

基于特征协同提取与增强的短路电流过零点预测方法

李小平¹,董登文¹,董海燕^{1†},林小军²,燕宁宁¹,窦建明³,李伟全⁴

(1. 兰州交通大学 自动化与电气工程学院,甘肃 兰州 730070;

2. 兰州工业学院 机电工程学院,甘肃 兰州 730050;

3. 兰州交通大学 机电工程学院,甘肃 兰州 730070;

4. 天水二一三电器集团有限公司,甘肃 天水 741000)

摘 要:相控开断技术能在短路电流最佳相位处切除故障,降低短路电流对电力设备的损伤.其难点在于实现短路电流过零点的准确、快速预测.为此,提出一种基于特征协同提取与增强的短路电流过零点预测方法,首先,利用卷积神经网络(convolutional neural network, CNN)结合挤压-激励(squeeze-and-excitation, SE)注意力机制构建特征提取与增强模块,突出短路电流局部关键特征;其次,将增强后的特征输入门控循环单元(gated recurrent unit, GRU),利用其门控机制和记忆能力建立时序模型;再次,采用多输入多输出(multiple input multiple output, MIMO)策略实现多步预测;最后,结合混沌进化优化(chaotic evolution optimization, CEO)算法进行超参数寻优,构建基于CEO算法的CNN-SE-GRU复合预测模型.仿真与实验结果表明:复合预测模型决定系数(R^2)为93.46%,均方根误差(RMSE)为69.33,平均绝对误差(MAE)为47.14.模型将采样时长缩短至2 ms,平均预测时间为15.78 ms,相比长短期记忆(long short-term memory, LSTM)网络递归预测耗时降低了97.51%;实验波形过零点预测平均绝对误差为0.18 ms,极值处平均相对误差为5.89%;模拟不同工况及噪声环境下零点平均预测误差小于0.32 ms.与传统方法相比,多步复合预测模型在保证预测精度的同时显著缩短了预测时间,能为断路器精准相控开断短路故障电流提供理论依据.

关键词:短路电流;过零点预测;CEO-CNN-SE-GRU模型;预测时间;相控开断

中图分类号:TM713

文献标志码:A

A short-circuit current zero-crossing point prediction method based on collaborative feature extraction and enhancement

LI Xiaoping¹, DONG Dengwen¹, DONG Haiyan^{1†}, LIN Xiaojun²,

YAN Ningning¹, DOU Jianming³, LI Weiquan⁴

(1. School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. School of Mechanical and Electrical Engineering, Lanzhou Institute of Technology, Lanzhou 730050, China;

3. School of Mechanical and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;

4. Tianshui 213 Electrical Apparatus Co., Ltd., Tianshui 741000, China)

* 收稿日期:2025-05-06

基金项目:甘肃省高等学校产业支撑计划资助项目(2023CYZC-72), Gansu Provincial Higher Education Industry Support Program (2023CYZC-72);甘肃省自然科学基金资助项目(24JRRA237), Gansu Natural Science Foundation Project(24JRRA237);甘肃省重点研发计划-工业类项目(24YFGA039), Gansu Key R&D Programs-Industrial Projects(24YFGA039);兰州市科技发展指导性计划项目(2025-5-010), Guiding Plan Project for Science and Technology Development in Lanzhou City (2025-5-010)

作者简介:李小平(1974—),男,甘肃甘谷人,兰州交通大学教授,博士

† 通信联系人, E-mail: donghaiyancool@126.com

Abstract: Phase-controlled switching technology can remove the fault at the optimal phase of the short-circuit current and reduce damage from the short-circuit current to power equipment. The primary challenge lies in achieving accurate and rapid prediction of short-circuit current zero-crossing points. To this end, this paper proposes a prediction method for short-circuit current zero-crossing points based on collaborative feature extraction and enhancement. First, a feature extraction and enhancement module is constructed by combining a convolutional neural network (CNN) with squeeze-and-excitation (SE) attention mechanism to highlight the local key features of short-circuit currents. Then, the enhanced features are fed into a gated recurrent unit (GRU) to establish a temporal model by utilizing its gating mechanism and memory capability. Subsequently, a multiple-input multiple-output (MIMO) strategy is adopted to realize multi-step prediction. Finally, the chaotic evolution optimization (CEO) algorithm is combined with hyperparameter optimization to construct the CEO algorithm-based CNN-SE-GRU composite prediction model. Simulation and experimental results demonstrate that the hybrid prediction model achieves a coefficient of determination (R^2) of 93.46%, a root mean square error (RMSE) of 69.33, and a mean absolute error (MAE) of 47.14. The model reduces the sampling duration to 2 ms with an average prediction time of 15.78 ms, representing a 97.51% reduction in prediction time compared to long short-term memory (LSTM) network recursive prediction. The mean absolute error for zero-crossing point prediction in experimental waveforms is 0.18 ms, with an average relative error of 5.89% at extreme values. Under simulations of different operating conditions and noise environments, the average prediction error for zero points is less than 0.32 ms. Compared with traditional methods, the multi-step hybrid prediction model significantly reduces prediction time while maintaining prediction accuracy, providing a theoretical basis for precise phase-controlled interruption of short-circuit fault currents by circuit breakers.

Key words: short-circuit current; zero-crossing point prediction; CEO-CNN-SE-GRU model; prediction time; phase-controlled switching

电力系统短路故障会造成电流突变,导致电力设备承受电动力冲击以及热损伤^[1]。断路器相控开断技术通过在电流预期相位处完成分闸操作,能快速切除系统故障,有效减少燃弧时间及电弧能量,显著降低分闸操作对电气设备的电磁暂态冲击^[2-4]。

快速、准确预测短路电流过零点,是实现相控分断故障电流的关键环节^[5]。目前,国内外学者对短路电流的零点预测开展了卓有成效的研究工作。国外有学者^[6-7]提出“安全点法”,将周期分量零点近似为短路电流零点,模型简单且误差为 ± 1 ms,但没有考虑非周期分量和谐波影响。THOMAS等^[8]提出一种自适应算法,在考虑谐波分量影响的同时,利用变时间窗缩短预测时间。袁召等^[9]通过移动窗口和改进半波傅里叶算法准确提取了非周期分量参数,有效降低了非周期分量对零点预测的影响,预测误差在 ± 1 ms内。黄智慧等^[10-11]提出了一种改进递推最小二乘(recursive least square, RLS)算法,将非周期分量通过泰勒级数展开成线性方程组,利用最小二乘

法进行参数估计,并引入时间常数补偿公式提高预测精度,实现了短路电流过零点实时预测。YANG等^[12]提出一种半周期消除预测算法,对周期分量和非周期分量分别采用最小二乘法 and 快速傅里叶变换进行计算,采样时间大于15 ms,预测误差为0.2 ms。荣文帅等^[13]探究发现最小二乘参数辨识计算简单、抗噪能力强,预测误差为0.33 ms;改进快速傅里叶算法理想状态预测效果较好,但对测量系统精度要求高,预测误差为0.51 ms。以上算法都是基于谐波分析法将短路电流波形进行分解,利用不同方法减少非周期分量的影响,提取故障电流特征参数后建立数学模型预测零点,虽然预测误差满足 ± 1 ms要求,但是通常需要10 ms以上的数据预测过零点。

近年来,基于机器学习的方法在短路电流幅值预测方面得到广泛研究和应用^[14-15]。YE等^[16]建立多输出回归模型计算含IIDG(inverter interfaced distributed generator, 逆变型分布式电源)配电网中的短路电流,平均误差为0.05%。陈俊杰等^[17]提出基于二维

云模型的短路电流预测方法,平均绝对误差为1.71%。黄旭等^[18]融合自适应混沌粒子群算法与BP(back-propagation,反向传播)神经网络,通过优化网络各层权重提高预测精度,平均绝对误差仅为1.872%。此外,ZHENG等^[19]提出一种XGBoost(extreme gradient boosting,极致梯度提升)的短路电流预测方法,预测误差小于3%。陈建明等^[20]提出一种改进的灰色BP神经网络模型通过动态数据迭代机制优化预测过程,误差仅为1.49%。ALJARRAH等^[21]开发了一种基于人工神经网络(artificial neural network, ANN)的短路电流预测工具,能预测0~100%的可再生能源渗透率范围内短路电流。以上研究均在短路电流幅值预测方面效果显著,但并未对短路电流过零点预测做深入探究。关于过零点预测问题,黄吕超等^[22]构建LSTM网络预测短路电流过零点,将采样时间缩短至3 ms,预测误差在 ± 0.5 ms以内,波峰及波谷处平均相对误差较大,其值为8.56%。VEERAMSETTY等^[23]通过15个采样点的滑动窗口提取斜率和截距等特征作为深度神经网络(deep neural network, DNN)的输入,准确检测出5%~50%噪声水平和10%~50%谐波失真情况下的波形零点。由此可见,基于深度学习的短路电流过零点预测方法在过零点和波峰波谷处预测误差较大,还有待改进。

综上所述,短路电流过零点预测方法中,基于谐波分析的方法需要采集10 ms以上的数据才能预测出过零点值,导致实时性差;基于深度学习的预测方法在过零点及波峰波谷处预测误差较大,影响预测准确性。因此,为了提高过零点预测的准确性和快速性,本文提出一种融合特征增强及参数优化的短路电流过零点预测方法。该方法首先以CNN为基础,利用其局部特征提取能力结合SE注意力机制的特征增强优势,构建CNN-SE特征提取与增强模块;其次,在此基础上,发挥GRU网络的门控机制和记忆能力,实现对短路电流时序特性的建模,并结合多输入多输出(MIMO)策略实现短路电流过零点预测;最后,为了充分发挥上述各模块的优势,采用CEO算法优化各部分超参数并融合为有机整体,达到提高短路电流过零点预测精度并缩短预测时间的目的。

1 基于CEO算法优化的CNN-SE-GRU模型

本文所提基于CNN-SE-GRU模型的预测方法结构如图1所示,总体上由三部分构成:数据集构

建、特征提取与增强和GRU多步预测。首先,采用短路电流表达式生成故障电流数据并添加随机白噪声作为数据集;其次,通过序列折叠层将输入数据转换成 $n \times 1$ 的空间结构,利用CNN模块对短路电流数据进行局部特征提取,并经SE注意力机制动态加强电流变化率和幅值等对零点预测有益的特征,构建CNN-SE特征提取与增强模块;最后,利用GRU网络门控机制和记忆能力从增强后的特征中提取完整的时序依赖关系,并融合多输入多输出(MIMO)策略构建CNN-SE-GRU复合多步预测模型。




图1 CNN-SE-GRU模型结构

Fig.1 CNN-SE-GRU model structure

1.1 基于CNN-SE的特征增强模块

现有基于深度学习的短路电流过零点预测方法直接将原始数据输入LSTM网络,缺乏对短路电流波形局部特征的针对性提取和筛选。然而,过零点附近的斜率变化、短时间窗内的幅值变化和波形梯度特征等局部信息对过零点准确预测具有重要意义。CNN能够提取时间序列的局部特征,被广泛应用于数据处理领域^[24]。本文构建了两层 3×1 的卷积核,第一个卷积核提取64通道的基础时序特征,主要包括时间梯度特征、波形对称性特征和时序单调性特征。第二个卷积核将特征空间扩展至128维,通过组合第一层的基础特征形成高级复合特征,实现了从检测电流变化到预测过零时刻的关键转换。计算公式为式(1)~式(2)。但其对不同特征通道采用均

匀权重分配策略,容易受到高频噪声和无关特征的干扰.因此引入SE注意力机制构建CNN-SE特征增强模块,结构如图2所示.挤压操作将卷积层输出的特征利用全局平均池化进行压缩后映射为一维特征数组;激励操作全面学习通道间的依赖性并标定特征通道的相应权重;点积操作将压缩后的一维特征数组与相应通道权重相乘,实现特征通道的注意力加权^[25].特征增强模块计算过程为式(3)~式(6).




图2 CNN-SE特征增强模块

Fig.2 CNN-SE feature enhancement module

$$z_j^l = \sum_{i \in M_j} a_i^{l-1} \otimes \omega_{ij}^l + b_j^l \quad (1)$$

$$a_j^l = f(z_j^l) = \begin{cases} 0, & z_j^l < 0 \\ z_j^l, & z_j^l \geq 0 \end{cases} \quad (2)$$

$$U_j^l = \frac{1}{H \times W} \sum_{h=1}^H \sum_{w=1}^W a_j^l(h, w) \quad (3)$$

$$F_1^l = f(\omega_1^l \cdot U^l + b_1^l) \quad (4)$$

$$s_j^l = \sigma(\omega_2^l \cdot F_1^l + b_2^l) \quad (5)$$

$$\tilde{a}_j^l = s_j^l \odot a_j^l \quad (6)$$

式中: l 表示网络层数; i, j 为神经元序号; M_j 表示卷积核在输入时间序列上滑动窗口覆盖的位置集合; a_i^{l-1} 表示 $l-1$ 层第 i 个神经元输出; ω_{ij}^l 表示权重矩阵; b_j^l 表示神经元的偏置项; $\otimes$ 表示卷积操作; z_j^l 表示神经元的加权输入; a_j^l 表示卷积层的输出特征; U^l 表示所有通道描述符组成的向量; H 和 W 分别表示特征的高度和宽度; $a_j^l(h, w)$ 表示通道在位置 (h, w) 处的特征值; F_1^l 表示第一个全连接层的输出特征; s_j^l 表示通道注意力权重; $\sigma(\cdot)$ 为Sigmoid激活函数; $\tilde{a}_j^l$ 表示重新标定后的特征序列。

CNN-SE模块通过两层卷积核的分层特征提取,捕获到短路电流的符号变化、上升趋势以及衰减指数等局部特征;随后利用SE注意力机制对高级复合特征序列进行通道的重标定,实现有选择地增强变化率和极值等有益特征。

1.2 基于GRU-MIMO的多步预测

短路电流包含周期分量和直流衰减分量,呈现复杂的非线性特性,传统线性变换难以对其准确建模. GRU网络解决了传统RNN梯度消失和梯度爆炸的问题,对复杂非线性序列有较强的建模能力^[26].其门控机制能够自动识别并记忆短路电流中的衰减趋势等重要时序特征.计算过程为式(7)~式(10).

递归预测策略将前一步预测值作为下一步预测的输入,模型简单但存在误差累积问题,而且循环递归过程增加了模型预测时间.然而短路电流过零点预测需要在继电保护动作前发出分闸命令,对后期过零点预测的准确性和快速性有更高要求.多输入多输出(MIMO)策略采用并行预测机制,能同时输出多个时间步的预测值,避免了递归预测中的误差累积^[27-28];并且单次前向传播形式缩短了预测时间.因此,本文将GRU网络和MIMO策略结合,预测结构如图3所示,通过多步联合预测的约束机制,将短路电流衰减过程中的连续性和规律性融入网络学习目标中.该策略使GRU在提取时序特征时,不仅关注单点预测精度,更要学习整个预测区间的深层衰减模式,确保多步预测序列在衰减过程中保持平滑,最终实现对短路电流指数衰减规律的精确建模.式(11)、式(12)为MIMO策略模型。




图3 GRU-MIMO多步预测结构

Fig.3 GRU-MIMO multi-step prediction structure

$$z_t = \sigma(W_z^T [h_{t-1}, x_t] + g_z) \quad (7)$$

$$r_t = \sigma(W_r^T [h_{t-1}, x_t] + g_r) \quad (8)$$

$$h_u = \tanh(W_h^T [r_t \odot h_{t-1}, x_t] + g_h) \quad (9)$$

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot h_u \quad (10)$$

$$F(\mathbf{h}_t) = \omega_{out} \mathbf{h}_t + \mathbf{b}_{out} \quad (11)$$

$$[\mathbf{y}_{t+1}, \dots, \mathbf{y}_{t+H}] = F(\mathbf{x}_t, \dots, \mathbf{x}_{t-d+1}) + B \quad (12)$$

式中: $\mathbf{x}_t$ 表示当前时刻输入信息; $\mathbf{h}_{t-1}$ 表示上一时刻的隐藏状态; $\mathbf{h}_t$ 表示当前时刻的隐藏状态; $\mathbf{h}_u$ 为候选隐藏状态, 使用的激活函数是 $\tanh$; $\mathbf{r}_t, \mathbf{z}_t$ 分别为重置门和更新门; σ 表示 Sigmoid 函数, 是 $\mathbf{r}_t, \mathbf{z}_t$ 的激活函数; $\mathbf{W}_r$ 与 $\mathbf{g}_r$ 分别为重置门的权重和偏置向量; $\mathbf{W}_z$ 与 $\mathbf{g}_z$ 分别为更新门的权重和偏置向量; $\omega_{out}, \mathbf{b}_{out}$ 分别表示输出层权重矩阵和偏置向量; $\mathbf{h}_t$ 为最后一步隐藏状态; $F(\cdot)$ 为 MIMO 策略映射函数. 图 3 中, d 为输入窗口大小; B 为噪声项; H 为预测步长.

GRU 结合 MIMO 策略的预测方法既保证了 GRU 网络对复杂非线性序列的有效建模能力, 又通过并行机制同时输出多步预测值, 避免了递归预测的误差累积. 在进行短路电流过零点预测时, 数据从输入层经过 GRU 层再到输出层进行一次完整计算, 预测出多步未来值, 接着采用线性插值法在零点附近区域进行计算, 最终输出精确零点时刻, 缩短了预测时间^[29].

1.3 混沌进化算法

GRU 网络隐含层节点数和初始学习率等超参数的最优组合会使模型保持在最佳状态, 因此利用混沌进化优化算法 (CEO) 对复合模型超参数进行寻优. 该算法利用超混沌序列指导搜索方向, 解决了传统优化算法面临的局部最优和搜索停滞问题. 式 (13) 为指数型离散忆阻器映射模型.

$$\begin{cases} \mathbf{x}_{t+1} = k \cdot (e^{-\cos \pi \mathbf{y}_t} - 1) \cdot \mathbf{x}_t \\ \mathbf{y}_{t+1} = \mathbf{y}_t + \mathbf{x}_t \end{cases} \quad (13)$$

式中: e 为自然底数; 模型在保留离散忆阻器非线性关系与状态更新机制的同时, 利用参数 k 扩展了系统的动力学行为. 当 $k \in [2.486, 2.77]$ 时, 具有两个正李雅普诺夫指数, 表现出超混沌特性^[30]. 实现过程主要有以下步骤:

1) 变异操作: 首先将原始个体映射到混沌空间, 利用式 (13) 超混沌映射生成混沌点, 然后将混沌点逆映射回原始搜索空间并生成 n 个演化方向, 代入变异算子搜索式 (14) 生成 n 个变异个体, 变异过程为:

$$\tilde{\mathbf{x}}_{t+1} = \mathbf{x}_t + a \cdot \mathbf{d}_t \quad (14)$$

$$\begin{cases} \tilde{\mathbf{x}}_{t+1}^n = \mathbf{x}_t + a \cdot (\mathbf{x}_{chaos}^{n'} - \mathbf{x}_t) \\ \tilde{\mathbf{y}}_{t+1}^n = \mathbf{y}_t + a \cdot (\mathbf{y}_{chaos}^{n'} - \mathbf{y}_t) \end{cases} \quad (15)$$

式中: $\mathbf{x}_t, \tilde{\mathbf{x}}_{t+1}$ 分别表示当前个体和变异后个体; 搜索

步长 $a \in \text{rand}[0, 1]$; $\mathbf{d}_t$ 是映射生成的进化方向, $\mathbf{x}_{chaos}^{n'}$, $\mathbf{y}_{chaos}^{n'}$ 分别表示混沌空间中 x, y 坐标映射回原始搜索空间后的值.

为了加快算法收敛进程, 从当前种群最优解 (Best_t) 附近搜索, 计算公式为:

$$\begin{cases} \tilde{\mathbf{x}}_{t+1}^n = \text{Best}_t + a \cdot (\mathbf{x}_{chaos}^{n'} - \mathbf{x}_t) \\ \tilde{\mathbf{y}}_{t+1}^n = \text{Best}_t + a \cdot (\mathbf{y}_{chaos}^{n'} - \mathbf{y}_t) \end{cases} \quad (16)$$

2) 交叉操作: 变异操作生成新个体后, 通过二项式交叉机制生成实验向量 $(\mathbf{x}_{trial,t}^n, \mathbf{y}_{trial,t}^n)$, 其中 $\mathbf{x}_{trial,t}^n = (\mathbf{x}_{trial,1,t}^n, \mathbf{x}_{trial,2,t}^n, \dots, \mathbf{x}_{trial,Dim,t}^n)$, $\mathbf{y}_{trial,t}^n = (\mathbf{y}_{trial,1,t}^n, \mathbf{y}_{trial,2,t}^n, \dots, \mathbf{y}_{trial,Dim,t}^n)$, Dim 表示优化维度. 式 (17) 为 $\mathbf{x}_{trial,t}^n$ 生成过程, $\mathbf{y}_{trial,t}^n$ 生成过程与其一致.

$$\mathbf{x}_{trial,j,t}^n = \begin{cases} \tilde{\mathbf{x}}_{j,t+1}^n, & (\text{rand}_j(0, 1) \leq C_c) \text{ 或 } (j = j_{\text{rand}}) \\ \mathbf{x}_{j,t}^n, & \text{其他} \end{cases} \quad (17)$$

式中: $j=1, 2, \dots, \text{Dim}$; j_{rand} 表示区间 $[1, \text{Dim}]$ 中的随机整数; $\text{rand}_j(0, 1)$ 表示每个 j 随机取 0 和 1 之间均匀分布的值; 交叉率 $C_c \in [0, 1]$.

3) 选择操作: 采用贪婪准则从变异及交叉操作后得到的 n 个实验向量中选择出最佳个体, 计算过程如下:

$$\mathbf{x}_{t+1} = \begin{cases} \mathbf{x}_{trial,t}^*, & f(\mathbf{x}_{trial,t}^*) \leq f(\mathbf{x}_t) \\ \mathbf{x}_t, & \text{其他} \end{cases} \quad (18)$$

$$\mathbf{y}_{t+1} = \begin{cases} \mathbf{y}_{trial,t}^*, & f(\mathbf{y}_{trial,t}^*) \leq f(\mathbf{y}_t) \\ \mathbf{y}_t, & \text{其他} \end{cases} \quad (19)$$

式中: $\mathbf{x}_{trial,t}^*, \mathbf{y}_{trial,t}^*$ 分别为实验向量 $(\mathbf{x}_{trial,t}^n, \mathbf{y}_{trial,t}^n)$ 中的最优实验向量.

优化过程如图 4 所示, 首先初始化种群并随机生成 6 组超参数组合, 分别代入 CNN-SE-GRU 模型计算初始种群适应度, 找出当前最佳超参数组合并保存最优适应度值. 然后随机配对种群个体进行变异和交叉操作, 生成候选超参数并计算适应度值, 选择操作保留初始适应度与候选超参数适应度中更优的组合. 当适应度变化小于 1×10^{-8} 或达到最大迭代次数时算法终止. 最后利用最优超参数组合构建 CEO-CNN-SE-GRU 复合模型. 根据文献 [30] 将选定个体 $\mathbf{x}_t$ 和 $\mathbf{y}_t$ 的混沌初始搜索范围分别设定为 $[-0.5, 0.5]$ 和 $[-0.25, 0.25]$, 指数型离散忆阻器映射模型的参数 K 设定为 2.66; 适应度函数选择 CNN-SE-GRU 模型计算的 RMSE^[31]; CEO 算法中采用随机

交叉率,增强了算法搜索的多样性;优化维度 Dim 设置为 3;具体优化隐含层节点数、初始学习率和 L2 正则化系数,其范围分别定义为 $[10, 85]$ 、 $[0.001, 0.01]$ 和 $[0.000\ 1, 0.01]$ ^[32].




图 4 超参数优化结构

Fig.4 Hyperparametric optimised structures

2 模型性能评估实验与结果分析

2.1 实验方案

2.1.1 评价指标

短路电流过零点预测属于回归任务,通常选取决定系数(R^2)、均方根误差(RMSE)和平均绝对误差(MAE)作为模型评价指标。

R^2 表示模型真实波形与预测波形之间的整体拟合优度,越接近 1 代表模型的拟合效果越好。计算方法如式(20)所示,其中, y_i 表示真实值, $\hat{y}_i$ 表示预测值, $\bar{y}_i$ 为真实值的平均值。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (20)$$

RMSE通过计算真实值与预测值之间的偏差来评估模型性能,主要衡量模型的预测精度,其值越接近 0,表示模型性能越好,计算表达式为:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (21)$$

MAE是预测值与真实值绝对差值的平均值,能直观地反映模型预测值和真实值之间的差距大小,计算表达式为:

$$\text{MAE} = \frac{1}{n} |y_i - \hat{y}_i| \quad (22)$$

此外,为评估模型在过零点时刻和极值幅值处的相对预测精度,引入平均相对误差(MRE),计算公式为:

$$\text{MRE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (23)$$

2.1.2 模型训练与过零点预测

利用 CEO-CNN-SE-GRU 复合模型对短路电流进行预测前,需要通过短路电流数据集对复合模型进行训练。然而短路故障发生后,由于故障类型、系统阻抗差异以及短路点位置不同,短路电流幅值差异较大,会增加模型训练难度甚至导致模型无法收敛。因此,提前对原始数据集进行归一化处理,将所有短路电流数据缩放到 $[0, 1]$ 内。计算公式为:

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (24)$$

式中: x 为原始数据集中的短路电流数据; $x_{\min}$ 、 $x_{\max}$ 分别为原始数据集中的最小值和最大值; x_{norm} 为归一化后的数据。

选择复合模型参数时,主要针对 CNN 的卷积层、GRU 的隐含层节点数和 SE 注意力机制的全连接层进行设置。模型参数设置如表 1 所示。

表 1 CEO-CNN-SE-GRU 模型参数

Tab.1 CEO-CNN-SE-GRU model parameters

模型参数	取值
GRU 隐含层节点数	10~85
初始学习率	0.001~0.01
L2 正则化系数	0.000 1~0.01
卷积层	2
卷积核大小	3×1
学习率调整因子	0.1
输入步长	20
移动步长	1
输出步长	360

图 5 为复合模型训练流程,首先对短路电流样本数据进行预处理并按 7:3 划分为训练集和测试集。其次初始化 CEO 算法,利用生成的 6 组候选超参数构建 CNN-SE-GRU 模型并进行适应度评估。随后 CEO 更新算子生成新的候选超参数组合并循环优化,当满足适应度变化小于 1×10^{-8} 或达到最大迭代次数时,则输出最优参数组合。最后利用最优参数重新构建 CNN-SE-GRU 复合多步预测模型,并利用测试集进行性能评估。

图 6 为基于复合模型的短路电流过零点预测流程。首先实时采集短路电流并进行数据预处理;其次




图5 CEO-CNN-SE-GRU 训练流程
Fig.5 CEO-CNN-SE-GRU training flow

调用训练好的最优 CNN-SE-GRU 模型预测过零点，然后通过线性插值法进行计算，最后输出精确过零点时刻。



图6 复合模型零点预测流程
Fig.6 Composite model zero prediction flow

2.1.3 模型验证

本文利用短路电流表达式随机生成8组故障波形并添加随机白噪声作为数据集，将每组数据前

70% 作为训练集，后 30% 作为测试集。每组波形长度为 100 ms，采样频率为 10 kHz，采样窗口设置为 2 ms，预测窗口设置为 36 ms。

为了进一步验证复合模型在实际工况下预测短路电流过零点的准确性，本文开展短路分断实验，现场采集故障波形数据。实验现场如图 7 所示，关键设备型号见表 2。




图7 实验现场图
Fig.7 Experiment scene image

表2 短路实验设备型号

Tab.2 Short-circuit experimental equipment models

设备名称	型号
冲击变压器	ISJ-10000/11
高压阻抗	I-10 kV/4 kA
数据采集处理系统	CY2009
人工中性点	SGFR-1140
选相开关	ZHN-10

实验设定系统频率为 50 Hz，测试电压为 410 V。断路器额定电流为 40 A，过载长延时整定值 I_t 为 40 A，短路短延时整定值 I_{sd} 为 80 A，非脱扣时间为 20 ms，最大分断时间为 80 ms。实验前调整阻抗装置设置好短路电流参数，断路器接入实验线路并合闸。实验中，将冲击变压器作为可控电源，配合高压阻抗和负载阻抗模拟电网阻抗特性，共同限制短路电流幅值；在故障模拟方面，通过选项开关切换组合状态，模拟不同类型的短路故障工况，人工中性点在单相接地故障测试中提供可靠接地；测量方面，高精度霍尔传感器将转换后的电压信号传输到数据采集处理系统，进而输出短路电流波形。整个实验

通过电气实验控制台控制启动和停止,并实时显示电压电流波形.实验全程通过温湿度计监测环境条件,为后续数据校正提供环境参数依据,提高实验数据的可靠性.

为了验证复合模型的预测性能,分别构建了GRU、CNN-GRU和CNN-SE-GRU三种对比模型,并将隐含层节点数、初始学习率及L2正则化系数分别设置为85、0.001和0.000 1,其余参数参照表1设定.复合模型利用CEO算法优化超参数时收敛曲线,如图8所示,适应度值从75降低至54,性能提升了28%.优化后的GRU隐含层节点数为82,初始学习率为0.009,L2正则化系数为 1.404×10^{-4} .




图8 CEO算法收敛曲线

Fig.8 CEO algorithm convergence curve

图9为利用最优参数构建的复合模型与三个对比模型性能指标对比.数据显示,经特征增强与超参数优化后的复合模型预测效果最佳,其 R^2 相比GRU、CNN-GRU和CNN-SE-GRU模型分别提升了7.57、3.59和0.37个百分点.CNN-GRU模型结合了卷积层提取的短路电流局部特征和GRU层捕获的长期依赖关系, R^2 提高了3.98个百分点.SE注意力机制的引入使CNN层提取的特征分配了权重,更聚焦关键特征并抑制了干扰信息,模型 R^2 从CNN-GRU模型的89.87%提升到93.09%,提升了3.22个百分点.

2.2 模型性能评价结果分析

2.2.1 准确性分析

模型训练结束后,保存最优模型权重以及归一化参数.在短路电流过零点预测阶段,调用训练好的模型进行多步预测.四种模型短路电流预测值与真实值波形对比如图10所示,横坐标为短路持续时间,纵坐标为短路电流值.表3和表4是零点及峰值误差统计结果.




图9 不同模型性能指标对比

Fig.9 Comparative analysis of performance metrics across different models




图10 多模型预测结果对比

Fig.10 Comparison of multi-model prediction results

结合图10和表3可知,GRU模型零点预测误差最大,平均绝对误差为0.3 ms,平均相对误差为2.71%;利用CNN模块对短路电流进行局部特征提取后零点平均绝对误差降低到0.07 ms,平均相对误差仅为0.66%;相比GRU模型,CNN-GRU模型零点平均绝对误差由0.30 ms降至0.07 ms,降低了76.7%,约为GRU模型的1/4;注意力机制计算了CNN通道权重,实现了特征加权,平均绝对误差相对于GRU模型降低了50%.引入CEO优化算法进行超参数优化后,模型性能最佳,零点平均相对误差

表3 不同模型零点真实值与预测值对比
Tab.3 Comparison of actual values and predicted values at zero points across different models

参数	真实值	预测值			
		GRU	CNN-GRU	CNN-SE-GRU	CEO-CNN-SE-GRU
t_1 时刻/ms	5.14	5.54	5.05	4.93	5.06
t_2 时刻/ms	17.15	17.39	17.08	17.11	17.14
t_3 时刻/ms	25.41	25.27	25.29	25.11	25.24
t_4 时刻/ms	36.93	37.34	36.93	36.98	36.98
平均绝对误差/ms	—	0.30	0.07	0.15	0.08
平均相对误差/%	—	2.71	0.66	1.41	0.60

表4 不同模型极值真实值与预测值对比
Tab.4 Comparison of actual values and predicted values at extreme points across different models

参数	真实值	预测值			
		GRU	CNN-GRU	CNN-SE-GRU	CEO-CNN-SE-GRU
P_1 /A	436.69	476.20	420.22	434.55	437.00
P_2 /A	-243.61	-234.02	-232.66	-226.03	-231.20
P_3 /A	412.07	455.63	401.69	423.60	415.47
平均绝对误差/A	—	30.89	12.60	10.42	5.37
平均相对误差/%	—	7.85	3.60	3.50	2.00

达到了最低,比CNN-GRU模型降低了9.09%,平均绝对误差增加了0.01 ms;

由图10和表4可知,GRU模型极值处平均绝对误差达到30.89 A,平均相对误差为7.85%;引入CNN模块后,模型的极值预测性能显著提升,平均绝对误差降低至12.60 A,平均相对误差降至3.60%,相比GRU模型极值预测精度提升了54%;融合注意力机制的CNN-SE-GRU模型在极值预测方面进一步提升,平均绝对误差降低到10.42 A,平均相对误差降至3.50%,相比CNN-GRU模型有小幅提升;CNN-SE-GRU模型结合CEO优化算法后极值预测能力大幅提升,平均绝对误差仅为5.37 A,平均相对误差降至2.00%,相比CNN-GRU模型提升了44%.

为了进一步分析复合模型过零点预测的准确性,本文利用实验波形数据进行验证,预测结果如图11所示.其中黑色实线为采集到的实验数据波形,蓝绿色与红色虚线分别是复合模型输入的数据及预测结果,由图可知,模型整体预测效果较好, t_3

处真实值和预测值基本重合.复合模型预测实验波形零点与极值误差对比统计结果如表5、表6所示, t_1 时刻处零点相对误差最大,达到3.67%,而 t_3 时刻处零点相对误差仅为0.06%,预测波形中零点平均绝对误差为0.18 ms,平均相对误差为1.45%;极大值 P_2 、 P_4 的平均相对误差比极小值 P_1 、 P_3 处平均相对误差降低了58%,四个极值点的平均相对误差为5.89%;结合图11和表5可知,复合模型平均零点绝对误差在0.2 ms以内,且极值偏差较小,验证了复合模型预测短路电流过零点的准确性.




图11 复合模型预测实验波形

Fig.11 Hybrid model predicted experimental waveform

表5 复合模型预测实验波形零点误差
Tab.5 Zero-point value errors in experimental waveforms predicted by the hybrid model

参数	真实值/ms	预测值/ms	绝对误差/ms	相对误差/%
t_1 时刻	10.89	10.49	0.40	3.67
t_2 时刻	20.81	20.68	0.13	0.62
t_3 时刻	30.81	30.83	0.02	0.06

表6 复合模型预测实验波形极值误差
Tab.6 Extreme value errors in experimental waveforms predicted by the hybrid model

参数	真实值/A	预测值/A	绝对误差/A	相对误差/%
P_1	-531.90	-484.54	47.36	8.90
P_2	516.24	500.63	15.61	3.02
P_3	-527.84	-487.35	40.49	7.67
P_4	519.14	498.56	20.58	3.96

综上所述,GRU模块捕捉故障波形长期依赖关系结合CNN模块提取短路电流局部特征后,增强了特征提取效果,提升了零点和极值处的预测精度;SE注意力机制对CNN层提取的局部特征分配权重,提高了模型的总体拟合优度,改善了极值偏差,但

使零点处的误差略有增大. CEO 优化算法通过优化超参数,使模型性能达到最佳,显著协调了各模块优势,在保持零点预测精度的同时,提升了极值预测能力,验证了基于 CEO 优化的 CNN-SE-GRU 模型在短路电流过零预测任务中的准确性.

2.2.2 快速性分析

短路故障发生后,复合预测模型需要在继电保护动作之前预测出短路电流过零点.预测的快速性既影响断路器相控分断短路故障的实现,又为机构动作时间提供必要的安全裕量,确保短路故障的快速切除.

为了验证复合模型预测过零点的快速性,首先调用训练好的最优复合模型并加载归一化参数;接着利用短路故障发生前 2 ms(20 个采样点)预测未来 36 ms 故障波形;随后对预测波形进行线性插值计算,获得精确零点时刻信息;最后统计从输入历史数据到输出零点预测结果的总耗时,验证模型预测过零点的快速性.

GRU 网络在继承 LSTM 网络时序建模能力的同时,减少了门控数量.使用 LSTM 模型递归预测过零点时,预测时间受限于门控数量和预测步数^[33];复合多步预测模型采用多输入多输出(MIMO)策略,预测时间与历史时间步和门控数量等有关,数据从输入层经过 GRU 层再到输出层进行一次完整计算,随后输出多步预测结果,避免了递归预测中的误差累积并缩短了预测时间^[34].图 12 为调用 LSTM 模型递归策略与复合模型 MIMO 策略预测 300 组短路电流过零点的预测时间统计结果.

其中图 12(a)的 LSTM 模型递归策略总体预测时间小于 700 ms,平均预测时间为 635 ms,整体预测时间较为分散;图 12(b)复合模型的 MIMO 策略平均预测时间为 15.78 ms,最小预测时间为 14 ms.相比 LSTM 模型递归预测,复合模型多步预测平均耗时降低了 97.51%,可见基于 MIMO 策略的复合多步预测模型缩短了预测时间,验证了该模型预测短路电流过零点的快速性.

2.2.3 适应性分析

实际工况中系统结构、故障类型及故障点位置等都会影响故障波形^[35].本文依照表 7 所示的参数范围,随机改变基波和各次谐波分量幅值、相角及非周期分量衰减常数等,生成 140 组短路故障电流样本.图 13 为复合多步预测模型 4 个零点预测误差分布情况,由图可知:各零点预测误差均在 0.63 ms 以内,零点 3 处平均预测误差最大,达到 0.39 ms;零




图 12 模型预测时间统计

Fig.12 Statistical analysis of model prediction time

点 4 处平均预测误差最小,仅为 0.14 ms,四个零点总体平均预测误差为 0.26 ms.

表 7 短路故障样本参数设定

Tab.7 Short circuit fault sample parameter setting

参数	取值下限	取值上限
工频基波分量幅值 A_1/A	310	340
二次谐波分量幅值 A_2/A	0	$0.1A_1$
三次谐波分量幅值 A_3/A	0	$0.05A_1$
高次谐波分量幅值 A_H/A	0	$0.03A_1$
相位 φ/rad	0	2π
衰减常数 T_a/ms	60	120
系统频率 f/Hz	49.7	50.3
信噪比 SNR/dB	20	50

图 14 根据 140 组故障样本预测结果,分别统计了衰减常数、周期分量幅值、短路故障发生相位和系统频率波动对零点和极值处预测误差的影响,可以看出,各种参数条件下零点平均预测误差均在 0.3 ms 以内,而极值预测误差与各参数变化相关性较强,整体误差范围在 10~40 A,平均预测误差约为 20 A;具体来看,图 14(c)故障发生相位改变对零点预测误差影响最小,变化幅度为 0.11 ms,而图 14(b)周期分量幅值变化对零点预测影响最大,变化幅度达到 0.16 ms.

为了进一步探究模型的抗噪性能,本文从 140




图13 复合模型预测误差统计
Fig.13 Statistical analysis of prediction errors in the hybrid model




图14 复合模型预测误差影响分析
Fig.14 Impact analysis of prediction errors in the hybrid model

组故障样本中随机选取 40 组, 分别添加 20~50 dB 白噪声, 模型预测误差统计结果如图 15 所示: 在所有噪声条件下, 模型预测误差均在 0.6 ms 以内, 20 dB 时平均误差最大为 0.32 ms, 50 dB 时平均预测误差降低至 0.26 ms. 可见, 模型在不同噪声环境下都能表现出良好的预测性能, 即使在 20 dB 的恶劣环境下, 平均预测误差依旧在 0.32 ms 以内, 体现了模型较强的抗噪性能.




图 15 复合模型噪声影响

Fig.15 Analysis of noise effects on the hybrid model

复合模型在频率、衰减常数、周期分量幅值和故障相角等参数变化情况下预测精度都较为稳定, 平均预测误差控制在 0.32 ms 以内, 并且模型抗噪性能良好, 体现了复合模型对不同故障情况下短路电流零点预测较强的适应性.

表 8 为不同短路电流预测算法所需采样时间及其对应零点预测误差对比, 由表可知, 相比其他算法, CEO-CNN-SE-GRU 复合模型预测算法在保证预测精度的同时, 缩短了采样时间; 结合多步策略, 提高了短路电流零点预测的快速性、准确性.

表 8 不同预测算法采样时间和预测误差

Tab.8 Sampling time and prediction error of different prediction algorithms

短路电流零点预测算法	采样时间/ms	预测误差/ms
加权最小均方差(WLMS)算法	10	±1
改进半波傅氏算法	$10+2/f_s$	±1
递推最小二乘(RLS)算法	15	±0.2
改进快速傅里叶算法	14	0.51
半周期消除预测算法	15	±0.2
渐消卡尔曼滤波算法	4	±0.5
长短期记忆(LSTM)网络算法	3	±0.5
CEO-CNN-SE-GRU 复合模型预测算法	2	±0.32

3 结论

本文提出一种基于 CEO 优化的 CNN-SE-GRU 复合模型短路电流过零点预测方法, 仿真与实验相结合验证了复合模型预测过零点的快速性和准确性, 主要结论为:

1) CEO-CNN-SE-GRU 复合模型将采样时间缩短至 2 ms, 解决了传统预测方法采样时间过长问题; 平均预测时间为 15.78 ms, 相比 LSTM 网络递归预测方法预测耗时降低了 97.51%; 验证了复合模型短路电流过零点预测的快速性.

2) CNN 模块的引入使零点预测误差降低了 76.7%, SE 注意力机制增强了极值处预测能力, CEO 算法进一步提高了预测精度, 各模块协同配合使复合预测模型 R^2 提升至 0.934 6, 较 GRU 模型提升了 7.57 个百分点, RMSE 和 MAE 降幅均超 30%; 实验波形过零点预测平均绝对误差为 0.18 ms, 平均相对误差为 1.45%, 极值点平均相对误差为 5.89%; 验证了特征协同提取与增强结合参数优化算法在短路电流零点预测任务中的准确性.

3) 复合模型在不同频率、衰减常数、周期分量幅值和故障相位下均表现稳定, 平均预测误差在 0.32 ms 以内; 在 20~50 dB 噪声环境下能保持较高预测精度, 展现了模型对不同故障工况下短路电流零点预测较强的适应性, 能为断路器精准相控分断短路故障电流提供理论支撑.

参考文献

[1] KASIKCI I. Short circuits in power systems: a practical guide to IEC 60909-0[M]. Hoboken: John Wiley & Sons, 2018:167-173.

[2] GUAN C, DING J G, YAO X F, et al. Study on short-circuit current interruption characteristics of double-break fast vacuum circuit breaker within the minimum arcing time[J]. International Journal of Electrical Power & Energy Systems, 2023, 147: 108865.

[3] 段雄英, 黄智慧, 廖敏夫, 等. 基于全响应算法的故障电流相控开断研究[J]. 高电压技术, 2014, 40(8): 2264-2270.

DUAN X Y, HUANG Z H, LIAO M F, et al. Research of controlled fault interruption based on complete response method [J]. High Voltage Engineering, 2014, 40(8): 2264-2270. (in Chinese)

[4] PANOIU C, CIULICA D, PANOIU M, et al. Research based on

- modeling and simulation of the transient regime in controlled switching with high power switches[J]. *Machines*, 2021, 9(5): 99.
- [5] 马飞越, 魏莹, 李龙启, 等. 基于Prony算法的高直流分量短路故障电流相控开断研究[J]. *电工电能新技术*, 2025, 44(4): 91-99.
- MA F Y, WEI Y, LI L Q, et al. Study on phase-controlled interruption of high DC component short-circuit fault currents based on Prony algorithm[J]. *Advanced Technology of Electrical Engineering and Energy*, 2025, 44(4): 91-99. (in Chinese)
- [6] POLTL A, FROHLICH K. A new algorithm enabling controlled short circuit interruption [J]. *IEEE Transactions on Power Delivery*, 2003, 18(3): 802-808.
- [7] POELTL A, FROHLICH K. Two new methods for very fast fault type detection by means of parameter fitting and artificial neural networks[J]. *IEEE Transactions on Power Delivery*, 1999, 14(4): 1269-1275.
- [8] THOMAS R P, SOLVER C E. A method for controlled fault interruption for use with HV SF6 circuit breakers[C]//2007 IEEE Lausanne Power Tech. July 1-5, 2007, Lausanne, Switzerland. IEEE, 2008: 1135-1140.
- [9] 袁召, 罗楚军, 方春恩, 等. 基于半波Fourier算法的故障选相控制系统的设计[J]. *高电压技术*, 2013, 39(4): 869-875.
- YUAN Z, LUO C J, FANG C E, et al. Design of control system for controlled fault interruption based on half-wave Fourier algorithm [J]. *High Voltage Engineering*, 2013, 39(4): 869-875. (in Chinese)
- [10] 黄智慧, 段雄英, 邹积岩, 等. 基于改进RLS算法的故障电流参数估计[J]. *中国电机工程学报*, 2014, 34(15): 2460-2469.
- HUANG Z H, DUAN X Y, ZOU J Y, et al. Fault current parameter estimation based on adaptive RLS algorithm [J]. *Proceedings of the CSEE*, 2014, 34(15): 2460-2469. (in Chinese)
- [11] 黄智慧, 张冬波, 邹积岩, 等. 基于改进RLS算法的短路电流相控开断控制系统设计[J]. *高电压技术*, 2016, 42(10): 3214-3220.
- HUANG Z H, ZHANG D B, ZOU J Y, et al. Design of control system for controlled fault interruption based on adaptive RLS algorithm[J]. *High Voltage Engineering*, 2016, 42(10): 3214-3220. (in Chinese)
- [12] YANG X, LONG Q, LI H, et al. Controlled fault current interruption scheme for improved fault prediction accuracy [J]. *Applied Sciences*, 2025, 15(6): 3106.
- [13] 荣文帅, 蔡志远. 断路器同步分断短路电流零点预测方法研究[J]. *电工技术学报*, 2019, 34(15): 3167-3174.
- RONG W S, CAI Z Y. Research on zero prediction method of synchronous breaking short circuit current of breaker [J]. *Transactions of China Electrotechnical Society*, 2019, 34(15): 3167-3174. (in Chinese)
- [14] WAN A P, CHANG Q, AL-BUKHAITI K, et al. Short-term power load forecasting for combined heat and power using CNN-LSTM enhanced by attention mechanism[J]. *Energy*, 2023, 282: 128274.
- [15] 李文英, 杨高才, 文明, 等. 基于时空图注意力的短期电力负荷预测方法[J]. *湖南大学学报(自然科学版)*, 2024, 51(2): 57-67.
- LI W Y, YANG G C, WEN M, et al. A short-term power load forecasting method based on spatiotemporal graph attention [J]. *Journal of Hunan University (Natural Sciences)*, 2024, 51(2): 57-67. (in Chinese)
- [16] YE R K, WANG H F, BASHIR T, et al. Fast and accurate method for short-circuit current calculation in distribution network with IIDGs[J]. *International Journal of Electrical Power & Energy Systems*, 2024, 155: 109622.
- [17] 陈俊杰, 缪希仁. 基于二维云模型的短路电流峰值预测[J]. *电力系统保护与控制*, 2018, 46(23): 94-101.
- CHEN J J, MIAO X R. Short circuit current peak prediction based on two-dimensional cloud model[J]. *Power System Protection and Control*, 2018, 46(23): 94-101. (in Chinese)
- [18] 黄旭, 何洪英, 罗滇生, 等. 一种新的短路电流预测方法[J]. *电力系统及其自动化学报*, 2017, 29(1): 24-29.
- HUANG X, HE H Y, LUO D S, et al. A novel prediction method of short-circuit current [J]. *Proceedings of the CSU-EPSA*, 2017, 29(1): 24-29. (in Chinese)
- [19] ZHENG X, WANG H F, JIANG K, et al. A novel machine learning-based short-circuit current prediction method for active distribution networks[J]. *Energies*, 2019, 12(19): 3793.
- [20] 陈建明, 张盼盼. 灰色BP神经网络模型在电力系统短路电流峰值预测中的应用[J]. *轻工学报*, 2018, 33(4): 79-85.
- CHEN J M, ZHANG P P. Application of grey BP neural network model in short circuit current peak prediction of power system[J]. *Journal of Light Industry*, 2018, 33(4): 79-85. (in Chinese)
- [21] ALJARRAH R, AL-OMARY M, ALSHABI D, et al. Application of artificial neural network-based tool for short circuit currents estimation in power systems with high penetration of power electronics-based renewables [J]. *IEEE Access*, 2023, 11: 20051-20062.
- [22] 黄吕超, 张露阳, 胡源源, 等. 基于长短期记忆网络的短路电流过零点预测方法[J]. *高电压技术*, 2023, 49(12): 5022-5031.
- HUANG L C, ZHANG L Y, HU Y Y, et al. Fast prediction method of short-circuit current zero based on an algorithm of long short term memory[J]. *High Voltage Engineering*, 2023, 49(12): 5022-5031. (in Chinese)
- [23] VEERAMSETTY V, EDUDODLA B R, SALKUTI S R. Zero-crossing point detection of sinusoidal signal in presence of noise and harmonics using deep neural networks[J]. *Algorithms*, 2021, 14(11): 329.
- [24] 李冬辉, 赵墨刊, 高龙. 基于CNN-GRU的冷水机组传感器偏差故障诊断方法[J]. *湖南大学学报(自然科学版)*, 2022, 49(2): 74-82.
- LI D H, ZHAO M K, GAO L. Fault diagnosis method of chiller sensor deviation based on CNN-GRU [J]. *Journal of Hunan*

- University (Natural Sciences), 2022, 49(2): 74–82. (in Chinese)
- [25] 李硕士, 刘洪瑞, 甘永东, 等. 基于残差密集块与注意力机制的图像去雾网络[J]. 湖南大学学报(自然科学版), 2021, 48(6): 112–118.
- LI S S, LIU H R, GAN Y D, et al. Image dehazing network based on residual dense block and attention mechanism[J]. Journal of Hunan University (Natural Sciences), 2021, 48(6): 112–118. (in Chinese)
- [26] 吴晓建, 危一华, 王爱春, 等. 基于融合Dropout与注意力机制的LSTM-GRU车辆轨迹预测[J]. 湖南大学学报(自然科学版), 2023, 50(4): 65–75.
- WU X J, WEI Y H, WANG A C, et al. Vehicle trajectory prediction based on LSTM-GRU integrating Dropout and attention mechanism[J]. Journal of Hunan University (Natural Sciences), 2023, 50(4): 65–75. (in Chinese)
- [27] 王漫漫, 邹斌, 石立坚, 等. 基于LSTM的北极海冰范围多步预测策略研究[J]. 海洋预报, 2025, 42(1): 11–22.
- WANG M M, ZOU B, SHI L J, et al. Research on multi-step prediction strategies of Arctic sea ice extent based on LSTM[J]. Marine Forecasts, 2025, 42(1): 11–22. (in Chinese)
- [28] BEN TAIEB S, BONTEMPI G, ATIYA A F, et al. A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition[J]. Expert Systems with Applications, 2012, 39(8): 7067–7083.
- [29] 徐世昌, 杨文安, 鄢雪峰. 五轴机床后处理非线性误差精确插补算法[J]. 机械制造与自动化, 2024, 53(6): 47–52.
- XU S C, YANG W A, YAN X F. Accurate interpolation algorithm for nonlinear errors in post-processing of five-axis machine tools[J]. Machine Building & Automation, 2024, 53(6): 47–52. (in Chinese)
- [30] DONG Y C, ZHANG S H, ZHANG H L, et al. Chaotic evolution optimization: a novel metaheuristic algorithm inspired by chaotic dynamics[J]. Chaos, Solitons & Fractals, 2025, 192: 116049.
- [31] 张登攀, 兰征, 杜怡衡. 基于PCHIP-VMD数据分析与SSA-LSTM模型的短期风电功率预测[J]. 电子测量与仪器学报, 2025, 39(5): 251–261.
- ZHANG D P, LAN Z, DU Y H. Short-term wind power forecasting based on PCHIP-VMD dataanalysis and SSA-LSTM model[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5): 251–261. (in Chinese)
- [32] 黄凯, 郝润凯, 郭永芳. 基于特征综合评价和模型优化的锂离子电池健康状态估计方法[J]. 电力系统及其自动化学报, 2025, 37(5): 131–140.
- HUANG K, HAO R K, GUO Y F. State-of-health estimation method for lithium-ion battery based on comprehensive feature evaluation and model optimization[J]. Proceedings of the CSU-EPSA, 2025, 37(5): 131–140. (in Chinese)
- [33] 黄吕超, 杨黄屯, 崔明涛, 等. 基于自学习的LSTM网络短路电流零点预测方法[J]. 电工电能新技术, 2024, 43(2): 78–86.
- HUANG L C, YANG H T, CUI M T, et al. A method for predicting short circuit current zeros in LSTM networks based on self-learning[J]. Advanced Technology of Electrical Engineering and Energy, 2024, 43(2): 78–86. (in Chinese)
- [34] DE STEFANI J, BONTEMPI G. Factor-based framework for multivariate and multi-step-ahead forecasting of large scale time series[J]. Frontiers in Big Data, 2021, 4: 690267.
- [35] TAO C X, XING B S, LI T G. A fault location method for hybrid transmission lines based on empirical Fourier decomposition[J]. Archives of Electrical Engineering, 2023: 1035–1053.