

DOI: 10.19783/j.cnki.pspc.241486

基于 IRIME-BP-LSTM 模型的继电保护装置剩余寿命预测方法

张洪嘉, 戴志辉, 贺欲飞, 贾文超

(河北省分布式储能与微网重点实验室(华北电力大学), 河北 保定 071003)

摘要: 目前继电保护装置寿命预测理论中存在缺少对单个装置状态准确评估预测、预测数据无法根据实际运行情况及时修正等问题, 导致预测结果不可靠。对此, 提出基于改进霜冰优化算法(improved rime optimization algorithm, IRIME)优化反向传播(backpropagation, BP)神经网络与长短期记忆网络(long short memory network, LSTM)模型的继电保护装置剩余寿命预测方法。首先, 总结运维经验与规程要求, 建立保护装置状态评估指标集, 形成初始输入向量。其次, 引入柯西变异机制改进霜冰优化算法, 利用 IRIME 对 BP 神经网络初始参数进行优化。然后, 将初始输入向量赋予优化后的神经网络, 进行保护装置状态评估, 形成装置运行状态的表征向量并构建时间序列。最后, 将构建的时间序列输入到 LSTM 网络中进行保护装置剩余寿命的预测。案例验证结果表明, 该方法在保护装置剩余寿命预测上具有更高的准确度, 可以为保护装置检修运维工作提供理论指导。

关键词: 继电保护装置; 剩余寿命预测; 状态评估; 改进霜冰优化算法; 长短期记忆网络

Remaining useful life prediction method for relay protection devices based on IRIME-BP-LSTM model

ZHANG Hongjia, DAI Zhihui, HE Yufei, JIA Wenchao

(Hebei Key Laboratory of Distributed Energy Storage and Microgrid (North China Electric Power University), Baoding 071003, China)

Abstract: Current methods for predicting the remaining useful life of relay protection device suffer from issues such as the lack of accurate assessment and prediction for individual device states, and the inability to timely correct prediction data according to actual operating conditions, resulting in unreliable prediction results. To address this, a method for predicting the remaining useful life of relay protection devices based on the IRIME-BP-LSTM model is proposed. First, operational experience and procedural requirements are summarized to establish a set of state assessment indicators for protection devices, forming the initial input vector. Then, the Cauchy mutation strategy is introduced to improve the rime optimization algorithm, which is used to optimize the initial parameters of the backpropagation (BP) neural network. Next, the initial input vector is assigned to the optimized neural network to assess the condition of the protection device, forming a representation vector of the device's operating state and constructing a time series. Finally, the constructed time series is fed to the long short-term memory (LSTM) network for predicting the remaining useful life of the protection device. Case study results show that the proposed method has higher accuracy in predicting the remaining useful life of protection devices and can provide theoretical guidance for relay maintenance and operation decision-making.

This work is supported by the National Natural Science Foundation of China (No. 51877084).

Key words: relay protection device; remaining useful life prediction; state assessment; improved rime optimization algorithm; long short-term memory

0 引言

随着新一代变电站与智能变电站的推广普及,

电网整体向着智能化、数字化方向发展, 对电力供应的质量和稳定性有了更高的要求, 继电保护装置安全可靠运行也成为重要议题^[1-3]。

为了保证保护装置安全可靠运行, 同时减少因检修导致的停机时间和频率, 需要尽可能地判断保

基金项目: 国家自然科学基金项目资助(51877084)

护装置何时进入故障高发期，在故障高发期来临之前停止使用并进行预防性维修^[4-6]。

确保继电保护装置的稳定运行，不仅要进行状态评估监测，实时准确地掌握装置工作状况，还要对装置的运行寿命进行预测，在装置进入故障高发期之前进行检修或停止运行，以确保装置的长期可靠性^[7-9]。文献[10]在 Weibull 分布的基础上设计了基于对数正态(log normal, LN)分布的寿命模型，使装置的预估寿命更加接近实际值，该方法基于二参数的 LN 分布，缺少对单个装置运行状态的准确描述。文献[11]利用 3 种智能算法对无监测设备的剩余寿命进行预测，缺少对设备状态评估的过程。文献[12]采用相对熵对特征量进行赋权分析，构建评估框架并形成时间序列，该方法可能受到人为主观判断的影响，进而影响赋权的合理性以及评估的准确性。文献[13]提出了一种基于马尔可夫链的保护装置剩余寿命预测方法，实现对剩余寿命的有效预测，但是在选择装置运行状态的指标时只考虑了温度与光强数据，指标描述不够全面。文献[14]在文献[13]的基础上通过云模型的隶属度函数来建立初始状态向量，依据马尔可夫链原理实现保护装置有效寿命，但是马尔可夫链原理不能在环境发生变化时对装置的运行状态进行有效跟踪，无法实现预测结果跟随实际情况进行修正；同时在利用云模型算法进行保护装置状态评估时，较为依赖历史数据的质量与数量，当异常状态样本过少时，可能会影响状态评估的准确度。

针对上述问题，本文利用改进霜冰优化算法(improved rime optimization algorithm, IRIME)提高反向传播神经网络(backpropagation neural network, BP)与长短期记忆网络(long short memory network, LSTM)的性能，形成基于“状态评估+时间序列预测”逻辑的继电保护装置剩余寿命预测方法。通过 IRIME 算法对 BP 神经网络初始参数进行优化，赋予神经网络最佳初始参数；同时构建保护装置状态评估指标集，通过 IRIME-BP 神经网络对指标集数据进行状态评估，形成保护装置的状态表征向量并构建表征向量的时间序列；最后通过 LSTM 对时间序列进行预测，完成对继电保护装置剩余寿命的预测。通过某供电公司保护装置历史状态数据库中的数据进行分析，结果表明本文提出的基于 IRIME-BP-LSTM 模型的预测方法可以对保护装置的运行状态进行准确地评估与预测，并实现预测数据的及时修正。

1 继电保护装置运行状态分析

1.1 保护装置状态评估指标集

指标集能否准确完整获取决定着模型评估的准确与否。因此，本文在考虑指标获取的全面性与可行性的情况下，建立保护装置状态评估指标集。根据 Q/GDW 10395-2022《电力系统继电保护及安全自动装置运行评价规程》^[15]和 Q/GDW 11285-2022《继电保护状态评价导则》^[16]的规范要求，本文从检修指标和实时运行指标两个维度建立保护装置状态评估指标集。同时，考虑到指标更新不及时导致数据不完整不准确的情况，本文选取最近一次记录的相关指标数据并在进行状态评估的过程中赋予其较低的权重，保证状态评估的准确性。

对于检修指标，需考虑评价保护装置历史功能的数据、保护装置整体性能数据以及装置的运行时间；对于实时运行指标，选取最能体现继电保护装置状态的电源模块、光通信模块和中央处理器作为分析对象^[17]。

通过对保护装置状态评估指标集理论与运维经验的梳理^[17-22]，本文建立如图 1 所示的继电保护装置状态评估指标集，并以该指标集作为继电保护装置状态等级的评判依据。指标集中：检修指标包括家族缺陷率 x_1 、反措未落实情况 x_2 、绝缘性能 x_3 、不正确动作率 x_4 、设备故障次数 x_5 及装置运行时间 x_6 ；运行指标包括光口接收功率 x_7 、光口发送功率 x_8 、工作电压 x_9 、装置工作温度 x_{10} 、断路器不动作次数 x_{11} 、异常告警率 x_{12} 。将获取的 12 个指标数据构成初始输入向量 $\mathbf{x}=[x_1, x_2, \dots, x_{12}]$ 。

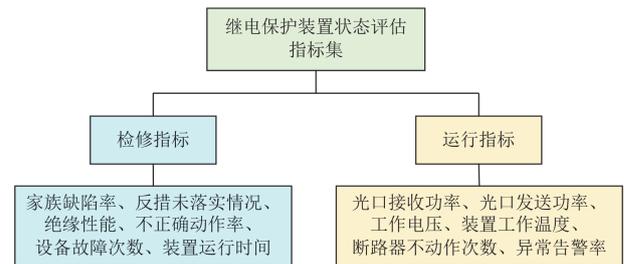


图 1 保护装置状态评估指标集

Fig. 1 Set of protective device condition assessment indicators

同时，根据上述规范要求，综合考虑实际情况对继电保护装置状态进行评估，可将继电保护装置状态分为“良好”、“正常”、“注意”、“异常”4 种等级并进行编码，如表 1 所示。其中： $\mathbf{Y}=[Y_1, Y_2, Y_3, Y_4]$ 为神经网络的输出向量，用来表示保护装置所处的状态等级，对应关系如表 1 所示。

表 1 状态等级及输出向量

Table 1 Status level and output vector

状态等级	状态代码	输出向量	等级编号
良好	G	[1 0 0 0]	1
正常	N	[0 1 0 0]	2
注意	W	[0 0 1 0]	3
异常	F	[0 0 0 1]	4

1.2 继电保护装置状态评估模型

通过对保护装置运行状态的及时监测与准确评估, 可以形成运行状态表征向量的时间序列, 为预测提供较为准确的数据支撑。目前在保护装置寿命预测的状态评估环节, 存在缺少评估过程、评估方法受人为主观因素干扰、启发算法易陷入局部最优解等问题, 影响评估结果的准确性, 进而影响后续时间序列预测的准确程度。针对上述问题, 本文在形成保护装置状态评估指标集的同时, 引入柯西变异机制改进霜冰优化算法, 提高算法跳出局部最优解的能力; 通过改进霜冰优化算法对 BP 神经网络的初始参数进行优化, 构建 IRIME-BP 神经网络模型, 利用指标集数据完成保护装置客观准确的状态评估。

1.2.1 改进霜冰优化算法

霜冰优化算法是 2023 年提出的一种智能算法, 该算法通过霜冰种群初始化、软霜搜索机制、硬霜穿刺机制和积极贪婪选择机制进行迭代, 具有较强的全局优化能力。霜冰优化算法流程为^[23-24]

霜冰种群初始化

$$\mathbf{R} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1j} \\ x_{21} & x_{22} & \dots & x_{2j} \\ \vdots & \vdots & & \vdots \\ x_{i1} & x_{i2} & \dots & x_{ij} \end{bmatrix} \quad (1)$$

式中: x_{ij} 为霜冰种群 \mathbf{R} 中的霜冰粒子。

软霜搜索机制

$$\mathbf{R}_{ij}^{\text{new}} = \mathbf{R}_{\text{best},j} + r_1 \cos \theta \cdot \beta [h \cdot (\mathbf{U}_{bij} - \mathbf{L}_{bij}) + \mathbf{L}_{bij}], r_2 < E \quad (2)$$

其中:

$$\theta = \frac{\pi T'}{10 \cdot T} \quad (3)$$

$$\beta = 1 - \left\lfloor \frac{wT'}{T} \right\rfloor / w \quad (4)$$

式中: $\mathbf{R}_{ij}^{\text{new}}$ 为更新后第 i 个霜冰体的第 j 个霜冰粒子的新位置; $\mathbf{R}_{\text{best},j}$ 为霜冰种群 \mathbf{R} 中最佳霜冰体第 j 个粒子的位置; r_1 为 $(-1,1)$ 范围内的随机数, 与 $\cos \theta$ 共同控制着粒子的扩散方向, 且 θ 会随着迭代次数

的增加而变化; β 为环境因素, 数学模型为阶跃函数; h 为附着度, 是 $(0,1)$ 内的随机数; \mathbf{U}_{bij} 、 \mathbf{L}_{bij} 分别为粒子逃逸空间的上、下界; r_2 为在 $(0,1)$ 范围内的一个随机数; E 为附着系数, r_2 与 E 共同控制霜冰粒子位置是否更新; T' 为当前迭代次数; T 为最大迭代次数; $\lfloor \cdot \rfloor$ 为向下取整函数; w 为用于控制阶梯函数的分段数量, 默认值为 5。

E 会随着迭代次数的增加而增大, 如式(5)所示。

$$E = \sqrt{T'/T} \quad (5)$$

硬霜穿刺机制如式(6)所示。

$$\mathbf{R}_{ij}^{\text{new}} = \mathbf{R}_{\text{best},j}, r_3 < F^{\text{normr}}(S_i) \quad (6)$$

式中: r_3 为 $(-1,1)$ 范围内的一个随机数; $F^{\text{normr}}(S_i)$ 为当前霜冰体适应度归一化的值, 表示第 i 个霜冰体被选中的概率。

算法原理如图 2 所示。

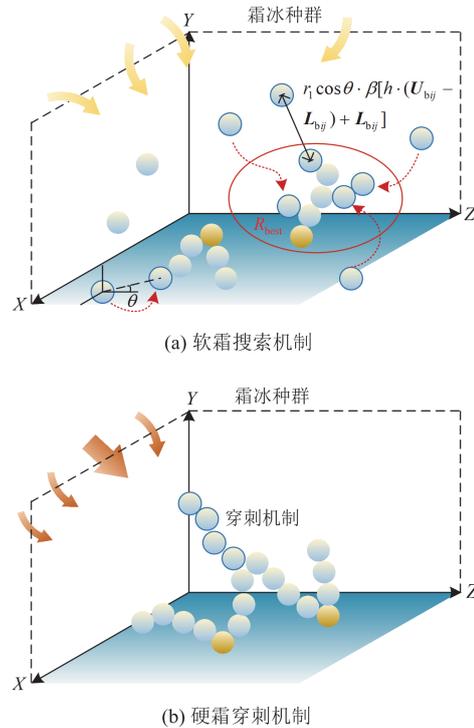


图 2 RIME 算法原理图

Fig. 2 RIME algorithm principle diagram

霜冰优化算法通过软霜搜索机制和硬霜穿刺机制实现霜冰体位置的更新。同时, 为防止算法在局部搜索阶段偏离目标值, 陷入局部最优的情况, 本文引入柯西变异机制改进霜冰优化算法, 将两次几乎没有差别的迭代结果作为历史最优值记录下来, 认为此时算法进入局部最优的情况, 此时利用柯西变异机制改变霜冰体的位置, 以更新最优值, 提高

算法收敛精度与稳定性。柯西分布如式(7)所示。

$$f(x; x_0, t_k) = \frac{t_k}{\pi[(x - x_0)^2 + t_k^2]}, -\infty < x < +\infty \quad (7)$$

式中: $f(x; x_0, t_k)$ 表示柯西概率密度函数; x_0 为定义分布峰值位置的位置参数; t_k 为最大值一半处的一半宽度的尺度参数, 当 $t_k = 1$ 、 $x_0 = 0$ 时称为标准柯西分布。

在最佳霜冰体的位置引入服从柯西分布的随机向量, 如(8)所示。

$$\mathbf{R}'_{\text{best},j} = \mathbf{R}_{\text{best},j} + \eta \mathbf{C}_{\text{auchy}}(1,0) \quad (8)$$

式中: $\mathbf{R}'_{\text{best},j}$ 为最佳霜冰体 $\mathbf{R}_{\text{best},j}$ 的变异位置; $\mathbf{C}_{\text{auchy}}(1,0)$ 为服从标准柯西分布的随机向量; η 为控制柯西变异机制强度的常数。

1.2.2 BP 神经网络

BP 神经网络是一种基于误差反向传播机制进行训练的多层前馈型神经网络^[25], 神经网络中各个神经元节点的输出如式(9)所示。

$$F_b = f\left(\sum_a w_{ab}x_a + \theta_b\right) \quad (9)$$

式中: F_b 为第 b 个神经元的输出; f 为激活函数, 通常采用 Sigmoid 函数; w_{ab} 为第 b 个神经元的 a 个输入权值; x_a 为第 b 个神经元的第 a 个输入; θ_b 为第 b 个神经元的阈值。

完整的 BP 神经网络模型通常由输入层、隐藏层和输出层 3 部分组成, 其核心原理是反向传播算法, 通过将输出的结果与期望的结果进行比较, 将比较计算后得到的误差反向传递至网络, 并运用梯度下降等优化技术来持续调节节点间的连接权重, 以达到减小误差、训练并优化网络的目的。减小误差的目标函数, 即损失函数 E_L 计算如式(10)所示。

$$E_L = \frac{1}{2} \sum_{b=1}^n (F_b - \hat{F}_b)^2 = \frac{1}{2} \sum_{b=1}^n [F_b - (wx_b + \theta_b)]^2 \quad (10)$$

式中: \hat{F}_b 表示预测输出; n 表示神经元个数。

1.2.3 IRIME-BP 神经网络模型

在单独使用 BP 神经网络时, 虽然可以满足分类功能的需求, 但由于 BP 神经网络的初始参数通常为随机赋值, 参数的优劣会直接影响神经网络训练时间的长短、收敛速度的快慢、是否容易陷入局部最优解。改进霜冰优化算法由于其独特机制, 能够快速准确地进行全局搜索并跳出局部最优的情况。因此, 本文采用改进霜冰优化算法对 BP 神经网络进行优化, 通过算法寻优找到最佳初始化参数, 将参数赋予 BP 神经网络后再进行反向传播优化训练。

1) 神经网络结构设置

本文选用 3 层神经网络进行计算, 即输入层、隐含层和输出层。输入层神经元个数即为指标集中指标的个数, 因此输入层神经元个数取 12; 输出层神经元个数取 4, 每个神经元的输出为保护装置在该状态等级的概率, 通过反归一化得到保护装置最终的状态等级; 最后根据经验式(11)确定隐含层神经元个数, 本文选取隐含层神经元个数为 14。BP 神经网络具体结构如图 3 所示。

$$m_{\text{HL}} = \sqrt{m_{\text{IL}} + m_{\text{OL}}} + \alpha \quad (11)$$

式中: m_{HL} 为隐含层神经元个数; m_{IL} 为输入层神经元个数; m_{OL} 为输出层神经元个数; α 为 [1,10] 的整数。

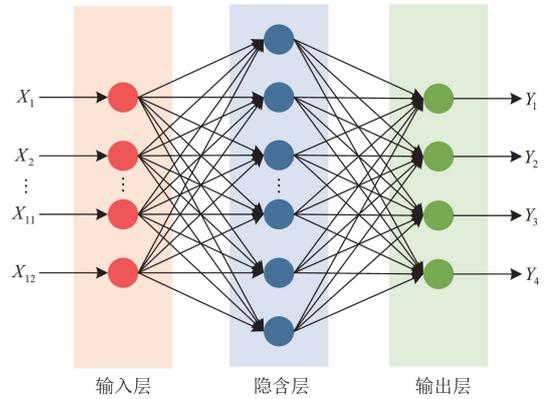


图 3 BP 神经网络结构

Fig. 3 BP neural network architecture

2) IRIME 算法优化 BP 神经网络初始参数

在确定了 BP 神经网络的拓扑结构之后, 将神经网络随机生成的初始权值和阈值输入改进霜冰优化算法, 通过算法机制计算霜冰个体的适应度并进行多次迭代, 得到最佳霜冰体位置, 将其位置信息解码得到的输出值作为最优初始权值 w_{best} 和最优阈值 θ_{best} 赋予神经网络, 进行后续的状态评估。模型具体流程如图 4 所示。

1.3 状态评估与时间序列的构建

将由 12 个指标归一化后形成的向量 $\mathbf{X} = [X_1, X_2, \dots, X_{12}]$ 作为输入向量输入到模型中, 进行保护装置的状态评估, 其中归一化处理如式(12)所示。

$$X_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, i = 1, 2, \dots, 12 \quad (12)$$

式中: x_i 为归一化前的指标数据; X_i 为归一化后的输入数据; x_{\max} 、 x_{\min} 分别为最大、最小指标数据。

由模型迭代训练后生成保护装置的状态表征向量 $\mathbf{P} = [P_1, P_2, P_3, P_4]$, 其中, P_2 表示保护装置处于状

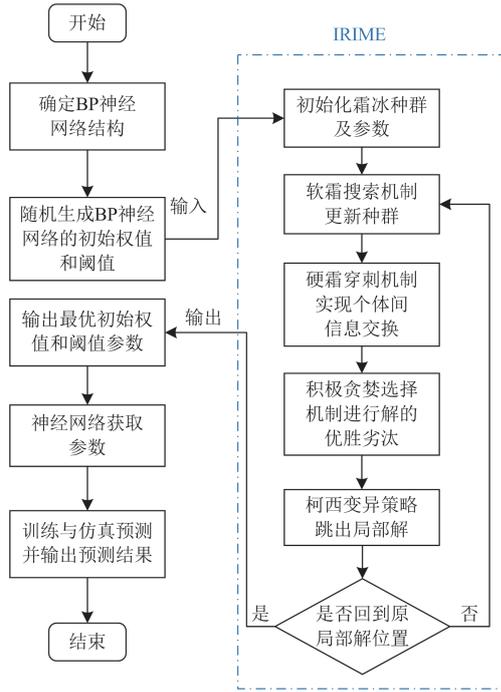


图4 改进霜冰优化算法优化BP神经网络初始参数流程
Fig. 4 Flowchart of IRIME algorithm for optimizing initial parameters of BP neural network

态等级 z 的概率, $z=1,2,3,4$ 。当 P_z 为 P_1-P_4 中的最大值时, 该状态等级对应的输出 $Y_z=1$; 否则, $Y_z=0$ 。取某个保护装置在不同时刻处于状态等级 1 的概率, 构成该保护装置状态表征向量的时间序列 $T_s=[P_{Ts1}, P_{Ts2}, \dots, P_{Tsn}]$, 其中, P_{Tsn} 表示保护装置在 n 时刻处于状态等级 1 的概率。

2 继电保护装置剩余寿命预测

保护装置寿命预测是基于状态表征向量的时间序列进行预测, 来获取下一时刻保护装置可能的状态。目前保护装置剩余寿命预测更多是采用机器学习算法, 当环境发生变化时不能很好地进行预测数据的跟踪与修正。因此, 本文采用长短期记忆网络进行状态表征向量时间序列的预测, 同时设定置信度水平, 当下一时刻保护装置状态概率 P_{Tsn} 小于置信度时, 可以认为保护装置即将进入故障高发期, 需提前进行干预性检修或退出运行, 减小故障发生的概率。

2.1 长短期记忆网络

长短期记忆网络是一种特殊结构的循环神经网络, 常用于处理序列数据的深度学习模型, 与传统的循环神经网络(recurrent neural network, RNN)相比, LSTM 引入了单元状态与 3 个门结构(输入门、遗忘门、输出门)来保护和控制信息, 这些机制使得

LSTM 能够更好地处理序列中的长期依赖关系, 克服了传统神经网络难以处理长时间序列的缺点^[26-27]。LSTM 内部结构如图 5 所示。

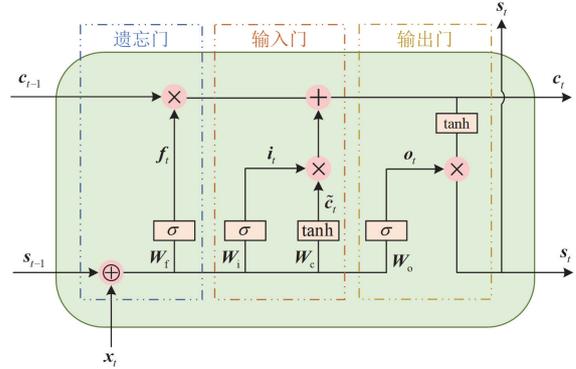


图5 长短期记忆网络内部结构图

Fig. 5 Internal structure diagram of LSTM network

1) 遗忘门

遗忘门负责决定是否将前一时刻的状态保留至当前状态中, 具体表达如(13)所示。

$$f_t = \sigma(W_f[s_{t-1}, x_t] + b_f) \quad (13)$$

式中: f_t 为内部当前时刻输出; $\sigma(\cdot)$ 表示 Sigmoid 激活函数; W_f 表示遗忘门的权值矩阵; s_{t-1} 为上一时刻输出; x_t 为当前时刻输入; $[s_{t-1}, x_t]$ 为两向量纵向链接操作; b_f 为输入的偏置项。

2) 输入门

输入门决定了当前时刻输入 x_t 有多少需要保存到当前单元状态 c_t , 具体表达如式(14)一式(16)所示。

$$i_t = \sigma(W_i[s_{t-1}, x_t] + b_i) \quad (14)$$

$$\tilde{c}_t = \tanh(W_c[s_{t-1}, x_t] + b_c) \quad (15)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (16)$$

式中: i_t 表示输入门内部当前时刻输出; \tilde{c}_t 表示单元状态当前时刻输出; c_t 表示输入门当前时刻总输出; W_i 表示输入门输入的权值矩阵; b_i 表示偏置项; W_c 表示单元状态的权值矩阵; b_c 表示单元状态的偏置项。符号“ \circ ”表示按元素逐乘计算。 i_t 与 \tilde{c}_t 的权值矩阵和偏置向量是不同的, 在训练的过程中需要单独训练。

3) 输出门

输出门主要负责调节有多少单元状态 c_t 可以传递到 LSTM 的当前输出值 s_t 中, 具体表达如式(17)和式(18)所示。

$$o_t = \sigma(W_o[s_{t-1}, x_t] + b_o) \quad (17)$$

$$s_i = o_i \circ \tanh(c_i) \quad (18)$$

式中： W_o 表示输出门的权值矩阵； b_o 表示输出门的偏置向量。

2.2 IRIME-BP-LSTM 预测模型

本文通过构建 IRIME-BP-LSTM 预测模型实现保护装置剩余寿命的预测，具体流程如图 6 所示。通过获取前文 IRIME-BP 神经网络模型对保护装置进行状态评估后形成的状态表征向量 $\mathbf{P}=[P_1, P_2, P_3, P_4]$ ，每隔 6 个月获取一次该保护装置的状态表征向量，构建状态表征向量的时间序列 T_s ，将时间序列输入到 LSTM 模型中，即可实现对保护装置下一

时刻状态的预测；当获取到下一时刻的状态表征向量时，可作为输入 x_t 输入到 LSTM 中，实现对时间序列的更新，在系统的修正下获取更加准确的预测结果。本文将 LSTM 的数据窗窗长设置为 5，即至少需要获取前 2.5 年的数据来进行后续的预测。同时，设置信度为 β ，依据常用的置信度水平范围 [0.6,0.8]，取置信度水平 0.75。

$$\{P_1 \leq \beta, \mathbf{P}=[P_1, P_2, P_3, P_4]\} \quad (19)$$

如果有式(19)成立，即保护装置处于良好的概率小于等于 75%时，认为装置处于失效状态，当前运行时间 T 即为保护装置最终寿命时间^[14]。

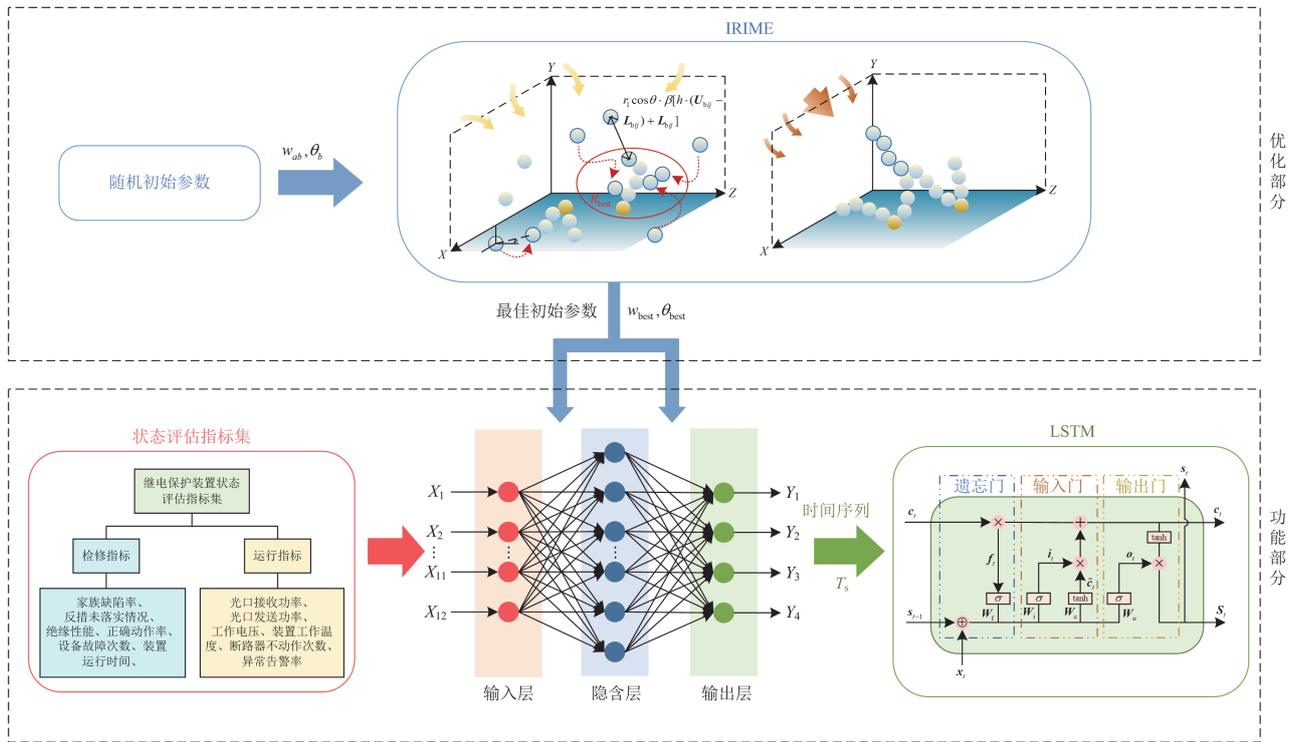


图 6 基于 IRIME-BP-LSTM 的保护装置剩余寿命预测流程

Fig. 6 Process of remaining useful life prediction for protective devices based on IRIME-BP-LSTM

3 案例验证

对装置状态评估的准确度直接决定后续时间序列以及剩余寿命预测的准确度，因此本文在案例验证的过程中，首先对 IRIME-BP 神经网络模型进行训练和准确度的验证；然后，在确认评估结果准确度达到要求的基础上，构建保护装置状态表征向量的时间序列，将时间序列输入 LSTM 中进行训练；最后，选取两个已退出运行的保护装置，将其编号为 1 号和 2 号，进行预测性能的验证，并与传统的马尔可夫链原理进行比较。

从某供电公司保护装置历史状态数据库中，随

机抽取 1108 条状态为“良好”、“正常”、“注意”、“异常”的样本，分别记录样本的工作电压、装置工作温度、断路器不动作次数等数据，形成保护装置状态评估指标集。

以其中一台保护装置为例，该保护装置状态等级为“良好”的某一时刻运行数据为：家族缺陷率 0、反措未落实情况 0、绝缘性能良好(为 0)、不正确动作率 0.08%、设备故障次数 0、装置运行时间 6.8 年、光口接收功率-15.613 dBm、光口发送功率-18.276 dBm、工作电压 4.5 V、装置工作温度 46.7 °C、断路器不动作次数 0、异常告警率 0。由以上数据构成的初始输入向量 \mathbf{x} 如式(20)所示。

$$\mathbf{x} = [0, 0, 0, 0.08, 0, 6.8, -15.613, -18.276, 4.5, 46.7, 0, 0] \quad (20)$$

根据归一化式(12)可得, 归一化后的输入向量 \mathbf{X} 如式(21)所示。

$$\mathbf{X} = [0, 0, 0, 0.19, 0, 0.523, 0.667, 0.803, 0.92, 0.150, 0, 0] \quad (21)$$

IRIME-BP 神经网络模型获取归一化后的输入向量, 对数据进行解析与评估, 最后在输出层输出该保护装置如式(22)所示的状态表征向量。该装置处于良好状态的概率为 97.3%, 处于正常状态的概率为 1.9%, 处于注意状态的概率为 0.5%, 处于异常状态的概率为 0.3%, 则该保护装置状态评估的结果为良好。

$$\mathbf{P} = [0.973, 0.019, 0.005, 0.003] \quad (22)$$

当某一指标数据在未能及时更新时, 例如: 某台保护装置的不正确动作率由 0.06%变化至 0.075%, 由于当月尚未进行巡检工作来更新检修指标数据, 此时使用最近一次记录数据, 即 0.06%来进行保护装置的状态评估, 输入向量的变化如式(23)所示。

$$\mathbf{X}' = [0, 0, 0, 0.186, 0, 0.347, 0.685, 0.714, 0.95, 0.12, 0, 0]$$

↓

$$\mathbf{X}'' = [0, 0, 0, 0.17, 0, 0.347, 0.685, 0.714, 0.95, 0.12, 0, 0] \quad (23)$$

输入向量为 \mathbf{X}' 时, IRIME-BP 神经网络模型输出的状态表征向量 \mathbf{P}' 如式(24)所示; 输入向量为 \mathbf{X}'' 时, IRIME-BP 神经网络模型输出的状态表征向量 \mathbf{P}'' 如式(25)所示。

$$\mathbf{P}' = [0.979, 0.011, 0.007, 0.003] \quad (24)$$

$$\mathbf{P}'' = [0.981, 0.01, 0.007, 0.002] \quad (25)$$

通过观察保护装置状态表征向量可以得出, 将指标数据进行近似处理后输出结果变化不大且状态等级均为“良好”, 因此当指标数据更新不及时或不完整时, 可通过选取最近一次记录的相关指标数据进行状态评估。

将所有保护装置样本数据处理后得到的输入向量输入到 IRIME-BP 神经网络中进行模型的训练及测试。将样本数据进行随机打乱, 选取 1000 条数据作为训练集, 108 条数据作为测试集。

训练集与测试集评估结果如图 7 所示, 其中训练集评估结果准确率为 99.1%, 测试集评估结果准确率为 97.222%。将相同的数据集输入到鲸鱼优化算法(whale optimization algorithm, WOA)、粒子群优化算法(particle swarm optimization, PSO)、遗传算法(genetic algorithm, GA)优化的 BP 神经网络模型中进行对比, 对比结果如表 2 所示。

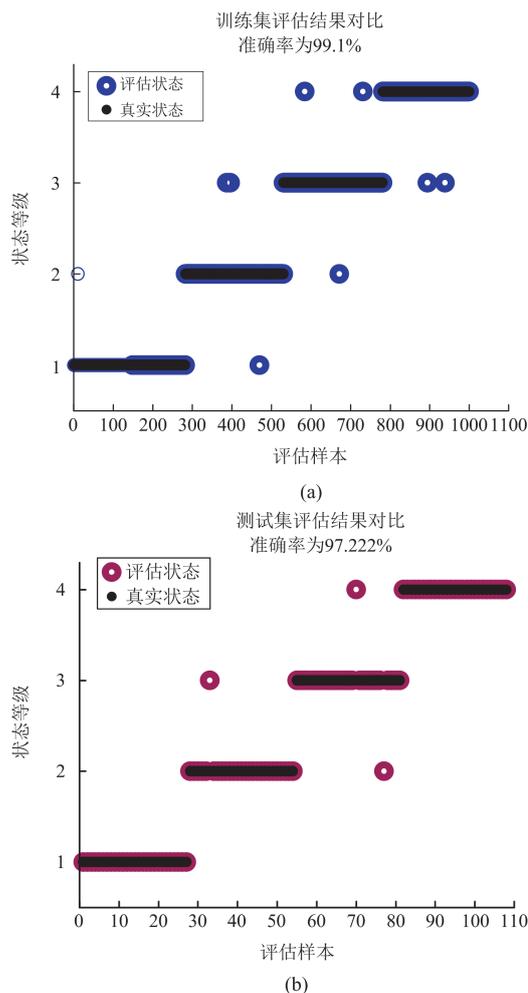


图 7 保护装置状态评估训练集与测试集结果对比图

Fig. 7 Comparison chart of training and test results for protective device condition assessment

表 2 智能算法优化 BP 神经网络模型准确度对比

Table 2 Comparison of accuracy in BP neural network models optimized by intelligent algorithms

模型	训练集准确率/%	测试集准确率/%
IRIME-BP	99.1	97.22
WOA-BP	95.34	93.01
PSO-BP	95.91	92.98
GA-BP	93.44	89.88

由表 2 可以看出: 本文所建立的 IRIME-BP 神经网络模型对继电保护装置状态评估的准确率相比最高, 可以用作后续时间序列的构建以及装置剩余寿命的预测。

以某台保护装置为例, 其状态表征向量如表 3 所示, 根据时间序列构建原理获得其运行状态的时间序列, 将所有构建的时间序列作为训练集输入到 LSTM 模型中, 模型的基础学习率变化如图 8 所示。

表 3 某台保护装置表征向量及时间序列

Table 3 Characterization vector and time series of a certain protection device

时间/年	状态表征向量	P_{Tsr}
1	[0.9941,0.005,0.0006,0.0003]	0.9941
1.5	[0.9836,0.008,0.0062,0.0022]	0.9836
2	[0.9699,0.014,0.0091,0.007]	0.9699
2.5	[0.9612,0.028,0.009,0.0018]	0.9612
3	[0.9564,0.03,0.01,0.0036]	0.9564
3.5	[0.9481,0.033,0.012,0.0069]	0.9481
时间序列	[0.9941 0.9836 0.9699 0.9612 0.9564 0.9481]	

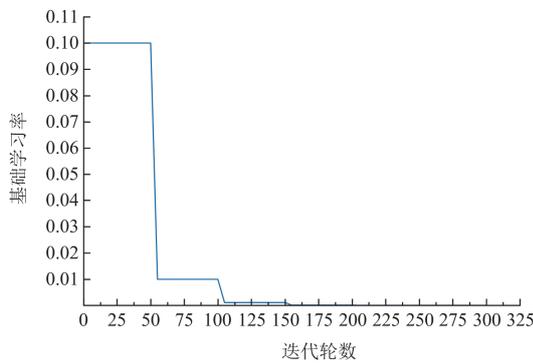


图 8 LSTM 模型基础学习率

Fig. 8 Basic learning rate of LSTM model

完成训练后, 选取 1 号和 2 号两台保护装置验证 LSTM 的预测能力, 并与传统马尔可夫预测原理进行对比, 计算两者与真实值之间的均方根误差 (root mean square error, RMSE)与平均绝对百分比误差(mean absolute percentage error, MAPE), 验证模型的有效性, 指标计算见式(26)、式(27)。

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{e}_i - e_i)^2} \quad (26)$$

$$E_{MAPE} = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{\hat{e}_i - e_i}{e_i} \right| \quad (27)$$

式中: \hat{e}_i 和 e_i 分别表示模型预测数据与样本实际评估数据; N 表示数据个数。

1 号装置在正常环境中运行至失效状态, 2 号装置由于某一时刻运行环境的变化, 导致装置在该时刻之后状态快速下降, 提前进入失效状态。1 号装置误差计算结果对比如图 9 所示, 1 号装置预测结果对比如图 10 所示, 2 号装置预测结果对比如图 11 所示。

通过预测数据与图像可以得知, 对于在正常环境中运行至失效状态的 1 号装置来说, 本文所提出

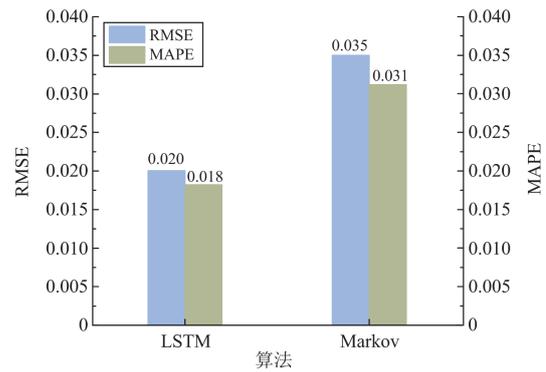


图 9 1 号装置 RMSE 与 MAPE 对比图

Fig. 9 Comparison chart of RMSE and MAPE for device 1

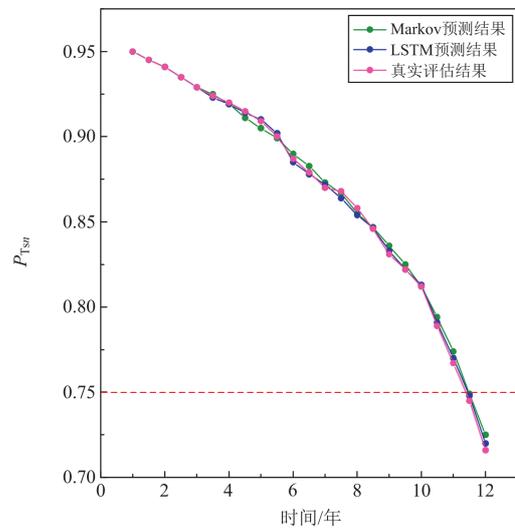


图 10 1 号装置预测结果对比图

Fig. 10 Comparison chart of prediction results for device 1

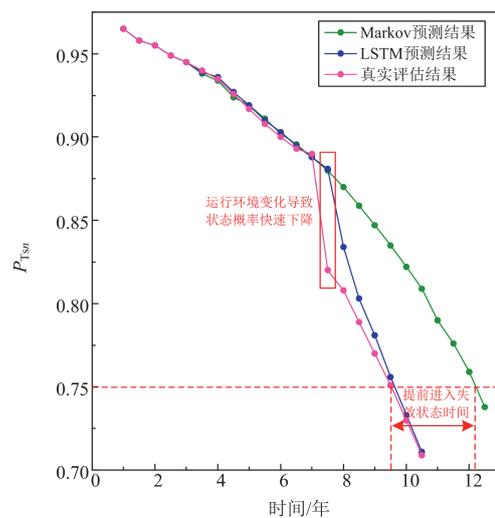


图 11 2 号装置预测结果对比图

Fig. 11 Comparison chart of prediction results for device 2

的预测方法与 Markov 算法都可以对其运行状态进行预测, 但 LSTM 的 RMSE 与 MAPE 值均低于 Markov 预测方法, 表明预测数据更加准确。预测曲线、实际曲线与 $y = 0.75$ 的交点均位于 [11, 11.5] 区间内, 可以认为算法预测 1 号装置的使用寿命为 11 年, 与实际的评估结果相符。对于 2 号装置而言, 该装置在第 7.5 年左右运行环境发生变化, 导致装置的运行状态快速下降, 此时 LSTM 可以及时准确地对预测结果进行修正, 弥补了传统 Markov 算法的不足。由图 11 可知, 运行环境发生变化后 LSTM 预测的装置使用寿命降低到了 9.5 年, 与实际评估结果相符。当剩余寿命预测模型于第 9.5 年预测出装置在下一时刻运行状态处于良好的概率低于 75% 时, 应在第 9.5 年到第 10 年之间对装置加强监测, 或对装置进行停电全面检测检修, 预防装置进入失效状态, 减少保护装置发生故障的概率。

4 结论

针对保护装置剩余寿命预测方法中存在缺少对单个装置寿命的准确预测, 以及无法实现预测数据及时更新的问题, 本文提出了基于 IRIME-BP-LSTM 模型的继电保护装置剩余寿命预测方法, 结合具体算例分析, 结论如下所述。

1) 分析了目前保护装置寿命预测领域的问题, 提出了“状态评估+时间序列预测”的预测逻辑; 梳理继电保护领域理论成果与运行维护的经验, 建立继电保护装置状态评估指标集, 作为保护装置状态等级的评判依据。

2) 利用柯西变异机制改进 RIME 算法优化 BP 神经网络的初始参数, 构建 IRIME-BP 神经网络模型进行保护装置状态评估, 训练集评估准确率为 99.1%, 测试集评估准确率为 97.22%。与 WOA、PSO、GA 等智能算法相比, 本文构建的算法具有较高的准确率, 可以为后续装置剩余寿命预测提供准确的评估结果。

3) 通过分析图像并计算误差可以得出, 本文提出的 IRIME-BP-LSTM 预测方法能够较为准确地对保护装置的剩余寿命进行预测, 预测的寿命时间与实际使用年限一致, 并且当运行环境发生变化时, 可以对装置的运行状态进行跟踪, 实现预测数据的及时修正。同时, IRIME-BP-LSTM 预测方法的 RMSE 与 MAPE 值均低于传统 Markov 预测方法。

参考文献

[1] 王增平, 林一峰, 王彤, 等. 电力系统继电保护与安全控制面临的挑战与应对措施[J]. 电力系统保护与控制, 2023, 51(6): 10-20.

WANG Zengping, LIN Yifeng, WANG Tong, et al. Challenges and countermeasures to power system relay protection and safety control[J]. Power System Protection and Control, 2023, 51(6): 10-20.

[2] 戴志辉, 耿宏贤, 韩健硕, 等. 基于矩阵算法和 BP 神经网络的智能站二次系统故障定位方法[J]. 华北电力大学学报(自然科学版), 2022, 49(6): 1-10.

DAI Zhihui, GENG Hongxian, HAN Jianshuo, et al. Fault location method of secondary system in smart substation based on matrix algorithm and BP neural network[J]. Journal of North China Electric Power University (Natural Science Edition), 2022, 49(6): 1-10.

[3] 周海成, 石恒初, 曾令森, 等. 基于关系超图增强 Transformer 的智能站二次设备故障诊断研究[J]. 电力系统保护与控制, 2024, 52(12): 123-132.

ZHOU Haicheng, SHI Hengchu, ZENG Lingsen, et al. Fault diagnosis of an intelligent substation secondary device based on a relational hypergraph-enhanced Transformer[J]. Power System Protection and Control, 2024, 52(12): 123-132.

[4] 熊小伏, 陈星田, 郑昌圣, 等. 继电保护系统状态评价研究综述[J]. 电力系统保护与控制, 2014, 42(5): 51-58.

XIONG Xiaofu, CHEN Xingtian, ZHENG Changsheng, et al. Overview of research on state evaluation of relaying protection system[J]. Power System Protection and Control, 2014, 42(5): 51-58.

[5] 董玉展. 基于数字孪生的保护系统状态评估和故障预警[D]. 济南: 山东大学, 2023.

DONG Yuzhan. State evaluation and fault prediction of protection system based on digital twin[D]. Jinan: Shandong University, 2023.

[6] 黄玲玲, 马永杰, 应飞祥, 等. 基于剩余寿命预测信息的风电场动态成组维护策略研究[J]. 电力系统保护与控制, 2024, 52(16): 178-187.

HUANG Lingling, MA Yongjie, YING Feixiang, et al. Dynamic group maintenance strategy for a wind farm based on residual life prediction information[J]. Power System Protection and Control, 2024, 52(16): 178-187.

[7] 李铁成, 刘清泉, 任江波, 等. 基于动态优化马尔可夫链的线路继电保护装置状态预测方法[J]. 电力系统保护与控制, 2022, 50(13): 97-106.

LI Tiecheng, LIU Qingquan, REN Jiangbo, et al. State prediction method of line relay protection device based on the Markov chain with dynamic optimization[J]. Power System Protection and Control, 2022, 50(13): 97-106.

[8] 叶远波, 李端超, 谢民, 等. 基于 SSA-SVM 的继电保护装置状态评估方法研究[J]. 电力系统保护与控制, 2022, 50(8): 171-178.

YE Yuanbo, LI Duanchao, XIE Min, et al. A state evaluation method for a relay protection device based on SSA-SVM[J]. Power System Protection and Control, 2022, 50(8): 171-178.

[9] 易永辉. 继电保护装置寿命分析及寿命影响机理研究[J]. 电力系统保护与控制, 2013, 41(2): 79-83.

- YI Yonghui. Research of relay protection device's life and relative effect mechanism[J]. Power System Protection and Control, 2013, 41(2): 79-83.
- [10] 罗琨, 时永肖, 李正新, 等. 智能变电站继电保护装置寿命模型及其辨识方法[J]. 智慧电力, 2021, 49(1): 96-101. LUO Kun, SHI Yongxiao, LI Zhengxin, et al. A life model and its identification method for relay protection device in smart station[J]. Smart Power, 2021, 49(1): 96-101.
- [11] 谢楠, 马振国, 唐兵, 等. 继电保护设备剩余寿命预测的智能算法研究[J]. 兰州理工大学学报, 2023, 49(2): 83-87. XIE Nan, MA Zhenguang, TANG Bing, et al. Study on intelligent algorithm for remaining useful life prediction of relay protection equipment[J]. Journal of Lanzhou University of Technology, 2023, 49(2): 83-87.
- [12] 王昭雷, 张惠山, 赵智龙, 等. 基于深度门控长短时记忆网络的继电保护装置寿命预测[J]. 河北电力技术, 2023, 42(6): 28-35. WANG Zhaolei, ZHANG Huishan, ZHAO Zhilong, et al. Life prediction of relay protection device based on depth gated long short-term memory network[J]. Hebei Electric Power, 2023, 42(6): 28-35.
- [13] 黄涛, 周鹏, 赖秋频, 等. 一种智能变电站保护装置寿命预测方法[J]. 电测与仪表, 2018, 55(12): 39-44. HUANG Tao, ZHOU Peng, LAI Qiupin, et al. A life prediction method for intelligent substation protection device[J]. Electrical Measurement & Instrumentation, 2018, 55(12): 39-44.
- [14] 陈海涛, 杨军, 施迎春, 等. 基于云模型与马尔科夫链的继电保护装置寿命预测方法[J]. 电力系统保护与控制, 2019, 47(16): 94-100. CHEN Haitao, YANG Jun, SHI Yingchun, et al. Life prediction method of relay protection device based on cloud model and Markov Chain[J]. Power System Protection and Control, 2019, 47(16): 94-100.
- [15] 中国电力科学研究院. 电力系统继电保护及安全自动装置运行评价规程: Q/GDW 10395—2022[S]. 北京: 中国电力出版社, 2022.
- [16] 中国电力科学研究院. 继电保护状态评价导则: Q/GDW 11285—2022[S]. 北京: 中国电力出版社, 2022.
- [17] 徐峰, 盛海华, 吴佳毅, 等. 基于灰色关联度的继电保护装置状态评价研究[J/OL]. 电测与仪表: 1-7[2024-11-01]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20240511.0905.004.html>. XU Feng, SHENG Haihua, WU Jiayi, et al. Research on state evaluation of relay protection device based on grey correlation degree[J/OL]. Electrical Measurement & Instrumentation: 1-7[2024-11-01]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20240511.0905.004.html>.
- [18] 戴志辉, 刘媛, 邱小强, 等. 基于变权重模糊综合评判法的保护装置状态评价[J]. 电测与仪表, 2021, 58(4): 150-157. DAI Zhihui, LIU Yuan, QIU Xiaoqiang, et al. Condition evaluation approach of protective devices based on fuzzy comprehensive evaluation with variable weight[J]. Electrical Measurement & Instrumentation, 2021, 58(4): 150-157.
- [19] 王宣航. 基于隶属云的继电保护状态灰色模糊综合评价方法研究[D]. 南宁: 广西大学, 2022. WANG Xuanhang. Grey fuzzy synthesis of relay protection state based on subordinate cloud research on evaluation methods[D]. Nanning: Guangxi University, 2022.
- [20] 周达明. 智能变电站继电保护数字孪生仿真推演与状态预测技术研究[D]. 武汉: 华中科技大学, 2022. ZHOU Daming. Research on digital twin of relay protection simulation deduction and state prediction technology in the intelligent substation[D]. Wuhan: Huazhong University of Science and Technology, 2022.
- [21] 斯捷, 陈植, 赵建, 等. 基于阻抗谱的电力电缆绝缘缺陷诊断函数故障定位与状态评估方法研究[J]. 电测与仪表, 2025, 62(7): 217-224. SI Jie, CHEN Zhi, ZHAO Jian, et al. Research on fault location and state evaluation method of diagnostic function for power cable insulation defects based on the impedance spectrum[J]. Electrical Measurement & Instrumentation, 2025, 62(7): 217-224.
- [22] 刘宏新. 智能变电站二次系统运行与维护[M]. 北京: 中国电力出版社, 2016.
- [23] SU H, ZHAO D, HEIDARI A A, et al. RIME: a physics-based optimization[J]. Neurocomputing, 2023, 532: 183-214.
- [24] YANG B, WANG J, SU S, et al. Mismatch losses mitigation of PV-TEG hybrid system via improved RIME algorithm: design and hardware validation[J]. Journal of Cleaner Production, 2024, 434.
- [25] 陈昱, 丁鸿, 崔勇, 等. 变电设备温度态势感知及辅助决策系统方案研究[J]. 发电技术, 2024, 45(4): 744-752. CHEN Yu, DING Hong, CUI Yong, et al. Research on temperature situation awareness and auxiliary decision-making system scheme of substation equipment[J]. Power Generation Technology, 2024, 45(4): 744-752.
- [26] ZHANG H, SUN H L, KANG L, et al. Prediction of health level of multiform lithium sulfur batteries based on incremental capacity analysis and an improved LSTM[J]. Protection and Control of Modern Power Systems, 2024, 9(2): 21-31.
- [27] 刘凡平. 神经网络与深度学习应用实战[M]. 北京: 电子工业出版社, 2018.

收稿日期: 2024-11-05; 修回日期: 2025-02-10

作者简介:

张洪嘉(1999—), 男, 硕士研究生, 研究方向为电力系统保护与控制; E-mail: zhanghjncepu@163.com

戴志辉(1980—), 男, 通信作者, 博士, 教授, 研究方向为电力系统保护与控制。E-mail: daihuadian@163.com

(编辑 张颖)