

一种基于数据驱动递归 AdaBoost 的三相不平衡 配电系统拓扑重构方法研究

蔡木良¹, 范瑞祥¹, 王皓天², 崔明建³, 李赢正¹, 程宏波⁴

(1. 国网江西省电力有限公司电力科学研究院, 江西 南昌 330096; 2. 国网江西省电力有限公司赣州供电分公司, 江西 赣州 342700; 3. 天津大学电气自动化与信息工程学院, 天津 300072; 4. 华东交通大学电气与自动化工程学院, 江西 南昌 330013)

摘要: 拓扑结构的有效重构可以显著提高电网的弹性和可靠性, 然而, 现有的系统拓扑重构模型计算能力仍不足以求解大量变量。为此, 提出了一种基于机器学习的递归自适应增强 (AdaBoost) 方法, 用以增强不平衡配电系统的拓扑重构。首先, 准备标签作为所提递归 AdaBoost 方法的输出, 使用经典的跨越树搜索算法进行拓扑重构。其次, 收集递归 AdaBoost 的输入进行训练, 通过应对非高斯噪声来部署配电系统状态估计 (DSSE) 模型的迭代过程, 并通过非线性最小二乘法 (NLS) 对 DSSE 进行求解。最后, 通过所提递归 AdaBoost 方法计算出最大后验概率, 说明了最优拓扑重构策略。以改进 IEEE 123 节点配电系统作为算例对所提方法的有效性进行了验证。

关键词: 自适应增强; 配电系统; 机器学习; 拓扑重构

中图分类号: TM73

文献标志码: A

DOI: 10.20204/j.sp.2025.04005

A Data-driven Recursive AdaBoost-Based Topology Reconfiguration Method for Three-phase Unbalanced Distribution Systems

CAI Muliang¹, FAN Ruixiang¹, WANG Haotian², CUI Mingjian³, LI Yingzheng¹, CHENG Hongbo⁴

(1. State Grid Jiangxi Electric Power Research Institute, Nanchang 330096, China; 2. State Grid Jiangxi Electric Power Company Limited Ganzhou Power Supply Branch, Ganzhou 342700, China; 3. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China; 4. School of Electrical and Automation Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: Effective topology reconfiguration can significantly enhance the resilience and reliability of power grids. However, existing topology reconfiguration models still lack sufficient computational capability to handle large-scale variables. To address this, this study proposes a machine learning-based recursive adaptive boosting (AdaBoost) method to improve the topology reconfiguration in unbalanced distribution systems. Firstly, training labels are prepared as outputs for the proposed recursive AdaBoost method, and a classical spanning tree search algorithm is employed for the topology reconfiguration. Secondly, inputs for the recursive AdaBoost are collected and trained by deploying an iterative process of the distribution system state estimation (DSSE) model to address non-Gaussian noise, where DSSE is solved via nonlinear least squares (NLS). Finally, the optimal topology reconfiguration strategy is determined by calculating the maximum posterior probability using the proposed recursive AdaBoost method. The effectiveness of the proposed method is validated through case studies on a modified IEEE 123-node distribution system.

Key words: AdaBoost; distribution system; machine learning; topology reconfiguration

0 引言

极端天气事件会在全球范围内导致严重停电, 威胁到配电系统的弹性和可靠性。气候变化使

风、暴风雪和洪水的频率和强度增加, 预计停电事件将显著增加, 从而对配电系统拓扑结构造成严重影响^[1-3]。因此, 拓扑重构策略对减轻负荷削减有重要意义。拓扑重构通过改变开关的状态来实现负载均衡, 是一个涉及多重约束的非线性组合问题, 特别是拓扑约束。与定期测量拓扑信息的输电系统不同, 配电系统常常面临拓扑信息不准确或不可用的问题^[4-6]。因此, 配电系统运营商亟需开发新的方法, 以快速恢复拓扑结构^[7-8]。本文旨在通过调整配电系统的拓扑结构, 解决拓扑重构问题, 恢复故障后的负载。

基金项目: 国家自然科学基金资助项目 (52207130); 江西省重点研发计划项目 (20223BBE51013)

Project Supported by the National Natural Science Foundation of China (52207130); Key R & D Program of Jiangxi Province, China (20223BBE51013)

解决拓扑重构问题的一类方法是构建分析优化模型。文献[9]将拓扑重构问题表示为多目标混合整数非线性规划问题并进行验证。文献[10]基于出行链技术和马尔可夫决策理论,建立了含电动汽车的主动配电网动态重构与有功-无功联合优化数学模型。文献[11]基于马尔可夫决策过程构建了相应的在线决策模型,并提出了在线优化决策问题的求解方法。然而,此类方法主要缺点是求解时间随整数变量增加而增长,模型复杂性随变量增多显著提升,易导致得到次优或不可行解。

另一类方法是构建基于机器学习方法的数据驱动模型。文献[12]提出递归贝叶斯方法,利用状态估计函数输出识别拓扑结构。文献[13]利用深度强化学习算法求解马尔可夫决策过程,以优化弹性拓扑重构调度。文献[14]提出了一种基于改进离散型麻雀搜索算法的配电网恢复重构方法。

近年来,自适应增强(Adaptive Boosting, AdaBoost)算法作为一种先进的基于机器学习的分类方法,通过集成多个学习者,构建了强大的决策模型。文献[15]提出了一种基于 AdaBoost 的集成学习方法,用于估计天气引起的电力中断,研究表明其准确性优于其他分类模型。文献[16]利用 AdaBoost 推导电力系统安全边界的概率描述,证明了其在系统优化中的有效性。文献[17]将 AdaBoost 应用于感应电动机故障检测,结果显示其性能指标优于其他分类器。文献[18]结合 S 变换与 AdaBoost,提出了一种新的电能质量评估技术,其在不同噪声条件下的表现优于支持向量机(Support Vector Machine, SVM)和决策树(Decision Tree, DT)。文献[19]通过模糊聚类阈值技术改进 AdaBoost,测试结果显示该安全评估方法在性能上优于 SVM、前馈神经网络和 K 近邻分类器。

针对上述问题,本文提出了一种改进递归 AdaBoost 方法,以实现不平衡配电系统中的拓扑重构。首先,使用一种现有的用于拓扑重构的生成树搜索 STS 算法作为递归 AdaBoost 生成闭合联络开关的标签。其次,本文设计了一个由电压、有功功率、无功功率的测量误差以及电压不平衡系数组成的输入向量作为所提出的方法准备输入。为了计算该输入向量,本文构建了配电系统状态估计 DSSE 模型来应对非高斯噪声。再次,本文采用非线性最小二乘法(Nonlinear Least Squares, NLS)来求解 DSSE 模型,将输入向量并放入递归 AdaBoost 中进行训练。最后,基于改进的 IEEE 123 节点配电系统进行仿真实验,验证了所提方法的有效性。

1 重构策略库构建

1.1 最优拓扑重构策略

本文采用了文献[20]中提出的跨越树搜索(Spanning Tree Search, STS)算法,通过最大化恢复负荷和最小化切换操作次数,寻找最佳候选分布系统拓扑重构策略。策略池通过 STS 标记所有最终重构策略,并将其作为提出的改进递归 AdaBoost 方法的训练输出。配电系统可以表示为一个连通图 $W(V, B)$, V 是负载节点的顶点集合, B 是馈线段的边集合,其中,联络开关(TS)打开的边集合记作 $W - T_0$ 。假设一条边 $e \in B$ 因系统故障而孤立,则通过用基本割集 $FC_{e_0}(T_0)$ 中的每个边 e_d 替换 T_0 中的边 e_0 , 得到第 i 个生成树 T_i :

$$\begin{cases} T_i = T_0 \oplus \{e_0, e_d\}, e_d \in FC_e(T_0), e_d \neq e_0; \\ d = 1, 2, \dots, N_{T_e}; T_i \in T_z \end{cases} \quad (1)$$

式中: T_0 为正常情况下原始配电网的生成树; T_z 为所有潜在的生成树; d 为边的序号; N_{T_e} 为基本割集 $FC_e(T_0)$ 中的边总数; $\oplus$ 为异或运算。

迭代 1: 考虑到边 e 因故障与配电系统断开连接, 以第 i 个生成树 T_i 和第 j 个生成树 T_j 为例进行说明。从 T_0 中得到生成树 T_i 和 T_j :

$$T_i = \{T|T = T_0 \oplus \{e, e_d\}, e_d \in FC_e(T_0)\} \quad (2)$$

$$T_j = \{T|T = T_0 \oplus \{e, e_d\}, e_d \in FC_e(T_0)\} \quad (3)$$

迭代 2: 以一个边 $e_k \in T_i \cap T_j$ 为例, 在 T_i 和 T_j 中, 计算 2 类生成树:

$$T_{i,e_k} = \begin{cases} T|T = T_i \oplus \{e_k, e_i'\}, \\ e_i' \in FC_{e_k}(T_0) \cap FC_{e_k}(T_i) \end{cases} \quad (4)$$

$$T_{j,e_k} = \begin{cases} T|T = T_j \oplus \{e_k, e_j'\}, \\ e_j' \in FC_{e_k}(T_0) \cap FC_{e_k}(T_j) \end{cases} \quad (5)$$

式中: T 为生成树; T_{i,e_k} 为边 e_k 替换 T_i 中的边 e_i' 得到的生成树; T_{j,e_k} 为边 e_k 替换 T_j 中的边 e_j' 得到的生成树; $FC_{e_k}(T_0)$ 为包含树 T_0 和边 e_k 的割集; $FC_{e_k}(T_i)$ 为包含树 T_i 和边 e_k 的割集; $FC_{e_k}(T_j)$ 为包含树 T_j 和边 e_k 的割集。

在式(5)中, 若 $FC_{e_k}(T_0) \cap FC_{e_k}(T_j) = \emptyset$ 且 $FC_{e_k}(T_0) \cap FC_{e_k}(T_i) \neq \emptyset$, 则生成树 T_i 被保留, 而生成树 T_j 被移除。否则, 生成树 T_i 被移除, 而生成树 T_j 被保留。

1.2 故障发生后的测量估计

将在 DSSE 迭代过程中估计的测量值用作所提

方法的输入。在运行 DSSE 之前,需要获得故障系统的连接矩阵。在发生故障后,本文提出邻接矩阵确定法(Connection Matrix Determination Algorithm, CDMA)来确定受干扰的系统拓扑结构。与文献[12]在平衡配电系统中使用 3 个实际测量值不同,本文使用由状态估计不良数据检测与辨识 DSSE 估计器在第 m 次迭代中估计得到不平衡电压值、有功功率、无功功率及电压不平衡系数。参考文献[12],假设实际测量值仅在变电站(即节点 1)可用,即电压 $(V_{a,1}, V_{b,1}, V_{c,1})$ 。第 m 次迭代中的误差向量 E^m 可表示为:

$$E^m = [V_{\{a,b,c\},1} - \hat{V}_{\{a,b,c\},1}^m, P_{1,2} - \hat{P}_{1,2}^m, Q_{1,2} - \hat{Q}_{1,2}^m] \quad (6)$$

式中: $P_{1,2}, Q_{1,2}$ 分别为线路 1-2 中的有功功率和无功功率的实际测量值; $\hat{P}_{1,2}^m, \hat{Q}_{1,2}^m$ 分别为第 m 次迭代线路 1-2 中的有功功率和无功功率的估计值; $V_{\{a,b,c\},1}$ 为变电站 a, b, c 三相电压实际测量值; $\hat{V}_{\{a,b,c\},1}^m$ 为第 m 次迭代变电站 a, b, c 三相电压估计值。

文献[21-22]使用了电压不平衡系数 VUF 度量指标作为物理度量指标,其定义为负序电压向量 V_{ne} 与正序电压向量 V_{po} 比值的百分比。本文在第 m 次迭代中使用节点 1 的电压不平衡系数 VUF^m ,表达式如下:

$$VUF^m = 100 \times V_{ne}^m / V_{po}^m \quad (7)$$

在第 r 种策略的第 m 次迭代中,获得递归提升算法的组合输入向量 $U_r^m = [E_r^m, VUF_r^m]$, E_r^m 是第 r 种策略的第 m 次迭代中的误差向量, VUF_r^m 是第 r 种策略的第 m 次迭代的电压不平衡系数。为了计算不平衡配电系统中输入向量的值,在第二节中提出一个基于 NLS 的状态估计不良数据检测与辨识 DSSE 模型并求解。

2 NLS 决策支持系统

为计算输入向量,本节采用了状态估计不良数据检测与辨识模型。传统基于加权最小二乘法(Weighted Least Squares, WLS)的 DSSE 模型预先假设噪声为高斯噪声,这种假设在实际应用中,特别是对于非高斯噪声而言过于理想化^[23],针对该问题,本文提出一种基于 NLS 的 DSSE 模型收集测量数据集。

在故障情况下,支路 $h \rightarrow k$ 的支路功率向量测量值为 $[S_{L,a}^{hk}, S_{L,b}^{hk}, S_{L,c}^{hk}]^T$, 节点 h 的注入功率向量测量值为 $[S_{IN,a}^{hk}, S_{IN,b}^{hk}, S_{IN,c}^{hk}]^T$, 其表达式如下:

$$\begin{bmatrix} S_{IN,a}^h \\ S_{IN,b}^h \\ S_{IN,c}^h \end{bmatrix} = \begin{bmatrix} V_a^h \\ V_b^h \\ V_c^h \end{bmatrix} \begin{bmatrix} I_{IN,a}^h \\ I_{IN,b}^h \\ I_{IN,c}^h \end{bmatrix}^* + \begin{bmatrix} \varepsilon_{IN,a}^h \\ \varepsilon_{IN,b}^h \\ \varepsilon_{IN,c}^h \end{bmatrix}, h \in N \quad (8)$$

$$\begin{bmatrix} S_{L,a}^{hk} \\ S_{L,b}^{hk} \\ S_{L,c}^{hk} \end{bmatrix} = \begin{bmatrix} V_a^h \\ V_b^h \\ V_c^h \end{bmatrix} \begin{bmatrix} I_{L,a}^{hk} \\ I_{L,b}^{hk} \\ I_{L,c}^{hk} \end{bmatrix} + \begin{bmatrix} \varepsilon_{L,a}^{hk} \\ \varepsilon_{L,b}^{hk} \\ \varepsilon_{L,c}^{hk} \end{bmatrix}, \begin{cases} k \in h \in N \\ k \neq h \end{cases} \quad (9)$$

式中: $[V_a^h, V_b^h, V_c^h]^T$ 为节点 h 的三相电压向量; $[\varepsilon_{L,a}^{hk}, \varepsilon_{L,b}^{hk}, \varepsilon_{L,c}^{hk}]^T, [\varepsilon_{IN,a}^h, \varepsilon_{IN,b}^h, \varepsilon_{IN,c}^h]^T$ 为过程噪声向量; N 为系统节点的集合; $(k \in h \in N) \cap (k \neq h)$ 为任何与节点 h 相连的节点 k ; $[I_{L,a}^{hk}, I_{L,b}^{hk}, I_{L,c}^{hk}]^T$ 为支路电流向量; $[I_{IN,a}^h, I_{IN,b}^h, I_{IN,c}^h]^T$ 为注入电流向量。

$$\begin{bmatrix} I_{L,a}^{hk} \\ I_{L,b}^{hk} \\ I_{L,c}^{hk} \end{bmatrix} = Z \left(\begin{bmatrix} V_a^h \\ V_b^h \\ V_c^h \end{bmatrix} - \begin{bmatrix} V_a^k \\ V_b^k \\ V_c^k \end{bmatrix} \right) + \lambda_h Y \begin{bmatrix} V_a^h \\ V_b^h \\ V_c^h \end{bmatrix} \quad (10)$$

$$\begin{bmatrix} I_{IN,a}^h \\ I_{IN,b}^h \\ I_{IN,c}^h \end{bmatrix} = \sum_{k \in h} \left\{ \lambda_h Y \begin{bmatrix} V_a^h \\ V_b^h \\ V_c^h \end{bmatrix} + Z \left(\begin{bmatrix} V_a^h \\ V_b^h \\ V_c^h \end{bmatrix} - \begin{bmatrix} V_a^k \\ V_b^k \\ V_c^k \end{bmatrix} \right) \right\} \quad (11)$$

式中: Z 为支路 $h \rightarrow k$ 的三相阻抗矩阵; Y 为节点 h 的三相并联导纳矩阵; $[V_a^k, V_b^k, V_c^k]^T$ 为节点 k 的三相电压向量; λ_h 为系数。

若支路电流从节点 h 测量,则 $\lambda_h = +0.5$; 若支路电流从节点 k 测量,则 $\lambda_h = -0.5$ 。式(8)和式(9)可以写为:

$$[S_{IN,a}^h, S_{IN,b}^h, S_{IN,c}^h]^T = f_{IN}(V_a, V_b, V_c) + \varepsilon_{IN} \quad (12)$$

$$[S_{L,a}^{hk}, S_{L,b}^{hk}, S_{L,c}^{hk}]^T = f_L(V_a, V_b, V_c) + \varepsilon_L \quad (13)$$

式中: $f_{IN}(V_a, V_b, V_c), f_L(V_a, V_b, V_c)$ 分别为节点注入状态函数方程向量、线路状态函数方程向量; $\varepsilon_{IN}, \varepsilon_L$ 为过程误差向量。

假设在使用 NLS 和 WLS 时存在小的过程误差 $[\varepsilon_{V,a}, \varepsilon_{V,b}, \varepsilon_{V,c}]^T$, 则电压幅值和相位的变化如下所示:

$$\begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} U_a^h \\ U_b^h \\ U_c^h \end{bmatrix} - \begin{bmatrix} V_a^h \\ V_b^h \\ V_c^h \end{bmatrix} + \begin{bmatrix} \varepsilon_{V,a} \\ \varepsilon_{V,b} \\ \varepsilon_{V,c} \end{bmatrix}, h \in N \quad (14)$$

式中: $[V_a^h, V_b^h, V_c^h]^T$ 为最初基于高斯噪声假设由 WLS 估计得到的节点 h 的三相电压向量^[12]; $[U_a^h, U_b^h, U_c^h]^T$ 为基于非高斯噪声假设需要由 NLS 估计得到的节点 h 的三相电压向量。

式(14)可概括为:

$$[0, 0, 0]^T = f_V(V_a, V_b, V_c, U_a, U_b, U_c) + \varepsilon_V \quad (15)$$

式中: $f_V(V_a, V_b, V_c, U_a, U_b, U_c)$ 为电压状态函数方程向量; ε_V 为过程误差向量。

推理可得三相配电系统的广义数学模型 G :

$$Y = G(X) + \varepsilon \quad (16)$$

式中: X 为估计变量的集合向量; Y 为测量值的集合向量; ε 为过程噪声的集合向量。

由于预先假设存在非高斯噪声,传统的 WLS 不适用于 DSSE 模型。因此,采用 NLS 来寻找估计值与原始测量值之间的最小误差。状态估计决策支持系统的目标函数 $f(X)$ 由式(17)给出:

$$\tilde{X} = \arg \min_X f(X) = \arg \min_X [Y - G(X)]^T [Y - G(X)] \quad (17)$$

式中: $\tilde{X}$ 为目标函数 $f(X)$ 达到最小值时 X 的取值向量。

定义 1: 式(17)中的非线性目标函数 $f(X)$ 是在 n 维实坐标空间 $\mathbb{R}^n$ 中定义的二阶连续可微函数。当前点向量 X_k 的邻域定义为 $C_k: C_k = \{X \in \mathbb{R}^n | \|X - X_k\| \leq \zeta_k\}$, 其中 ζ_k 是信赖域半径。为求解式(17)中的非线性最小二乘问题, 本文使用信赖域方法:

$$\begin{cases} \min q_k(\Theta) = f(\Theta) + g_k^T \Theta + \frac{1}{2} \Theta^T H_k \Theta \\ \text{s.t. } \|\Theta_k\| \leq \zeta_k \end{cases} \quad (18)$$

式中: $q_k(\Theta)$ 为模型函数; $\Theta = X - X_k$, 为求解变量的信赖域; g_k 为目标函数 $f(\cdot)$ 在当前点向量 X_k 处的梯度; H_k 为在当前点 X_k 处的海森矩阵; $\|\cdot\|$ 为 2-范数。

3 递归 AdaBoost 算法与拓扑重构

3.1 递归 AdaBoost 算法

本文提出了一种改进递归 AdaBoost 算法, 该算法是一种一开一关 (open-1-close-1, O1C1) 方法。对于“一开一关”方法, 当一个闭合的开关打开时, 打开的联络开关有且仅有一个下游节点闭合, 以确保网络连接性。在第 m 次迭代中, 关闭第 r 个联络开关以获得恢复的拓扑结构。第 r 个联络开关的恢复拓扑 $\mathcal{T}_r$ 的后验概率 $\mathcal{P}(\mathcal{T}_r | \mathbf{M}^m)$ 由式(19)给出:

$$\arg \max \mathcal{P}(\mathcal{T}_r | \mathbf{M}^m) = \frac{\mathcal{P}'(\mathcal{T}_r | \mathbf{M}^m) \mathcal{P}(\mathcal{T}_r | \mathbf{M}^{m-1})}{\sum_{t=1}^{N_T} \mathcal{P}'(\mathcal{T}_t | \mathbf{M}^m) \mathcal{P}(\mathcal{T}_t | \mathbf{M}^{m-1})} \quad (19)$$

式中: $\mathbf{M}^m$ 为输入向量集; N_T 为联络开关的总数; $\mathcal{P}(\mathcal{T}_r | \mathbf{M}^{m-1})$ 为第 $m-1$ 次迭代中使用所提递归 AdaBoost 计算得到的第 r 个重构策略的先验概率; $\mathcal{P}'(\mathcal{T}_r | \mathbf{M}^m)$ 为第 m 次迭代中使用传统 AdaBoost 算法估计的第 r 个重构策略的后验概率; $\mathcal{P}(\mathcal{T}_t | \mathbf{M}^{m-1})$ 为第 $m-1$ 次迭代中使用所提递归 AdaBoost 计算得到的第 t 个重构策略的先验概率; $\mathcal{P}'(\mathcal{T}_t | \mathbf{M}^m)$ 为第 m 次迭代中使用传统 AdaBoost 算法估计的第 t 个重构策略的后验概率。

每个联络开关以相等的概率恢复一个拓扑结

构, 即 $\mathcal{P}(\mathcal{T}_r | \mathbf{M}^0) = 1/N_T$, 通过 2 次迭代推导出后验概率 $\mathcal{P}(\mathcal{T}_r | \mathbf{M}^1)$ 和 $\mathcal{P}(\mathcal{T}_r | \mathbf{M}^2)$ 。当信赖域算法在第 N_m 次迭代终止时, 得到第 r 个重构策略的后验概率 $\mathcal{P}(\mathcal{T}_r | \mathbf{M}^{N_m})$:

$$\mathcal{P}(\mathcal{T}_r | \mathbf{M}^{N_m}) = \frac{\mathcal{P}'(\mathcal{T}_r | \mathbf{M}^{N_m}) \mathcal{P}'(\mathcal{T}_r | \mathbf{M}^{N_m-1}) \cdots \mathcal{P}'(\mathcal{T}_r | \mathbf{M}^1)}{\sum_{t=1}^{N_T} \mathcal{P}'(\mathcal{T}_t | \mathbf{M}^{N_m}) \mathcal{P}'(\mathcal{T}_t | \mathbf{M}^{N_m-1}) \cdots \mathcal{P}'(\mathcal{T}_t | \mathbf{M}^1)} \quad (20)$$

式中: $\mathcal{T}_t$ 为第 t 个联络开关的恢复拓扑; $\mathcal{P}'$ 为使用传统 AdaBoost 算法估计的重构策略后验概率。

3.2 拓扑重构方法

基于递归 AdaBoost 算法所提拓扑重构方法主要包括输入向量准备、最优重构策略标签准备、递归 AdaBoost 训练及应用 3 个主要步骤。具体步骤如下:

步骤 1: 在系统故障发生后, 采用所提 CMDA 来确定连接矩阵。然后, 通过 NLS 求解 DSSE 模型, 在每次迭代中收集输入向量, 包括误差向量和电压不平衡系数 VUF 。

步骤 2: 使用现有的 STS 算法获得最优重构策略。将输入向量和作为相应标签的重构策略放入传统的 AdaBoost 模型中, 在每次迭代中进行训练。

步骤 3: 基于步骤 2 中的传统 AdaBoost 提出改进的递归 AdaBoost 算法。当故障发生时, 执行在线测试过程以获得最优重构策略。

4 算例分析

为了验证所提递归 AdaBoost 方法的有效性, 采用了 4 种经典的监督机器学习方法进行比较, 即朴素贝叶斯 (Naive Bayes, NB)^[12]、高斯判别分析 (Gaussian Discriminant Analysis, GDA)^[24]、分类树 (Classification Tree, CTR)^[25] 和 K 近邻 (K-Nearest Neighbor, KNN)^[26]。在 MATLAB R2017a 环境中进行仿真实验。在本节中, 使用三相不平衡 IEEE 123 节点配电网系统^[19]进行算例分析。IEEE 123 节点配电网是一个辐射状配电系统, 单相和两相负载的存在导致负载不平衡。在系统中添加 5 个常开联络开关以创建重构场景, 如图 1 所示, 即 116-118 线路上的联络开关 TS1, 49-117 线路上的 TS2, 38-60 线路上的 TS3, 86-115 线路上的 TS4 和 55-95 线路上的 TS5。本文模拟了 32 个线路故障进行案例研究。对于每个故障, 进行 1 000 次蒙特卡洛模拟以生成用于训练和测试的数据集。其中, 80% 的数据集用于训练, 其余 20% 的数据集用于测试。

假设过程噪声服从非高斯分布,使用基于矩的埃尔米特变换模型生成非高斯噪声,其中均值为零,标准差设置为相应值的比例。标准差比例(Standard Deviation Proportion,SDP)系数用 γ 表示,并设置为0.001,0.003,0.005,0.008和0.01。使用MATLAB中的NLS求解器Isqnonlin求解DSSE模型,停止迭代的容差阈值设置为 1×10^{-6} ,最大迭代次数设置为400。




图1 含5个常开联络开关的辐射状配电网重构场景
Fig.1 Reconstruction scenario of a radial distribution network with 5 normally open tie switches

4.1 网络拓扑重构过程

图1展示了使用本文提出的改进递归AdaBoost方法进行网络拓扑重构的过程。以19-36线路和

73-77线路上的2个独立故障为例。图1(a)展示了正常情况下修改后的IEEE 123节点配电系统,即具有完整拓扑结构的事件前状态。此时连接矩阵已知且具有明确的潮流方向(见线路上的绿色箭头)。图1(b)展示了发生事件时拓扑结构被破坏的状态,网络拓扑因极端故障而被破坏,使得2个孤岛电网与主配电系统隔离(见图1(b)中的绿色和蓝色阴影区域)。本文提出的改进递归AdaBoost方法能够使联络开关TS2和TS3闭合,从而完全恢复配电网拓扑结构,图1(c)展示了使用递归AdaBoost恢复拓扑结构后的事件状态。连接矩阵通过1.2节中所提出的CMDA算法进行更新。因此,潮流方向用红色箭头更新(见图1(c))。

4.2 改进递归AdaBoost的有效性

4.2.1 重构策略的概率分析

基于所提的改进递归AdaBoost方法,比较4种拓扑重构场景下闭合联络开关的概率。使用STS的准确基准重构策略包括以下4种:(1)14-53线路故障并闭合116-118线路上的TS1;(2)22-24线路故障并闭合49-117线路上的TS2;(3)37-38线路故障并闭合38-60线路上的TS3;(4)78-79线路故障并闭合86-115线路上的TS4。4种开关闭合概率如图2所示。




图2 用于拓扑重构的联络开关闭合概率

Fig.2 Closing probability of tie switch for topology reconfiguration

由图2(a)可知,闭合联络开关TS1的概率(见蓝色线)随着迭代次数显著增加,成为最有可能的策略,而其余策略(闭合TS2,TS3,TS4和TS5)以显著较低的概率被排除。类似地,在图2(b),2(c)和2(d)中,

TS2, TS3 和 TS4 分别被确定为拓扑重构中最有可能闭合的联络开关。而其余联络开关的概率较低。

为了验证所提方法的有效性,图3比较了在98-102号线上故障场景下 NB,CTR,GDA 及本文所提改进递归 AdaBoost 方法的性能。在 STS 算法中,将闭合联络开关 TS1 作为重构策略。由图3(a)可知,采用 NB 方法时,闭合 TS2 为最优重构策略。由图3(b)可知,采用 CTR 方法时的概率不稳定,在第5次迭代之前,闭合 TS2 为最优重构策略,而在此之后闭合 TS1 为最优重构策略。由图3(c)可知,采用 GDA 方法时,在第6次迭代后,才能将闭合 TS2 作为最优重构策略。综上所述,由图3(d)可知,本文所提递归 AdaBoost 能够将 TS1 识别为最优重构策略,优于其他几种方法,验证了该方法的有效性。




图3 不同方法性能对比

Fig.3 Performance comparison of different methods

4.2.2 拓扑重构准确性分析

在本次分析中,使用6400个算例来分别测试使用 NB,GDA,CTR 及本文所提改进递归 AdaBoost 的拓扑重构准确性。图4比较了在考虑和不考虑递归过程时的拓扑重构准确性。为了评估不同方法之间的性能,使用准确性度量标准 $A^{[11]}$ 进行比较,其表达式如下:

$$A = \frac{TP + TN}{TP + FN + FP + TN} \quad (21)$$

式中: TP 为真正值; TN 为真负值; FN 为假负值; FP 为假正值。




图4 拓扑重构准确性比较

Fig.4 Accuracy comparison of topology reconfiguration

图4(a)为不考虑递归过程时拓扑重构的准确

性,在最开始时,重构(分类)准确性随着迭代次数而增加。然而,从第5次迭代到第7次迭代,准确性降低,且结果不稳定。图4(b)考虑了递归过程,在从第5次迭代到第7次迭代期间显示出更稳定的结果和更高的准确性。该结果表明,将机器学习技术用于配电系统拓扑重构时,递归过程是影响准确性的重要因素。此外,与其他方法相比,本文所提改进递归 AdaBoost 方法具有更高的准确性,验证了所提方法的有效性。

5 结论

针对三相不平衡配电系统拓扑重构问题,本文提出一种改进递归 AdaBoost 方法。通过算例分析,得到主要结论如下:

1) 提出了一个不需要任何高斯噪声假设的 DSSE 模型,从而得到所提出模型的输入向量,与依赖于高斯噪声的传统 WLS 方法不同,采用 NLS 可有效处理非高斯噪声。

2) 提出了一种 CMDA,基于已知的潮流流向准确确定邻接矩阵,从而使 NLS 能够有效应用在 DSSE 模型的求解中。

3) 提出的改进递归 AdaBoost 算法能够显著提升不同配电系统拓扑重构最优策略的概率估计效果,从数学角度推导证明了该方法的有效性。

参考文献

- [1] GRIFFIN P A. Energy finance must account for extreme weather risk[J]. Nature Energy, 2020, 5(2): 98-100.
- [2] 徐雪松,唐加乐,曾子洋,等. 极端自然灾害下我国城市电力系统韧性提升框架与发展策略研究[J]. 中国工程科学, 2024, 26(2): 198-209.
XU Xuesong, TANG Jiale, ZENG Ziyang, et al. Framework and strategy for enhancing resilience of China's urban power systems under extreme natural disasters[J]. Strategic Study of Chinese Academy of Engineering, 2024, 26(2): 198-209.
- [3] 朱峰辰,翁嘉明,刘东,等. 网格化配电网的控制设备即插即用关键技术探讨[J]. 供用电, 2024, 41(5): 18-27.
ZHU Fengchen, WENG Jiaming, LIU Dong, et al. Discussion on key technology of control equipment plug and play for web-based cellular distribution network [J]. Distribution & Utilization, 2024, 41(5): 18-27.
- [4] 蔡田田,姚浩,杨英杰,等. 基于云-边协同的配电网快速供电恢复智能决策方法[J]. 电力系统保护与控制, 2023, 51(19): 94-103.
CAI Tiantian, YAO Hao, YANG Yingjie, et al. Cloud-edge collaboration-based supply restoration intelligent decision-making method[J]. Power System Protection and Control, 2023, 51(19): 94-103.

- [5] 黎燕,程馨,黄祖梁,等. 高可靠性三相多功能并网变换器研究[J]. 中国电力,2023,56(5):172-181.
LI Yan, CHENG Xin, HUANG Zuliang, et al. Research on high reliability three-phase multi-function grid-connected converter [J]. Electric Power, 2023, 56(5): 172-181.
- [6] 梁栋,郭育威,王笑雪,等. 考虑储能与动态重构的柔性互联配电网两阶段鲁棒优化[J]. 电力建设,2022,43(9):94-103.
LIANG Dong, GUO Yuwei, WANG Xiaoxue, et al. Two-Stage robust optimization for flexible interconnected distribution systems considering energy storages and dynamic reconfiguration [J]. Electric Power Construction, 2022, 43(9): 94-103.
- [7] 陈钢,黄国政,邓瑞麒,等. 结合网络重构的主动配电网日前无功电压双层优化[J]. 供用电,2022,39(5):13-24.
CHEN Gang, HUANG Guozheng, DENG Ruiqi, et al. Bi-level optimization of day-ahead reactive-voltage in active distribution network with network reconfiguration[J]. Distribution & Utilization, 2022, 39(5): 13-24.
- [8] 刘迪,张强,吕干云. 量子粒子群算法在配电网重构中的改进和应用[J]. 电测与仪表,2022,59(3):58-65.
LIU Di, ZHANG Qiang, LV Ganyun, et al. Improvement and application of quantum-behaved particle swarm optimization in distribution network reconfiguration[J]. Electrical Measurement & Instrumentation, 2022, 59(3): 58-65.
- [9] KHUSHALANI S, SOLANKI J M, SCHULZ N N. Optimized restoration of unbalanced distribution system[J]. IEEE Transactions on Power Systems, 2007, 22(2): 624-630.
- [10] 程杉,钟仕凌,尚冬冬,等. 考虑电动汽车时空负荷分布特性的主动配电网动态重构[J]. 电力系统保护与控制,2022,50(17): 1-13.
CHENG Shan, ZHONG Shiling, SHANG Dongdong, et al. Dynamic reconfiguration of an active distribution network considering temporal and spatial load distribution characteristics of electric vehicles [J]. Power System Protection and Control, 2022, 50(17): 1-13.
- [11] 李明轩,魏韡,许寅,等. 基于预演算法的灾后配电网应急抢修决策优化[J]. 电力建设,2023,44(12):85-94.
LI Mingxuan, WEI Wei, XU Yin, et al. Rollout Algorithm-based post-disaster distribution system emergency repair optimization[J]. Electric Power Construction, 2023, 44(12): 85-94.
- [12] SINGH R, MANITSAS E, PAL B C, et al. A recursive Bayesian approach for identification of network configuration changes in distribution system state estimation[J]. IEEE Transactions on Power Systems, 2010, 25(3): 1329-1336.
- [13] YAO S H, GU J X, WANG P, et al. Resilient load restoration in microgrids considering mobile energy storage fleets: A deep reinforcement learning approach[C]. 2020 IEEE Power & Energy Society General Meeting (PESGM). Ieee, 2020: 1-5.
- [14] 李浩,张禄亮,麦章渠,等. 基于改进离散型麻雀搜索算法的配电网恢复重构方法[J]. 智慧电力,2023,51(7):16-22,30.
LI Hao, ZHANG Luliang, MAI Zhangqu, et al. Distribution network recovery reconfiguration method based on improved discrete sparrow search algorithm[J]. Smart Power, 2023, 51(7): 16-22, 30.
- [15] KANKANALA P, DAS S, PAHWA A. AdaBoost+: An ensemble learning approach for estimating weather-related outages in distribution systems[J]. IEEE Transactions on Power Systems, 2013, 29(1): 359-367.
- [16] CREMER J L, KONSTANTELOS I, TINDEMANS S H, et al. Datadriven power system operation: Exploring the balance between cost and risk[J]. IEEE Transactions on Power Systems, 2018, 34(1): 791-801.
- [17] MARTIN-DIAZ I, MORINIGO-SOTELO D, DUQUE-PEREZ O, et al. Early fault detection in induction motors using AdaBoost with imbalanced small data and optimized sampling[J]. IEEE Transactions on Industry Applications, 2016, 53(3): 3066-3075.
- [18] REDDY M V, SODHI R. A rule-based S-transform and AdaBoost based approach for power quality assessment[J]. Electric Power System Research, 2016, 134: 66-79.
- [19] THIRUGNANASAMBANDAM V, JAIN T. AdaBoost classifiers for phasor measurements-based security assessment of power systems [J]. IET Generation, Transmission & Distribution, 2017, 12(8): 1747-1755.
- [20] LI J, MA X Y, LIU C C, et al. Distribution system restoration with microgrids using spanning tree search[J]. IEEE Transactions on Power Systems, 2014, 29(6): 3021-3029.
- [21] MUSCAS C, SULIS S, ANGIONI A, et al. Impact of different uncertainty sources on a three-phase state estimator for distribution networks[J]. IEEE Transactions on Instrumentation and Measurement, 2014, 63(9): 2200-2209.
- [22] VON J A, BANERJEE B. Assessment of voltage unbalance[J]. IEEE Transactions on Power Delivery, 2001, 16(4): 782-790.
- [23] CUI M J, WANG J H. Deeply hidden moving-target-defense for cybersecure unbalanced distribution systems considering voltage stability[J]. IEEE Transactions on Power Systems, 2020, 36(3): 1961-1972.
- [24] FUKUNAGA K, MANTOCK J. Nonparametric discriminant analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1983(6): 671-678.
- [25] DIAO R, VITTAL V, LOGIC N. Design of a real-time security assessment tool for situational awareness enhancement in modern power systems[J]. IEEE Transactions on Power Systems, 2009, 25(2): 957-965.
- [26] FAYED H A, ATIYA A F. A novel template reduction approach for the k-nearest neighbor method[J]. IEEE Transactions on Neural Networks, 2009, 20(5): 890-896.

(责任编辑 付小平)

收稿日期:2024-11-04; 修改日期:2025-02-26

作者简介:蔡木良(1989),男,江西抚州人,高级工程师,主要研究方向为配网优化运行等。E-mail:675175117@qq.com