为 y ,各特征矩阵可表示为:

$$F_1=(f_{11},f_{12},\cdots,f_{1x})\in R^{m\times x} \tag{17}$$

$$F_2=(f_{21},f_{22},\cdots,f_{2y})\in R^{m\times y} \tag{18}$$

式中,各个特征集内特征维度 x,y 的总和即等于特征维度 l ,即 $F=(F_1,F_2)$ 。

本研究共提取了 11 个电流信号特征,15 个振动信号特征,采用基于相似度的特征自适应融合技术以提高特征集的识别度。

皮尔逊(Pearson)相关系数常被用于评估特征时间序列间关联性,在相似性度量中应用广泛^[20]。本研究选用 Pearson 相关系数 R 计算各个特征向量 x_i 与高压断路器机械状态类型之间的相似度,如式(19)所示。

$$R=\frac{\sum_{i=1}^N(x_i-\bar{x})(y_i-\bar{y})}{\left[\sum_{i=1}^N(x_i-\bar{x})^2\sum_{i=1}^N(y_i-\bar{y})^2\right]^{1/2}} \tag{19}$$

式中, $\bar{x}$ 为 $\{x_0^i\}_{i=1:N}$ 的均值, $\bar{y}$ 为 $\{y_0^i\}_{i=1:N}$ 的均值, N 表示各种状态下数据样本的长度,机械状态类型标签 $y=[y_1,y_2,\cdots,y_i]$,其中 $y_i=[1,2,\cdots,i]$, y_i 表示具有长度为 l 的矩阵向量, l 代表数据样本的数量。

提取巡检集数据样本的电流信号及振动信号的特征集 $M*N$, M 为样本个数, N 为特征类型个数;分别提取每一类特征的特征向量 $M*l$,并构建样本标签 y ;对特征向量及样本标签进行归一化处理,表达式为:

$$X_{\text{nom}}=\frac{X-X_{\min}}{X_{\max}-X_{\min}}\in[0,1] \tag{20}$$

式中, X_{nom} 归一化后的数据, X 原始样本数据, $X_{\min}$ 为样本数据最小值, $X_{\max}$ 为样本数据最大值。

计算特征向量和样本标签的相关系数,得到所有特征的相关系数矩阵 D ;对相关系数进行权

重转换,得到权重系数 Q ,表达式为:

$$Q=D/\text{sum}(D) \tag{21}$$

对特征进行加权处理,得到融合特征,可表示为:

$$A=F*Q \tag{22}$$

依次拼接融合特征分量即可以得到各信号融合特征分量矩阵,可表示为:

$$A_1=F_1*Q=(a_1,a_2,\cdots,a_x)\in D^{m\times j} \tag{23}$$

$$A_2=F_2*Q=(a_{x+1},a_{x+2},\cdots,a_y)\in D^{m\times j} \tag{24}$$

式中, A_1 为电流信号融合特征分量矩阵, A_2 为振动信号融合特征分量矩阵。

由此得到多信号融合特征矩阵,表示为:

$$A=(A_1,A_2)\in D^{m\times l} \tag{25}$$

2.5 BWO-CNN-LSTM 神经网络建模

在使用 CNN-LSTM 模型对不同机状态的数据进行故障预测时,需要设置好合适的模型参数。为此,本研究采用 BWO 对 CNN-LSTM 故障预测模型进行组合参数寻优。首先,将实验数据划分为训练集和测试集,并进行数据归一化处理,训练集和测试集的比例为 8:2。接着,设定好种群数量 n 、最大迭代次数 $T_{\max}$ 等初始参数。然后,设置适应度函数。选择训练集识别率作为 BWO 优化 CNN-LSTM 超参数的适应度函数,利用 BWO 优化算法对 CNN-LSTM 故障预测模型的最佳参数进行寻优。循环迭代直到满足终止条件,输出 CNN-LSTM 故障预测模型的最佳参数。

经过 BWO 算法参数寻优后模型参数如表 1 所示。将最佳参数组合代入 CNN-LSTM 故障预测模型中。

表 1 CNN-LSTM 模型参数
Tab.1 CNN-LSTM model parameters

编号	网络层	卷积核尺寸/步长	激活函数
1	卷积层	16×16	ReLU
2	池化层	16×1	ReLU
3	Flatten 层	—	—
4	Lstm	100	Tanh
5	dropout 层	0.25	—
6	全链接层	4	ReLU
7	输出层	—	softmax

本研究通过 BWO 算法优化参数后,构建

BWO-CNN-LSTM 模型用于故障预测。在 CNN 部分,该模型由两个卷积层和两个最大池化层组成,激活函数采用 Relu 函数;在 LSTM 部分,采用两层 LSTM 网络堆叠。图 5 为本研究提出的 BWO-CNN-LSTM 预测模型。




图 5 BWO-CNN-LSTM 流程

Fig.5 BWO-CNN-LSTM flow

3 结果分析与对比

3.1 实验平台和数据描述

线圈电流信号常用于监测高压断路器的电气操作状态和故障检测,而振动信号则用于评估其机械运行状态,在断路器机械状态检测中具有重要参考价值。本研究选取了 VS1-12 型高压断路器作为研究对象进行了实例分析并采集测试数据。高压断路器的数据采集系统由电源模块、信号采集模块、控制模块和电脑组成。在数据采集的过程中,采样率设置为 128 kHz,采样时间为 300 ms,实验平台如图 6 所示。



图 6 实验平台

Fig.6 Experimental platform

本研究分别采集了 8 种机械状态下的振动信号和电流信号,包括正常分闸状态、分闸线圈铁心

轻度卡涩、分闸线圈铁心中度卡涩、分闸线圈铁心重度卡涩、正常合闸状态、合闸弹簧轻度疲劳、合闸弹簧中度疲劳和合闸弹簧重度疲劳,每种状态下均采集了 50 个样本,共计 400 个样本。结果如表 2 所示。考虑到实验的安全性和可行性,在与 HVCB 制造商的技术人员充分讨论后,本研究对高压断路器的故障情况进行了模拟。

表 2 高压断路器机械状态数据集

Tab.2 Mechanical condition data set of high-voltage circuit breaker

标签	机械状态类型	状态描述
F1	正常分闸	正常状态
F2	分闸线圈铁芯轻度卡涩	一个 100 g 重物被悬挂在分闸线圈的铁芯之下
F3	分闸线圈铁芯中度卡涩	一个 200 g 重物被悬挂在分闸线圈的铁芯之下
F4	分闸线圈铁芯重度卡涩	一个 300 g 重物被悬挂在分闸线圈的铁芯之下
F5	正常合闸	正常状态
F6	合闸弹簧轻度疲劳	将合闸弹簧的预储存能量的长度增加 135 mm
F7	合闸弹簧中度疲劳	将合闸弹簧的预储存能量的长度增加 138 mm
F8	合闸弹簧重度疲劳	将合闸弹簧的预储存能量的长度增加 141 mm

本实验以采集到的 4 种状态(正常分闸、分闸线圈铁心中度卡涩、正常合闸以及合闸弹簧中度疲劳)的时域振动信号为示例,如图 7 所示。

由图 7 可以看出,当高压断路器发生合闸弹簧疲劳故障时,振动幅度振幅变化较大,表明弹簧的弹性减弱;当发生分闸线圈铁芯中度卡涩故障时,振幅逐渐减小,这表明分闸线圈的铁芯卡涩问题,引发了间歇性的机械卡滞现象。尽管不同工况下的振动信号在时域上的幅值和波形存在差异,但这些特征并不足以精确区分高压断路器的工作状态。因此,需要进一步分析信号,以便挖掘更具区分度的故障特征。




图 7 高压断路器 4 种工况振动信号时域图

Fig.7 Time-domain diagrams of vibration signals for four operating conditions of high-voltage circuit breakers

3.2 不同优化算法的预测结果分析

本研究将采用组合预测模型,针对正常分闸状态、分闸线圈铁芯不同程度卡涩(轻度、中度、重度)、正常合闸状态以及合闸弹簧不同程度疲劳(轻度、中度、重度)的训练集数据进行学习。随后,选取了剩余 80 组数据作为测试样本,其中每种机械状态各 10 组,输入至 BWO-CNN-LSTM 预测模型中。

为了全面验证 BWO-CNN-LSTM 组合预测模型的性能和可靠性,将 BWO-CNN-LSTM 模型的预测结果与另外两种组合预测模型 GWO-CNN-LSTM 和 PSO-CNN-LSTM 的预测结果进行了详细比较。通过图 8 可以直观地看到各模型在不同机械状态下的预测性能表现。

实验结果显示,BWO-CNN-LSTM 模型的平均预测准确率卓越,达到了 97.5%,明显优于采用 GWO-CNN-LSTM 和 PSO-CNN-LSTM 的模型。说

明 BWO-CNN-LSTM 模型在预测高压断路器故障方面的精确度和可靠性更高。分析不同优化算法对模型性能的深刻影响。




图 8 不同组合模型的预测精度对比

Fig.8 Comparison of prediction accuracy of different combination models

3.3 联合电流-振动信号与单信号的对比分析

电流信号特征和振动信号特征是描述断路器运行情况和机械状态的重要参数。电流信号特征能够反映断路器脱扣阶段的状态信息,而振动信号特征则能够反映断路器操动阶段的状态信息。本研究通过特征自适应加权融合技术,将两种信号特征进行有机融合,可以提取出更为准确和全面的特征信息,从而提高故障预测的准确性和可靠性。

为了验证振动信号和电流信号特征联合使用的必要性,本研究对单一电流信号特征、单一振动信号特征以及联合电流和振动信号特征 3 种不同情况下的故障预测准确率进行了测试比较。通过实验分别评估了单独使用电流信号和振动信号时的故障预测准确率,以及将两者结合后的故障预测效果。实验结果显示,单一电流信号和单一振动信号在故障预测中的准确率分别达到了 87.5% 和 90%,联合使用电流和振动信号特征的方法准确率达到 97.5%。与传统特征融合方法相比,联合使用电流和振动信号特征的方法能自适应调整特征权重,优化特征集并考虑互补性与冗余性。传统方法采用固定权重,处理复杂问题效果差,而自适应加权融合可动态调整特征关系,提升模型在非线性、非平稳振动信号中的性能与鲁棒性。

4 结论

为提高断路器故障预测的性能,本研究提出了一种基于特征自适应加权融合技术与 BWO-CNN-LSTM 模型的故障预测方法,所得结论如下:

1)针对高压断路器的振动信号和线圈电流

信号,分别采用不同的特征提取方法,通过基于相关系数的特征自适应加权融合技术,构成多信号融合特征矩阵,降低了特征复杂度,有效地融合了多个信号的信息。

2) 在故障预测方面,本研究引入了 BWO-CNN-LSTM 机械状态预测模型,通过白鲸优化算法对模型进行优化,并将其应用于状态预测中。结果显示,相比于传统的 PSO 算法和 GWO 算法,

BWO-CNN-LSTM 模型在故障预测的准确性和可靠性上表现更优。

3) 将电流信号与振动信号联合特征向量的预测效果进行了对比分析。结果显示,联合电流-振动特征向量的预测精度显著高于单一信号特征向量,说明将多个信号进行联合可以更全面地反映机械设备的运行状态,提高了故障预测的准确性和可靠性。

参考文献:

- [1] LI X F, ZHENG X Y, ZHANG T, et al. Robust fault diagnosis of a high-voltage circuit breaker via an ensemble echo state network with evidence fusion[J]. *Complex & Intelligent Systems*, 2023, 9(5): 5991-6007.
- [2] JANSSEN A, MAKAREINIS D, SOLVER C E. International surveys on circuit-breaker reliability data for substation and system studies[J]. *IEEE Transactions on Power Delivery*, 2014, 29(2): 808-814.
- [3] FLETCHER P L. A summary of the final results and conclusions of the second international enquiry on the reliability of high voltage circuit - breakers [C] // Second International Conference on the Reliability of Transmission and Distribution Equipment. Coventry, UK: IEE, 1995: 24-30.
- [4] 高学金, 马东阳, 韩华云, 等. 基于 DAE 和 TCN 的复杂工业过程故障预测[J]. *仪器仪表学报*, 2021, 42(6): 140-151.
- [5] 朱伏平, 秦琴, 杨方燕, 等. 基于信息融合技术的滚动轴承故障预测方法[J]. *机械设计*, 2023, 40(1): 56-64.
- [6] ZHENG X G, LI J X, YANG Q Y, et al. Prediction method of mechanical state of high-voltage circuit breakers based on LSTM-SVM[J]. *Electric Power Systems Research*, 2023, 218: 109224.
- [7] ZHANG Q, ZHANG H Y, LU X W. Adaptive feature fusion for small object detection[J]. *Applied Sciences*, 2022, 12(22): 11854.
- [8] WANG C, PENG G H, DE BAETS B. Deep feature fusion through adaptive discriminative metric learning for scene recognition[J]. *Information Fusion*, 2020, 63: 1-12.
- [9] 张雅晖, 杨凯, 杨帆. 基于小波包能量分析和信号融合的异步电机转子故障诊断[J]. *电测与仪表*, 2024, 61(4): 161-168.
- [10] SHI J C, REN Y, TANG H S, et al. Hydraulic directional valve fault diagnosis using a weighted adaptive fusion of multi-dimensional features of a multi-sensor[J]. *Journal of Zhejiang University: Science A*, 2022, 23(4): 257-271.
- [11] TIAN H, FAN H C, FENG M W, et al. Fault diagnosis of rolling bearing based on HPSO algorithm optimized CNN-LSTM neural network[J]. *Sensors*, 2023, 23(14): 6508.
- [12] 张荣升, 刘丽桑, 徐辉, 等. 改进蝠鲼觅食优化算法的配电网故障定位[J]. *福建工程学院学报*, 2022, 20(3): 267-274.
- [13] 万书亭, 马晓棣, 豆龙江, 等. 基于 VMD-MSE 的高压断路器故障诊断[J]. *中国工程机械学报*, 2019, 17(5): 444-449.
- [14] ZHONG C T, LI G, MENG Z. Beluga whale optimization: a novel nature-inspired metaheuristic algorithm[J]. *Knowledge-Based Systems*, 2022, 251: 109215.
- [15] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. *计算机学报*, 2017, 40(6): 1229-1251.
- [16] 胡任远, 刘建华, 王璇, 等. 引入双循环机制深度学习模型的文本情感分析[J]. *福建工程学院学报*, 2022, 20(4): 383-390.
- [17] 杨秋玉, 阮江军, 庄志坚, 等. 高压断路器机械振动信号的参数自适应降噪方法[J]. *高电压技术*, 2021, 47(12): 4274-4287.
- [18] 杨秋玉, 阮江军, 黄道春, 等. 基于 VMD-Hilbert 边际谱能量熵和 SVM 的高压断路器机械故障诊断[J]. *电机与控制学报*, 2020, 24(3): 11-19.
- [19] RUDSARI F N, RAZI-KAZEMI A A, SHOOREHDELI M A. Fault analysis of high-voltage circuit breakers based on coil current and contact travel waveforms through modified SVM classifier[J]. *IEEE Transactions on Power Delivery*, 2019, 34(4): 1608-1618.
- [20] 聂磊, 张吕凡, 徐诗奕, 等. 基于相似度特征融合和 CNN 的滚动轴承剩余寿命预测[J]. *噪声与振动控制*, 2023, 43(5): 115-121.