

基于决策树的含高比例光伏低压配网非参运行优化

朱泽安¹, 潘廷哲^{2,3}, 孟子杰¹, 金鑫^{2,3}, 蔡新雷¹, 罗鸿轩^{2,3}, 李超¹

(1. 广东电网有限责任公司电力调度控制中心, 广州 510600; 2. 南方电网科学研究院, 广州 510663; 3. 广东省电网智能量测与先进计量企业重点实验室, 广州 510663)

摘要: 配电网中灵活性资源与分布式光伏的协同运行调度对提升分布式可再生能源消纳水平和促进国家“双碳”目标的实现具有重要意义, 然而, 传统调度方法往往要求配电网的详细拓扑及线路阻抗信息, 而这些模型信息在实际低压配电网中经常未知。为了克服这一挑战, 提出了一种基于决策树的配电网非参运行优化方法。首先, 通过无监督聚类算法从历史数据中提取拓扑状态信息, 并生成“伪标签”; 然后, 结合运行数据训练决策树, 学习运行策略与潮流约束可行性的关系, 并将决策树等效转化为易于求解的混合整数线性形式, 实现潮流约束的无模型非参重构; 最后, 算例仿真验证了该方法在网络拓扑变化、线路阻抗信息等未知条件下仍可精准地刻画潮流约束的可行域, 且计算效率远高于基于模型的方法。

关键词: 光伏发电; 配电网; 决策树; 机器学习; 混合整数线性规划

Non-Parametric Optimal Operation for Low-Voltage Distribution Networks with High Penetration of PV Generation Based on Decision Tree

ZHU Zean¹, PAN Tingzhe^{2,3}, MENG Zijie¹, JIN Xin^{2,3}, CAI Xinlei¹, LUO Hongxuan^{2,3}, LI Chao¹

(1. Power Dispatching and Control Center of Guangdong Power Grid Co., Ltd., Guangzhou 510600, China; 2. Electric Power Research Institute, CSG, Guangzhou 510663, China; 3. Guangdong Provincial Key Laboratory of Intelligent Measurement and Advanced Metering of Power Grid, Guangzhou 510663, China)

Abstract: In the distribution network, the coordinated scheduling of flexible resources and distributed photovoltaics(PV) plays a crucial role in enhancing the consumption level of distributed renewable energy and promoting the realization of national "dual carbon" goals. However, traditional scheduling methods often require detailed topology and line impedance information of the distribution network, which is frequently unknown in actual distribution networks. To overcome this challenge, a non-parametric operation optimization method for distribution networks based on decision tree is proposed. This method first leverages unsupervised clustering to extract the topology status implied in the historical data to generate "pseudo labels", and then train a decision tree to learn the relationship between operation strategies and the feasibility of flow constraints from historical operation data of the distribution network by training decision trees, and equivalently transforms the decision trees into mixed-integer linear forms that are easy to solve, thereby achieving a non-parametric reconstruction of flow constraints. Case studies show that this method can accurately depict the feasible domain of flow constraints under conditions where network topology and line impedance information are unknown, and its computational efficiency is significantly higher than that of traditional model-based methods.

Key words: PV generation; distribution network; decision tree; machine learning; mixed-integer linear programming

基金项目: 国家重点研发计划资助项目(2022YFE0205300); 中国南方电网有限责任公司科技项目(036000KK52222004(GDKJXM20222117))。

Foundation item: Supported by the National Key Research and Development Program of China (2022YFE0205300); the Science and Technology Project of China Southern Power Grid Co., Ltd.(036000KK52222004(GDKJXM20222117))。

0 引言

受国家“双碳”目标的驱动,分布式光伏发电在配电网中的应用日益增加^[1]。这一趋势提高了可再生能源在配电网中的渗透率,减少了化石能源消耗所带来的碳排放^[2]。同时,光伏发电波动性较大,也为配电网的运行带来了极大的挑战^[3]。因此,如何利用配电网中现有的灵活性资源,例如温控负荷^[4]、分布储能系统^[5]、电动汽车^[6]等,促进光伏发电在配电网中的就地消纳比率,是当前配电网运行的重要任务之一^[7-8],且具有现实的工程意义。

一般而言,灵活性资源与光伏发电的协调运行是基于配电网的物理模型即潮流模型来实现的^[9]。文献[10]基于最优潮流模型开发了一种双层优化框架,用于协调配电网中的移动储能系统与分布式可再生能源的运行。文献[11]构建了一个最优潮流模型以描述配电网的功率分布,并利用广义 Benders 分解方法实现电压控制。然而,配电网原始的潮流模型非凸,难以通过现有的优化算法高效处理。因此,大部分文献引入了线性化方法或松弛方法,将非凸的潮流模型转化为易于处理的凸形式。文献[12]利用一种二阶锥凸松弛对潮流模型进行处理,并基于此详细描述了含高比例可再生能源的配电网的可行域。文献[13]采用了线性化方法对潮流模型进行近似,然后构建了含多种灵活性资源的配电网最优调度模型。上述基于模型的方法可以有效地实现配电网中分布式光伏发电与灵活性资源的协同运行。然而,其研究对象均为高压或中压配电网(电压等于大于等于 10 kV),对应的阻抗与拓扑信息在工程应用上一般准确已知^[14]。在实际低压配电网中,由于未知的设备更改或者设备维护行为,实际拓扑和阻抗信息经常未知或精准度较差^[15]。因此,上述基于模型的方法可能难以用于指导低压配电网运行。

智能电表在配电网中的应用日益广泛,极大地降低了收集运行数据的成本^[16]。因此,越来越多的国内外学者引入机器学习算法实现高效的配电网运行优化。这些基于学习的方法的核心思想较为统一,即利用历史运行数据训练代理模型指导灵活性资源与分布式光伏的协同运行。当训练完成后,给定运行工况,该代理模型即可迅速给出相应的最优运行策略^[17]。文献[18]提出了一种基于监督学习的

针对最优潮流问题的代理优化模型,它通过最小化预测策略与历史最优运行策略的均方根误差实现代理模型的训练。文献[19]利用相似的方法实现了灵活性资源与可再生能源的高效协同运行。文献[20]提出了一种基于强化学习的方法实现最优潮流问题的高效求解。与前述基于监督学习的方法不同,该方法通过与一个虚拟环境不断互动实现代理优化模型的更新。文献[21]也采用强化学习方法指导建筑温控负荷的运行,从而降低能源成本。上述工作同样大多聚焦于中压或高压配电网。少部分工作,如文献[22-23]针对低压配电网开发了基于强化学习的运行优化方法。然而,这些方法仍建立在模型信息之上。

上述研究表明基于模型与基于学习的方法均可实现配电网中灵活性资源与光伏的协同运行,提升光伏的就地消纳,降低配电网总运行能源成本,但其应用时通常需要精准的网络拓扑、线路阻抗参数等模型信息。考虑到实际低压配电网中上述模型信息通常未知或不精准,因此上述方法均难以实际应用。针对上述问题,本文提出一种基于学习的非参优化方法,用于指导低压配电网的运行。该方法首先利用无监督学习方法对历史数据进行聚类,并为其生成“伪标签”,以区分他们的拓扑状态。其次,将上述为标签与历史运行数据作为训练集训练决策树模型,用于判断给定运行决策的可行性。最后,将该决策树转化为易于求解的混合整数线性形式,并作为原始潮流约束的代理模型,在优化模型中进行集成,从而实现低压配电网中灵活性资源与分布式光伏的非参运行优化。

1 含分布式光伏及灵活性资源配电网建模

低压配电网是电力系统中负责将电力从变电站传输到用户端的重要部分。随着分布式光伏的广泛应用,其与低压配电网中的灵活性资源(如储能设备、可调节负荷等)的协同运行成为了提高光伏消纳能力和优化电网运行的关键。为此,配电网的运行策略不仅要考虑如何高效利用分布式光伏和灵活性资源,还必须满足安全运行约束,以保证电网的稳定和安全。

本节首先构建了一个包含分布式光伏和灵活性资源(以温控负荷与储能系统为例)的配电网运行优化模型。该模型综合考虑了分布式光伏、温控负荷

与储能设备的调控能力, 旨在实现配电网中光伏发电与灵活性资源的高效协同运行。为了便于表示, 使用 $i \in N, (i, j) \in B$, 以及 $t \in T$ 分别表示配电网节点、线路以及时间的索引, 其中 N 、 B 分别为配电网节点和支路的集合, T 为时间集合。

1.1 配电网运行模型

1.1.1 分布式光伏模型

分布式光伏的实际输出功率 $P_{i,t}^{\text{DG}}$ 可由其最大可输出功率 $G_{i,t}^{\text{DG}}$ 及弃光率 $\lambda_{i,t}$ 决定, 如式(1)所示。

$$P_{i,t}^{\text{DG}} = G_{i,t}^{\text{DG}} (1 - \lambda_{i,t}), \forall i \in N, \forall t \in T \quad (1)$$

1.1.2 灵活性资源模型

本文采用温控负荷与储能系统为例代表配电网中的灵活性资源。温控负荷的运行可由室内热力学模型描述^[24], 如式(2)所示。

$$\tau_{i,t+1}^{\text{in}} = a_i^{\text{in}} \tau_{i,t}^{\text{in}} + a_i^{\text{out}} \tau_{i,t}^{\text{out}} + a_i^{\text{TCL}} (h_{i,t}^{\text{heat}} - \gamma_i^{\text{COP}} \cdot p_{i,t}^{\text{cool}}), \forall i \in N, \forall t \in T \quad (2)$$

式中: $\tau_{i,t}^{\text{in}}$ 为室内温度; $\tau_{i,t}^{\text{out}}$ 为室外环境温度; $h_{i,t}^{\text{heat}}$ 为室内由人员活动或者电子设备造成的发热功率; γ_i^{COP} 为该空调的能效比; $p_{i,t}^{\text{cool}}$ 为空调制冷的电功率; a_i^{in} 、 a_i^{out} 和 a_i^{TCL} 分别为对应的建筑热力学参数, 可参考文献[25]计算。

储能系统的运行过程可由式(3)描述。

$$E_{i,t+1} = E_{i,t} + \eta^{\text{ch}} p_i^{\text{ch}} - p_i^{\text{dis}} / \eta^{\text{dis}}, \forall i \in N, \forall t \in T \quad (3)$$

式中: $E_{i,t}$ 为储能系统在 t 时刻储存的能量; η^{ch} 与 η^{dis} 分别为充电与放电效率; p_i^{ch} 与 p_i^{dis} 分别为充电与放电功率。

1.1.3 配电网模型

配电网的运行模型可由下述潮流方程描述。

$$\begin{cases} \sum_{k \in C_j} P_{jk,t} = p_{j,t} + P_{ij,t} - r_{ij,t} I_{ij,t}^2 \\ \sum_{k \in C_j} Q_{jk,t} = q_{j,t} + Q_{ij,t} - x_{ij,t} I_{ij,t}^2 \\ V_{j,t}^2 = V_{i,t}^2 - 2(r_{ij,t} P_{ij,t} + x_{ij,t} Q_{ij,t}) + (r_{ij,t}^2 + x_{ij,t}^2) I_{ij,t}^2 \\ I_{ij,t}^2 = \frac{P_{ij,t}^2 + Q_{ij,t}^2}{V_{i,t}^2} \end{cases} \quad (4)$$

$\forall (i, j) \in B, \forall t \in T$

式中: C_j 为与节点 j 相连接的所有节点集合; k 为该集合中的其中一个节点; $P_{ij,t}$ 和 $Q_{ij,t}$ 分别为线路 (i, j) 的有功功率潮流与无功功率潮流; $p_{j,t}$ 及 $q_{j,t}$ 分别为节点 j 的有功功率及无功功率注入; $r_{ij,t}$ 和 $x_{ij,t}$ 分别为线路 (i, j) 上的电阻与电抗; $I_{ij,t}$ 为线路 (i, j) 上的电流有效值; $V_{i,t}$ 为节点 i 上的电压有效

值。其中, 节点注入功率可由下述节点功率平衡方程描述。

$$\begin{cases} p_{i,t} = -p_{j,t}^{\text{cool}} - p_{j,t}^{\text{d}} + p_{j,t}^{\text{DG}}, \forall i \in N, \forall t \in T \\ q_{i,t} = -\kappa_i \cdot p_{j,t}^{\text{cool}} - q_{j,t}^{\text{d}}, \end{cases} \quad (5)$$

式中: $p_{j,t}^{\text{d}}$ 和 $q_{j,t}^{\text{d}}$ 为与节点 i 相连的用户基本有功、无功负荷(即除空调之外的总电功率需求); κ_i 为空调无功功率消耗与有功功率消耗的比值, 可由其功率因数计算获得。配电网与上级电网的功率交换量 g_i (即根节点处的有功功率注入)可由系统整体的功率平衡获得。

$$g_i = - \sum_{i \in N \setminus \{0\}} p_{i,t} + \sum_{(i,j) \in B} r_{ij,t} I_{ij,t}^2, \forall t \in T \quad (6)$$

式中 $\sum_{(i,j) \in B} r_{ij,t} I_{ij,t}^2$ 为配电网中线路上功率损失的总和。

1.2 配电网优化调度模型

1.2.1 目标函数

本文以最小化配电网的购电成本 F 为优化目标, 可根据配电网与上级电网的功率交换量 g_i 直接计算获得, 如式(7)所示。

$$\min F = \sum_{t \in T} c_t^{\text{buy}} g_t^{\text{buy}} - c_t^{\text{sell}} g_t^{\text{sell}} \quad (7)$$

式中: c_t^{buy} 与 c_t^{sell} 分别为单位功率购电与售电价格; g_t^{buy} 与 g_t^{sell} 为两个辅助变量, 用于表示当前时间购电与售电功率, 并需满足下述约束。

$$\begin{cases} g_t^{\text{buy}} - g_t^{\text{sell}} = g_t, \\ g_t^{\text{buy}} \geq 0, g_t^{\text{sell}} \geq 0, \end{cases} \quad \forall t \in T \quad (8)$$

1.2.2 约束条件

针对分布式光伏, 其弃光率 $\lambda_{i,t}$ 须保持在 0 到 1 之间。

$$0 \leq \lambda_{i,t} \leq 1, \forall i \in N \quad (9)$$

针对温控负荷, 首先室内温度需要保持在舒适范围内。

$$\tau_i^{\text{min}} \leq \tau_{i,t} \leq \tau_i^{\text{max}}, \forall i \in N \quad (10)$$

式中 τ_i^{min} 与 τ_i^{max} 分别为室内温度允许的下界和上界。

同时, 空调的电功率必须处在允许范围内。

$$0 \leq p_{i,t}^{\text{cool}} \leq p_i^{\text{cool,max}}, \forall i \in N \quad (11)$$

式中 $p_i^{\text{cool,max}}$ 为空调允许的最大电功率。

针对储能系统, 首先其存储的能量需要保持在允许范围内。

$$0 \leq E_{i,t} \leq E_i^{\text{max}}, \forall i \in N \quad (12)$$

式中 E_i^{max} 为第 i 个储能系统的容量。同时, 充放电功率需要保持在允许范围内。

$$0 \leq p_{i,t}^{\text{ch}} \leq p_i^{\text{ES,max}}, \forall i \in N \quad (13)$$

$$0 \leq p_{i,t}^{\text{dis}} \leq p_i^{\text{ES,max}}, \forall i \in N \quad (14)$$

式中 $p_i^{\text{ES,max}}$ 为储能系统的最大允许充放电功率。

针对配电网，其节点电压与线路潮流必须保持在安全范围内。

$$V_i^{\min} \leq V_{i,t} \leq V_i^{\max}, \forall i \in N \quad (15)$$

$$P_{ij,t}^2 + Q_{ij,t}^2 = S_{ij,t}^2 \leq (S_{ij}^{\max})^2, \forall (i,j) \in B \quad (16)$$

式中： $V_i^{\max}$ 、 $V_i^{\min}$ 分别为节点电压的上下界； $S_{ij,t}$ 为线路上的视在功率潮流； $S_{ij}^{\max}$ 为其上界。

2 非参运行优化模型

本文提出了一种基于决策树的非参运行优化模型，可在模型信息未知的条件下指导低压配电网的运行。该方法的流程如图 1 所示。首先，考虑到历史数据集可能包含低压配电网在不同拓扑下的运行状态数据，该方法首先利用无监督学习方法对历史数据进行聚类，并生成“伪标签”以区分不同拓扑状态。其次，将该伪标签及低压配电网历史运行数据作为训练集，训练决策树模型，用于判断运行决策在给定运行工况下对于运行安全约束的可行性。随后，将训练完毕的决策树模型等效转化为现有优化求解器可处理的混合整数线性形式的约束。最终，这些混合整数约束被集成到配电网的运行优化问题中，以代替原来的潮流方程约束。




图 1 本文所提方法的整体流程

Fig. 1 Procedure of the proposed method

与传统方法相比，所提出的方法的创新性在于：

1) 所提方法利用数据驱动的决策树模型重构了原有的潮流方程约束，因此该方法无需已知精确的拓扑与线路阻抗。

2) 所提方法利用无监督学习方法，基于拓扑状态对历史样本进行聚类，使得该方法可考虑拓扑变化的不确定性。

3) 所提方法的等效混合整数线性重构仅包含少量 0-1 变量与线性约束，计算效率远高于传统基于模型的方法。

2.1 基于无监督聚类的伪标签生成

在低压配电网中，由于经常发生设备的更改与维护，因此其历史数据可能记录的不同拓扑下的运行状态。考虑到不同的拓扑状态对应不同的调度可行域，因此十分有必要基于拓扑状态对历史数据进行区分。本文利用经典的无监督学习方法 K-means 对历史运行数据进行聚类，并根据聚类结果为每个样本生成“伪标签”（以 $\zeta \in \{1, 2, \dots\}$ 表示），用于标识其对应的拓扑状态。这些伪标签将作为一个重要特征，参与后续决策树的训练。

2.2 决策树训练

本文通过训练一个决策树模型，用于判断给定的配电网运行策略是否可行（即该策略是否能满足配电网运行的安全约束）。决策树是一种常用的机器学习方法，常用于分类和回归任务^[26]。决策树在每个分支节点根据某一特征进行条件划分。例如，针对二分类问题，决策树通过一系列条件判断将整个定义域分为两部分。如图 2 所示，每个方框代表一个判断条件，每个分支代表判断结果的不同情况，而每个叶节点代表最终的分类结果（例如，可行或不可行）。训练完毕后，该决策树可集成进配电网优化调度问题中，用于描述运行策略与其可行性之间的关系。在进一步限制该决策树输出为“可行”后（即必须满足其“可行”对应的某一支条件），可保证优化调度问题输出解满足原始配电网运行安全约束。




图 2 用于判断运行策略可行性的决策树示意图

Fig. 2 Decision tree diagram for judging the feasibility of a given operational strategy

在本文构建的决策树模型中，输入变量 x_t 由节点的功率注入值及其对应的伪标签组成。

$$x_t = (p_t, q_t, \zeta), \forall t \in T \quad (17)$$

式中 p_t 、 q_t 分别为节点 j 注入的有功功率及无功功率。

决策树的输出 y_t 被定义为运行策略的可行性, 如式(18)所示。

$$y_t = \begin{cases} 1, & \text{可行,} \\ 0, & \text{不可行,} \end{cases} \quad \forall t \in T \quad (18)$$

决策树的训练数据特征可直接从历史的节点功率注入数据中获得。训练数据的标签则根据历史电网的运行状态得出。若历史数据显示某时刻配电网运行状态正常, 则对应的标签记为“1”; 相反, 若配电网运行状态异常, 则标记为“0”。

2.3 决策树混合整数重构

在决策树模型训练完毕后, 可通过其分支条件描述潮流约束的可行域。具体而言, 若要求输入变量 x_i 被划分至某一指向“可行”的叶节点区域, 它必须满足从根节点至该叶节点路径上的所有分支条件。对于图 1 所示的情形, 若输入变量 x_i 期望被归类至最左侧的“可行”区域, 那么 x_i 必须同时满足 $x_{1,t} \leq b_1$ 与 $x_{2,t} \leq b_2$, 其中 $x_{i,t}$ 为 x_i 的第 i 个分量。因此, 该分支对应的可行域可表示为由上述分支条件围成的区域 $\{X_i | AX_i \leq b\}$, 其中 $AX_i \leq b$ 代表从根节点至此叶节点区域路径上的所有分支条件, X_i 为输入变量 x_i 组成的向量形式; A 与 b 分别为由前述分支条件构成的矩阵与向量。

一个训练完毕的决策树可能包含多个指向“可行”状态的分支。输入变量 x_i 落入任意一个此种分支对应的可行区域均可满足原始潮流约束。因此, 本文通过引入一组 0-1 变量确保输入 x_i 精确落入某一个分支对应的可行域, 如下式所示。

$$A_j X_i \leq b_j + M(1 - z_{j,t}), \quad \forall j \in J, \forall t \in T \quad (19)$$

$$\sum_{j \in J} z_{j,t} = 1, \quad \forall t \in T \quad (20)$$

式中: $z_{j,t}$ 为引入的 0-1 变量; J 为“可行”的叶节点集合; $j \in J$ 表示指向“可行”的叶节点的索引; M 为常数; A_j 为 A 的第 j 个向量; b_j 为 b 的第 j 个值。式(20)限制了输入 x_i 必须且只能落入某一指向“可行”的分支。

完成上述步骤后, 原始潮流约束的可行域可通过式(19)–(20)进行精确刻画。据此, 式(19)–(20)可作为原始潮流约束的代理模型, 进而将其作为约束条件集成入配电网的优化调度问题之中。本文所提的非参优化模型仅依赖历史运行数据训练决策树, 无需配电网的详细拓扑结构与线路阻抗等参数信息。因此, 即使上述参数未知, 本文方法为仍

可用于指导配电网的优化调度。

3 算例分析

3.1 IEEE-33 节点系统算例分析

3.1.1 测试系统参数设置

为验证本研究提出方法的有效性, 本文选择 IEEE 33 节点配电网作为测试算例, 并进行了仿真研究。仿真的系统结构如图 3 所示。




图 3 IEEE 33 节点测试算例结构图

Fig. 3 Structure of IEEE 33-node test system

该测试算例的调度运行周期为 24 h, 时间分辨率为 1 h。系统中包含 8 个分布式光伏发电单元, 且每个节点都连接有具备灵活性的温控负荷。该测试系统的电压等级为 12.66 kV, 允许的节点电压范围为 $[0.9 \text{ p. u.}, 1.1 \text{ p. u.}]$ 。允许的最大线路潮流为 5 MVA。温控负荷设备的能效比为 6, 其最大有功功率出力为 0.05 MW。与温控负荷相连的建筑室内的热力学参数 a_i^{in} , a_i^{out} , 以及 a_i^h 分别设置 0.961, 0.039, 及 1.961 $^{\circ}\text{C}/\text{MW}$ 。室内舒适温度范围设为 $[24^{\circ}\text{C}, 28^{\circ}\text{C}]$ 。配电网的单位购电及售电价格详见图 4, 室内热负荷与室外环境温度关系如图 5 所示, 系统总有功及无功负荷情况如图 6 所示。




图 4 单位购电/售电成本

Fig. 4 Unit prices for electricity purchasing and selling

为全面测试所提方法的性能, 构建了 6 种不同光伏出力的场景, 场景 S1—S6 如图 7 所示, 光伏渗透率逐步提升。通过这些场景分析, 本文旨在展现所提方法在不同光伏渗透水平下的调度运行效果。




图5 总室内热负荷与室外温度

Fig. 5 Total indoor heat load and outdoor temperature




图6 总有功/无功功率负荷

Fig. 6 Total active and reactive power demands




图7 光伏最大可用出力的6种场景

Fig. 7 Six scenarios of the available PV outputs

3.1.2 对比模型与数据生成过程

为了突出本文所提方法的优点,引入了一种基于模型的方法作为对比。该对比方法假定已知配电网的详细拓扑结构和线路阻抗参数,并采用文献[12]提出的二阶锥松弛技术来处理原始潮流方程的非凸性问题。通过与该模型方法的比较可以更加直观地展示本文方法在处理配电网优化问题时的效率和准确性。

本文提出的方法需要配电网历史数据训练决策树。该历史数据通过如下步骤生成。首先,随机生成1 000个服从均匀分布的 x_i 的样本,作为决策树训练的特征;其次,将这些样本输入到Matpower中,计算相应的电流和电压值;然后,通过比较电流和电压值与其对应的上下界,确定每个样本的可行性,作为决策树训练的标签。在训练过程中,70%的样本用作训练集,剩余30%的样本用作测试集。

3.1.3 仿真算例结果

图8展示了6种场景下本文方法与基于模型的方法所造成的电压约束违反量。如图8所示,两种方法输出的运行策略均能够满足节点电压约束(违约为0)。基于模型的方法在已知精确的网络拓扑与阻抗信息的前提下,其输出策略总能满足运行约束。而本文所提出的方法在不知晓上述网络参数的情况下,通过决策树模型从历史运行数据中学习节点电压约束。该决策树随后被等效转化为混合整数线性约束,且在此过程中未引入任何额外的近似误差。因此,只要决策树的分类精度达到较高水平,本文所提出方法便能精确地重构原始运行约束。




图8 6种场景下的各种方法造成的电压约束违反量

Fig. 8 Voltage violations caused by different methods in the six scenarios

图9展示了不同场景下两种方法的最大线路潮流,其中黑色虚线代表线路潮流上限5 MVA。




图9 6种场景下的各种方法造成的最大线路潮流

Fig. 9 Maximum branch flows by different methods in the six scenarios

如图9所示,在大多数场景中,两种方法均能满足线路潮流约束。在场景S6中,本文所提方法的运行策略导致了约0.1 MVA的潮流约束违反量。这一违约量可能是由决策树的近似误差所导致,但相比于5 MVA的上限而言,该违反量非常小。值得注意的是,本文所提方法完全基于历史数据,而无需依赖拓扑与阻抗信息。上述结果表明,本文所提方法能够从数据中较为精确地学习线路潮流约束。

图 10 展示了两种方法在不同场景下的运行成本。观察结果可以发现, 两种方法的运行成本差异极为微小, 最大相对差异仅为 0.1 %。这一结果表明, 即便在未知网络拓扑与线路阻抗信息的条件下, 本文所提方法仍能够保证输出运行策略的最优性。




图 10 6 种场景下的各种方法的总运行成本

Fig. 10 Total operation costs of different methods in the six scenarios

图 11 展示了两种方法在不同场景下计算最优运行策略所需的时间, 如图 11 所示, 本文所提方法的计算时间仅为基于模型方法的十分之一。本方法通过训练决策树来近似原始的非凸潮流约束, 并将决策树等效地转换为含有少量 0-1 变量的线性约束, 这使得现有的优化求解器能够高效地求解。相比之下, 基于模型的方法采用二阶锥松弛技术处理原始潮流约束的非凸性问题, 导致引入了大量的二次约束, 从而使得其计算效率远低于本文所提出的方法。




图 11 6 种场景下的各种方法的总计算时间

Fig. 11 Solving times of different methods in the six scenarios

3.1.4 高光伏渗透率场景测试结果

在高光伏渗透率场景(S6)下, 对本文所提方法的表现进行了具体分析。通过利用温控负荷的灵活性, 有效促进了分布式光伏的就地消纳。图 12 展示了总热负荷与总制冷负荷的变化关系。

在 7 时之前, 由于光伏出力为 0, 无需利用灵活性来促进光伏消纳, 因此总热负荷与总制冷负荷




图 12 本文所提方法在场景 S6 中的总热负荷与总制冷负荷

Fig. 12 Total heat load and cooling supply given by the proposed method in scenario S6

基本保持一致。从 7 时至 16 时, 随着光伏出力的增加, 温控负荷设备开始执行“预冷”策略, 即采用高于总热负荷的制冷功率降低室内温度, 从而减少后续几个小时的温控负荷功率消耗。在 16 时至 20 时, 光伏出力逐渐减少, 建筑室内环境开始利用“预冷”储存的冷量来满足部分制冷需求, 因此这一时段内总热负荷大于总制冷量。在 20 时之后, 由于“预冷”储存的冷量已经耗尽, 制冷负荷逐渐回归至与总热负荷相同的水平。这一结果表明, 通过合理调控温控负荷, 可以有效地促进分布式光伏的消纳, 从而提高配电网的运行效率。图 13 显示了该场景下, 本方法输出的运行策略对应的各节点电压, 其中黑色虚线表示节点电压的上下限。




图 13 本文所提方法在场景 S6 中的各节点电压

Fig. 13 Bus voltages by the proposed method in scenario S6

结果表明, 各节点电压均保持在允许范围内。在早上 7 时之前, 由于光伏出力接近 0, 各节点电压普遍低于 1 p. u.。从 7 时至 12 时, 随着光伏出力的逐渐增加, 各节点可以利用本地光伏发电满足功率需求, 减少了从远处根节点获取有功的需要, 避免了因长距离传输导致的电压下降, 因此节点电压逐渐升高并超过 1 p. u.。中午 12 时至 17 时, 光伏出力逐渐减少, 节点电压也相应下降。在 17 时至 19 时, 尽管光伏出力已接近 0, 但通过温控负荷设备的预冷操作, 降低了该时段的电功率消耗, 使得节点电压保持在较高水平。19 时之后, 由于温控负

荷的冷量储存已耗尽, 节点电压再次回落至较低水平。

图 14 展示了配电网中各个线路的潮流分布情况。与图 12 相似, 在 7 时之前, 由于光伏出力接近 0, 线路上的潮流主要由节点负荷决定。在 7 时至 12 时, 随着光伏出力的逐渐增大, 系统开始实现功率的“倒送”, 即潮流从子节点流向父节点, 以充分利用光伏发电。因此, 随着光伏出力的增加, 部分线路的潮流也相应增大。从 12 时至 17 时, 光伏出力逐渐减少, 线路潮流也逐渐回归到原始水平。在 17 时至 19 时, 由于温控负荷设备已经进行了预冷操作, 此时段内的温控负荷较低, 导致线路潮流保持在较低水平。从 20 时开始, 由于预冷“储存”的冷量已经消耗殆尽, 温控负荷重新增加, 因此需要从根节点输送更多的功率以满足温控负荷的需求, 导致线路潮流略有提升。




图 14 本文所提方法在场景 S6 中的各线路潮流

Fig. 14 Branch flows given by the proposed method in scenario S6

3.2 实际低压配电网算例测试

3.2.1 系统参数设置

为了进一步验证所提方法的有效性, 本文基于北美实际低压配电网^[27]对比了不同光伏渗透率下几种方法的性能。该配电网的电压等级为 400 V, 其结构如图 15 所示。它包含 3 个储能设备, 3 个分布式光伏。图 15 中的红线代表线路开关, 包含 4 种可能的拓扑状态。

- 1) 开关 9-10 与 43-44 闭合, 其余开关断开。
- 2) 开关 9-10 与 40-44 闭合, 其余开关断开。
- 3) 开关 26-10 与 43-44 闭合, 其余开关断开。
- 4) 开关 26-10 与 40-44 闭合, 其余开关断开。

节点电压的安全范围设置为 $[0.93 \text{ p.u.}, 1.07 \text{ p.u.}]$; 最大线路潮流为 0.2 MVA。该测试算例的电价与外部环境温度与 33 节点测试算例保持一致。有功无功负荷如图 16 所示。




图 15 实际低压配电网结构

Fig. 15 Structure of the actual low-voltage distribution network




图 16 低压配电网测试算例中的有功/无功负荷

Fig. 16 Active/reactive power demands in the low-voltage distribution network test case




图 17 低压配电网测试算例中的光伏最大出力

Fig. 17 Available outputs of PVs in the low-voltage distribution network test case

如图 17 所示, 本文为该低压配电网算例构建了 5 种不同光伏渗透率的场景, 以更好地说明所提方法的优势。

3.2.2 对比模型与历史数据生成

除前述基于模型的方法之外, 本节引入了“模仿学习”方法^[18]作为新的对比模型。该方法利用神经网络直接学习从用户负荷、光伏出力到最优决策的映射关系。

本文为每种拓扑状态下均生成 10 000 个样本 (一共 40 000 个样本), 模拟该低压配电网的历史数据。该数据集中仅包含功率注入、节点电压、支路潮流, 而未包含实际的拓扑状态。该数据集后续将用于决策树的训练。

模仿学习方法需要通过求解大量基于模型的最优运行问题生成训练标签。本文通过将前述 40 000

个样本带入并求解基于模型的运行优化问题来获得所需标签。该过程需要详细的模型信息,因此模仿学习方法难以用于网络拓扑与线路阻抗未知的低压电网中。同时,大量求解优化问题也十分耗时。在本测试算例中,需要花费约 30 h 完成标签生成过程。

3.2.3 聚类结果

图 18 显示了历史数据的聚类结果(利用 t-SNE 技术将聚类后的数据降成二维,方便可视化)。图 18 中不同的颜色代表不同的伪标签。不同标签下的数据距离较远,这意味着不同拓扑状态下的运行数据差别较为明显。因此,将该伪标签作为重要特征之一,可为后续的决策树训练提供拓扑状态信息。




图 18 历史数据聚类结果

Fig. 18 Results of the clustering on the historical dataset

3.2.4 仿真算例结果

图 19 显示了在场景 S1—S5 下,各个方法在不同拓扑状态下的电压违约量。




图 19 场景 S1—S5 中不同拓扑状态下各方法的电压违约量

Fig. 19 Voltage violations of each method under different topology configuration in Scenarios S1—S5

与 33 节点测试算例的结果类似,在所有场景中,本文所提方法所造成的电压违约量较低,说明其不仅可行性较好,且能适应历史数据中的拓扑变

化。虽然基于模型的方法在场景 S1—S3 中所造成的电压违约量较小,其在 S4 与 S5 的表现较差。这是因为该方法的可行性表现依赖于其所使用的二阶锥凸松弛的准确性,而该松弛方法的准确性与系统中是反向潮流(即从子节点流向父节点的潮流)的大小有关^[28]。在 S1—S3 中,光伏渗透率较低,此时系统中不存在反向潮流或者反向潮流较小,因此该松弛误差较小,其对应的违约量也较小。当光伏渗透率较大时,系统中可能存在较为明显的反向潮流,此时该二阶锥松弛将带来显著的误差,导致明显的电压违约。模仿学习方法将基于模型的方法的决策作为训练标签,因此两种方法的表现非常接近。

图 20 显示了各个场景下的线路潮流违约量。




图 20 场景 S1—S5 中不同拓扑状态下各方法的潮流违约量

Fig. 20 Branch flow violations of each method under different topology configuration in Scenarios S1—S5

与图 19 类似,本文所提方法在所有场景下的线路潮流违约量均较小。基于模型的方法由于其在光伏渗透率较高的场景下是松弛误差较大,因此其在 S4—S5 中的线路潮流违约量较大。由于模仿学习的方法以基于模型的方法为学习目标,因此它们的可行性表现十分相似。

图 21 显示了各个方法在不同场景、拓扑状态下的总运行成本。

在场景 S1—S3 中,3 种方法的总成本非常接近。此时,基于模型的方法输出的是全局最优解。因此, S1—S3 的结果显示了本文所提方法较好的最优性。在 S4—S5 中,虽然其他两种方法的运行成本较本文所提方法更低,但这是通过牺牲可行性




图 21 场景 S1—S5 中不同拓扑状态下各方法的总运行成本

Fig. 21 Total cost of each method under different topology configurations in Scenarios S1—S5

所带来的。

4 结论

本文针对实际配电网中详细拓扑与线路阻抗信息常常未知的问题提出了一种基于决策树的配电网非参数化运行优化方法。该方法首先利用无监督聚类方法,从历史数据中提取拓扑状态信息并生成“伪标签”。然后,通过训练决策树从历史运行数据中学习运行策略与潮流约束的关系,并将决策树等效转化为易于求解的混合整数线性形式,实现了潮流约束的非参数化重构。仿真结果验证了该方法的有效性,主要结论如下。

1) 本文所提方法能在未知网络拓扑与线路阻抗信息的条件下,精准刻画潮流约束的可行域,为实际配电网的调度优化提供指导。

2) 该方法的等效混合整数线性重构仅包含少量 0-1 变量与线性约束,计算效率远高于传统基于模型的方法。

通过合理的协同运行,灵活性资源可有效促进分布式光伏的消纳,从而提高配电网的运行效率。

参考文献

- [1] 谢东,刘明波,徐立新.含分布式能源电力系统输配协调优化研究综述及展望[J].南方电网技术,2023,17(4):25-37. XIE Dong, LIU Mingbo, XU Lixin. Review and prospect of transmission-distribution co-optimization of power systems with distributed energy resources [J]. Southern Power System Technology, 2023, 17(4): 25-37.
- [2] 张勇军,刘子文,邓丰强.柔性互联配电网研究现状综述及其发展探索[J].广东电力,2020,33(12):3-13.

- [3] ZHANG Yongjun, LIU Ziwen, DENG Fengqiang. Review on research status and development of flexible interconnected distribution networks [J]. Guangdong Electric Power, 2020, 33(12): 3-13.
- [3] HU, Junjie, LIU Xuetao, MOHAMMAD Shahidehpour, et al. Optimal operation of energy hubs with large-scale distributed energy resources for distribution network congestion management [J]. IEEE Transactions on Sustainable Energy, 2021, 12(3), 1755-1765.
- [4] 施佳锋,张宏杰,李中伟,等.计及配电网约束的温控负荷参与电网二次调频的优化调度方法[J].自动化技术与应用,2022,41(8):84-88
- SHI Jiafeng, ZHANG Hongjie, LI Zhongwei, et al. Optimization dispatch method of temperature-controlled load participating in secondary frequency regulation of power grid considering distribution network constraints [J]. Techniques of Automation and Applications, 2022, 41(8): 84-88.
- [5] 马丽,李伟,裴玮,等.含高比例光伏配电网中计及需求侧响应的混合储能配置优化[J].高电压技术,2024,50(4):1416-1425.
- MA Li, LI Wei, PEI Wei, et al. Hybrid energy storage configuration optimization in distribution network with high-proportion pv considering demand response [J]. High Voltage Engineering, 2024, 50(4): 1416-1425.
- [6] 车彬,张泽龙,杨燕.考虑 V2G 储能特性与负荷需求响应的主动配电网低碳鲁棒调度[J].电网与清洁能源,2024,40(1):29-39.
- CHE Bin, ZHANG Zelong, YANG Yan. Research on the low-carbon robust dispatch of active distribution networks considering storage characteristics of V2G and load demand response [J]. Power System and Clean Energy, 2024, 40(1): 29-39.
- [7] 杨跃,安然然,梁晓兵,等.计及灵活性约束的配电网-微电网灵活性资源协同规划模型[J].广东电力,2023,36(8):54-69.
- YANG Yue, AN Ranran, LIANG Xiaobing, et al. Collaborative planning model of distribution network-microgrid flexibility resources with flexibility constraints [J]. Guangdong Electric Power, 2023, 36(8): 54-69.
- [8] 张子昊,包涛,王鹏宇,等.基于多阶段决策的需求侧聚合响应策略[J].南方电网技术,2023,17(9):1-9.
- ZHANG Zihao, BAO Tao, WANG Pengyu, et al. Demand side aggregation response strategy based on multi-stage decision [J]. Southern Power System Technology, 2023, 17(9): 1-9.
- [9] 张晋铭,欧阳森,吴晗,等.计及配电网可靠性和运行经济性的电网侧储能优化配置[J].电力自动化设备,2024,44(7):62-68,85.
- ZHANG Jinming, OUYANG Sen, WU Han, et al. Optimal configuration of grid-side energy storage considering reliability and operation economy of distribution network [J]. Electric Power Automation Equipment, 2024, 44(7): 62-68, 85.
- [10] 刘科研,盛万兴,詹惠瑜,等.考虑多台区互联的中低压交流混合配电网双层协同优化调度方法[J].电力建设,2024,45(1):33-44.
- LIU Keyan, SHENG Wanxing, ZHAN Huiyu, et al. Bi-level optimization scheduling of mid-low-voltage AC/DC hybrid distribution network considering interconnection between networks [J]. Electric Power Construction, 2024, 45(1): 33-44.
- [11] 闫明文,刘惠颖,宫游,等.基于改进 Benders 分解的配电网

- 扩展规划机会约束优化方法[J].电测与仪表,2023,60(1):124-131.
- YAN Mingwen, LIU Huiying, GONG You, et al. Chance-constrained optimization method for distribution network expansion planning based on modified Benders decomposition [J]. Electrical Measurement & Instrumentation, 2023, 60(1): 124-131.
- [12] 徐添锐,丁涛,李立,等.适应三相不平衡主动配电网无功优化的二阶锥松弛模型[J].电力系统自动化,2021,45(24):81-88.
- XU Tianrui, DING Tao, LI Li, et al. Second-order cone relaxation model adapting to reactive power optimization for three-phase unbalanced active distribution network [J]. Automation of Electric Power Systems, 2021, 45(24): 81-88.
- [13] 丁豪杰,李宏仲.基于全纯嵌入线性潮流的配电网灵活性资源优化配置[J].电力系统及其自动化学报,2024,36(3):107-117.
- DING Haojie, LI Hongzhong. Optimal allocation of flexible resources in distribution networks based on holomorphic embedding linear power flow [J]. Proceedings of the CSU-EPSA, 2024, 36(3): 107-117.
- [14] CHEN Ge, ZHANG Hongcai, SONG Yonghua. Efficient constraint learning for data-driven active distribution network operation [J]. IEEE Transactions on Power Systems, 2023 39(1): 1472-1484.
- [15] PAPPU S J, NIRAV B, RAMKRISHNA P, et al. Identifying topology of low voltage distribution networks based on smart meter data [J]. IEEE Transactions on Smart Grid, 2017, 9(5): 5113-5122.
- [16] GOUGH M B, SANTOS S F, ALSKAIF T, et al. Preserving privacy of smart meter data in a smart grid environment [J]. IEEE Transactions on Industrial Informatics 2021, 18(1): 707-718.
- [17] 冯斌,胡轶婕,黄刚,等.基于深度强化学习的新型电力系统调度优化方法综述[J].电力系统自动化,2023,47(17):187-199.
- FENG Bin, HU Yijie, HUANG Gang, et al. Review on optimization methods for new power system dispatch based on deep reinforcement learning [J]. Automation of Electric Power Systems, 2023, 47(17): 187-199.
- [18] PAN Xiang, ZHAO Tianyu, CHEN Minghua, et al. Deepopf: a deep neural network approach for security-constrained DC optimal power flow [J]. IEEE Transactions on Power Systems, 2020, 36(3): 1725-1735.
- [19] CHEN Wenbo, PARK Seonho, TANNEAU Mathieu et al. Learning optimization proxies for large-scale security-constrained economic dispatch [J]. Electric Power Systems Research, 2022(213): 108566.1-108566.10.
- [20] 李晓旭,田猛,朱紫阳,等.基于鲁棒强化学习的配网潮流优化方法[J].高电压技术,2023,49(6):2329-2339.
- LI Xiaoxu, TIAN Meng, ZHU Ziyang, et al. Distribution network power flow optimization method based on robust reinforcement learning [J]. High Voltage Engineering, 2023, 49(6): 2329-2339.
- [21] 宋永华,余佩佩,张洪财.实时电价机制下基于复合两端采样强化学习的区域供冷系统需求响应运行控制[J].中国科学:技术科学,2023,53(10):1699-1712.
- SONG Yonghua, YU Peipei, ZHANG Hongcai. Optimal reinforcement learning control of a district cooling system based on compound secondary sampling under real-time electricity prices [J]. Scientia Sinica (Technologica), 2023, 53(10): 1699-1712.
- [22] DI Cao, ZHAO Junbo, HU Weihao, et al. Data-driven multi-agent deep reinforcement learning for distribution system decentralized voltage control with high penetration of PVs [J]. IEEE Transactions on Smart Grid, 2021, 12(5): 4137-4150.
- [23] DI Cao, ZHAO Junbo, HU Weihao, et al. Deep reinforcement learning enabled physical-model-free two-timescale voltage control method for active distribution systems [J]. IEEE Transactions on Smart Grid, 2021, 13(1): 149-165.
- [24] 闫涛,陈继忠,闫雪生,等.构网型储能系统现场调试平台电网扰动控制策略研究[J].高压电器,2023,59(7):30-38.
- YAN Tao, CHEN Jizhong, YAN Xuesheng, et al. Research on power grid disturbance control strategy for grid-forming energy storage equipment on-site commissioning system [J]. High Voltage Apparatus, 2023, 59(7): 30-38.
- [25] CHEN Xin, DALL'ANESE Emiliano, ZHAO Changhong et al. Aggregate power flexibility in unbalanced distribution systems [J]. IEEE Transactions on Smart Grid, 2019, 11(1): 258-269.
- [26] PRIYANKA N A, KUMAR D. Decision tree classifier: a detailed survey [J]. International Journal of Information and Decision Sciences, 2020, 12(3): 246-269.
- [27] RUDION K, ORTHS A, STYCZYNSKI Z A, et al. Design of benchmark of medium voltage distribution network for investigation of DG integration [C]//2006 IEEE Power Engineering Society General Meeting (PESGM), June 18-22, 2006, Montreal, Canada. New York: IEEE, 2006: 1-6.
- [28] LOW S H. Convex relaxation of optimal power flow-part II: exactness [J]. IEEE Transactions on Control of Network Systems, 2014, 1(2): 177-189.

收稿日期:2024-02-22;网络首发日期:2024-07-30

作者简介:

朱泽安(1993),男,通信作者,工程师,博士,研究方向为电力系统灵活性、电力系统优化运行,whuzza@163.com;

潘廷哲(1994),男,研究员,硕士,研究方向为电力需求侧管理与智能用电技术;

孟子杰(1985),男,高级工程师,硕士,研究方向为电力系统优化调度与运行。