

基于改进龙卷风优化算法的谐波阻抗估计方法

夏焰坤¹, 郑高萍¹, 黄 鹏², 张 恒¹, 周 杭¹

(1. 西华大学 电气与电子信息学院, 四川 成都 610039; 2. 国网宜宾供电公司, 四川 宜宾 644000)

摘 要: 针对系统侧谐波阻抗在电网运行方式变化及电容器投切等工况下发生突变, 且在背景谐波波动较大时估计精度下降的问题, 提出一种基于改进龙卷风优化算法优化深度混合核极限学习机(DHKELM)的谐波阻抗估计方法。首先, 为削弱背景谐波和异常值的影响, 采用最大信息系数(MIC)筛选谐波电压和谐波电流幅值强相关性数据; 其次, 根据 PELT 算法检测出的阻抗粗估值突变点对谐波数据样本进行划分。最后, 对每段谐波数据分别使用 DHKELM 估计得到系统侧谐波阻抗。此外, 为提高模型预测精度, 提出了一种基于多策略混沌和 Nelder-Mead 单纯形法改进的龙卷风优化算法 ITOC 对 DHKELM 模型的隐含层节点数、核参数和权重等进行优化。基于诺顿等效模型及 IEEE13 节点系统开展仿真, 并结合实测数据进行案例分析。结果表明: 在用户侧谐波阻抗非大于系统侧的情况下, 诺顿仿真中所提方法在不同背景谐波波动系数下阻抗估计的误差均较小; 在 IEEE13 节点系统仿真中, 幅值和相位估计的 RMSE 分别为 0.002Ω 和 0.058° ; 在实例分析中, 幅值和相位的 RMSE 分别为 0.03Ω 和 0.02° , 表现出较高的估计精度与稳定性。

关键词: 系统侧谐波阻抗; 最大信息系数; PELT 算法; 深度混合核极限学习机; 龙卷风优化算法

中图分类号: TM711; TP18 **文献标志码:** A **doi:** 10.13705/j.issn.1671-6833.2027.01.002

随着电力电子设备的大规模接入以及风电、光伏等可再生能源的高比例并网, 电网中非线性特性显著增强, 谐波问题日益突出, 已成为影响电能质量及电力设备安全运行的重要因素。谐波阻抗的准确估计及用户侧与系统侧谐波责任的合理划分, 是实现谐波有效管控与治理的前提^[1-2]。

现有的谐波阻抗估计方法包括干预式和非干预式两大类^[3-4]。干预式方法会改变设备的网络拓扑结构和运行状态, 会对电力系统造成干扰。非干预式方法则通过在公共连接点(point of common coupling, PCC)测量的谐波电压电流数据来估计谐波阻抗, 避免了对系统正常运行的影响, 因而应用得更为广泛。传统的非干预式方法包括波动量法^[5-6]、回归法^[7-8]和独立随机矢量法^[9]等。波动量法和回归法在背景谐波变化大的情况下误差较大。独立随机矢量法利用随机矢量协方差特性可以在背景谐波波动时一定程度上提高估计精度, 但当用户侧谐波阻抗非远大于系统侧时, 其准确性会降低。此外, 为提

升估计性能, 夏焰坤等^[10-11]引入改进极限学习机模型对谐波阻抗进行回归预测。

上述传统的谐波阻抗估计方法通常假设系统侧谐波阻抗恒定。然而在实际情况中, 系统侧谐波阻抗会由于短路故障、电网运行方式变化和电容器投切等各种原因而突然变化。针对系统侧谐波阻抗突变问题, 现有研究多采用数据分段的形式处理。夏焰坤等^[12]提出采用小波包能量谱方法对数据进行分解, 在能量突变点处划分数据段, 但对噪声敏感, 波动大的情况下易误检。Fan 等^[13]通过基于拉普拉斯混合模型估算效用端谐波阻抗。杨勇等^[14]提出使用二元分割的 Pettitt 方法对谐波阻抗突变点进行检验, 但是计算复杂度较高。刘青松等^[15]使用的贝叶斯突变检测通过概率推导的方式判定该时刻是否为阻抗突变点。然而, 上述方法多依赖于谐波阻抗粗估值进行突变识别, 易受背景谐波波动影响, 在背景谐波水平较高及两侧阻抗接近时难以保证分段准确性, 从而降低整体估计精度。此外, 现有研究对

收稿日期: 2026-06-10; 修订日期: 2026-07-03

基金项目: 国家自然科学基金资助项目(62203368)

作者简介: 夏焰坤(1984—), 男, 湖北黄冈人, 西华大学教授, 博士, 主要从事电力系统及电能质量分析方面研究, E-mail: yankunjtdx@163.com。

用户侧与系统侧谐波阻抗相对关系对估计性能的影响考虑不足。

针对上述问题,本文提出一种基于最大信息系数(maximum information coefficient, MIC)数据筛选和 PELT(pruned exact linear time)突变点检测的优化深度混合核极限学习机(deep hybrid kernel extreme learning machine, DHKELM)的系统侧谐波阻抗估计方法。首先,采用 MIC 对 PCC 处谐波电压和谐波电流数据进行相关性筛选;其次,使用 PELT 算法对系统侧谐波阻抗粗估值的突变位置进行定位并实现数据分段;最后,基于 DHKELM 对各分段数据进行阻抗回归,并引入基于多策略混沌和 Nelder-Mead 单纯形法改进的龙卷风优化算法(ITOC)对 DHKELM 模型参数进行优化。

1 基本原理

1.1 谐波阻抗估计模型

采用如图 1 所示的诺顿等效电路作为谐波分析的模型。 $\dot{V}_{\text{pcc}}$ 、 $\dot{I}_{\text{pcc}}$ 分别等效为公共连接点(PCC)处测量得到的谐波电压和谐波电流; Z_s 、 Z_c 分别等效为系统侧和用户侧谐波阻抗; $\dot{I}_s$ 、 $\dot{I}_c$ 分别等效为系统和用户侧谐波电流。




图 1 诺顿等效电路

Figure 1 Norton equivalent circuit

根据图 1 得其等效电路方程为

$$\dot{V}_{\text{pcc}} = \dot{I}_{\text{pcc}} Z_s + \dot{I}_s Z_s \quad (1)$$

背景谐波表示为

$$\dot{V}_s = \dot{I}_s Z_s \quad (2)$$

根据式(1)可知,背景谐波是回归法估计谐波阻抗产生误差的主要原因。当背景谐波波动较大时, $|\dot{V}_{\text{pcc}}|$ 和 $|\dot{I}_{\text{pcc}}|$ 相关性较弱,估计谐波阻抗的误差较大。因此,可通过筛选背景谐波平稳即 $|\dot{V}_{\text{pcc}}|$ 和 $|\dot{I}_{\text{pcc}}|$ 相关性较强的数据段进行谐波阻抗估计,减小背景谐波波动产生的误差。

为模拟背景谐波对谐波阻抗估计的影响,本文设置背景谐波波动系数 k 表示背景谐波波动程度:

$$|\dot{I}_s| = k |\dot{I}_c| \quad (3)$$

1.2 基于最大信息系数 MIC 数据筛选

最大信息系数 MIC 是一种用于衡量两个变量之间相关性的分析方法。对两变量的散点图先进行任意形式的网格划分,随后在每个格点内估算近似概率密度,并基于这些局部密度计算互信息,从而揭示变量间的相关性。MIC 具有稳健性,对于含有噪声谐波数据样本具有较好的鲁棒性。

采用 MIC 对公共连接点处的谐波电压和谐波电流进行相关性分析的过程^[16-17]如下。

设谐波电压样本集为 $U = \{u_i | i = 1, \dots, n\}$, 谐波电流样本集为 $I = \{i_i | i = 1, \dots, n\}$, 构建集合 $D = \{(u_i, i_i) | i = 1, \dots, n\}$, 其中 n 为样本数量。

给定一个网格 $G = (x, y)$, 将样本空间划分为 $x \times y$, 将 $D = \{(u_i, i_i)\}$ 中的 u_i 、 i_i 的值分别网格化到 x 、 y 中。谐波电压和电流的互信息计算公式为

$$\text{MI}(D|G) = \sum_{u \in U} \sum_{i \in I} p(u, i) \log_2 \frac{p(u, i)}{p(u)p(i)} \quad (4)$$

式中: $D|G$ 表示数据集 D 在网格 G 划分下所引入的概率分布; $p(u, i)$ 为 U 与 I 的联合概率密度; $p(u)$ 、 $p(i)$ 分别为 U 、 I 的边缘概率密度。

若网格数量是固定的,不同的网格划分方法会得到不同的互信息值,计算任何网格划分情况下所实现的最高可能互信息值作为 D 在网格 G 上的最大互信息:

$$\text{MI}^*(D, x, y) = \max \text{MI}(D|G) \quad (5)$$

随后,将不同网格 G 划分下的最大互信息进行归一化处理:

$$M(D)_{x,y} = \frac{\text{MI}^*(D, x, y)}{\log_2 \min\{x, y\}} \quad (6)$$

基于上式归一化处理后的标准化最大互信息,最大信息系数 MIC 定义如下:

$$\text{MIC}(D)_{x,y} = \max_{xy < B(n)} \{M(D)_{x,y}\} \quad (7)$$

为减少计算工作量,网格划分数受到限制 $xy < B(n)$, $B(n) = n^a$, $B(n)$ 为样本数 n 的函数。

1.3 基于 PELT 的谐波阻抗突变检测

在实际工况下,系统侧谐波阻抗会由于短路故障、电网运行方式变化和电容器投切等突发事件而产生明显的突变。由于阻抗突变的随机性,传统方法难以直接对其进行准确预测。本文根据突变点时间划分相对稳定的数据段分别进行阻抗估计以提高预测精度。因此准确定位出阻抗发生突变的时间点是本文所提谐波阻抗估计方法的关键。

忽略背景谐波的影响,系统侧谐波阻抗粗估值为

$$|Z_h| = \frac{|\dot{V}_{pec}|}{|\dot{I}_{pec}|} \quad (8)$$

本文采用 PELT 算法^[18]根据 $|Z_h|$ 进行突变点检测。PELT 算法使用动态规划来确定全局最优解,通过引入剪枝技术在保证准确检测的同时表现出最低的时间复杂度,有效地减少了冗余计算。此外,通过调整惩罚项,可以提高对噪声和异常值的鲁棒性。针对含有较多噪声的谐波数据具有较高的稳定性。

设计算所得谐波阻抗估值序列为 $z_{1:n} = (z_1, z_2, \dots, z_n)$, 假定存在 m 个突变点, 其位置 $\tau_{1:m} = (\tau_1, \tau_2, \dots, \tau_m)$, 将阻抗序列划分成 $m+1$ 个连续的段, 其中第 j 段表示为 $z_{(\tau_{j-1}+1):\tau_j}$ 。变化点检测可以表述为找到可行序列分割的优化问题^[19], 变点检测的目标函数表达式为

$$\min \left\{ \sum_{j=1}^{m+1} C(z_{(\tau_{j-1}+1):\tau_j}) + \beta f(m) \right\} \quad (9)$$

式中: $\beta f(m)$ 为一个考虑了分割的复杂性与过度拟合的惩罚项, 在 PELT 算法中, 惩罚项与突变点数量 m 呈线性相关, 因此该惩罚项可进一步表示为 βm , 其中 $\beta = p \log n$, p 为增加一个变化点所引入的额外参数的数量; C 为衡量一段数据与其统计模型拟合程度的成本函数, 对于数据样本的不同统计特征, 所选择的成本函数也相应变化。本文选择均值作为统计特征, 因此成本函数的表达式如下所示:

$$C(z_{(\tau_{j-1}+1):\tau_j}) = \sum_{i=\tau_{j-1}+1}^{\tau_j} (z_i - \bar{z}_{(\tau_{j-1}+1):\tau_j})^2 \quad (10)$$

式中: $\bar{z}_{(\tau_{j-1}+1):\tau_j}$ 表示 $z_{(\tau_{j-1}+1):\tau_j}$ 这段序列的平均值。

PELT 采用最优分割方法作为目标函数, 通过动态规划方法迭代计算最优变化点位置^[19]。迭代过程如下所示:

$$\begin{aligned} F(s) &= \min_{\tau \in \tau_s} \left\{ \sum_{j=1}^{m+1} [C(z_{(\tau_{j-1}+1):\tau_j}) + \beta] \right\} = \min_t \\ &\left\{ \min_{\tau \in \tau_t} \sum_{j=1}^{m+1} [C(z_{(\tau_{j-1}+1):\tau_j}) + \beta] + C(z_{(t+1):n}) + \beta \right\} = \\ &\min_t \{ F(t) + C(z_{(t+1):n}) + \beta \} \quad (11) \end{aligned}$$

这个递归过程可依次求解 $F(s)$, $s = 1, 2, \dots, n$ 。在此过程中, 算法会存储每个步骤的最佳分割, 有效跟踪所有已识别变化点的数量和位置。

PELT 算法的剪枝策略旨在减少可能的候选变化点位置的数量, 其本质是将永远不会成为最小值的 τ 从每次最小化迭代中去除, 从而降低计算复杂度^[20]。假设存在一个常数 K , 使得所有 $t < s < T$ 满足:

$$C(z_{(t+1):s}) + C(z_{(s+1):T}) + K \leq C(z_{(t+1):T}) \quad (12)$$

如果

$$F(t) + C(z_{(t+1):s}) + K \geq F(s) \quad (13)$$

成立, 那么对于任何 $T > s$, T 之前的最近突变点位于 s 的最佳分割优于将该突变点位于 t 的任何分割。

1.4 基于 ITOC 优化 DHKELM 模型

1.4.1 深度混合核极限学习机 DHKELM

深度混合核极限学习机 DHKELM 以 ELM-AE 作为基本模块, 采用贪婪式的逐层无监督预训练对输入进行表征学习, 从而抽取原始数据的高层次特征。HKELM 作为回归层, 解决复杂的非线性问题, 提高预测精度。DHKELM 模型的构建过程^[21-23]如下。

(1) 在 ELM-AE 模型中随机生成输入层和隐藏层之间的正交参数 (a_n, b_n) 。

(2) 计算 ELM-AE 模型中每个隐藏层的输出矩阵 h_n 和输出权重 β_n

$$h_n = g(a_n x + b_n); \quad (14)$$

$$\beta_n = \left(\frac{E}{C} + (h_n)^T h_n \right)^{-1} (h_n)^T \quad (15)$$

式中: a_n 为随机输入权重; b_n 为偏置; x 为输入数据矩阵; $g(\cdot)$ 为激活函数; E 为单位矩阵; C 为正则化参数。

(3) 更新输出矩阵 h_n , 将上一层的 h_n 作为当前层 ELM-AE 的输入矩阵 h_{n+1} 。

$$h_{n+1} = g(\beta_{n+1}^T h_n), n = 0, 1, \dots, m-1 \quad (16)$$

(4) 为克服传统 ELM 随机参数初始化带来的不稳定性, 引入混合核函数 K_{mix} , 通过计算训练样本间的非线性相似度构建全局核矩阵 f_{KELM} , 以此替代随机隐层特征映射。基于此, DHKELM 模型的输出权重与最终决策函数分别表示为

$$\beta = \left(\frac{E}{C} + f_{\text{KELM}} \right)^{-1} h_n; \quad (17)$$

$$f(x) = \begin{bmatrix} K_{\text{mix}}(x, x_1) \\ \vdots \\ K_{\text{mix}}(x, x_N) \end{bmatrix} \left(\frac{E}{C} + f_{\text{KELM}} \right)^{-1} Z \quad (18)$$

式中: K_{mix} 为混合核函数, 采用线性加权策略对高斯核与多项式核进行融合, 增强模型的拟合与泛化能力, 并结合不同核在各类问题上的优势; Z 为目标标签矩阵。

1.4.2 龙卷风优化算法 TOC

龙卷风优化算法是 Braik 等^[24]在 2025 年提出的一种元启发式算法, 受自然雷暴和风暴通过科里奥利力演变为龙卷风的自然启发。TOC 算法通过数学建模, 模拟了风暴和雷暴形成龙卷风的行为步骤, 主要的数学模型见[24]。

1.4.3 改进龙卷风优化算法 ITOC

为提高龙卷风优化算法对 DHKELM 模型参数的寻优性能,对传统龙卷风优化算法进行改进。改进的 ITOC 算法通过混沌初始化提高初始种群质量,增强个体初始分布的随机性与均匀性,并在后期结合 Nelder-Mead 单纯形法增强局部搜索能力,从而平衡全局探索和局部开发,提高收敛精度和速度。

TOC 算法采用随机初始化种群初始化方式易导致个体聚集,最终影响算法的局部开发和全局探索能力。为提升 TOC 算法初始化阶段的表现,采用多策略混沌系统 MSCS 对 TOC 算法进行种群初始化,具体形式如下所示:

$$y_i = lb + F_{MSCS}(\delta, z_i) \cdot (ub - lb)。 \quad (19)$$

式中: y_i 为第 i 个个体; $F_{MSCS}(\delta, z_i)$ 表示多策略混沌系统; ub 、 lb 分别为搜索空间的上下限。

多策略混沌系统由 Logistic 混沌映射 $f_1(\mu, z_i)$ 和 sine 混沌映射 $f_2(a, z_i)$ 组成^[25],实现复杂而均匀的混沌行为:

$$f_1(\mu, z_i) = \mu z_i(1 - z_i); \quad (20)$$

$$f_2(a, z_i) = \frac{4}{a} \sin \pi z_i; \quad (21)$$

$$z_{i+1} = F_{MSCS}(\delta, z_i) = |\sin(\pi(4\delta f_1(4, z_i) + (1 - \delta)f_2(4, z_i)))|。 \quad (22)$$

式中: $\mu \in [0, 4]$ 为 Logistic 混沌映射的控制参数; $a \in [0, 4]$ 为 sine 混沌映射的控制参数,此处取 $a = \mu = 4$; $\delta \in [0, 1]$ 为 MSCS 调制参数,本文取 $\delta = 1$ 。

单纯形法采用以当前最优解为中心的缩放变换,聚焦局部区域,获得更高精度的解,从而增强算法的局部开发能力。在算法迭代后期 $t > 0.6 \max Iter$ 时激活 Nelder-Mead 单纯形法,每次激活最多执行 5 次迭代。具体步骤^[26]如下。

(1) 每个个体根据适应度值排序 $F(y_1) \leq F(y_2) \leq \dots \leq F(y_{n+1})$, 平均最佳的两个个体以获得单纯形质心的位置,计算公式如下所示:

$$y_c = \frac{y_1 + y_2}{2}。 \quad (23)$$

(2) 通过质心 y_c 和最差解 y_{n+1} 构造反射点位置:

$$y_r = y_c + \alpha(y_c - y_{n+1})。 \quad (24)$$

式中: α 为反射系数,通常取 1.0。

(3) 如果 $F(y_r) > F(y_1)$, 则表明找到全局最优解的最佳方法是在反射方向上搜索。通过结合质心 y_c 和反射位置 y_r 进一步扩大探索区域:

$$y_e = y_c + \varepsilon(y_r - y_c)。 \quad (25)$$

式中: y_e 为扩张运算后的点; ε 为扩张系数,通常取

2.0。若 $F(y_e) < F(y_r)$, 则更新 $y_{n+1} = y_e$ 。

(4) 若 $F(y_n) < F(y_r) < F(y_{n+1})$ 成立,则根据式(26)进行压缩操作:

$$y_{oc} = y_c + \gamma(y_r - y_c)。 \quad (26)$$

式中: γ 为压缩系数,取 0.5。如果收缩位置优于质心位置,则最差解将更新为收缩位置。

(5) 如果收缩点没有改进,即 $F(y_r) < F(y_{n+1})$, 则通过式(27)进行缩减:

$$y_{ic} = y_c + \gamma(y_r - y_c)。 \quad (27)$$

2 系统侧谐波阻抗估计模型

本文所提系统侧谐波阻抗估计方法主要由数据采集、数据筛选、数据分段、算法改进、模型训练、ITOC-DHKELM 估计和性能评估等部分组成。流程如图 2 所示。




图 2 系统侧谐波阻抗估计模型

Figure 2 System-side harmonic impedance estimation model

本文实验在配备 Intel Core i7-13650HX 处理器, 24 GB 内存的硬件平台上进行, 在 Windows 11 操作系统下, 基于 MATLAB R2024b 环境运行。DHKELM 模型隐含层为 3, 采用 tanh 激活函数, 多项式核参数 $[1, 5]$, ITOC 算法迭代次数设置为 30 次, 群体规模为 20。

算法 1 基于 ITOC-DHKELM 的谐波阻抗估计算法

输入: 原始谐波序列 $\dot{V}_{pec}$ 、 $\dot{I}_{pec}$, MIC 阈值 τ , PELT 惩罚系数 β , 最大迭代次数 $\max Iter$;

输出: 系统侧谐波阻抗预测值 Z_{se} 。

① $(V_h, I_h) = MIC(\dot{V}_{pec}, \dot{I}_{pec}, \tau)$ // 筛选非线性相关性数据;

② $Z_h = V_h / I_h$ // 计算谐波阻抗粗估值;

③ $CP = PELT(Z_h, \beta)$ // 检测阻抗突变点并划分

平稳数据集;

④ $\{D_{\text{train}}, D_{\text{test}}\} = \text{Datasplit}(V_h, I_h, CP)$ //根据突变点分组并划分数据集;

⑤ $X = \text{MSCS}(N, \text{dim})$ //利用多策略混沌映射初始化种群;

⑥for t in $1, \dots, \text{maxIter}$ do

⑦ $\text{Fitness} = \text{MSE}$ //计算适应度值函数;

⑧ $(X_{\text{best}}, f_{\text{min}}) = \text{GetBest}(X, \text{Fitness})$ //找出最优适应度及龙卷风对应位置;

⑨ $X_{\text{new}} = \text{Nelder-Mead}(X_{\text{best}})$ //引入 Nelder-Mead 单纯形法进行局部寻优;

⑩ $X = \text{UpdateTornado}(X, X_{\text{new}})$ //更新最优龙卷风位置;

⑪end for

⑫ $\theta^* = X_{\text{best}}$ //DHKELM 最优超参数;

⑬ $\text{Model} = \text{TrainDHKELM}(D_{\text{train}}, \theta^*)$ //训练深度混合核极限学习机模型;

⑭ $Z_{\text{se}} = \text{Model.Predict}(D_{\text{test}})$ //系统侧谐波阻抗预测;

⑮ return Z_{se}

3 仿真分析

3.1 诺顿等效电路模型(仿真 1)

为了验证所提方法有效性,基于图 1 所示的诺顿等效模型开展仿真分析。模型的具体参数设置如下。

系统频率 50 Hz,仿真选取 3 次谐波。

系统侧谐波阻抗: $0 \sim t_0, Z_s = 15 + j19.99 \Omega; t_0 \sim t_1, Z_s = 20.5 + j24 \Omega; t_1 \sim t_2, Z_s = 14.5 + j18 \Omega; t_2 \sim t_3, Z_s = 19.53 + j23 \Omega$ 。其中, t_0, t_1, t_2, t_3 分别对应样本点

1 500、3 000、4 500、6 000。用户侧谐波阻抗: $Z_c = 30 + j50 \Omega$,实部和虚部均添加 $\pm 10\%$ 的随机扰动和 5%的正态扰动。

用户侧谐波电流: $I_c = 103.92 - j60 \text{ A}$,幅值和相角均添加 $\pm 10\%$ 随机扰动和 20%正态扰动。系统侧谐波 I_s 的幅值: $|I_s| = k |I_c|$;相角 70° ,添加 10%随机扰动。

在公共连接点随机抽样得到 6 000 组谐波电压电流数据,其中前 84%组数据作为训练样本,后 16%数据作为测试样本。

本文采用平均绝对误差 MAE、均方根误差 RMSE 和第 i 个点的估计误差 E_i 为评估指标:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Z_s - Z_{se}|; \tag{28}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_s - Z_{se})^2}; \tag{29}$$

$$E_i = \left| \frac{Z_s - Z_{se}}{Z_s} \right| \times 100\%。 \tag{30}$$

式中: Z_s 为系统侧谐波阻抗实际值; Z_{se} 为系统侧谐波阻抗估计值。

为评估 MIC 相关性筛选、PELT 突变点检测以及龙卷风优化算法及其改进策略对系统侧谐波阻抗预测模型准确性的具体贡献,本文在不同背景谐波条件下进行消融实验,估计结果如表 1 和表 2 所示。其中,MD 为 MIC-DHKELM,MPD 为 MIC-PELT-DHKELM,MPTD 为 MIC-PELT-TOC-DHKELM,所提方法为 MPID。由表 1 和表 2 可知,PELT 和优化算法改进策略对整体模型的精度贡献较大;MPID 随背景谐波波动系数 k 变化的误差和波动最小,稳定性相对更高。

表 1 仿真 1 的消融实验幅值估计结果

Table 1 Amplitude estimation results from ablation experiments in Simulation 1										Ω
k	DHKELM		MD		MPD		MPTD		MPID	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
0.1	1.33	1.52	0.86	1.05	2.85×10^{-2}	4.07×10^{-2}	4.24×10^{-4}	4.01×10^{-3}	2.39×10^{-4}	7.77×10^{-4}
0.5	1.50	1.63	1.40	1.62	5.88×10^{-2}	9.32×10^{-2}	8.34×10^{-4}	3.71×10^{-3}	5.11×10^{-4}	1.24×10^{-3}
0.9	1.59	1.78	1.47	1.71	4.39×10^{-2}	6.60×10^{-2}	7.31×10^{-4}	5.69×10^{-3}	4.67×10^{-4}	1.57×10^{-3}
1.3	1.91	2.15	1.46	1.60	5.45×10^{-2}	9.21×10^{-2}	2.36×10^{-3}	1.48×10^{-2}	6.74×10^{-4}	2.12×10^{-3}

表 2 仿真 1 消融实验相位估计结果

Table 2 Phase estimation results from ablation experiments in Simulation 1										$(^\circ)$
k	DHKELM		MD		MPD		MPTD		MPID	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
0.1	0.79	0.92	0.71	0.86	5.21×10^{-2}	8.39×10^{-2}	7.03×10^{-4}	6.30×10^{-3}	4.24×10^{-4}	1.42×10^{-3}
0.5	0.96	1.14	0.77	0.93	1.05×10^{-1}	1.63×10^{-1}	1.68×10^{-3}	7.46×10^{-3}	9.16×10^{-4}	2.31×10^{-3}
0.9	0.93	1.12	0.83	0.99	8.59×10^{-2}	1.34×10^{-1}	1.44×10^{-3}	1.25×10^{-2}	9.19×10^{-4}	3.33×10^{-3}
1.3	0.95	1.13	0.92	1.06	1.03×10^{-1}	1.73×10^{-1}	4.20×10^{-3}	2.38×10^{-2}	1.14×10^{-3}	3.53×10^{-3}

研究用户侧谐波阻抗远大于系统侧时的阻抗估计情况。设置 $Z_c = 100 + j200 \, \Omega$, 其他条件不变情况下, 计算在 $k = 1.3$ 条件下的估计精度, 结果如表 3 所示。与表 1 和 2 即在用户侧谐波阻抗非远大于系统侧的情况下的实验结果对比可知, 其误差值较小, 说明两侧阻抗比会对估计结果产生影响, Z_c/Z_s 越大, 其估计误差越小。

表 3 阻抗估计结果

Table 3 Impedance estimation results

方法	MAE		RMSE	
	幅值/ Ω	相位/ $^\circ$	幅值/ Ω	相位/ $^\circ$
DHKELM	1.66	0.74	1.99	0.90
MD	1.28	0.71	1.50	0.82
MPD	0.04	0.08	0.06	0.13
MPTD	1.35×10^{-3}	2.40×10^{-3}	6.80×10^{-3}	1.40×10^{-2}
MPID	3.47×10^{-4}	6.60×10^{-4}	1.67×10^{-3}	3.36×10^{-3}

图 3 为 4 个时间段阻抗估计误差图, 可以直观比较 MPD、MPTD 和 MPID 在 $k = 1.3$ 条件下的估计精度。由图 3 可以看出, MPD 估计误差分布最为宽散, 存在若干较大离群值; MPTD 将大部分估计压缩到较低误差区间, 但仍有少量离散误差点; 而 MPID 在 4 个时间段中均呈现出接近零且高度聚集的误差

分布, 几乎无显著离群点, 有效证明了本文所提方法的准确性。




图 3 4 个时间段阻抗估计误差

Figure 3 Four-segment impedance estimation error

为了全面评估所提模型的预测性能, 将其与 CNN^[27]、LSTM^[28]、GRU^[29-30]、CNN-LSTM^[27] 模型以及极限学习机相关模型^[31] (ELM、DBO-HKELM) 进行系统的对比实验。图 4 采用雷达图展示了不同背景谐波波动系数下各模型的估计结果, 其中各径向轴代表不同的背景谐波强度, 离中心点的距离代表误差量值。可以看出, 所提模型形成的闭合区域面积最小且最靠近中心, 而其他对比模型的误差轨迹明显向外扩散, 证明所提模型在所有测试工况下均保持了最低的估计误差, 具有较好抗干扰能力。




图 4 仿真 1 的对比实验估计结果

Figure 4 Estimation results from Simulation 1 comparison experiment

3.2 IEEE13 节点系统 (仿真 2)

仿真 2 采用基于图 5 所示的 IEEE13 节点系统进行验证, 系统参数详见[32]。在该系统中, 节点 13 处连接谐波负载, 将 7 次谐波电流注入系统。此外, 在节点 4 处添加一个谐波源, 即系统等效谐波源。节点 4 和节点 13 注入的 7 次谐波电流幅值为基波电流的 11.9%, 相位为 -84.11° , 均对其添加 $\pm 5\%$ 的随机扰动和 5% 的正态扰动。模拟系统侧谐波阻抗的突变通过调整电容器容量实现, 容量变化见表 4。

为了展示背景谐波影响, 将节点 4 注入的谐波电流增加到原值的 m 倍。图 6 展示了在不同 m 值下消融实验的结果。由图 6 可知, 随着 m 值的增大, 即背景谐波干扰强度的提升, 5 种方法的预测误




图 5 IEEE13 节点系统
Figure 5 IEEE13-node system

表 4 电容器接入容量

Table 4 Capacitor connection capacity

样本点	接入容量/kvar
1~2 000	6 000
2 001~4 000	5 800
4 001~6 000	5 000




图 6 仿真 2 消融实验估计结果

Figure 6 Simulation 2 ablation experiment results

差基本呈现上升趋势。MPID 的估计性能最佳,误差值最小,PELT 和优化算法改进策略对整体模型的准确性贡献较大,MIC 贡献较小。

因篇幅限制,此处仅选取在 $m = 12$ 条件下与其他模型进行对比,结果如表 5 所示,可知 MPID 在阻抗幅值与相位两项指标上均取得最小误差,幅值的 MAE 低至 0.000 3,预测效果优于 CNN、LSTM、GRU 等其他对比模型。

表 5 仿真 2 的对比实验估计结果

Table 5 Estimation results from Simulation 2 comparison experiment				
方法	MAE		RMSE	
	幅值/Ω	相位/°	幅值/Ω	相位/°
CNN	0.032 0	0.242	0.042	0.320
LSTM	0.165 0	1.178	0.192	1.382
GRU	0.031 0	0.216	0.037	0.265
CNN-LSTM	0.019 0	0.111	0.026	0.158
ELM	0.035 0	0.260	0.043	0.325
DBO-HKELM	0.020 0	0.175	0.029	0.245
MPID	0.000 3	0.009	0.002	0.058

4 实例分析

对某变电站 110 kV 母线的实测数据进行案例分析。采用电能分析仪测量 PCC 处的电压和谐波电流,通过快速傅里叶变换得到谐波电压和谐波电流。案例分析以 3 次谐波为例。每间隔 3 s 在 PCC 处测量一次,获得 12 000 个样本,得到 PCC 处的 3 次谐波电压和电流,其波形如图 7 示。




图 7 PCC 处 3 次谐波电压和电流

Figure 7 Third harmonic voltage and current at PCC

随机选取其中一段 1 800 个带负载的样本数据作为研究对象。基于 PCC 处的谐波电压和谐波电流实测数据,开展消融实验以及与其他深度学习模型的对比实验,阻抗幅值和相位估计结果的误差分别如表 6 和表 7 所示。

表 6 消融实验估计结果

Table 6 Estimation results of the ablation experiment				
方法	MAE		RMSE	
	幅值/Ω	相位/°	幅值/Ω	相位/°
DHKELM	18.93	7.81	20.11	8.30
MD	18.04	7.44	18.68	7.71
MPD	1.08	0.63	1.52	0.92
MPTD	0.06	0.04	0.15	0.10
MPID	0.01	0.01	0.03	0.02

表 7 对比实验估计结果

Table 7 Estimation results of the comparison experiment				
方法	MAE		RMSE	
	幅值/Ω	相位/°	幅值/Ω	相位/°
CNN	10.18	4.19	13.81	5.69
LSTM	16.23	6.70	18.30	7.55
GRU	16.16	6.67	18.51	7.64
CNN-LSTM	11.11	4.60	14.74	6.08
ELM	29.11	12.01	29.23	12.06
DBO-HKELM	20.91	8.63	21.44	8.85
MPID	0.010	0.010	0.030	0.020

由表 6 可知,随着 MIC 相关性筛选、PELT 突变点检测及 TOC 优化策略的引入,模型的估计效果明显变好,引入 PELT 突变点检测模块的 MPD 使幅值的 MAE 下降至 1.08 Ω,采用 ITOC 的 MPID 方法使阻抗幅值 MAE 降至 0.010 Ω,相位 MAE 降至 0.010°,验证了各模块对提升谐波阻抗估计精度的有效贡献。

由表 7 可知,在面对含有强背景谐波干扰的实测数据时,CNN、LSTM 等模型幅值的 MAE 均分布在 10.18~29.11 Ω,其相位的误差也处于较高水平,显示出在处理复杂实测非平稳数据时的局限性。相比

之下,MPID 在噪声与波动背景下估计精度仍然较高。

上述分析结果表明,本文提出的方法在实际工程中具有实用性和准确性。

5 结论

考虑到由电网运行方式变化和电容器投切等造成的系统侧谐波阻抗突变问题,本文提出一种基于 MIC 数据筛选和 PELT 突变点检测的改进龙卷风优化深度混合核极限学习机的谐波阻抗估计方法。通过仿真和实例分析,可得如下结论。

(1)采用最大信息系数 MIC 对 PCC 处测量的谐波电压、电流相关性较强的数据进行筛选,有效抑制背景谐波波动对阻抗估计的干扰。

(2)提出的基于动态规划和剪枝技术的 PELT 算法在不同背景谐波波动系数下均可对整体测量序列中的突变位置进行可靠定位并将数据划分为若干稳定段。

(3)提出的改进龙卷风优化算法 ITOC 优化 DHKELM 模型的分段系统侧谐波阻抗估计方法在用户侧谐波阻抗非远大于系统侧且背景谐波波动系数较大的情况下,仍能保持较高的阻抗估计精度,具有更高的准确性和稳定性。

参考文献:

- [1] Liu Tongyu, Shu Qin, Xu Fangwei, et al. A method for determining harmonic contribution and harmonic source current based on minimum mutual information and Bayesian optimization[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-8.
- [2] Wang Haojie, Wang Chang, Xu Fangwei, et al. Estimation method for variable harmonic impedance based on Legendre polynomial fitting[J]. Electric Power Automation Equipment, 2024, 44(11): 195-201. [王浩杰, 王畅, 徐方维, 等. 基于勒让德多项式拟合的变谐波阻抗估计方法[J]. 电力自动化设备, 2024, 44(11): 195-201.]
- [3] Wang Chuan, Xu Fangwei, Guo Kai, et al. Novel approach and index for evaluating harmonic contributions of multiple harmonic sources based on Gaussian mixture model with multipoint harmonic phasor measurements[J]. IEEE Transactions on Power Delivery, 2026, 41(2): 499-507.
- [4] Chen Yihan, Zeng Chengbi, Miao Hong, et al. Beta mixture model combined with K-S test for system harmonic impedance estimation[J]. Proceedings of the CSU-EPSCA, 2025, 37(6): 121-128. [陈一涵, 曾成碧, 苗虹, 等. Beta 混合模型结合 K-S 检验的系统谐波阻抗估计[J]. 电力系统及其自动化学报, 2025, 37(6): 121-128.]
- [5] Zhao Yongyang, Xu Fangwei, Shu Qin, et al. Harmonic impedance estimation on system side based on minimum fluctuation energy of background harmonic[J]. Automation of Electric Power Systems, 2019, 43(24): 142-148. [赵永扬, 徐方维, 舒勤, 等. 基于背景谐波最小波动能量的系统侧谐波阻抗估计[J]. 电力系统自动化, 2019, 43(24): 142-148.]
- [6] Wang Xiaoming, Zheng Hao, Zhao Wenguang, et al. Utility harmonic impedance estimation method considering time-varying characteristics of background harmonics[J]. Journal of Power Supply, 2025(3): 36-46. [王小明, 郑浩, 赵文广, 等. 计及背景谐波时变特征的系统谐波阻抗估计方法[J]. 电源学报, 2025(3): 36-46.]
- [7] Lin Shunfu, Li Yukun, Cheng Weijian, et al. Improved recursive least square method for system harmonic impedance estimation[J]. Power System Technology, 2023, 47(7): 2879-2886. [林顺富, 李育坤, 程卫健, 等. 一种改进递推最小二乘的系统谐波阻抗估计方法[J]. 电网技术, 2023, 47(7): 2879-2886.]
- [8] Xu Fangwei, Xie Peiang, Wang Chuan, et al. Time-varying harmonic impedance estimation based on locally-geographically weighted regression[J]. Jiangsu Electrical Engineering, 2025, 44(1): 20-29. [徐方维, 谢佩昂, 王川, 等. 基于局部-地理加权回归的时变谐波阻抗估计[J]. 电力工程技术, 2025, 44(1): 20-29.]
- [9] Wu Yayue, Xu Fangwei, Zhang Weijun, et al. System-side harmonic impedance estimation based on modified independent random vectors[J]. Automation of Electric Power Systems, 2019, 43(20): 146-152. [吴雅玥, 徐方维, 张伟骏, 等. 基于修正独立随机矢量的系统侧谐波阻抗估计[J]. 电力系统自动化, 2019, 43(20): 146-152.]
- [10] Xia Yankun, Zhu Zhaoqing, Tang Wenzhang, et al. Harmonic emission level estimation method based on an improved bald eagle search optimized extreme learning machine[J]. Power System Protection and Control, 2024, 52(1): 156-165. [夏焰坤, 朱赵晴, 唐文张, 等. 基于改进秃鹰算法优化极限学习机的谐波发射水平估计[J]. 电力系统保护与控制, 2024, 52(1): 156-165.]
- [11] Xia Yankun, Huang Peng, Ren Junjie, et al. Improved dung beetle optimizer for optimizing hybrid kernel extreme learning machine for system harmonic impedance estimation[J]. Proceedings of the CSU-EPSCA, 2024, 36(11): 69-78. [夏焰坤, 黄鹏, 任俊杰, 等. 改进蜣螂算法优化混合核极限学习机的系统谐波阻抗估计[J]. 电力系统及其自动化学报, 2024, 36(11): 69-78.]
- [12] Xia Yankun, Ren Junjie. Harmonic impedance estimation

- based on BP-adaboost algorithm[J]. Proceedings of the CSU-EPSA, 2024, 36(3): 118-125. [夏焰坤, 任俊杰. 基于反向传播-自适应提升算法的谐波阻抗估计[J]. 电力系统及其自动化学报, 2024, 36(3): 118-125.]
- [13] Fan Yu, Xu Fangwei, Wang Chang, et al. A harmonic impedance on utility side estimation method based on Laplace mixture model[J]. IEEE Transactions on Power Delivery, 2024, 39(3): 1774-1782.
- [14] Yang Yong, Li Wentao, Liu Wenfei, et al. Utility harmonic impedance estimation based on time series clustering and improved Pettitt method[J]. Proceedings of the CSU-EPSA, 2024, 36(1): 89-98. [杨勇, 李文涛, 刘文飞, 等. 基于时序聚类及改进 Pettitt 的系统谐波阻抗估计[J]. 电力系统及其自动化学报, 2024, 36(1): 89-98.]
- [15] Liu Qingsong, Miao Hong, Zeng Chengbi, et al. System harmonic impedance estimation based on Bayesian change-point detection and non-convex penalized regression[J]. Power System Protection and Control, 2025, 53(9): 107-117. [刘青松, 苗虹, 曾成碧, 等. 基于贝叶斯突变检测与非凸惩罚回归的系统谐波阻抗估计[J]. 电力系统保护与控制, 2025, 53(9): 107-117.]
- [16] Zheng Kaidi, Miao Xiren, Lin Yurun, et al. Phase sequence identification method for users in low-voltage transform district with photovoltaic based on maximal information coefficient[J]. Electric Power Automation Equipment, 2024, 44(12): 108-114. [郑楷迪, 缪希仁, 林雨润, 等. 基于最大互信息系数的低压光伏台区用户相序辨识方法[J]. 电力自动化设备, 2024, 44(12): 108-114.]
- [17] Xi Lei, Wang Wenzhuo, Bai Fangyan, et al. Grid false data injection attack localization detection based on MIC-double-deck confidence XGBoost tree[J]. Power System Technology, 2025, 49(2): 824-833. [席磊, 王文卓, 白芳岩, 等. 基于最大信息系数-双层置信极端梯度提升树的电网虚假数据注入攻击定位检测[J]. 电网技术, 2025, 49(2): 824-833.]
- [18] Liu Zhenyu, Lu Wei, Wu Jiayan, et al. A PELT-KCN algorithm for FMCW radar interference suppression based on signal reconstruction[J]. IEEE Access, 2020, 8: 45108-45118.
- [19] Killick R, Fearnhead P, Eckley I A. Optimal detection of changepoints with a linear computational cost[J]. Journal of the American Statistical Association, 2012, 107(500): 1590-1598.
- [20] Liu Shuo, Jin Jing, Liu Shilong, et al. Change point detection for FOGs scale factor test data using pruned exact linear time (PELT) algorithm[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 9527108.
- [21] Jiang Jiandong, Zhang Haifeng, Guo Jiaqi. Short-term wind power forecasting prediction based on improved dung beetle optimization algorithm[J]. Journal of Zhengzhou University (Engineering Science), 2025, 46(4): 129-136. [蒋建东, 张海峰, 郭嘉琦. 基于改进蜣螂优化算法的短期风电功率预测[J]. 郑州大学学报(工学版), 2025, 46(4): 129-136.]
- [22] Fan Xingming, Xu Honghua, Zhang Sishun, et al. Fault diagnosis of high voltage circuit breaker based on improved dung beetle optimizer algorithm deep hybrid kernel extreme learning machine[J]. Transactions of China Electrotechnical Society, 2025, 40(12): 3994-4003. [范兴明, 许洪华, 张思舜, 等. 基于改进蜣螂优化算法深度混合核极限学习机的高压断路器故障诊断[J]. 电工技术学报, 2025, 40(12): 3994-4003.]
- [23] Guo Lijin, Ma Zongyang, Hu Xiaoyan. Short-term photovoltaic power prediction based on data augmentation and optimization of DHKELM[J]. Acta Energaie Solaris Sinica, 2025, 46(8): 463-471. [郭利进, 马棕阳, 胡晓岩. 基于数据增强和优化 DHKELM 的短期光伏功率预测[J]. 太阳能学报, 2025, 46(8): 463-471.]
- [24] Braik M, Al-Hiary H, Alzoubi H, et al. Tornado optimizer with Coriolis force: a novel bio-inspired meta-heuristic algorithm for solving engineering problems[J]. Artificial Intelligence Review, 2025, 58(4): 123.
- [25] Zhu Yunwei, Huang Haisong, Wei Jianan, et al. ISO: an improved snake optimizer with multi-strategy enhancement for engineering optimization[J]. Expert Systems with Applications, 2025, 281: 127660.
- [26] Xia Bin, Wang Chao, Sun Xin, et al. Multi-modal optimal design of permanent magnet synchronous motor based on improved firefly algorithm[J]. Electric Machines and Control, 2024, 28(4): 131-138. [夏斌, 王超, 孙鑫, 等. 基于改进萤火虫算法的永磁同步电机多模态优化设计[J]. 电机与控制学报, 2024, 28(4): 131-138.]
- [27] Lu Jixiang, Zhang Qiwei, Yang Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(8): 131-137. [陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(8): 131-137.]
- [28] Huang Manyun, Wang Tianhao, Wei Zhinong, et al. Dynamic harmonic state estimation of an unscented Kalman filter based on long short-term memory neural networks[J]. Power System Protection and Control, 2022, 50(11): 1-11. [黄蔓云, 王天昊, 卫志农, 等. 基于长短期记忆网络的 UKF 动态谐波状态估计[J]. 电力系

统保护与控制, 2022, 50(11): 1–11.]

[29] Shang Zhongwen, Zhang Qian, Zhao Chanjuan, et al. Load prediction of electric vehicle charging station based on ASC-GCN-GRU [J]. Acta Energiæ Solaris Sinica, 2026, 47(5): 489–497. [尚中雯, 张倩, 赵婵娟, 等. 基于 ASC-GCN-GRU 的电动汽车充电站负荷预测 [J]. 太阳能学报, 2026, 47(5): 489–497.]

[30] Chen Xiang, Yang Ling, Xu Zhaoyang, et al. A time-varying harmonic impedance estimation method based on improved BP neural network with attention mechanism [J]. Electric Power Systems Research, 2025, 248: 111905.

[31] Zhou Qiang, Lv Zhong, Xie Shaofeng. Estimating harmonic impedance of electric power system based on extreme learning machine [J]. Chinese Journal of Power Sources, 2015, 39(11): 2517–2519. [周强, 吕忠, 解绍锋. 基于 ELM 的电力系统谐波阻抗估计 [J]. 电源技术, 2015, 39(11): 2517–2519.]

[32] Wang Chuan, Xu Fangwei, Shu Qin, et al. A noninvasive method to estimate the variable utility harmonic impedance [J]. IEEE Transactions on Power Delivery, 2023, 38(3): 1747–1754.

Harmonic Impedance Estimation Method Based on Improved Tornado Optimization Algorithm

XIA Yankun¹, ZHENG Gaoping¹, HUANG Peng², ZHANG Heng¹, ZHOU Hang¹

(1. School of Electrical Engineering and Electronic Information, Xihua University, Chengdu 610039, China; 2. State Grid Yibin Power Supply Company, Yibin 644000, China)

Abstract: To address the issue of sudden changes in system-side harmonic impedance under operating conditions such as changes in power grid operating modes and capacitor switching, as well as the decline in estimation accuracy when background harmonic fluctuations are significant, a harmonic impedance estimation method based on the deep hybrid kernel extreme learning machine (DHKELM) optimized by improved tornado optimization algorithm was proposed. Firstly, to mitigate the effects of background harmonics and outliers, the maximum information coefficient (MIC) was used to filter data with strong correlations between harmonic voltage and harmonic current amplitudes. Secondly, the harmonic data samples were segmented based on the abrupt change points in the coarse impedance estimates detected by the PELT algorithm. Finally, the system-side harmonic impedance was estimated for each segment of harmonic data using the DHKELM. Furthermore, to improve the model’s prediction accuracy, a tornado optimization algorithm (ITOC) enhanced by multi-strategy chaos and the Nelder-Mead simplex method was proposed to optimize the number of hidden layer nodes, kernel parameters, and weights of the DHKELM model. Simulations were conducted using the Norton equivalent model and an IEEE 13-node system, and case studies were performed in conjunction with measured data. The results showed that, when the harmonic impedance on the customer-side was no greater than that on the system-side, the errors in impedance estimation under different background harmonic coefficients in the Norton simulation were all relatively small. In the IEEE 13-node system simulation, the *RMSE* for amplitude and phase angle estimates were 0.002 Ω and 0.058°, respectively. In the case study analysis, the *RMSE* for amplitude and phase angle were 0.03 Ω and 0.02°, respectively, demonstrating high estimation accuracy and stability.

Keywords: system-side harmonic impedance; maximum information coefficient; PELT algorithm; deep hybrid kernel extreme learning machine; tornado optimization algorithm