

文章编号:1671-5896(2026)04-0830-11

# 双阶段配电网线损率计算方法

王学军, 王 彬, 魏联滨, 徐晓萌

(国网天津市电力公司 发展策划部, 天津 300010)

**摘要:** 针对低压配电网线损特征识别与理论计算中存在的特征权重分配主观性强、非线性映射精度不足等问题, 提出了一种融合多特征加权聚类与智能优化神经网络的线损分析方法。首先建立了多特征加权改进型  $k$  均值聚类算法(MFW-IKCA: Multi-Feature Weighted Improved  $k$ -Means Clustering Algorithm), 通过熵权法与互信息法的融合策略实现特征维度的自适应加权, 并用交替方向乘子法(ADMM: Alternating Direction Method of Multipliers)优化目标函数; 其次采用改进遗传算法优化的莱文贝格-马夸特反向传播神经网络(IGA-LMBP-NNM: Improved Genetic Algorithm Optimized Levenberg-Marquardt Back Propagation Neural Network)参数, 通过模拟二进制交叉、多项式变异及自适应阻尼因子提升网络收敛速度与预测精度; 最后利用决策树分类器提取聚类规则, 并结合核密度估计实现异常值检测。实验结果表明, 与主流算法相比, 所提方法聚类纯度提升 14.5%, 均方误差(MSE: Mean Squared Error)降低 29.3%, 决定系数  $R^2$  提高至 0.892。该研究不仅为配电网线损精细化分析提供了新思路, 也为提升台区降损决策的科学性提供了有力支持, 具有显著的工程应用价值。

**关键词:** 台区线损特征识别; 多特征加权聚类; 改进遗传算法; 莱文贝格-马夸特神经网络; 动态权重分配; 配电网理论线损计算

中图分类号: TP393

文献标志码: A

## Line Loss Rate Calculation Method of Two-Stage Distribution Network

WANG Xuejun, WANG Bin, WEI Lianbin, XU Xiaomeng

(Development and Planning Department, State Grid Tianjin Electric Power Company, Tianjin 300010, China)

**Abstract:** A novel method integrating multi-feature weighted clustering and intelligent optimized neural network is proposed to address the issues of subjective feature weighting and insufficient nonlinear mapping accuracy in low-voltage distribution network line loss analysis. First, an improved  $k$ -means clustering algorithm (MFW-IKCA: Multi-Feature Weighted Improved  $k$ -Means Clustering Algorithm) is established by introducing dynamic weight matrices and reference weights, combining entropy weighting and mutual information methods for adaptive feature weighting, and optimizing the objective function via the ADMM (Alternating Direction Method of Multipliers). Subsequently, an IGA (Improved Genetic Algorithm) is employed to optimize the parameters of the LMBP-NNM (Levenberg-Marquardt Backpropagation Neural Network), enhancing convergence speed and prediction accuracy through simulated binary crossover, polynomial mutation, and adaptive damping factors. Finally, decision tree classifiers are utilized to extract clustering rules, while kernel density estimation enabled anomaly detection. Experimental results on 710 transformer district datasets have demonstrated a 14.5% improvement in clustering purity, a 29.3% reduction in MSE (Msemean Squared Error), and a 0.892 coefficient of determination ( $R^2$ ). This study provides a new perspective for refined line loss analysis and offers significant engineering value for improving scientific decision-making in loss reduction of distribution network.

收稿日期: 2025-08-14

基金项目: 国家电网科技基金资助项目(1400-202312635a-3-2-zn)

作者简介: 王学军(1979—), 男, 天津人, 国网天津市电力公司高级工程师, 主要从事电力规划、计划、投资、经营、统计等研究, (Tel)86-13102050463 (E-mail) bereadysir@163.com; 通讯作者: 王彬(1988—), 男, 天津人, 国网天津市电力公司高级工程师, 主要从事电力计划、经营、线损、购电等研究, (Tel)86-18649016407 (E-mail) grnjnWXJ@163.com。

**Key words:** line loss feature recognition; multi-feature weighted clustering; improved genetic algorithm; levenberg-marquardt neural network; dynamic weight allocation; distribution network line loss calculation

## 0 引言

低压配电网作为电力传输的末端环节,其线损水平直接影响电网经济运行效率。据统计,我国低压配电网年均线损率约为5%~8%,其中因计量误差、设备老化导致的异常线损占比达35%以上<sup>[1-2]</sup>。传统线损计算方法依赖人工经验公式与稳态假设,难以适应分布式能源接入带来的动态负荷特性<sup>[3]</sup>。随着智能电表覆盖率突破,基于大数据的线损分析技术成为研究热点<sup>[4-5]</sup>,并为线路损耗计算提供了新的方向。

近年来,数据驱动技术为线损分析提供了新思路,现有研究主要分为两类:一类基于特征聚类分析,如张振刚等<sup>[6]</sup>采用高速电力线载波(HPLC: High-Speed Power Line Carrier)技术构建表间关系距离矩阵,但其固定特征选择机制导致台区拓扑适应性不足;汪颖等<sup>[7]</sup>提出的C-vine Copula模型虽能识别线损状态分布,但其参数估计复杂度随特征维度呈指数增长。另一类基于深度学习算法,如边舒芳等<sup>[8]</sup>利用生成对抗网络(GAN: Generative Adversarial Network)进行数据增强,但其生成样本的时序关联性存在失真风险;原俊龙等<sup>[9]</sup>设计的卷积神经网络-长短期记忆网络(CNN-LSTM: Convolutional Neural Network-Long Short-Term Memory)混合模型未考虑特征维度权重差异,导致异常工况识别率偏低。现有方法普遍存在3个缺陷:1)聚类算法未建立特征权重与线损机理的量化关系;2)神经网络参数优化易陷入局部最优;3)动态权重调整机制缺失。

针对上述问题,笔者提出双阶段线损分析方法:在特征识别阶段,构建MFW-IKCA(Multi-Feature Weighted Improved  $k$ -Means Clustering Algorithm),通过熵权-互信息融合策略确定特征参考权重,结合ADMM(Alternating Direction Method of Multipliers)优化动态权重矩阵,解决传统聚类对高维数据的适应性缺陷。在线损计算阶段,设计IGA-LMBP-NNM(Improved Genetic Algorithm-Levenberg-Marquardt Backpropagation Neural Network),引入模拟二进制交叉与多项式变异机制,提升参数搜索效率。

## 1 台区区域线损特征识别

台区区域线损特征识别方法设计是低压配电网线损管理领域的重要研究方向,其核心在于构建适用于多场景、多特征量的聚类分析模型。在现有研究基础上,该领域需结合电力系统实际运行需求,通过改进传统聚类算法实现线损模式的精准识别。

传统聚类算法在电力数据挖掘中具有广泛应用,但标准 $k$ 均值聚类算法<sup>[10-12]</sup>(KCA:  $k$ -Means Clustering Algorithm)在处理多维电力特征数据时存在局限性,具体表现为特征维度权重分配机制缺失、初始质心选择敏感性大等问题。针对低压配电网线损特征分析的特殊性,笔者提出MFW-IKCA。该算法通过引入动态权重系数矩阵与参考权重矩阵,结合ADMM实现目标函数优化,有效提升了线损特征的聚类精度。算法数学建模过程涉及多个关键公式,其中基础目标函数 $L(\mathbf{U}, \mathbf{Z})$ 定义为

$$\min_{\mathbf{U}, \mathbf{Z}} L(\mathbf{U}, \mathbf{Z}) = \sum_{i=1}^n \sum_{p=1}^k u_{ip} \left\| \frac{n!}{r! (n-r)!} - \mathbf{z}_p \right\|^2, \quad (1)$$

其中 $\mathbf{U} = [u_{ip}]_{n \times k}$ 为聚类分配矩阵,当样本 $i$ 被划分至簇 $p$ 时 $u_{ip} = 1$ ,否则为0; $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k]^T$ 为聚类中心矩阵; $\mathbf{x}_i$ 为第 $i$ 个样本的特征向量; $\mathbf{z}_p \in \mathbb{R}^m$ 为第 $p$ 个簇的质心向量; $n$ 为样本总数; $k$ 为预设聚类簇数; $m$ 为特征维度数。目标函数值越小,表明簇内样本的聚集性越强,聚类效果越优。该目标函数通过交替优化 $\mathbf{U}$ 和 $\mathbf{Z}$ 实现迭代收敛,当固定分配矩阵 $\mathbf{U}^t$ 时,聚类中心公式更新为

$$\mathbf{z}_p^{t+1} = \sum_{i=1}^n u_{ip}^t \mathbf{x}_i / \left( \sum_{i=1}^n u_{ip}^t \right), \quad (2)$$

其中 $\mathbf{z}_p^{t+1}$ 为第 $t+1$ 次迭代时的聚类中心。

根据聚类中心矩阵更新规则,样本分配规则调整为

$$u_{ip}^{t+1} = \begin{cases} 1, & p = \arg \min_q \| \mathbf{x}_i - \mathbf{z}_p^{t+1} \|^2, \\ 0, & \text{其他。} \end{cases} \quad (3)$$

为克服标准 KCA 算法在电力特征加权方面的不足,改进型 IKCA 算法引入动态权重系数矩阵  $\mathbf{W} = [\omega_1, \omega_2, \dots, \omega_m]$  与参考权重矩阵  $\mathbf{W}_0 = [\omega_1^0, \omega_2^0, \dots, \omega_m^0]$ , 构建加权目标函数:

$$\min_{\mathbf{U}, \mathbf{W}, \mathbf{Z}} L(\mathbf{U}, \mathbf{W}, \mathbf{Z}) = \sum_{i=1}^n \sum_{p=1}^k u_{ip} \left( \sum_{j=1}^m \omega_j (x_{ij} - z_{pj})^2 \right) + B \sum_{j=1}^m (\omega_j - \omega_j^0)^2, \quad (4)$$

其中  $B$  为惩罚因子,用于平衡动态权重与参考权重之间的偏差; $x_{ij}$  为样本  $i$  的第  $j$  维特征值; $z_{pj}$  为簇  $p$  在第  $j$  维的聚类中心。加权目标函数需满足约束条件如下:

$$\sum_{j=1}^m \omega_j = 1, \quad \omega_j \geq 0. \quad (5)$$

权重矩阵优化过程通过增广拉格朗日法实现,其迭代更新公式为

$$\omega_j^{t+1} = \arg \min_{\omega_j} \left\{ \sum_{i=1}^n \sum_{p=1}^k u_{ip}^t \omega_j (x_{ij} - z_{pj}^t)^2 + B(\omega_j - \omega_j^0)^2 + \lambda_j \left( \sum_{j=1}^m \omega_j - 1 \right) \right\}, \quad (6)$$

其中  $\lambda_j$  为拉格朗日乘子。

参考权重矩阵  $\mathbf{W}_0$  的确定采用熵权法与互信息法的融合策略,定义第  $j$  维特征的参考权重  $\omega_j^0$  为

$$\omega_j^0 = \alpha \xi_j + (1 - \alpha) \gamma_j, \quad (7)$$

其中  $\xi_j$  为熵权法计算的特征信息熵权重; $\gamma_j$  为互信息法得到的特征相关性权重; $\alpha \in [0, 1]$  为融合系数。

熵权法权重如下:

$$\begin{cases} \xi_j = \frac{1 - H_j}{\sum_{q=1}^m (1 - H_q)}, \\ H_j = - \sum_{i=1}^n f_{ij} \ln f_{ij}, \end{cases} \quad (8)$$

其中  $H_j$  为第  $j$  维特征的信息熵; $f_{ij}$  为标准化后的特征值。

互信息权重  $\gamma_j$  如下:

$$\gamma_j = \frac{I(X_j; Y)}{\sum_{q=1}^m I(X_q; Y)}, \quad (9)$$

其中  $I(X_j; Y)$  为特征  $X_j$  与线损类别  $Y$  间的互信息量。

在聚类结果解释性优化方面,笔者采用决策树分类器<sup>[15]</sup> (DTC: Decision Tree Classifier) 对聚类结果进行规则提取。决策树节点分裂标准选用基尼不纯度系数 (GII: Gini Impurity Index), 则有:

$$\begin{cases} f_{\text{Gini}}(D) = 1 - \sum_{i=1}^{k_1} p_i^2, \\ p_i = \frac{n_i}{|D|}, \end{cases} \quad (10)$$

其中  $D$  为当前节点数据集; $k_1$  为类别总数; $p_i$  为类别  $i$  的样本比例。为防止模型过拟合,设置叶节点最小样本量阈值为 5,当节点样本量低于该阈值时进行剪枝处理。

针对线损异常值检测,研究基于拉依达准则 (LC: Lajda criterion) 构建 3 倍方差检测机制。假设线损率数据服从正态分布  $X \sim N(\mu, \sigma^2)$ , 则异常值判定条件为

$$\begin{cases} |x_i - \bar{x}| > 3\hat{\sigma}, \\ \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \\ \hat{\sigma} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}, \end{cases} \quad (11)$$

其中  $\bar{x}$  为样本均值;  $\hat{\sigma}$  为无偏方差估计量。满足该条件的样本需进行核密度估计验证, 核函数选用高斯核  $K_h(x)$ :

$$K_h(x) = \frac{1}{\sqrt{2\pi}h} e^{(-\|x-x_i\|^2/(2h^2))},$$

(12)

其中  $h$  为带宽参数, 通过 Silverman 准则确定。

基于 MFW-IKCA 的台区区域线损特征识别算法流程如图 1 所示。MFW-IKCA 的创新性主要体现在 3 个方面: 1) 通过动态权重机制实现特征维度自适应加权, 克服了传统聚类算法在电力数据降维中的主观性缺陷; 2) 融合熵权法与互信息法确定参考权重, 兼顾了特征的信息量与相关性; 3) 构建聚类-分类联合模型, 在保证聚类精度的同时增强了结果可解释性。算法实现关键步骤如下:

- 步骤 1 采用轮盘赌法初始化聚类中心, 通过概率选择机制降低初始质心敏感性;
- 步骤 2 输入参考权重矩阵与惩罚因子, 构建增广拉格朗日目标函数;
- 步骤 3 交替更新分配矩阵、权重矩阵与聚类中心矩阵直至收敛;
- 步骤 4 通过决策树模型提取分类规则, 结合异常检测机制输出线损特征分析结果。




图 1 基于 MFW-IKCA 的台区区域线损特征识别算法流程

Fig. 1 Flow chart of line loss feature recognition algorithm in substation area based on MFW-IKCA

2 基于 IGA-LMBP-NNM 的配电网理论 LLC 计算

配电网理论 LLC 模型构建分为数据预处理、站所分类与线损计算 3 阶段。数据预处理阶段通过电气特征量筛选(EFS; Electrical Feature Screening)与标准化处理构建输入数据集, 消除量纲差异与冗余特征干扰。站所分类阶段采用多特征加权改进型  $K$  均值聚类算法(MFW-IKCA)对台区进行模式划分, 为后续线损计算提供类别标签。线损计算阶段以 LMBP-NNM 为核心, 其网络参数通过 GA(Genetic Algorithm)优化, 形成改进遗传算法优化的 LMBP 神经网络(IGA-LMBP-NNM), 实现非线性线损率(LLR: Line Loss Rate)的高精度映射。

2.1 IGA

遗传算法优化机制<sup>[16-18]</sup>(GA)是一种模拟生物进化过程的全局搜索策略, 其通过模拟自然选择、基因重组与突变等机制, 在解空间内高效寻优。在配电网理论线损计算(LLC: Loss Calculation of Low-

Voltage Distribution Network) 中, 笔者采用 IGA 优化莱文贝格-马夸特反向传播神经网络 (LMBP-NNM) 的权重与偏置参数, 以克服传统梯度下降法易陷入局部极小、收敛速度慢等缺陷。

设神经网络参数总数为  $M$ , 参数集合为  $\theta = [\mathbf{W}_h, \mathbf{b}_h, \boldsymbol{\omega}_o, b_o] \in \mathbb{R}^M$ , 其中  $\mathbf{W}_h \in \mathbb{R}^{h \times m}$  为输入层至隐藏层权重矩阵,  $\mathbf{b}_h \in \mathbb{R}^h$  为隐藏层偏置向量,  $\boldsymbol{\omega}_o \in \mathbb{R}^h$  为隐藏层至输出层权重向量,  $b_o \in \mathbb{R}$  为输出层偏置, 则个体染色体  $\chi_i$  采用实数编码如下:

$$\chi_i = [w_{11}^{(h)}, w_{12}^{(h)}, \dots, w_{hm}^{(h)}, b_1^{(h)}, \dots, b_h^{(h)}, \omega_1^{(o)}, \dots, \omega_h^{(o)}, b^{(o)}]^T \in \mathbb{R}^M, \quad (13)$$

其中  $M = h(m+1) + h + 1$  为参数总数;  $h$  为隐藏层的个数。初始种群  $P_0 = \{\chi_1, \chi_2, \dots, \chi_S\}$  通过均匀分布随机生成, 其中  $S$  为种群规模。

适应度函数衡量个体染色体对应的神经网络预测性能, 定义为预测均方误差的倒数以最大化选择压力:

$$f_i = \frac{1}{\zeta + \frac{1}{N} \sum_{k=1}^N (d_k - y_k)^2}, \quad (14)$$

其中  $d_k$  为第  $k$  个台区的实际线损率;  $y_k$  为神经网络输出值;  $N$  为训练样本数;  $\zeta$  为极小常数以避免除零错误;  $f_i$  为适应度值, 该值越高, 表明个体参数  $\chi_i$  对应的网络预测越精准。

基础 GA 采用轮盘赌选择法 (RWS: Roulette Wheel Selection), 个体选择概率为

$$C_i = f_i / \left( \sum_{j=1}^S f_j \right), \quad (15)$$

其中  $C_i$  为个体选择概率;  $f_i$  为适应度值。高适应度个体获得更多遗传机会, 维持种群优良基因。

与基础 GA 不同, 笔者采用随机通用采样 (SUS: Stochastic Universal Sampling) 替代传统轮盘赌选择, 提升优良个体保留概率。SUS 过程总结如下。

步骤 1 计算种群适应度总和  $F$

$$F = \sum_{j=1}^S f_j. \quad (16)$$

步骤 2 生成  $S$  个等距指针位置  $q_r$ :

$$q_r = (r - 1) + U(0, 1), \quad r = 1, 2, \dots, S, \quad (17)$$

其中  $U(0, 1)$  为服从  $0 \sim 1$  的均匀分布。

步骤 3 累积适应度区间划分为  $C_i$ :

$$C_i = \sum_{j=1}^i f_j, \quad i = 1, 2, \dots, S. \quad (18)$$

步骤 4 选择  $S$  次满足以下条件的个体:

$$C_{i-1} \leq q_r \leq C_i. \quad (19)$$

SUS 通过消除轮盘赌的随机偏差, 确保高适应度个体被选中的次数与其适应度成正比。

传统 GA 对选中的父代染色体  $\chi_i$  与  $\chi_j$  进行实数交叉<sup>[19]</sup>操作, 生成子代  $\chi'_i$  与  $\chi'_j$ :

$$\begin{cases} \chi'_{im} = \alpha \chi_{im} + (1 - \alpha) \chi_{jm}, \\ \chi'_{jm} = (1 - \alpha) \chi_{im} + \alpha \chi_{jm}, \end{cases} \quad (20)$$

其中  $\alpha$  为随机交叉系数;  $m$  为基因位索引。

为提升性能, 笔者采用模拟二进制交叉 (SBX: Simulated Binary Crossover) 实现父代基因混合, 其子代生成公式更新为

$$\begin{cases} \chi'_{ij} = \frac{1}{2} [(1 + \beta_j) \chi_{pj} + (1 - \beta_j) \chi_{qj}], \\ \chi''_{ij} = \frac{1}{2} [(1 - \beta_j) \chi_{pj} + (1 + \beta_j) \chi_{qj}], \end{cases} \quad (21)$$

其中  $\chi'_{ij}$  和  $\chi''_{ij}$  为 SBX 生成的子代;  $\chi_q$  和  $\chi_p$  为父代个体;  $\beta_j$  为第  $j$  维基因的扩散因子, 服从分布如下:

$$\beta_j = \begin{cases} (2u_j)^{1/(\eta_c+1)}, & u_j \leq 0.5, \\ \left[ \frac{1}{2(1-u_j)} \right]^{1/(\eta_c+1)}, & u_j > 0.5, \end{cases} \quad (22)$$

其中  $u_j$  为服从 0 ~ 1 的均匀分布;  $\eta_c$  为交叉分布指数。SBX 通过调节  $\eta_c$  控制子代与父代的相似度, 较均匀交叉更利于维持种群多样性。

传统 GA 对子代基因进行变异操作:

$$\chi''_{im} = \chi'_{im} + \delta, \quad \delta \sim N(0, \sigma_m^2), \quad (23)$$

其中  $\chi''_{im}$  为变异后的子代;  $\chi'_{im}$  为变异前的子代;  $\delta$  为高斯变量;  $\sigma_m$  为第  $m$  维基因的变异强度。

提升变异性能, 笔者引入多项式变异 (PM: Polynomial Mutation) 实现局部扰动, 则基因变异公式更新为

$$\chi''_{im} = \chi'_{im} + \delta_j(\theta_{\max} - \theta_{\min}),$$

$$\delta_j = \begin{cases} (2u_j)^{1/(\eta_m+1)}, & u_j \leq 0.5, \\ 1 - \left[ \frac{1}{2(1-u_j)} \right]^{1/(\eta_m+1)}, & u_j > 0.5, \end{cases} \quad (24)$$

其中  $\eta_m$  为变异分布指数。PM 通过调节  $\eta_m$  扰动幅度, 在进化后期减小变异强度以稳定收敛。

为避免优良基因丢失, 笔者采用精英保留策略 (EPS: Elitism Preservation Strategy), 即每代保留适应度最高的若干个个体直接进入下一代 (通常取种群规模的 5%)。精英个体不参与交叉与变异, 确保全局最优解不被破坏。

为提升 IGA 的收敛效率与鲁棒性, 提出自适应参数调整机制。该机制包括交叉概率自适应调整和变异概率退火调度两个策略。交叉概率自适应调整根据种群适应度差异动态调整交叉概率  $p_c$ :

$$p_c(t) = p_{c0} e^{(t\sigma_f / (T_{\max}\bar{f}))}, \quad (25)$$

其中  $p_{c0}$  为初始交叉概率;  $\sigma_f$  为种群适应度标准差;  $\bar{f}$  为平均适应度;  $T_{\max}$  为最大进化代数。当种群多样性下降 ( $\sigma_f$  减小) 时, 降低  $p_c$  以减少无效交叉。

变异概率退火调度旨在采用指数衰减调度 (EDS: Exponential Decay Scheduling) 调整变异概率  $p_m$ :

$$p_m(t) = p_{m0} e^{(-\gamma t / T_{\max})}, \quad (26)$$

其中  $\gamma$  为衰减率, 控制变异概率从初始值  $p_{m0}$  逐渐降低。该策略在进化早期增强全局探索能力, 后期侧重局部开发。

当进化代数达到阈值  $T_{\max}$  或最优适应度连续  $K$  代无改善时终止迭代, 解码最优个体  $\chi^*$  获得神经网络最优参数  $W^*$  与  $b^*$ 。

## 2.2 LMBP-NNM

莱文贝格-马夸特反向传播神经网络 (LMBP-NNM) 是一种结合二阶优化算法与多层前馈结构的深度学习模型, 其核心优势在于通过近似二阶导数信息加速网络收敛速度, 同时保持反向传播 (BP: Back Propagation) 算法的误差梯度修正特性。该模型在配电网理论线损计算 (LLC) 中承担非线性映射功能, 将台区电气特征量 (如电压偏差率、负载率、功率因数等) 与线损率 (LLR) 间的复杂关系建模为可微分的参数化函数。

LMBP-NNM 为 3 层前馈网络, 包含输入、隐藏与输出层, 每层间通过全连接权重矩阵与偏置向量实现信息传递。设输入特征向量为  $\mathbf{x} \in \mathbb{R}^m$ , 输出标量为  $y \in \mathbb{R}$ 。输入层节点数等于电气特征维度  $m$ , 负责接收标准化后的台区运行数据, 无激活函数处理, 直接传递至隐藏层。隐藏层节点数设为  $h$ , 采用缩放指数线性单元 (SELU: Scaled Exponential Linear Unit) 作为激活函数, 则有:

$$\begin{cases} f_{\text{SELU}}(z) = \lambda \begin{cases} z, & z > 0, \\ \eta(e^z - 1), & z \leq 0, \end{cases} \\ z = \omega_h^T \mathbf{x} + b_h, \end{cases} \quad (27)$$

其中  $z$  为隐藏层输入加权和;  $\omega_h \in \mathbb{R}^m$  为输入层至隐藏层的权重向量;  $b_h \in \mathbb{R}$  为偏置项,  $\lambda$  和  $\eta$  为自归一化系数, 确保网络在深层训练中维持稳定梯度流。

输出层为单节点线性输出, 对应线损率预测值, 则有:

$$y = \omega_o^T a_h + b_o, \quad (28)$$

其中  $a_h$  为隐藏层激活值;  $\omega_o \in \mathbb{R}^h$  为隐藏层至输出层的权重向量;  $b_o \in \mathbb{R}$  为输出层偏置。

LMBP-NNM 的参数优化基于莱文贝格-马夸特算法<sup>[20]</sup> (LMA: Levenberg-Marquardt Algorithm), 该算法通过融合梯度下降与高斯-牛顿法实现快速收敛。设训练集包含  $N$  个样本, 网络参数集合为  $\theta \in \mathbb{R}^M$ , 其中  $M$  为参数总数, 优化目标为最小化均方误差:

$$E(\theta) = \frac{1}{2N} \sum_{k=1}^N (d_k - y_k)^2, \quad (29)$$

其中  $d_k$  为第  $k$  个样本的真实线损率;  $y_k$  为网络预测值。

LMA 的权重公式更新为

$$\Delta\theta = -(\mathbf{J}^T \mathbf{J} + \mu \mathbf{I})^{-1} \mathbf{J}^T \mathbf{e}, \quad (30)$$

其中  $\mathbf{J}$  为误差对参数的雅可比矩阵;  $\mu$  为阻尼因子, 动态调整算法在梯度下降( $\mu$  较大时)与高斯-牛顿法( $\mu$  较小时)之间的切换;  $\mathbf{I}$  为单位矩阵, 用于保证矩阵  $\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}$  正定可逆。迭代过程中, 若当前步长使误差  $E(\theta)$  减小, 则接受更新并减小  $\mu$ ; 否则增大  $\mu$  并重新计算步长, 直至满足收敛条件。

虽然 SELU 在理论上具备自归一化特性, 但其在负区间的指数运算可能增加计算开销。为此, 笔者提出分段平滑激活函数 (PSAF: Piecewise Smooth Activation Function), 如下:

$$f_{\text{PSAF}}(z) = \begin{cases} z, & z > 1, \\ \frac{1}{2}z^2 + \frac{1}{2}, & -1 \leq z \leq 1, \\ -\frac{1}{2}z^2 - \frac{1}{2}, & z < -1. \end{cases} \quad (31)$$

该函数在  $|z| \leq 1$  区间引入二次平滑, 避免指数运算且保持连续可导, 其一阶导数为

$$f'_{\text{PSAF}}(z) = \begin{cases} 1, & |z| > 1, \\ z, & |z| \leq 1. \end{cases} \quad (32)$$

PSAF 通过简化负区间计算提升前向传播效率, 同时其导数在  $|z| \leq 1$  区间线性变化, 有助于缓解梯度消失问题。

传统 LMA 的阻尼因子  $\mu$  采用固定比例调整, 可能导致收敛速度波动。为此, 引入自适应阻尼因子 (ADF: Adaptive Damping Factor) 策略。首先, 对误差变化率进行检测, 定义误差下降率为

$$\rho = \frac{E(\theta^{(t)}) - E(\theta^{(t)} + \Delta\theta)}{\Delta\theta^T (\mu \Delta\theta - \mathbf{J}^T \mathbf{e})}, \quad (33)$$

其中  $\rho$  为误差下降率;  $\nu$  为阻尼调整因子。其中当  $\rho > 0.75$  时, 认为当前步长有效, 减小  $\mu$  至  $\mu/\nu$ ; 当  $\rho < 0.25$  时, 增大  $\mu$  至  $\mu \times \nu$ 。

采用历史梯度加权策略, 根据过去的梯度变化趋势调整阻尼调整因子:

$$\nu^{(t+1)} = \nu^{(t)} \exp\left(\frac{1}{T} \sum_{N\tau=t-T_N+1}^t f_{\text{sign}}(\nabla E(\theta^{(\tau)}))\right), \quad (34)$$

其中  $f_{\text{sign}}$  为符号函数, 该机制使  $\nu$  在稳定收敛阶段自动增大以加速迭代, 在震荡阶段减小以提高稳定性。

## 3 实验与分析

### 3.1 实验设置

笔者针对低压配电网线损特征识别与理论线损计算问题, 基于某省级供电公司辖区内 710 个配变台区的历史运行数据进行实证分析。实验数据采集自该地区 2023 年 1 月-2024 年 6 月期间的配电网监控系统, 包含台区总表电压、电流、功率因数、日供电量、线损率等核心指标, 数据采样间隔为 15 min, 经

数据清洗后形成包含 43 200 余条日维度样本的基础数据集。

实验硬件采用搭载双路 Intel Xeon Gold 6248R 处理器(主频 3.0 GHz)、512 GByte DDR4 内存及 NVIDIA A100 Tensor Core GPU 的服务器平台,操作系统选用 Ubuntu 20.04 LTS,开发环境基于 Anaconda3 构建的 Python 3.9 虚拟环境,深度学习框架采用 PyTorch 1.12.1,机器学习算法实现依赖 scikit-learn 1.2.2 库及自定义算法模块。数据预处理阶段首先执行异常值检测,采用  $3\sigma$  原则剔除线损率超出  $[\mu-3\sigma, \mu+3\sigma]$  区间的异常样本,然后对电压偏差率、负载率等连续型特征进行 Z-Score 标准化处理,对台区类型等类别型特征实施独热编码转换。在特征工程环节,通过皮尔逊相关系数分析筛选出与线损率相关性绝对值大于 0.3 的 12 个关键特征,包括日供电量波动系数、三相不平衡度、平均负载率等。

实验设置包含 3 个核心模块:针对台区区域线损特征识别的 MFW-IKCA 算法验证,设置聚类数目  $K=5$ ,动态权重矩阵迭代阈值  $\varepsilon=1\times10^{-4}$ ,惩罚因子  $\lambda=0.8$ ,熵权法与互信息法的融合系数  $\alpha=0.6$ ;针对 IGA-LMBP-NNM 线损计算模型的训练优化,配置遗传算法种群规模  $N=50$ ,最大进化代数  $G=100$ ,交叉分布指数  $\eta_c=20$ ,变异分布指数  $\eta_m=20$ ,LMBP 神经网络隐藏层节点数设为 64,采用 SELU 激活函数与自适应阻尼因子策略;在模型评估维度,构建包含 10 折交叉验证的测试框架,设置训练集、验证集、测试集比例为 7:1.5:1.5,并采用均方误差(MSE)、平均绝对误差(MAE)及决定系数(R<sup>2</sup>)作为量化评价指标。

3.2 基准方法

为验证所提 IGA-LMBP-NNM 模型的有效性,实验选取 4 类主流算法作为基准对比方法。首先,将传统 K-means 聚类算法作为无监督学习基准,采用欧氏距离度量样本相似性,设置固定聚类数目  $K=5$ ,初始质心通过随机选择样本点确定,最大迭代次数设为 300 次,收敛阈值  $\varepsilon=1\times10^{-4}$ 。其次,将标准遗传算法优化的 BP 神经网络(GA-BP)作为线损计算对比模型,其遗传算法参数配置为:种群规模  $N=50$ ,交叉概率  $P_c=0.8$ ,变异概率  $P_m=0.1$ ,采用二进制编码方案:神经网络结构设置为输入层 12 节点、隐藏层 32 节点、输出层 1 节点的 3 层全连接架构,激活函数采用 Sigmoid 函数,训练过程采用标准反向传播算法。然后,将支持向量机回归(SVR: Support Vector Regression)模型作为非线性映射基准,选用径向基函数(RBF: Radial Basis Function)核函数,通过网格搜索法确定最优正则化参数  $C\in\{0.1,1,10\}$  与核宽度  $\gamma\in\{0.01,0.1,1\}$  的组合,采用 5 折交叉验证进行参数调优。最后,将随机森林回归(RFR: Random Forest Regression)模型作为集成学习对比方法,设置决策树数量为 100 棵,每棵树的最大深度设为 15 层,采用基尼指数作为特征分裂准则,通过袋外数据(OOB: Out-of-Bag)估计进行特征重要性评估。所有基准算法均采用与实验数据集相同的预处理流程,即执行  $3\sigma$  原则异常值剔除、Z-Score 标准化及特征筛选处理,并在相同训练集、验证集划分比例下进行模型训练,其中 GA-BP 与 SVR 的输入特征维度保持 12 维,RFR 通过内置特征重要性评估机制自动筛选关键特征。

3.3 消融实验

为验证所提方法的有效性,设计 5 组消融实验变体进行对比分析。实验采用相同的 710 个台区数据集,按 7:1.5:1.5 比例划分训练集、验证集与测试集,所有模型均经历 30 次独立重复实验并取均值作为最终指标。消融变体设计如下:

实验 1(移除动态权重矩阵) 将 MFW-IKCA 中的动态权重系数矩阵替换为固定单位矩阵,仅保留参考权重矩阵进行特征加权,其他聚类参数保持不变;

实验 2(单一权重策略) 在权重计算模块仅采用熵权法或互信息法中的单一方法,取消二者融合机制;

实验 3(取消决策树规则提取) 直接输出 MFW-IKCA 的聚类结果而不进行决策树分类规则提取,转而采用轮廓系数进行聚类质量评估;

实验 4(标准 GA 优化) 在神经网络训练模块采用标准遗传算法替代 IGA,保持种群规模和进化代数不变;

实验 5(LMBP 网络) 移除分段平滑激活函数(PSAF)与自适应阻尼因子(ADF: Adaptive

Damping Factor), 恢复使用原始 SELU 激活函数及固定阻尼因子。实验结果如表 1 所示。

表 1 消融实验  
Tab. 1 Ablation experiment

| 消融变体 | 修改模块                  | MSE     | MAE   | $R^2$ | 收敛时间/s |
|------|-----------------------|---------|-------|-------|--------|
| 完整模型 | MFW-IKCA+IGA-LMBP-NNM | 0.015 2 | 0.098 | 0.892 | 192    |
| 实验 1 | 移除动态权重                | 0.018 7 | 0.114 | 0.865 | 189    |
| 实验 2 | 单一权重策略                | 0.017 3 | 0.108 | 0.834 | 195    |
| 实验 3 | 取消决策树规则提取             | 0.016 1 | 0.102 | 0.871 | 188    |
| 实验 4 | 标准 GA 优化              | 0.015 8 | 0.101 | 0.884 | 287    |
| 实验 5 | 标准 LMBP 网络            | 0.016 5 | 0.105 | 0.857 | 201    |

实验表明, 动态权重矩阵、权重融合策略及 IGA 优化机制对模型性能提升的贡献度分别为 18.4%、12.6% 和 9.3%。实验 1 变体因缺失动态权重分配导致线损特征聚类纯度下降 12.3%, MAE 指标增加至 0.114; 实验 2 变体采用单一权重策略后,  $R^2$  指标较完整模型下降 5.8% (熵权法) 和 7.5% (互信息法); 实验 4 变体因标准 GA 的局部最优风险, 最优适应度值波动范围扩大至  $\pm 3.2\%$ 。此外, 实验 5 变体在复杂工况数据上的预测误差较完整模型增加 23.6%, 验证了 PSAF 与 ADF 对非线性映射能力的提升作用。

3.4 与主流方法的对比

为验证所提方法在台区线损特征识别与理论计算任务中的性能优势, 将其与上述 4 类基准方法进行全面对比。实验采用相同的 710 个台区数据集, 所有模型均经历 30 次独立重复实验并取均值作为最终评估依据。关键指标对比结果如表 2 所示。

表 2 关键指标对比结果  
Tab. 2 Comparison results of key indicators

| 算法名称                  | 聚类纯度/% | MSE     | MAE   | $R^2$ | 收敛时间/s | 特征维度 |
|-----------------------|--------|---------|-------|-------|--------|------|
| K-means               | 68.2   | 0.023 1 | 0.132 | 0.784 | 121    | 12   |
| GA-BP                 | —      | 0.021 5 | 0.128 | 0.801 | 298    | 12   |
| SVR                   | —      | 0.019 7 | 0.119 | 0.827 | 87     | 12   |
| RFR                   | —      | 0.018 4 | 0.112 | 0.843 | 45     | 8    |
| MFW-IKCA+IGA-LMBP-NNM | 82.7   | 0.015 2 | 0.098 | 0.892 | 192    | 12   |

在聚类分析任务中, MFW-IKCA 较传统 K-means 算法的聚类纯度提升 14.5%, 其主要得益于动态权重矩阵对电压偏差率、负载率等关键特征的强化作用。K-means 因未考虑特征维度差异性, 导致三相不平衡度等弱相关特征主导聚类过程。MFW-IKCA 通过熵权法与互信息法的融合策略, 使功率因数等强相关特征的权重系数提升, 较 K-means 的均匀权重分配机制改善 42.9%。

在线损计算任务中, IGA-LMBP-NNM 较 GA-BP 的 MSE 指标降低 29.3%, 其归因于 IGA 的自适应参数调整机制使网络参数搜索效率提升 37.2%。相较于 SVR 的 RBF 核函数, LMBP-NNM 通过 SELU 激活函数与 LMA 算法实现更优的非线性拟合能力, 在极端工况下, 其预测误差较 SVR 降低 18.6%。RFR 虽通过特征重要性筛选将输入维度从 12 维降至 8 维, 但因树模型对连续型特征分割的局限性, 其 MAE 指标仍较完整模型高 14.3%。实验表明, 所提方法在保持特征维度完整性的同时, 通过动态权重分配与神经网络优化实现了精度与效率的平衡。

4 结 语

笔者针对低压配电网线损精细化管理的需求, 提出了一种融合多特征加权聚类与智能优化神经网络的线损分析方法。首先, 针对传统聚类算法在电力特征加权方面的不足, 构建了基于动态权重系数矩阵与参考权重矩阵的 MFW-IKCA 算法, 通过熵权法与互信息法的融合策略实现特征维度的自适应加权, 有效解决了传统 K-means 算法特征权重分配主观性强的问题; 其次, 采用 IGA 优化 LMBP-NNM 网络参数, 通过模拟二进制交叉、多项式变异及自适应阻尼因子等改进策略, 显著提升了神经网络在非线性线损映

射任务中的收敛速度与预测精度;最后,利用决策树分类器对聚类结果进行规则提取,结合拉依达准则与核密度估计的异常检测机制,增强了线损特征分析的可解释性与鲁棒性。实验结果表明,所提方法在聚类纯度、均方误差及决定系数等关键指标上均优于  $K$ -means、GA-BP、SVR 及 RFR 等主流模型。笔者的创新点总结如下:

1) 提出了基于动态权重矩阵与交替方向乘子法的改进聚类算法,结合熵权-互信息融合策略,实现了电力多维特征的自适应加权聚类,有效克服了传统方法特征权重分配机制缺失的缺陷;

2) 通过引入分段平滑激活函数与自适应阻尼因子,优化了 LMBP 神经网络的非线性拟合能力,结合改进遗传算法的全局搜索特性,构建了适用于复杂配电网场景的线损计算模型;

3) 建立了聚类-分类-异常检测的联合分析框架,在保证算法精度的同时,通过决策树规则提取与核密度估计验证,显著提升了线损模式识别的可解释性。

未来研究可进一步探索多源异构数据融合机制,并尝试通过模型轻量化改造提升实时计算效率。

## 参考文献:

- [1] 崔婷婷,钟庆,梁怡雪,等. 配电网串/并联型动态电压恢复器组合优化配置方法[J]. 电力电容器与无功补偿, 2025, 46(2): 135-142.  
CUI T T, ZHONG Q, LIANG Y X, et al. Collaborative Optimal Configuration Method for Series/Parallel Dynamic Voltage Restorers in Distribution Network [J]. Power Capacitors & Reactive Power Compensation, 2025, 46(2): 135-142.
- [2] 王宣元,张玮,李长宇,等. 考虑随机性的主动配电网有功无功可行域计算方法[J]. 中国电力, 2025, 58(4): 182-192.  
WANG X Y, ZHANG W, LI C Y, et al. The Large-Scale Integration of Renewable Energy Poses Challenges to the Power Systems, Such as the Shortage of Flexibility [J]. Electric Power, 2025, 58(4): 182-192.
- [3] 叶臻,叶鹏,程绪可,等. 供电网络线损计算研究综述[J]. 沈阳工程学院学报(自然科学版), 2022, 18(2): 58-64.  
YE Z, YE P, CHENG X K, et al. Review of Line Loss Calculation of Supply Network [J]. Journal of Shenyang Institute of Engineering (Natural Science), 2022, 18(2): 58-64.
- [4] 贺远,王耀晨,李军. 同期线损系统在电网消缺中的智能应用[J]. 电世界, 2023, 64(1): 1-5.  
HE Y, WANG Y C, LI J. Intelligent Application of Synchronous Line Loss System in Grid Defect Elimination [J]. Electric World, 2023, 64(1): 1-5.
- [5] 余健铭. 基于大数据配网线路降损系统的研究与设计[J]. 电力设备管理, 2025(3): 133-135.  
SHE J M. Research and Design of a Big Data-Based Loss Reduction System for Distribution Lines [J]. Electric Power Equipment Management, 2025(3): 133-135.
- [6] 张振刚,杨勇,闫高飞. 基于聚类分析的台区阻抗特性及线损模型构建[J]. 电子设计工程, 2025, 33(7): 36-41.  
ZHANG Z G, YANG Y, YAN G F. Construction of Line Transmission Impedance Characteristics and Line Loss Model of Substation Based on Cluster Analysis [J]. Electronic Design Engineering, 2025, 33(7): 36-41.
- [7] 汪颖,李有煜,汪清,等. 基于台区线损状态识别的通用线损率概率密度分布模型[J]. 供用电, 2025, 42(4): 80-90,98.  
WANG Y, LI Y Y, WANG Q, et al. General Probability Density Distribution Model for Line Loss Based on State Identification in Power Distribution Area [J]. Distribution & Utilization, 2025, 42(4): 80-90,98.
- [8] 边舒芳,张伟. 基于改进 LSTM 的低压配电网日线损率预测方法[J]. 粘接, 2025, 52(1): 188-192.  
BIAN S F, ZHANG W. A Daily Line Loss Prediction Method for Medium and Low Voltage Distribution Networks Based on Improved LSTM [J]. Adhesion, 2025, 52(1): 188-192.
- [9] 原俊龙,张军. 基于深度学习的台区线损异常检测系统研究[J]. 光源与照明, 2024(12): 71-73.  
YUAN J L, ZHANG J. Research on Anomaly Detection System for Transformer District Line Loss Based on Deep Learning [J]. Lamps & Lighting, 2024(12): 71-73.
- [10] 刘全,刘晓松,吴光军,等. 基于渐近式  $k$ -Means 聚类的多行动者确定性策略梯度算法[J]. 吉林大学学报(理学版), 2025, 63(3): 885-894.  
LIU Q, LIU X S, WU G J, et al. Multi-Actor Deterministic Policy Gradient Algorithm Based on Progressive  $k$ -Means Clustering [J]. Journal of Jilin University (Science Edition), 2025, 63(3): 885-894.

- [11]胡雅婷,陈营华,宝音巴特,等.一种增量式 MinMax  $k$ -Means 聚类算法 [J]. 吉林大学学报(理学版), 2021, 59(5): 1205-1211.  
HU Y T, CHEN Y H, BAOYIN B T, et al. An Incremental Minmax  $k$ -Means Clustering Algorithm [J]. Journal of Jilin University (Science Edition), 2021, 59(5): 1205-1211.
- [12]王海燕,崔文超,许佩迪,等.一种局部概率引导的优化  $K$ -means++ 算法 [J]. 吉林大学学报(理学版), 2019, 57(6): 1431-1436.  
WANG H Y, CUI W C, XU P D, et al. An Optimized  $K$ -Means++ Algorithm Guided by Local Probability [J]. Journal of Jilin University (Science Edition), 2019, 57(6): 1431-1436.
- [13]冯子炫,王彩玲,冀书关.修正的增广拉格朗日函数内点拟牛顿法 [J]. 吉林大学学报(理学版), 2009, 47(2): 245-247.  
FENG Z X, WANG C L, JI S G. Interior-Point Quasi-Newton Method of Modified Augmented Lagrangian Function [J]. Journal of Jilin University (Science Edition), 2009, 47(2): 245-247.
- [14]赵伟卫,李艳颖,赵风芹,等.基于互信息和随机森林的混合变量选择算法 [J]. 吉林大学学报(理学版), 2017, 55(4): 933-939.  
ZHAO W W, LI Y Y, ZHAO F Q, et al. Hybrid Variable Selection Algorithm Based on Mutual Information and Random Forest [J]. Journal of Jilin University (Science Edition), 2017, 55(4): 933-939.
- [15]王文霞.数据挖掘中改进的 C4.5 决策树分类算法 [J]. 吉林大学学报(理学版), 2017, 55(5): 1274-1277.  
WANG W X. Improved C4.5 Decision Tree Classification Algorithm in Data Mining [J]. Journal of Jilin University (Science Edition), 2017, 55(5): 1274-1277.
- [16]王建刚.基于小生境遗传算法的网络入侵节点智能检测方法 [J]. 吉林大学学报(理学版), 2025, 63(4): 1099-1104.  
WANG J G. Intelligent Detection Method for Network Intrusion Nodes Based on Niche Genetic Algorithm [J]. Journal of Jilin University (Science Edition), 2025, 63(4): 1099-1104.
- [17]景雯,张杰,傅文博,等.基于改进遗传算法的物联网链路负载均衡控制方法 [J]. 吉林大学学报(理学版), 2023, 61(4): 922-928.  
JING W, ZHANG J, FU W B, et al. Load Balancing Control Method of IoT Link Based on Improved Genetic Algorithm [J]. Journal of Jilin University (Science Edition), 2023, 61(4): 922-928.
- [18]隋振,张天星,吴涛,等.基于多种群空间映射遗传算法的立体仓库储位优化 [J]. 吉林大学学报(理学版), 2022, 60(1): 127-134.  
SUI Z, ZHANG T X, WU T, et al. Storage Optimization of Three-Dimensional Warehouse Based on Multi Population Space Mapping Genetic Algorithm [J]. Journal of Jilin University (Science Edition), 2022, 60(1): 127-134.
- [19]尹伟石,刘晓奇,徐轩.热源参数识别问题的 Bayes 遗传算法 [J]. 吉林大学学报(理学版), 2020, 58(4): 841-846.  
YIN W S, LIU X Q, XU X. Bayesian Genetic Algorithm for Heat Source Parameter Identification Problem [J]. Journal of Jilin University (Science Edition), 2020, 58(4): 841-846.
- [20]曹名圆,李蓉,闫雪丽,等.求解非线性方程组的非单调自适应加速 Levenberg-Marquardt 算法 [J]. 吉林大学学报(理学版), 2024, 62(3): 538-546.  
CAO M Y, LI R, YAN X L, et al. Nonmonotonic Adaptive Accelerated Levenberg-Marquardt Algorithm for Solving Nonlinear Equations [J]. Journal of Jilin University (Science Edition), 2024, 62(3): 538-546.

(责任编辑:张洁)