

文章编号:1672-3961(2025)05-0051-11

DOI:10.6040/j.issn.1672-3961.0.2024.329

# 基于拓扑门控的数据-机理混合驱动的主动配电网线损计算方法

安海云<sup>1</sup>,周前<sup>1</sup>,刘玉方<sup>2</sup>,黄成<sup>1</sup>,陈哲<sup>1</sup>,吴秋伟<sup>3\*</sup>

(1.国网江苏省电力有限公司电力科学研究院,江苏 南京 211103; 2.国网江苏省电力有限公司,江苏 南京 211103; 3.清华大学清华深圳国际研究生院,广东 深圳 518055)

**摘要:**传统的配电网线损计算方法不能同时兼顾物理模型的因果逻辑性与数据模型的计算精度优势,无法对不同主体接入下的主动配电网线损进行准确计算。因此,本研究提出一种基于拓扑门控的数据-机理混合驱动的主动配电网线损计算方法。基于随机矩阵理论对不同主体接入后的主动配电网线损特征进行相关性分析,得到与线损率相关性最强的线损特征。然后,基于传统线损计算的机理模型与数据模型,利用拓扑门控融合机理模型的因果逻辑性与数据模型的预测精度,建立基于拓扑门控的数据-机理混合驱动的线损计算模型。以分布式电源、储能、电动汽车充电桩接入下的某地区主动配电网为算例进行分析,采用平均绝对误差与均方根误差等评价指标评估模型的计算精度。算例结果表明,本研究所提方法具有较高的计算精度,能够较好地适应不同主体接入后的主动配电网线损计算。

**关键词:**配电网线损;相关性分析;数据驱动;拓扑门控**中图分类号:**TM732**文献标志码:**A**引用格式:**安海云,周前,刘玉方,等. 基于拓扑门控的数据-机理混合驱动的主动配电网线损计算方法[J]. 山东大学学报(工学版), 2025, 55(5):51-61.

AN Haiyun, ZHOU Qian, LIU Yufang, et al. A hybrid data-mechanism driven approach to active distribution network line loss calculation [J]. Journal of Shandong University (Engineering Science), 2025, 55(5):51-61.

## A hybrid data-mechanism driven approach to active distribution network line loss calculation

AN Haiyun<sup>1</sup>, ZHOU Qian<sup>1</sup>, LIU Yufang<sup>2</sup>, HUANG Cheng<sup>1</sup>, CHEN Zhe<sup>1</sup>, WU Qiuwei<sup>3\*</sup>

(1. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, Jiangsu, China; 2. State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211103, Jiangsu, China; 3. Tsinghua Shenzhen International Graduate School, Tsinghua University, Shenzhen 518055, Guangdong, China)

**Abstract:** Traditional distribution network line loss calculation methods can not simultaneously consider the causal logic of the physical model and the computational accuracy advantage of the data model, and are unable to accurately calculate the active distribution network line loss under the access of different subjects. Therefore, this paper proposed a hybrid data-mechanism driven active distribution network line loss calculation method based on topology gating. Firstly, the correlation analysis of active distribution network line loss features after different subjects' access was performed based on random matrix theory, and the line loss features with the strongest correlation with line loss rate were obtained. Then, based on the mechanism model and data model of traditional line loss calculation, topological gating was used to fuse the causal logic of the mechanism model with the prediction accuracy of the data model to establish a hybrid data-mechanism driven line loss calculation model based on topological gating. The active distribution network in a region with distributed power, energy storage, and electric vehicle charging pile access was taken as an example for analysis, and evaluation indexes such as average absolute error and root mean square error were used to assess the calculation accuracy of the model. The example results showed that the method proposed in this paper had high calculation accuracy and could be well adapted to the calculation of line loss of active distribution network after the access of different subjects.

**Keywords:** power distribution network line loss; correlation analysis; data-driven; topology-gated

收稿日期:2024-12-13

基金项目:国网江苏省电力有限公司科技资助项目(5400-202318203A-1-1-ZN)

第一作者简介:安海云(1984—),女,高级工程师,博士,主要研究方向为电力系统及其自动化。E-mail:haiyun\_229@163.com

\*通信作者简介:吴秋伟(1977—),男,副教授,博士生导师,博士,主要研究方向为配电网优化运行。E-mail: quiwu@163.com

## 0 引言

在“双碳”目标引领下,我国提出建设新型电力系统,而在新型电力系统中,新能源发电占比增长明显<sup>[1-2]</sup>。大量分布式电源、储能、电动汽车充电桩接入到配电网中,使配电网从无源网络变为有源网络,导致支路潮流走向由单一流动变为双向流动,这使得配电网的线损计算变得更为困难<sup>[3]</sup>。

线损的精准计算可以更好地了解配电网的实际运行状况,实现对配电网线损的实时监测和动态调节。

现有的配电网线损计算方法可被归类为机理模型与数据模型两大范畴<sup>[4]</sup>。机理模型方法作为传统且持续推进的方法,已相当成熟。比如基于潮流计算和状态估计技术<sup>[5-6]</sup>的方法,通过实时测量数据校正负荷数据,有效提升线损预测的精确度,但该技术往往忽视了数据的不精确性,且高度依赖于电网的拓扑模型,不适用于配网运行环境日益复杂的情况。改进的等值电阻法<sup>[7]</sup>,尽管尝试修正不精确参数,却受限于数据采集的难度和异常数据处理机制的缺失,可能导致计算过程的不收敛,限制应用范围。此外,通过引入最小负荷率和边界理论概念的方法<sup>[8]</sup>,虽旨在增加电流曲线信息量并放宽假设条件,但统计得到的形状系数和负荷率在应用于复杂线损计算时,仍可能带来偏差。针对低压台区用户的分类负荷曲线叠加法<sup>[9]</sup>,虽有其特定应用场景,却不适用于10 kV配网。基于统计偏差和技术偏差的线损率分析<sup>[10]</sup>,虽提供了一定程度的精细化,但阈值设定和指数选择的高度敏感性,影响结果的稳定性和可靠性。潮流分析与模糊识别结合的方法<sup>[11]</sup>,尽管在估算发电曲线以计算线损方面有所探索,但频繁的潮流分析迭代和发电曲线的不精确性,限制了其精度。精细化线损计算方法<sup>[12-13]</sup>,利用实时计量数据和线路拓扑,但仍依赖于简化的模型和经验参数,影响计算精度。上述机理驱动的线损计算方法因果逻辑性强、对数据质量要求低,但大多采用简化的模型及经验参数,计算精度较低。

随着数据驱动技术的蓬勃发展,数据模型方法在线损计算领域崭露头角。这些方法,如基于粒子群算法优化支持向量回归的模型<sup>[14]</sup>,虽展现了强大的预测能力,但由于对数据质量存在高度敏感性,在数据异常或缺失时会降低准确性。高斯牛顿法虽被用于潮流计算和理论线损估算<sup>[15-16]</sup>,但节点数据的全面采集要求不仅增加了实施难度,还可能导

致数值误差,影响结果的精确性。瞬态自适应麻雀搜索算法优化形变LSTM网络的预测方法<sup>[17]</sup>,虽在预测精度上有所提升,但未处理多源数据中的异常值,数据精度成为制约性能的关键因素。基于灰色关联分析法和BP神经网络的预测模型<sup>[18]</sup>,虽在特征指标选择和预测模型构建上有所创新,但隐含层节点数的确定仍是难题。多模型融合的Stacking集成学习方法<sup>[19]</sup>,虽通过集成不同机器学习算法提高了负荷预测的鲁棒性,但性能仍高度依赖于数据的质量和数量。总体而言,数据驱动方法虽在计算精度上展现出优势,但模型参数完全依赖于数据,对数据质量提出严苛要求,且存在泛化风险<sup>[20-22]</sup>。

针对上述问题,本研究提出一种基于拓扑门控的数据-机理混合驱动的配电网线损计算方法,充分融合数据驱动以及机理驱动的优点,能够更精确地计算分布式电源、储能及电动汽车充电桩等不同主体大规模接入后的配网线损。首先,采用随机矩阵理论量化分析分布式电源接入后的配网线损与线损特征指标之间的相关性;然后,根据配电网拓扑结构、线路参数、各节点的历史功率曲线以及历史测量数据,分别构建基于回路分析法的机理驱动模型以及基于深度神经网络的数据驱动模型,在此基础上通过拓扑门控将机理模型嵌入数据模型中,建立基于拓扑门控的数据-机理混合驱动的线损计算模型,对所有模型的线损率计算结果进行拟合,得到与实际值偏差最小的线损率曲线。实现对配网线损的精确计算。

## 1 配电网线损率相关性分析

由于分布式电源出力具有不确定性,需要对分布式电源接入的配电网线损与线损特征之间的相关性进行多时间维度的量化分析<sup>[23]</sup>,本研究基于随机矩阵理论分析分布式电源接入的配电网多时间维度的运行状态数据,确定线损与线损特征之间的相关性以及相关性随时间的变化情况。

### 1.1 数据预处理

由于采集设备故障和人为操作失误等因素的影响,电力系统运行数据可能出现缺失或异常。因此,为了确保数据的质量,在进行线损数据分析之前,需要对原始数据进行处理<sup>[24]</sup>。

#### (1) 缺失值处理

随机森林法<sup>[25]</sup>是一种填充缺失值的方法。使用随机森林法填充缺失值时,缺失值所在的特征将作为需要预测的目标变量,而其他特征将作为预测

的输入变量。遍历所有的特征,从缺失最少的开始进行填补。填充一个缺失值后,可以使用新填充的数据重新训练随机森林模型,并使用该模型填充下一个缺失值,直到所有的缺失值都被填充完毕。

### (2) 异常值处理

本研究采用 Z-score 法<sup>[23]</sup>检测数据的异常值。计算公式为

$$Z_i^s = \frac{x_i - \mu}{\sigma}, \quad (1)$$

式中: $x_i$ 为数据点; $\mu$ 为所有数据点的均值; $\sigma$ 为所有数据点的标准差; $|Z_i^s|$ 表示标准差范围内的分数与总体均值的距离,一般将阈值设置为 2.5,当 $|Z_i^s|$ 大于阈值时,判定为异常值。

### (3) 数据归一化

对数据进行标准化处理,可以避免计算过程中指标之间的量纲影响。通过将原始数据转换为具有相同量纲的数据,使得各指标处于同一数量级,从而方便进行综合对比。计算公式为

$$x'_i = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (2)$$

式中, $x$ 为线损指标; $x_{\min}$ 为指标中的最小值; $x_{\max}$ 为指标中的最大值; $x'_i$ 为归一化后的指标。

## 1.2 随机矩阵的基本原理

用随机矩阵分析矩阵的线性特征根,可以研究系统的能谱和本征态,揭示数据整体的行为特征后,可以对复杂系统的性质进行宏观研究<sup>[25]</sup>。本研究以随机矩阵理论中的单环定理<sup>[23]</sup>为基础,分析线损率的相关性。单环定理假设矩阵 $\hat{X}$ 为一个 $N$ 行 $T$ 列的矩阵,并且其中各个元素均为独立分布的随机变量,本研究选用线损率、电压、电流、功率这四个相互独立的因素分析线损率的相关性,因此,矩阵的列数 $T=4$

$$\hat{X} = (\hat{x}_1, \hat{x}_2, \hat{x}_3, \hat{x}_4)^T, \quad (3)$$

式中, $\hat{x}_1, \hat{x}_2, \hat{x}_3, \hat{x}_4$ 分别表示线损率、电压、电流以及功率的 96 时刻数据。

对矩阵 $\hat{X}$ 中的元素进行基本变换处理,得到过渡矩阵 $\tilde{X}$

$$\tilde{x}_{i,j} = [\hat{x}_{i,j} - \mu(\hat{x}_i)] \times \frac{\sigma(\tilde{x}_i)}{\sigma(\hat{x}_i)} + \mu(\tilde{x}_i) \quad (4)$$

式中: $\tilde{x}_{i,j}$ 为过渡矩阵 $\tilde{X}$ 第 $i$ 行第 $j$ 列的元素; $\tilde{x}_i$ 是过渡矩阵 $\tilde{X}$ 第 $i$ 行的向量, $\tilde{x}_i = (\tilde{x}_{i,1}, \tilde{x}_{i,2}, \dots, \tilde{x}_{i,T})$ ;  $\mu(\hat{x}_i)$ 为线损特征 $\hat{x}_i$ 的均值; $\sigma(\hat{x}_i)$ 为线损特征 $\hat{x}_i$ 的标准差; $\mu(\tilde{x}_i)$ 为线损特征 $\tilde{x}_i$ 的均值且 $\mu(\tilde{x}_i) = 0$ ;

$\sigma(\tilde{x}_i)$ 为线损特征 $\tilde{x}_i$ 的标准差且 $\sigma(\tilde{x}_i) = 1$ 。

线损特征奇异值等价矩阵为 $\tilde{X}_u$

$$\tilde{X}_u = \sqrt{\tilde{X}\tilde{X}^T} \times U, \quad (5)$$

式中, $U$ 为哈尔西矩阵。对于线损特征奇异值等价矩阵有 $\tilde{X}_u\tilde{X}_u^T = \tilde{X}\tilde{X}^T$ 。

对线损特征奇异值等价矩阵进行单位化处理,得到标准线损特征矩阵 $\tilde{Z}$

$$\tilde{z}_i = \frac{\tilde{x}_{u,i}}{\sqrt{N\sigma(\tilde{x}_{u,i})}}, \quad i=1,2,\dots,N, \quad (6)$$

式中, $\tilde{z}_i$ 以及 $\tilde{x}_{u,i}$ 分别表示对应矩阵 $\tilde{Z}$ 和 $\tilde{X}_u$ 对角线上的元素。当矩阵行列趋近于无穷,即 $N$ 与 $T$ 趋近于无穷,且比值不变,即 $N/T$ 为恒定值时,线损特征矩阵 $\tilde{Z}$ 的特征值经验谱分布函数如下所示

$$p(\lambda) = \begin{cases} \frac{1}{\pi c L} |\lambda|^{(L/2)-2}, & (1-c)^{L/2} \leq |\lambda| \leq 1 \\ 0, & \text{其他} \end{cases}, \quad (7)$$

式中: $c=N/T$ 为矩阵行列比, $c \in (0, T]$ ;  $\lambda$ 为所建立的线损特征矩阵的特征值; $p(\lambda)$ 为 $\tilde{Z}$ 的特征值经验谱分布函数; $L$ 为线损特征矩阵的维数。由此可见, $\tilde{Z}$ 的特征值分布在一个外环半径为 1,内环半径为 $(1-c)^{L/2}$ 的环内。

## 1.3 线损率相关性分析

### 1.3.1 相关性量化指标

本研究采用平均谱半径(mean spectral radius, MSR)作为线损率相关性分析的量化指标。将矩阵的全部特征值模的平均值定义为平均谱半径,是线损率、电压、电流、功率等线损特征的统计量。平均谱半径

$$\kappa_{\text{MSR}} = \frac{1}{N} \sum_{i=1}^N |\lambda_i|, \quad (8)$$

式中: $\kappa_{\text{MSR}}$ 为平均谱半径, $N$ 为矩阵的行数, $\lambda_i$ 为所建立的线损特征矩阵的第 $i$ 个特征的特征值。

虽然单个特征值无法准确描述矩阵的性质,但矩阵的统计特征可以通过计算所有特征值的平均谱半径来表示。平均谱半径不但可以反映线损特征值的分布情况还可以反映矩阵的迹。由大数定理和中心极限定理可知,矩阵的迹能够反映线损特征相关性的特性。本研究通过观察平均谱半径的变化来揭示线损特征与线损率之间的相关性。

### 1.3.2 分析步骤

对 $n_1$ 个线损率变量,分析 $n_2$ 个线损特征对其的影响,本研究分析电压、电流、功率三个线损特征对单一线损率变量产生的影响,分析步骤如下。

#### (1) 数据源构建

采集一段时间 $T_c$ 内的 $n_1$ 个线损率变量,构建

矩阵  $\mathbf{Z}_{n_1} \in \mathbf{C}^{n_1 \times T_C}$ ; 同理得到线损特征矩阵  $\mathbf{Z}_{n_2} \in \mathbf{C}^{n_2 \times T_C}$ 。一般  $n_1 \neq n_2$ 。当二者数量差距较大时,例如  $n_2$  大于  $n_1$  时,为了避免维数差异过大导致某个变量的作用被弱化,对数量较少的  $\mathbf{Z}_{n_1} \in \mathbf{C}^{n_1 \times T_C}$  扩展  $k^c$  次<sup>[27]</sup>。

$$\mathbf{Z}'_{n_1} = \begin{bmatrix} \mathbf{Z}_{n_1} \\ \mathbf{Z}_{n_1} \\ \vdots \\ \mathbf{Z}_{n_1} \end{bmatrix}^{(k^c \times n_1) \times T_C}, \quad (9)$$

式中,  $k^c$  取小于  $n_1/n_2$  的最大整数。

为了避免数据扩展对相关性造成影响,对  $\mathbf{Z}'_{n_1}$  引入随机噪声。

$$\mathbf{Z}_{n_3} = \mathbf{Z}'_{n_1} + m \times \mathbf{K}, \quad (10)$$

式中:  $\mathbf{K}$  为  $(k^c \times n_1) \times T_C$  的噪声矩阵,且服从正态分布;  $m$  为噪声幅值。

为了避免噪声幅值对分析结果的影响,采用固定信噪比的方式进行分析,信噪比的定义如下

$$\rho = \frac{\text{Tr}(\mathbf{Z}_{n_3} \mathbf{Z}'_{n_3})}{\text{Tr}(\mathbf{K} \mathbf{K}^T) \times m^2}. \quad (11)$$

式中,  $\text{Tr}(\ )$  表示括号内矩阵的迹。

根据上述求得的线损率矩阵  $\mathbf{Z}_{n_1}$ , 引入随机噪声的线损特征矩阵  $\mathbf{Z}_{n_3}$  以及噪声矩阵  $\mathbf{K}$ , 可以构建出适用于相关性分析的试验数据源矩阵  $\mathbf{A}$  与对比数据源矩阵  $\mathbf{A}_K$ 。

$$\mathbf{A} = \begin{bmatrix} \mathbf{Z}_{n_1} \\ \mathbf{Z}_{n_3} \end{bmatrix}, \quad \mathbf{A}_K = \begin{bmatrix} \mathbf{Z}_{n_1} \\ \mathbf{K} \end{bmatrix}. \quad (12)$$

## (2) 数据获取窗口

选用  $N_w \times T_w$  的数据获取窗口对线损特征数据源进行采样处理, 其中  $N_w$  为每周周期采样数据, 与矩阵行数相等,  $T_w$  为采样周期。经过处理后, 可以通过窗口滑动进行连续采样处理, 这样能够同时进行历史数据和实时数据的分析。

## (3) 分析步骤

通过数据采样窗口分别求试验矩阵  $\mathbf{A}$  与对比矩阵  $\mathbf{A}_K$  的标准矩阵并计算平均谱半径  $\kappa_{\text{MSR}, \mathbf{A}}$  和  $\kappa_{\text{MSR}, \mathbf{A}_K}$ 。通过窗口的移动得到随时间变化的  $\kappa_{\text{MSR}, \mathbf{A}}(t)$  和  $\kappa_{\text{MSR}, \mathbf{A}_K}(t)$ 。将  $n_1$  个线损率变量和  $n_2$  个线损特征变量的相关性变化定义为

$$d_{\text{MSR}}(t) = \kappa_{\text{MSR}, \mathbf{A}_K}(t) - \kappa_{\text{MSR}, \mathbf{A}}(t). \quad (13)$$

$t_1$  到  $t_2$  时间内, 线损特征与线损率的相关性为  $s_{\text{MSR}}$

$$s_{\text{MSR}} = \int_{t_1}^{t_2} d_{\text{MSR}}(t) dt. \quad (14)$$

## 2 基于拓扑门控的数据-机理混合驱动的线损计算模型

为了充分发挥机理模型与数据模型的优点, 建立数据-机理混合驱动的线损计算模型。首先, 根据配电网拓扑结构、线路参数以及各节点历史负荷构建基于回路分析法的主动配电网线损计算的机理模型; 其次构建基于深度神经网络的主动配电网线损计算的数据驱动模型; 最后利用拓扑门控将机理模型嵌入数据模型中, 建立基于拓扑门控的数据-机理混合驱动的线损计算模型。

### 2.1 基于回路分析法的配电网线损计算模型

在配电网中, 假设有  $Q+1$  个节点, 每个节点可以与外部电路相连。本研究使用了一个有向图  $M$  来表示这个网络, 其中图的顶点代表电网中的节点, 边代表电流的流动方向和支路。每个节点对应着一个顶点, 标记为  $1, \dots, Q+1$ , 公共接地点用  $\bar{1}$  表示, 电位取值为 0。节点  $q$  的电压表示为  $u_q$ 。配电网络图如图 1 所示, 这个有向图可以分为两部分, 表示为  $M = l \cup \varepsilon$ , 一部分是内部子图  $l$ , 由配电网的支路和节点构成; 另一部分是外部子图  $\varepsilon$ , 由节点和公共地点构成, 外部子图连接了配电网每个节点到公共地点  $\bar{0}$ 。对于没有支路连接而完全由树干构成的有向图共有  $Q+1$  个节点和  $b$  条支路, 则  $b = Q$ 。




图1 简单配电网网络图

Fig.1 Simple distribution network diagram

以图 1 为例, 支路阻抗矩阵为  $\mathbf{Z}_b = \mathbf{R}_b + j\mathbf{X}_b$ ,

$$\mathbf{Z}_b = \begin{bmatrix} \mathbf{Z}_1 & & & \\ & \mathbf{Z}_2 & & \\ & & \ddots & \\ & & & \mathbf{Z}_b \end{bmatrix}, \quad (15)$$

式中:  $\mathbf{Z}_b$  为对角阵,  $\mathbf{Z}_i$  为支路阻抗,  $i = 1, 2, \dots, b$ 。矩阵实部  $\mathbf{R}_b$  为支路电阻矩阵。

$$\mathbf{R}_b = \begin{bmatrix} r_1 & & & \\ & r_2 & & \\ & & \ddots & \\ & & & r_b \end{bmatrix}, \quad (16)$$

式中:  $r_i$  为支路电阻,  $i=1, 2, \dots, b$ 。

$M$  中全部支路组成配电网最大支撑树, 定义  $\bar{p}_j$  为电源节点到负荷节点的路径,  $\bar{p}$  与  $\varepsilon$  的边构成回路, 全网回路总数为  $G$ , 将回路电流列向量  $\mathbf{i}_s$  定义为

$$\mathbf{i}_s = \begin{bmatrix} i_1 \\ i_2 \\ \vdots \\ i_G \end{bmatrix} = \begin{bmatrix} I_1 e^{j\theta_1} \\ I_2 e^{j\theta_2} \\ \vdots \\ I_G e^{j\theta_G} \end{bmatrix}, \quad (17)$$

式中:  $i_1 \dots i_G$  为各回路电流,  $I_1, I_2, \dots, I_G$  为回路电流幅值,  $\theta_1 \dots \theta_G$  为对应的相角。

$D$  为  $G \times G$  维的网络路径矩阵, 矩阵元素  $D_{ij}$  定义为

$$D_{ij} = \begin{cases} 1, & l_i \in \bar{p}_j \\ 0, & l_i \notin \bar{p}_j \end{cases}, \quad (18)$$

式中:  $l_i \in \bar{p}_j$  表示从线路首端到节点  $j$  的路径,  $\bar{p}_j$  经过支路  $i$  ( $i=1, 2, \dots, b, j=1, 2, \dots, G$ );  $l_i \notin \bar{p}_j$  表示从线路首端到节点  $j$  的路径  $\bar{p}_j$  不经过支路  $i$ 。

支路电流列向量  $\mathbf{i}_b$  可以表示为

$$\mathbf{i}_b = \begin{bmatrix} i_{b1} \\ i_{b2} \\ \vdots \\ i_{bb} \end{bmatrix}, \quad (19)$$

式中,  $i_{b1}, i_{b2}, \dots, i_{bb}$  表示各支路电流。

由此可得网络支路电流列向量  $\mathbf{i}_b$  和回路电流列向量  $\mathbf{i}_s$  之间的关系为

$$\mathbf{i}_b = \mathbf{D}^T \mathbf{i}_s, \quad (20)$$

式中:  $\mathbf{D}^T$  表示网络路径矩阵  $D$  的转置。

通过对以上分析的推导, 可以得出结论: 每个节点与配电线首端电源节点之间的电压差可以表示为该节点所在支路到首端电源节点所经过的所有支路电压之和。

$$\Delta \mathbf{V} = \mathbf{DZ}_b \mathbf{i}_b = \mathbf{DZ}_b \mathbf{D}^T \mathbf{i}_s, \quad (21)$$

式中,  $\Delta \mathbf{V}$  为各节点与首端节点之间的电压差列向量。

将路径互阻抗矩阵定义为

$$\boldsymbol{\Sigma} = \mathbf{DZ}_b \mathbf{D}^T. \quad (22)$$

式(21)可表达为

$$\Delta \mathbf{V} = \boldsymbol{\Sigma} \mathbf{i}_s. \quad (23)$$

由此可得配电网线损计算步骤如下 ( $k$  为迭代次数)。

(1) 取电源节点电压列向量形式  $\mathbf{V}^0 = V_0 \mathbf{E}$ , 式中,  $V^0$  为电源节点电压,  $\mathbf{E}$  为  $N \times 1$  阶元素全为 1 的矩阵。

(2) 计算节点注入电流  $i_{sq}^k = (S_q / V_q^{k-1})^*$ ,  $q=1, 2, \dots, n$ , 式中,  $S_q$  为节点  $q$  的功率。

(3) 计算  $\Delta \mathbf{V}^k$ 。

(4) 计算  $\mathbf{V}^k = \mathbf{V}^0 - \Delta \mathbf{V}^k$ 。

(5) 设置计算精度为  $\lambda$ , 重复上述步骤直至满足  $\Delta \mathbf{V}^{k'} = |\mathbf{V}^k - \mathbf{V}^{k-1}| \leq \lambda$ , 输出  $\mathbf{V}^k$ , 若不满足跳转至(2)。

由式(21)可知, 配电网复功率损耗为

$$\dot{S} = \mathbf{i}_b^H \mathbf{Z}_b \mathbf{i}_b = \mathbf{i}_b^H \mathbf{DZ}_b \mathbf{D}^T \mathbf{i}_s = \mathbf{i}_s^H \boldsymbol{\Sigma} \mathbf{i}_s, \quad (24)$$

式中:  $\mathbf{i}_b^H, \mathbf{i}_s^H$  分别为  $\mathbf{i}_b, \mathbf{i}_s$  的共轭转置;  $\boldsymbol{\Sigma} = \mathbf{DZ}_b \mathbf{D}^T$  为回路阻抗矩阵。

虽然基于回路分析法的物理计算模型具有因果逻辑性强, 对数据质量要求低等优点, 但是对于多主体接入的配电网可能会出现迭代求解效率低, 耗费大量计算资源等问题。

## 2.2 基于深度神经网络的配电网线损计算模型

在数据模型构建中, 神经网络的种类繁多。本研究选择使用深度神经网络 (deep neural network, DNN)<sup>[28]</sup>, 深度神经网络结构如图 2 所示。图 2 中,  $x_n$  为输入的线损特征,  $y_1$  为输出的线损率。整个模型由三个层次构成: 输入层用于样本数据, 即输入线损率与电压、电流、功率等线损特征; 经过分析处理后的数据, 即计算得出的线损率, 通过输出层输出; 隐含层由各种计算函数组成。这些函数通过节点连接, 并根据数据输入和计算情况来确定具体的数据。




图 2 深度神经网络模型结构图

Fig.2 Deep neural network model structure

深度神经网络将输入的线损特征  $\mathbf{X}$  通过前向传播映射到输出特征  $\mathbf{Y}$  的线损率, 前向传播公式为

$$\mathbf{H}^l = g(\mathbf{W}^l \mathbf{H}^{l-1} + \mathbf{u}^l), \quad (25)$$

式中,  $\mathbf{H}^l$  为深度神经网络的第  $l$  层的线损特征向量,  $\mathbf{W}^l$  为  $l-1$  层向  $l$  层传播时的权重矩阵,  $\mathbf{u}^l$  为  $l$  层的偏置向量,  $g$  为非线性激活函数。

$L$  表示深度神经网络的隐藏层。若深度神经网络共有  $L-1$  层隐藏层, 那么最后一层隐藏层到输出层的传播公式为

$$Y = W^L H^{L-1} + u^L, \quad (26)$$

式中,  $W^L$  为  $L-1$  层向  $L$  层传播时的权重矩阵,  $H^{L-1}$  为深度神经网络的第  $L-1$  层的线损特征向量,  $u^L$  为  $L$  层的偏置向量。

本研究以深度神经网络为基础, 构建了一个线损计算模型。该模型使用传播公式对不同层之间的数据进行处理。输出数据为配电网的线损率, 并且只有一个输出层。

虽然基于深度神经网络的数据驱动模型, 预测结果精确, 但对数据质量要求高, 且可能不满足各个节点或支路的物理约束。相比机理模型, 数据驱动模型不具有参数解释功能, 可信度较低。

### 2.3 基于拓扑门控的数据-机理混合驱动的线损计算模型

本研究在深度神经网络中嵌入配电线路的拓扑信息与各节点、支路的约束条件, 使神经网络能够在训练过程中学习拓扑结构中的物理机理, 比如基尔霍夫定律、欧姆定律等。进一步配合正则动态加权, 提高数据驱动的线损计算精度, 具有物理模型的机理性与数据模型的精确性优势, 更好地解决多主体接入后带来的配电网线损计算问题。本研究提出了基于拓扑门控的数据-机理混合驱动的线损计算模型, 计算模型如图3所示。图3中,  $\mathcal{L}_{\text{physic}_p}$  为支路有功功率相关约束,  $\mathcal{L}_{\text{physic}_q}$  为支路无功功率相关约束,  $K$  为神经网络层数。

#### 2.3.1 拓扑门控原理

传统深度学习方法常借助导纳矩阵描绘支路状态及节点连接, 但导纳矩阵在处理如电源、负荷等连续变量时信息不足, 且易受共线性问题困扰,

影响模型训练效果。现有的数据驱动方法需针对每种拓扑分别训练模型, 效率低下。解决此问题的关键在于有效表示网络拓扑结构, 使其能作为神经网络的输入, 与电流、电压等数值特征相提并论。因此, 本研究提出拓扑门控网络(temporal graph neural network, TGNN), 该网络能使神经网络充分利用电力系统拓扑信息, 显著增强潮流计算的建模能力。如图3中拓扑门控机制部分所展示, TGNN框架通过两个核心分支——潮流特征网络与拓扑特征网络, 分别捕捉电力系统的初始潮流状态与结构信息。具体而言, 潮流特征网络表征节点的电压幅值、相角及功率(包括有功和无功)等关键数值特征, 同时该框架纳入了拓扑数据。通过拓扑特征网络, 这些拓扑信息被有效提取并编码为向量形式。

TGNN的创新之处在于采用的门控机制, 该机制将物理模型嵌入数据驱动模型。在模型训练阶段, 门控机制利用拓扑特征作为指导信号, 动态调整潮流特征网络的内部参数, 确保模型准确预测线损率的变化。这种将拓扑信息作为门控信号的策略, 不仅增强模型对节点上下文环境的理解能力, 还结合了配电线路的拓扑结构, 从而进行精确的线损率预测。这一设计将融合线损计算的物理模型与数据驱动模型, 实现模型泛化能力的提升。

$$G^h = g(W^h G^{h-1} + u^h), \quad (27)$$

$$H^l = g(g(W^l H^{l-1} + u^l) \odot G^h), \quad (28)$$

式中:  $G^h$  为第  $h$  层的表示拓扑特征的门控向量;  $G^0$  为初始拓扑结构;  $W^h$  为  $h-1$  层向  $h$  层传播时的权重矩阵;  $u^h$  为  $h$  层的偏置向量;  $\odot$  为哈达玛积。

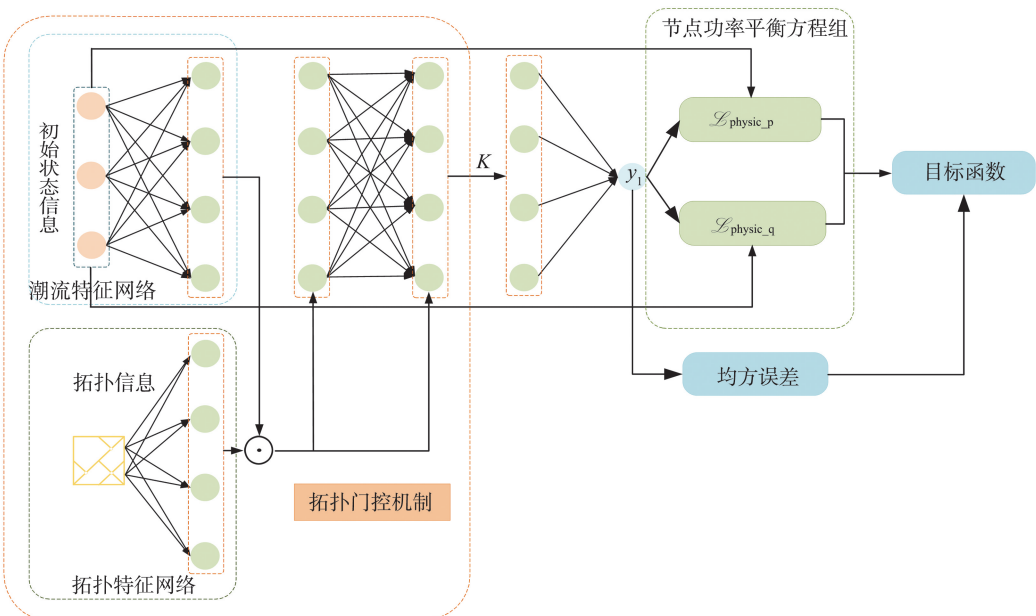


图3 基于拓扑门控的数据-机理混合驱动的线损计算模型结构图

Fig.3 Structure of a hybrid data-mechanism driven line loss calculation model based on topological gating

### 2.3.2 嵌入物理约束的正则化方法

本研究通过正则化手段将底层物理约束融入模型。具体做法是将物理方程式转化为正则项,并纳入目标函数中,以此引导神经网络参数的优化路径。借助这些物理方程式中的原理指导TGNN训练,得到基于拓扑门控的数据-机理混合驱动的线损计算模型。该模型能够遵循基尔霍夫定律、欧姆定律及电网拓扑等约束,有效防止过拟合,提升预测精度,同时确保预测结果既精确又符合物理规律。

为了使该模型的潮流计算物理量满足节点功率平衡方程的约束,本研究提出使节点功率误差最小的目标函数  $\mathcal{L}$

$$\mathcal{L} = (1-\alpha)\mathcal{L}_{\text{MSE}} + \alpha(\mathcal{L}_{\text{phys\_p}} + \mathcal{L}_{\text{phys\_q}}), \quad (29)$$

$$\mathcal{L}_{\text{phys\_p}} = \frac{1}{n} \sum_{i=1}^N \mathcal{L}_{\text{phys\_pi}}, \quad (30)$$

$$\mathcal{L}_{\text{phys\_q}} = \frac{1}{n} \sum_{i=1}^N \mathcal{L}_{\text{phys\_qi}}, \quad (31)$$

式中: $\mathcal{L}_{\text{MSE}}$ 为均方误差表示的损失函数, $\mathcal{L}_{\text{phys\_pi}}$ 和 $\mathcal{L}_{\text{phys\_qi}}$ 表示节点有功功率与无功功率背离节点功率平衡方程的程度, $\alpha$ 为正则权重。由节点功率平衡方程可得:

$$\mathcal{L}_{\text{phys\_p}} = [P_i^{G'} - P_i^D - U_i \sum_{j=1}^N U_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij})]^2, \quad i = 1, 2, \dots, Q, \quad (32)$$

$$\mathcal{L}_{\text{phys\_q}} = [Q_i^{G'} - Q_i^D - U_i \sum_{j=1}^N U_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij})]^2, \quad i = 1, 2, \dots, N, \quad (33)$$

式中, $P_i^{G'}$ 和 $Q_i^{G'}$ 分别代表节点*i*发电机输出的有功功率与无功功率, $P_i^D$ 和 $Q_i^D$ 分别代表节点*i*负荷消耗的有功功率与无功功率, $G_{ij}$ 和 $B_{ij}$ 分别代表节点*i*与节点*j*的线路电导和电纳, $U_i$ 代表节点*i*的电压幅值, $\theta_{ij}$ 代表节点*i*与节点*j*的相角差, $Q$ 为系统的节点总数。

### 2.3.3 动态权重调整策略

基于拓扑门控的数据-机理混合驱动的线损计算模型由均方误差损失项和物理正则项共同指导模型参数的更新。但是直接整合物理正则项可能会降低模型的预测精度。为解决这一问题,本研究采用了一种动态权重调整策略来优化训练过程。具体策略分为两个阶段:初期主要依赖均方

误差(MSE)驱动梯度下降算法的反向传播;然后逐步增加物理正则项在目标函数中的权重,使其随着训练轮次的增加而线性上升。表达式如下

$$\alpha = \begin{cases} 0, & \text{if } R_{tr} \leq R_{tr}^d \\ \alpha_{\max}^* R_{tr} / R_{tr}^{\max}, & \text{if } R_{tr} > R_{tr}^d \end{cases}, \quad (34)$$

式中, $\alpha$ 为物理正则项的权重, $R_{tr}$ 为当前训练轮数, $R_{tr}^{\max}$ 为最大训练轮数, $\alpha_{\max}^*$ 为最大权重占比, $R_{tr}^d$ 为训练轮数阈值。特别地,当 $R_{tr}$ 超过 $R_{tr}^d$ 时,正则项开始被赋予权重。训练初期采用较小的正则项权重,使模型优先关注数据特征和模式,以加速拟合过程。随着训练次数的增加,逐渐增加正则项的权重,使模型更多地考虑物理约束,从而提升预测值的物理一致性。

### 2.3.4 基于拓扑门控的数据-机理混合驱动的线损计算模型训练流程

基于拓扑门控的数据-机理混合驱动的线损计算模型的训练流程如图4所示。该流程结合了物理机理与数据驱动,物理机理部分,如图4绿色区域所示,旨在反映电力系统的物理特性和约束;而数据驱动部分,则专注于学习潮流问题的非线性映射及计算,如图4蓝色区域(数据准备)和橙色区域(训练流程)所示。

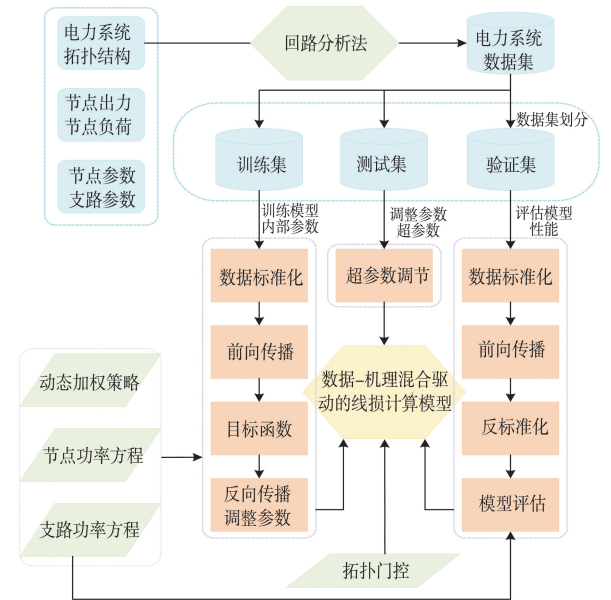


图4 数据-机理混合驱动线损计算模型的训练流程  
Fig.4 Training process for a hybrid data-mechanism driven line loss calculation model

#### (1) 数据准备流程

首先,对数据进行预处理操作,剔除不收敛的样本,以保障数据的完整性和精确度。接着,将此数据集细分为训练集、验证集和测试集。

## (2) 模型架构设计

为了确保模型的计算结果紧密贴合电力系统的物理定律,将节点功率方程以正则化形式整合进神经网络的优化目标内。此外,引入门控机制来融合电力系统的拓扑结构信息,使神经网络能够有效捕捉并模拟节点间的连接关系。在模型训练阶段,实施动态权重调整,适时调节正则项的权重,旨在优化模型的学习过程并提升训练成效。

## (3) 模型训练流程

针对含有  $n$  个节点的电网系统,首先选定线损计算的初始信息,即各母线节点的发电机注入功率(有功  $P^G$  和无功  $Q^G$ )以及负载功率(有功  $P^D$  和无功  $Q^D$ ),其中第  $i$  个母线节点的输入特征为  $[P_i^G, Q_i^G, P_i^D, Q_i^D]$ 。同时,利用电网的拓扑结构信息构建拓扑特征向量  $T$ ,作为拓扑特征网络的输入。输出则为模型计算得出的线损率。

## 3 仿真分析

本研究选用的数据集包括江苏省南京市江宁区 10 kV 配电网的 10 kV 寺后 162 线的 2 784 条线损数据,主要包括各节点 96 个时刻的有功功率、无功功

率、电压等数据。利用数据-机理混合驱动的线损计算模型计算该线路的线损,并与传统物理计算模型、传统数据计算模型进行对比分析。本研究的输入数据为 2024-01-20 当日的各节点有功功率、无功功率以及线损率,数据采集时间间隔为 15 min,在该线路拓扑结构的基础上进行线损率的计算,输出结果为该线路的总线损率。线路拓扑图如图 5 所示,基准电压为 12.66 kV,其中 0 节点、4 节点为分布式电源的接入节点,7 节点为电动汽车接入节点,11 节点为储能接入节点。相关模型在 Python3.7 环境下完成编程计算。为了评估线损计算的结果,选择平均绝对误差 MAE、均方根误差 RMSE、拟合优度  $R^2$  对模型进行评估,如下所示

$$E_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |y_i - y'_i|, \quad (35)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^N (y_i - y'_i)^2}, \quad (36)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - y'_i)^2}{\sum_{i=1}^N (y_i - y_a)^2}, \quad (37)$$

式中,  $y_i$  为线损真实值,  $y'_i$  为线损计算值,  $y_a$  为线损均值,  $n$  为样本数量。

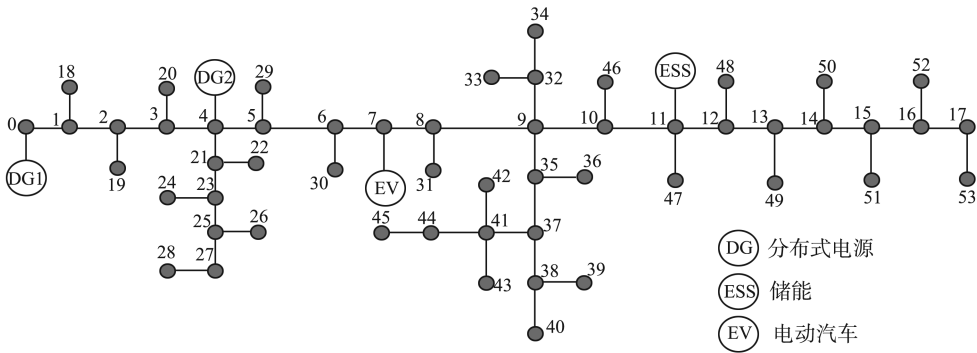


图 5 某地区 10 kV 配电网线路拓扑结构

Fig.5 Line topology of 10 kV distribution network in a region

### 3.1 基于线损特征相关性分析的数据-机理混合驱动的线损计算模型

采用本研究所提方法对南京市江宁区 10 kV 寺后 162 线路的 2024 年 1 月 20 日当日的数据的线路关口量测数据的线损率与电压、电流、功率进行相关性分析。  $T_w$  取 100,  $N_w$  为矩阵行数, 信噪比取 500。

表 1 线损率与电流、电压和功率的相关性

Table 1 The magnitude of the correlation between line loss rate and current, voltage and power

因素	电压	电流	功率
相关性	0.100 1	0.206 1	0.261 2

线损率与电压、电流、功率的相关性如表 1 所示。通过随机矩阵计算得到的相关性结果显示,功率和电流与线损率的相关性较大,而电压与线损率之间的相关性最小。这是因为电压水平通常较为稳定,对线损率的影响相对较小。

### 3.2 线损率计算结果

为了更好地验证模型性能,将本研究所提出的采用基于拓扑门控的数据-机理混合驱动线损计算方法与传统的基于回路电流法和深度神经网络线损计算方法进行仿真对比。训练集与测试集的比例按照一般的设置比例设为 8:2,并采用 5 折交叉验证对模型进行训练。配网线损计算结果如图 6

所示。




图6 配电网线损计算结果

Fig.6 Distribution network line loss calculation results

从图6中可以看出,本研究所提方法计算得到的线损率更接近实际值,线损计算精度优于传统单机理驱动模型与单深度神经网络模型。这是因为本研究所建立的基于拓扑门控的线损分析模型能够充分发挥各个算法的优势,并丢弃计算效果较差的环节。该模型的本质在于,机理模型通过10 kV配电网的拓扑结构和节点负荷数据计算出配电网线损,数据模型从不同角度观测数据并根据观测情况以及算法原理,建立适当的模型计算线损。机理模型与数据模型的计算原理与计算方式不同,基于拓扑门控的数据-机理混合驱动的线损计算模型将机理模型嵌入到数据模型中,得到集成了机理模型与数据模型的最优计算值,可将机理模型的因果逻辑性与数据模型的计算精度高的优势结合起来,并且弱化了机理模型计算精度差以及数据模型对数据精度要求高的缺点,提供更准确和稳定的计算结果。

### 3.3 不同计算方法性能比较

为了进一步验证线损计算的准确性,基于三个评估指标,对比本研究所提方法与其他方法,对比结果如表2所示。其中,拟合优度与计算精度成正比,其余指标与计算精度成反比。

表2中基于回路分析法的机理模型计算由于模型简单,稳定性较差,导致计算精度不如其他方法;由于线损特征数据经过预处理,能够较好地满足深度神经网络模型对数据精度的需求,因此深度神经网络模型有较好的计算精度;本研究所提方法的各项指标优于其余两种方法,这进一步表明本研究采用基于拓扑门控的数据-机理混合驱动的线损计算方法通过对机理模型与数据模型的优化,能够有效

提升配网线损的计算精度。

表2 不同模型计算误差对比

Table 2 Comparison of calculation errors of different models

模型	平均绝对误差	均方根误差	拟合优度
基于回路分析法的机理模型	0.16	0.21	0.24
深度神经网络模型	0.07	0.08	0.47
本研究模型	0.04	0.04	0.82

## 4 结论

本研究针对分布式电源接入配电网导致配网线损难以精确计算的现状,结合机理驱动模型与数据驱动模型的优势,提出一种数据-机理混合驱动的线损计算方法。本方法主要包括线损特征的相关性分析以及基于数据-机理混合驱动的线损计算两个部分。通过基于随机矩阵理论的分布式电源接入配网的线损率相关性分析,得到线损计算模型的输入数据;构建基于回路电流法的线损计算机理模型与基于深度神经网络的线损计算模型,采用拓扑门控将机理模型嵌入数据模型中,建立数据-机理混合驱动的配网线损计算模型。算例结果对比表明:本研究所提基于拓扑门控的数据-机理混合驱动的方法能够有效提升主动配电网线损计算的精度。

### 参考文献:

[1] 曹永吉,张恒旭,张怡,等. 基于事件驱动的机组快速频率响应控制方法[J]. 电力系统自动化, 2021, 45(19): 148-154.  
CAO Yongji, ZHANG Hengxu, ZHANG Yi, et al. Event-driven fast frequency response control method for generator unit[J]. Automation of Electric Power Systems, 2021, 45(19): 148-154.

[2] 李文升,刘晓明,曹永吉,等. 考虑电力系统灵活性的网-储联合规划[J]. 智慧电力, 2023, 51(4): 30-37.  
LI Wensheng, LIU Xiaoming, CAO Yongji, et al. Joint planning of energy storage and transmission line considering power system flexibility [J]. Smart Power, 2023, 51(4): 30-37.

[3] 张恒旭,曹永吉,张怡,等. 电力系统频率动态行为衍变与分析方法需求综述[J]. 山东大学学报(工学版), 2021, 51(5): 42-52.  
ZHANG Hengxu, CAO Yongji, ZHANG Yi, et al. Review of frequency dynamic behavior evolution and analysis method requirements of power system [J]. Journal of Shandong University (Engineering Science),

- 2021, 51(5): 42-52.
- [4] 赵康宁. 基于贝叶斯神经网络的分布式光伏预测及应用[D]. 北京: 中国电力科学研究院, 2020.  
ZHAO Kangning. Distributed photovoltaic prediction and application based on Bayesian neural network [D]. Beijing: China Electric Power Research Institute, 2020.
- [5] RASTGOU A, MOSHTAGH J, BAHRAMARA S. Improved harmony search algorithm for electrical distribution network expansion planning in the presence of distributed generators[J]. Energy, 2018, 151: 178-202.
- [6] 孙宏斌, 张伯明. 配电匹配潮流技术及其在配电状态估计中的应用[J]. 电力系统自动化, 1998, 22(7): 18-22.  
SUN Hongbin, ZHANG Boming. Distribution matching power flow technology and its application to state estimation for distribution systems [J]. Automation of Electric Power Systems, 1998, 22(7): 18-22.
- [7] 付学谦. 考虑配电网网损和电能质量的分布式电源优化配置[D]. 广州: 华南理工大学, 2015.  
FU Xueqian. Optimal allocation of distributed generation considering network loss and power quality of distribution network [D]. Guangzhou: South China University of Technology, 2015.
- [8] 霍佳丽. 电力系统理论线损计算实用方法的分析研究[D]. 重庆: 重庆大学, 2009.  
HUO Jiali. Analysis and research on practical method of theoretical line loss calculation in power system [D]. Chongqing: Chongqing University, 2009.
- [9] 董继征, 陈洪云, 何怡刚. 基于负荷分类的台区线损测算方法[J]. 现代电力, 2006, 23(1): 44-48.  
DONG Jizheng, CHEN Hongyun, HE Yigang. Method for calculating transformer district line loss based on load classification[J]. Modern Electric Power, 2006, 23(1): 44-48.
- [10] 黄明欣, 唐酿, 黄辉, 等. 基于统计偏差和技术偏差的低压台区线损率分析方法[J]. 现代电力, 2024, 41(4): 673-679.  
HUANG Mingxin, TANG Niang, HUANG Hui, et al. A statistical and technical deviations based analysis approach for line loss rate in low-voltage transformer district [J]. Modern Electric Power, 2024, 41(4): 673-679.
- [11] BOWDEN G J, BARKER P R, SHESTOPAL V O, et al. The Weibull distribution function and wind power statistics[J]. Wind Engineering, 1983, 7(2): 85-98.
- [12] 祖凯涛, 林卓琼. 配电网精细化线损计算及降损分析[J]. 陕西电力, 2016, 44(1): 60-64.  
ZU Kaitao, LIN Zhuoqiong. Line loss fine calculation and loss-reducing analysis [J]. Shaanxi Electric Power, 2016, 44(1): 60-64.
- [13] 王磊, 张建宾, 余昆, 等. 基于典型负荷曲线的配电网线损计算方法研究[J]. 智慧电力, 2020, 48(3): 124-130.  
WANG Lei, ZHANG Jianbin, YU Kun, et al. Calculation method of distribution line loss based on typical load curve [J]. Smart Power, 2020, 48(3): 124-130.
- [14] 徐茹枝, 王宇飞. 粒子群优化的支持向量回归机计算配电网理论线损方法[J]. 电力自动化设备, 2012, 32(5): 86-89.  
XU Ruzhi, WANG Yufei. Theoretical line loss calculation based on SVR and PSO for distribution system [J]. Electric Power Automation Equipment, 2012, 32(5): 86-89.
- [15] 张勇军, 石辉, 翟伟芳, 等. 基于层次分析法-灰色综合关联及多灰色模型组合建模的线损率预测[J]. 电网技术, 2011, 35(6): 71-76.  
ZHANG Yongjun, SHI Hui, ZHAI Weifang, et al. Line loss rate prediction based on combinatorial modeling by analytic hierarchy process-gray comprehensive relationship and multi grey models [J]. Power System Technology, 2011, 35(6): 71-76.
- [16] 张力. 配电网理论线损计算分析与研究[D]. 兰州: 兰州理工大学, 2013.  
ZHANG Li. Analysis and research on theoretical line loss calculation of distribution network [D]. Lanzhou: Lanzhou University of Technology, 2013.
- [17] 吴丽珍, 秦文彬, 赵一凡, 等. 基于 TASSA-Mg LSTM 的配电网线损预测方法[J]. 电力系统及其自动化学报, 2023, 35(12): 40-49.  
WU Lizhen, QIN Wenbin, ZHAO Yifan, et al. Prediction method for distribution network line loss based on TASSA-Mg LSTM [J]. Proceedings of the CSU-EPSA, 2023, 35(12): 40-49.
- [18] 张勤, 周步祥, 林楠, 等. 基于灰色模型与神经网络组合的线损率预测[J]. 电力系统及其自动化学报, 2013, 25(5): 162-166.  
ZHANG Qin, ZHOU Buxiang, LIN Nan, et al. Line loss rate forecasting based on combination of grey model and neural network [J]. Proceedings of the Chinese Society of Universities for Electric Power System and Its Automation, 2013, 25(5): 162-166.
- [19] 史佳琪, 张建华. 基于多模型融合 Stacking 集成学习方式的负荷预测方法[J]. 中国电机工程学报, 2019, 39(14): 4032-4042.  
SHI Jiaqi, ZHANG Jianhua. Load forecasting based on

- multi-model by Stacking ensemble learning [J]. Proceedings of the CSEE, 2019, 39(14): 4032-4042.
- [20] 王彪,吕洋,陈中,等.考虑信息时移的分布式光伏机理-数据混合驱动短期功率预测[J].电力系统自动化,2022,46(11):67-74.
- WANG Biao, LYU Yang, CHEN Zhong, et al. Hybrid mechanism-data-driven short-term power forecasting of distributed photovoltaic considering information time shift [J]. Automation of Electric Power Systems, 2022, 46(11): 67-74.
- [21] 尚宇炜,郭剑波,吴文传,等.数据-知识融合的机器学习(1):模型分析[J].中国电机工程学报,2019,39(15):4406-4416.
- SHANG Yuwei, GUO Jianbo, WU Wenchuan, et al. Machine learning methods embedded with domain knowledge(part I): model analysis[J]. Proceedings of the CSEE, 2019, 39(15): 4406-4416.
- [22] 尚宇炜,郭剑波,吴文传,等.数据-知识融合的机器学习(2):泛化风险[J].中国电机工程学报,2019,39(16):4641-4649.
- SHANG Yuwei, GUO Jianbo, WU Wenchuan, et al. Machine learning methods embedded with domain knowledge (part II): generalization risk[J]. Proceedings of the CSEE, 2019, 39(16): 4641-4649.
- [23] 庄远灿.基于过程状态特征化的10 kV配电网线损计算及相关性分析[D].广州:华南理工大学,2018.
- ZHUANG Yuancan. Line loss calculation and correlation analysis of 10 kV distribution network based on process state characterization [D]. Guangzhou: South China University of Technology, 2018.
- [24] 马丽叶,刘建恒,卢志刚,等.基于深度置信网络的低压台区理论线损计算方法[J].电力自动化设备,2020,40(8):140-146.
- MA Liye, LIU Jianheng, LU Zhigang, et al. Theoretical line loss calculation method of low voltage transform district based on deep belief network[J]. Electric Power Automation Equipment, 2020, 40(8): 140-146.
- [25] 张一彦,陆嘉铭,贺静,等.基于改进随机森林算法的线损率预测研究[J].电力大数据,2025,28(3):19-26.
- ZHANG Yiyan, LU Jiaming, HE Jing, et al. A Study on line loss rate prediction based on an improved random forest algorithm[J]. Power Big Data, 2025, 28(3): 19-26.
- [26] 李子龙,刘亚东,王耀东,等.基于大维随机矩阵的电网异常快速检测方法[J].陕西电力,2017,45(3):77-81.
- LI Zilong, LIU Yadong, WANG Yaodong, et al. Abnormal situation detection in power grid with large-dimensional random matrix spectral distribution [J]. Shaanxi Electric Power, 2017, 45(3): 77-81.
- [27] XU X Y, HE X, AI Q, et al. A correlation analysis method for power systems based on random matrix theory[J]. IEEE Transactions on Smart Grid, 2017, 8(4): 1811-1820.
- [28] 黎静华,黄乾,韦善阳,等.基于S-BGD和梯度累积策略的改进深度学习方法及其在光伏出力预测中的应用[J].电网技术,2017(10):3292-3299.
- LI Jinghua, HUANG Qian, WEI Shanyang, et al. Improved deep learning algorithm based on S-BGD and gradient pile strategy and its application in PV power forecasting[J]. Power System Technology, 2017(10): 3292-3299.

(编辑:熊小原)