

计及台区电能质量的分布式电源电压调控策略

管永明^{1,2}, 史玉良^{1,2*}, 王继虎³, 吕 梁^{1,2}, 陈志勇¹, 李 晖¹

(1. 山东大学软件学院, 山东济南 250101; 2. 地纬智能科技股份有限公司, 山东济南 250100;

3. 山东大学控制科学与工程学院, 山东济南 250101)

摘要: 针对高渗透率分布式光伏接入配电台区引发的电压波动问题, 提出一种计及台区电能质量的分布式电源电压调控策略。首先, 基于台区拓扑结构构建分布式光伏-负荷节点连接关系图, 以此为依据进行动态调控区域划分、关键电压节点筛选及多目标优化函数设计。在此基础上, 构建了一种基于时频分类与混合专家网络(Mixture of Experts, MoE)的光伏出力预测模型, 通过融合时域变化特征与频域周期规律, 增强出力波动的分类表征能力, 并借助MoE结构实现数据分类下的专业定向预测, 从而显著提升预测精度与稳定性。进一步, 以预测结果为输入, 采用模型预测控制方法, 将电压约束、有功功率输出及调控频率等多重限制条件直接嵌入滚动优化目标, 生成前瞻性协同调控策略, 以解决传统逆变器调控滞后、动作频繁及出力降额等问题。为提升台区级调控效率并降低计算负担, 设计了具备自趋优更新机制的经验回放区, 结合调控边界自感知规则, 在预测完成后可触发精简调控模式, 直接选取相似历史策略执行, 并通过奖励机制持续优化策略库, 从而在保证调控稳定性的同时大幅提升响应速度。仿真结果表明, 所提方法在预测准确性上显著优于多种对比方案, 其测试准确率达99.29%, 标准差仅0.71%, 波动范围控制在3.27%。在电压调控效果方面, 该方法在负荷突增导致电压越下限、光伏出力波动引起电压越上限等多类场景中, 均能实现快速且平稳的电压恢复; 在电压越下限2%~10%场景下, 调控完成速度较现有方法提升2.4倍以上; 在越上限2%~7%场景中, 调控速度快1.5倍以上, 且全过程电压偏差始终维持在±2%以内, 有效避免了频繁调控与发电损失; 在电压越上限7%~10%场景中, 通过降低有功功率输出实现压降, 所提方法在2s内即可完成调控, 且有功率输出较传统方式提升约3%, 显著缓解了因过压保护导致的停机风险。综上所述, 文章所提出的融合精准预测、滚动优化与经验回放机制的电压调控策略, 不仅具有较高的预测精度与响应速度, 而且能有效保障台区电压稳定并提升光伏出力, 为分布式新能源从“规模扩张”向“质量提升”转型提供了可行的技术支撑。

关键词: 分布式光伏; 台区电压调控; 时频分类; 混合专家网络; 模型预测控制; 调控边界感知

基金项目: 国家自然科学基金(No.62376135, No.62406176); 中国博士后科学基金(No.2024M751810); 山东省重点研发计划(竞争性创新平台)项目(No.2025CXPT101); 山东省自然科学基金(No.ZR2024QF091)

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112(2026)01-0206-13

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250980

Voltage Regulation Strategy for Distributed Photovoltaic Considering Power Quality in the Substation Area

GUAN Yongming^{1,2}, SHI Yuliang^{1,2*}, WANG Jihu³, LYU Liang^{1,2}, CHEN Zhiyong¹, LI Hui¹

(1. School of Software, Shandong University, Jinan, Shandong 250101, China;

2. Dareway Software Co., Ltd., Jinan, Shandong 250100, China;

3. School of Control Science and Engineering, Shandong University, Jinan, Shandong 250101, China)

Abstract: Addressing the voltage fluctuation issues caused by high-penetration distributed photovoltaic (PV) integration into distribution areas, a distributed PV voltage regulation strategy that takes into account the power quality of the area is proposed. Firstly, based on the topology structure of the area, a distributed PV-load node connection graph is constructed. This serves as the basis for dynamic regulation area division, key voltage node screening, and multi-objective optimization function design. On this basis, a PV output prediction model based on time-frequency classification and mixture of experts (MoE) is developed. By integrating time-domain variation characteristics and frequency-domain periodic patterns, the classification and representation ability of output fluctuations is enhanced. Additionally, MoE is utilized to improve prediction accuracy and stability. Furthermore, using the prediction results as input, a model predictive control method is adopted to directly embed multiple constraints such as voltage constraints, active power output, and regulation frequency into the rolling optimization objective, generating a forward-looking collaborative regulation strategy to address issues such as lagging regu-

lation, frequent actions, and output derating of traditional inverters. To enhance the efficiency of area-level regulation and reduce computational burden, an experience replay area with a self-optimizing update mechanism is designed. Combined with regulation boundary self-sensing rules, a simplified regulation mode can be triggered after prediction completion, directly selecting similar historical strategies for execution. The strategy library is continuously optimized through a reward mechanism, significantly improving response speed while ensuring regulation stability. Simulation results show that the proposed method significantly outperforms multiple comparative schemes in prediction accuracy, achieving a test accuracy of 99.29%, a standard deviation of only 0.71%, and a fluctuation range controlled within 3.27%. In terms of voltage regulation effects, the method achieves rapid and smooth voltage recovery in various scenarios such as voltage undershoot caused by sudden load increases and voltage overshoot caused by PV output fluctuations. Specifically, in scenarios where the voltage undershoots by 2%~10%, the regulation completion speed is increased by more than 2.4 times compared to existing methods. In scenarios where the voltage overshoots by 2%~7%, the regulation speed is increased by more than 1.5 times, and the voltage deviation throughout the entire process remains within $\pm 2\%$, effectively avoiding frequent regulation and power generation losses. In scenarios where the voltage overshoots by 7%~10%, the proposed method achieves regulation within 2 seconds by reducing active power output, and the active power output is increased by about 3% compared to traditional methods, significantly mitigating the risk of downtime caused by overvoltage protection. In summary, the voltage regulation strategy that integrates precise prediction, rolling optimization, and experience replay mechanisms not only exhibits high prediction accuracy and response speed, but also effectively ensures voltage stability in the substation area and enhances photovoltaic output. This provides feasible technical support for the transformation of distributed renewable energy from “scale expansion” to “quality improvement”.

Keywords: distributed photovoltaics; substation voltage regulation; time-frequency classification; hybrid expert network; model predictive control; regulate boundary perception

Foundation Item(s): National Natural Science Foundation of China (No.62376135, No.62406176); China Postdoctoral Science Foundation (No.2024M751810); Shandong Provincial Key Research and Development Plan (Competitive Innovation Platform) Project (No.2025CXPT101); Shandong Provincial Natural Science Foundation (No.ZR2024QF091)

0 引言

在“双碳”目标与能源转型战略的推动下^[1],我国分布式光伏实现了爆发式增长,已成为能源结构调整的核心力量。以山东省为例,截至2025年6月,全省分布式光伏装机5 929万kW,占光伏装机总规模的65%,然而规模化增长背后,因分布式光伏电压波动等问题^[2],严重影响了用户设备正常使用及配电设备安全^[3],进一步加剧了反送电问题,这与分布式能源“就近消纳”的本质定位背道而驰^[4]。

围绕上述问题,目前部分学者及机构已开展研究。如张鑫灏等人^[5]提出一种双模式主动电压协调控制策略,通过模式选择提升了分布式光伏对低电压的调控能力;李海啸等人^[6]为降低分布式光伏电站存在的过电压越限风险,提出一种基于增广拉格朗日结合非精确牛顿法的分布式非凸电压优化方法,通过无功功率最优调度将电压调控至安全范围内;王允祥等人^[7]针对低压台区分布式光伏反向重过载、电压越限和网损增加等多目标调控需求,提出一种基于双层强化学习的光伏逆变器多模态自适应控制策略,实现多时间尺度调控目标的协同趋优。上述方法均基于逆变器对无功功率进行调整实现了对电压的调控,在电压低时,逆变器可通过输出无功功率补偿电压,在电

压高时,逆变器可通过吸收无功功率降低电压,但上述调控量均有限,尤其在电压超出阈值时,逆变器会降低有功功率输出即弃光甚至停机^[8]。此外,逆变器调控频繁往往导致响应延迟,这进一步导致有功功率输出下降,同时过度频繁的调控可能触发保护机制,如过流保护、过热保护等,导致降额运行或停机。故上述方法缺乏适应光伏出力波动的动态适应性,导致弃光比例居高不下。而传统PI控制难以实现动态快速响应保证光伏电能质量^[9],尤其在光伏出力突变时,输出电能质量往往不符合并网要求。当前模型预测控制(Model Predictive Control, MPC)作为一种多变量、多约束优化控制策略^[10],具有两大核心优势:一是基于分布式光伏出力预测模型,提前预测未来多个时刻的光伏出力输出状态,实现“预判式”控制,动态响应速度比PI快3~5倍;二是可将多约束条件直接嵌入优化目标,无需额外调节器,简化控制结构。

为有效推动分布式新能源从“规模扩张”向“质量提升”转型,本文基于上述研究基础,以台区为基本单元,开展分布式电源电压调控策略研究,主要贡献如下:

(1)针对分布式光伏电源存在多样性、波动性的出力特点,采用时频分类结合混合专家网络(Mixture of Experts, MoE)^[11]构建分布式光伏出力预测模型,时

域数据提供特征数据随时间变化过程的特征(如幅度、趋势和瞬时特征),频域数据提供特征数据的频率、周期性规律,两者结合可互补信息增强分类准确性,同时,MoE根据分类数据训练预测模型,可有效缓解光伏出力波动导致的预测模型“即使拥有百万级参数,单一模式难以充分提取波动特性”的问题,从而有效提升了光伏出力预测准确度;

(2)针对传统逆变器调控存在响应滞后、操作频繁、出力降额多的问题,通过电压调控范围、有功功率及调控频率等约束直接嵌入优化目标,采用MPC实现预判式及整体规划的滚动优化调控^[12],最大限度地提升分布式光伏有功功率输出,规避了逆变器频繁调控导致出力下降问题,同时为后续一段时间内的电压调控留有一定裕度空间;

(3)为提升台区级分布式光伏调控效率、降低终端计算资源消耗,本文构建了具备自趋优更新的经验回放区,通过设定调控边界自我感知规则,在分布式光伏出力预测模型输出后、开展模型预测控制前,支持光伏预测出力归类触发精简模式,即直接从经验回放区选取最相似历史调控曲线的调控策略,作用于本次调控,并通过奖励机制持续更新调控策略,从而进一步提升了台区级电压调控响应速度,并保证了调控结果的稳定性和可预见性^[13]。

1 台区级分布式电源电压调控策略

1.1 基于区域节点拓扑分布设计调控目标

台区微电网包含多个分布式光伏电源,为适应新能源出力的随机性和间歇性,每个光伏电源均配备分布式光伏逆变器(Distributed PhotoVoltaic Inverter, DPVI),一方面,基于控制指令向台区微电网输出有功功率;另一方面,针对光伏出力波动性,多个DPVI协同开展区域电压调控,在保障台区微电网电能质量的同时,支撑余量并网参与电力市场交易。

本文根据台区规模将其分为多个区域,每个区域包含多个分布式光伏电源,鉴于用电关联导致电压关联,选定一个能够灵敏感应各区域内其他节点电压变化的节点作为关键节点,通过多个DPVI协同调控关键节点的电压,使区域内所有节点电压运行在关键节点监测的电压波动阈值范围内。基于区域分布式光伏电源及负荷分布,定义区域分布式光伏-负荷节点拓扑,以某一包含多分布式光伏电源的台区作为示例,将分布式光伏电源、负荷用户均作为节点 e_i ,则分布式光伏电源节点集为 $E = \{e_1, e_2, \dots, e_i, \dots, e_j\}$;将任意节点间存在的用电关联(如输电线)作为边 a_{ij} ,并以此构建邻接矩阵 $A = (a_{ij})_{I \times I}$,其中, $i, j \in [1, I]$ 。

1.1.1 关键节点选取

本文通过计算区域内各节点间的电压波动关联性,作为节点间电压灵敏感应的评估指标,旨在保证区域内各节点间的电压偏差最小。节点 n 的一致性可观指标用 S_{Gn} 表示:

$$S_{Gn} = \min \frac{1}{T} \sum_{k=1}^N |\Delta U_n - \Delta U_k| \quad (1)$$

其中, N 表示区域内节点数目; $|\Delta U_n - \Delta U_k|$ 表示节点 n 与节点 k 的电压波动差额,根据历史数据统计获取; ΔU_n 与 ΔU_k 分别表示节点 n 和节点 k 的电压变化量; T 表示样本数据累计值的时间,本文选择 $T=1$ 年进行计算。

本文将具有最小电压灵敏度 S_{Gn} 的节点作为关键节点,一个区域设定一个关键节点。

1.1.2 设计调控目标

本文基于DPVI指令电流生成原理的研究基础^[14],开展台区级电压调控。旨在通过改变逆变器输出电流的大小和相位,从而完成对分布式光伏有功功率输出或无功功率输出的调控,基于预判式完成台区电压调控。其中,指令电流生成如图1所示。

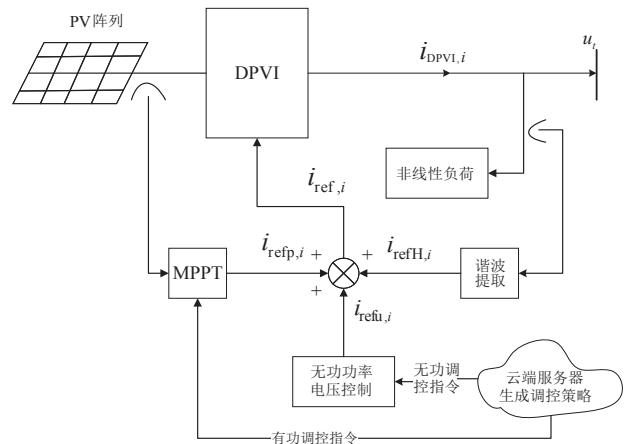


图1 DPVI指令电流生成原理

Figure 1 Generation principle of DPVI command current

根据图1定义第 i 个DPVI电流输出包含有功功率电流 $i_{\text{refp},i}$ 、谐波治理电流 $i_{\text{refH},i}$ 及可用于无功功率输出调控的剩余电流 $i_{\text{refu},i}$,具体表示为

$$i_{\text{rated},i} = i_{\text{refp},i} + i_{\text{refH},i} + i_{\text{refu},i} \quad (2)$$

其对应的最大剩余功率容量 $Q_{\text{res},i}$ 可表示为

$$Q_{\text{res},i} = U \times \sqrt{I_{\text{rated},i}^2 - I_{\text{refp},i}^2 - I_{\text{refH},i}^2} \quad (3)$$

其中, $I_{\text{rated},i}$ 为第 i 个DPVI的额定电流; $i_{\text{refp},i}$ 为第 i 个DPVI提供有功功率的电流; $i_{\text{refH},i}$ 为第 i 个DPVI的谐波提取模块给出,用于抑制本地非线性负载电流中的谐波的电流; $I_{\text{refp},i}$ 和 $I_{\text{refH},i}$ 分别为 $i_{\text{refp},i}$ 和 $i_{\text{refH},i}$ 的有效

值; U 为通过电能质量监测装置实时监测电压有效值, 其支持 10 ms 级的快速电压变化事件记录。

本文基于每个区域内设定的一个关键节点, 负责监测其他节点电压与电压控制设定值的偏差, 并将偏差值传递给区域内各节点。各节点通过自身配备的 DPVI 改变上述三部分输出电流的大小和相位, 即可完成有功及无功功率输出调整, 进而实现对区域内关键节点电压的控制(此时设定逆变器剩余功率容量与无

$$\begin{aligned} \psi'_i &= -\sum_{j=1}^m a_{ij} \psi_j + d_i l_u k_l Q_{\text{res},l} (U_{\text{ref}} - u) \\ &= -\sum_{j=1}^m a_{ij} (U_{\text{rated}} \times I_{\text{ref},j}) / Q_{\text{res},j} + d_i l_u k_l Q_{\text{res},l} (U_{\text{ref}} - u) \leq \max \psi_i \\ &= -\sum_{j=1}^m a_{ij} (U_{\text{rated}} \times I_{\text{ref},j}) / \left(\sqrt{Q_{\text{rated},j}^2 - (\xi_j \cdot p_j^t)^2} - U_{\text{rated}} \cdot I'_{\text{refH},j} \right) \\ &\quad + d_i l_u k_l \left(\sqrt{Q_{\text{rated},l}^2 - (\xi_l \cdot p_l^t)^2} - U_{\text{rated}} \cdot I'_{\text{refH},l} \right) (U_{\text{ref}} - u) \end{aligned} \quad (4)$$

其中, ψ'_i 为下一时段的剩余容量利用率; ψ_i 为区域内第 i 个 DPVI 的剩余容量利用率; $i \in \{1, m\}$, m 为区域内 DPVI 的个数; a_{ij} 为区域内分布式光伏-负荷节点拓扑图对应的拉普拉斯矩阵 L 的第 i 行第 j 列元素; d_i 是关键节点 DPVI 标识, 当且仅当 i 为关键节点时, $d_i=1$, 否则为 0; l_u 为电压控制分组内监控节点 DPVI 信息权重, 也称为反馈信息权重; $Q_{\text{res},l}$ 为电压控制分组内监控节点 DPVI 剩余容量上限; $Q_{\text{rated},j}$ 为第 j 个 DPVI 的额定容量, 同理 $Q_{\text{rated},l}$; ξ_t 为在 t 时刻的有功功率输出设定比例; p_j^t 表示在 t 时刻第 j 个 DPVI 的预测有功功率, 同理 p_l^t ; k_l 为关键节点 l DPVI 相对于其他节点的电压灵敏度系数, 通过潮流计算得出; U_{ref} 为关键节点电压控制设定值, 通常取为 $U_{\text{ref}}=1.0$ p.u., 表示将分布式光伏并网点的电压控制在额定电压 220 V 的 1.0 倍, 即电压标幺值(per unit, p.u.) 为 1.0; 若关键节点电压 u 与 U_{ref} 在一定差额阈值范围内(如 $\pm 2\%$), 则区域内其他 DPVI 不需要开展电压调控, 若超过差额阈值范围, 则根据拓扑关联性各自改变其功率输出, 实现对关键节点的调控, 直至波动稳定在差额阈值范围内。根据 1.2.1 节构建的分布式光伏出力预测模型获取, 并通过模型预测控制, 获取其为满足电压调控输出的最优有功功率输出有效值; $I_{\text{refH},j}$ 和 $I_{\text{refH},l}$ 分别为第 j 个 DPVI 和关键节点 DPVI 的谐波治理电流, 本文取最大值, 保证满足在 $t+1$ 时刻的谐波治理需求。

本文通过调节区域内各节点 DPVI 的有功及无功功率输出, 对关键节点进行电压调控, 为提高调控实时性, 需对各节点分布式光伏出力进行预测, 基于模型预测控制前瞻式生成调控输出有功功率比例及无

功功率调节满足功率理论三角关系, 如当 DPVI 输出 90% 的额定有功功率时, 剩余 10% 的额定容量理论上最多可吸收约 43.6% 额定有功功率对应的无功功率)。

鉴于 DPVI 的剩余容量与可改变无功功率输出量存在比例关联, 而改变无功功率可以在一定范围内改变关键节点电压, 故由式 (3) 可以通过控制第 i 个 DPVI 的剩余容量利用率 ψ_i , 实现对关键节点电压的调控, 故区域内第 i 个 DPVI 的控制策略为

功功率调控策略, 进而在保证关键节点电压稳定的基础上, 最大化有功功率输出。

1.2 基于模型预测控制的调控策略生成

1.2.1 时频分类结合 MoE 的分布式光伏预测

假设历史数据集包含 N 个样本, 初始设定为 K 个分类样本集, 第 i 个样本的出力曲线数据表示为 P_i , 气象数据表示为 x_i^{wvp} 。定义样本 i 与第 k 个聚类中心 $(\mu_k^p, \mu_k^{\text{wvp}})$ 的距离为

$$\begin{aligned} d(i, k) &= (1 - \alpha) (1 - \text{NCC}(P_i, \mu_k^p)) \\ &\quad + \alpha (1 - \text{Cos sim}(\text{FFT}(x_i^{\text{wvp}}), \text{FFT}(\mu_k^{\text{wvp}}))) \end{aligned} \quad (5)$$

其中, $\alpha \in [0, 1]$, 为时频域特征权重系数, 通过光伏出力预测模型反馈调参得出; μ_k^p 和 μ_k^{wvp} 分别表示第 k 个分类样本集的时域出力曲线聚类中心和频域气象数据聚类中心, $k \in [1, K]$ 。

(1) 光伏出力曲线形状相似性评估

$\text{NCC}(P_i, \mu_k^p)$ 为归一化互相关系数, 用于量化光伏出力曲线与聚类中心曲线形状的相似性。假设 $P_i = [p_1, p_2, \dots, p_T]$, $\mu_k^p = [v_1, v_2, \dots, v_T]$, 则归一化互相关系数为

$$\text{NCC}(P_i, \mu_k^p) = \frac{1}{T-1} \sum_{t=1}^T \frac{(p_t - \bar{p})(v_t - \bar{v})}{\sigma_p \sigma_v} \quad (6)$$

其中, $\text{NCC}(P_i, \mu_k^p)$ 越大, 表示 P_i 与 μ_k^p 曲线形状越相似。

(2) 多元气象频域特征相似性评估

本文通过傅里叶变换提取气象因子的频域数据分布, 结合余弦相似度量化待预测日与分类样本中心气象数据的相似性, 用以对待预测日进行聚类匹配。其中, $\text{Cos sim}(\text{FFT}(x_i^{\text{wvp}}), \text{FFT}(\mu_k^{\text{wvp}}))$ 为余弦相似

度,用于量化气象数据在频域上的相似性。通过不同时间窗口相似度权值叠加进行样本数据的划分,具体包含小时级样本气象数据集和分钟级样本气象数据集,即在小时级样本气象数据频域相似度的基础上,叠加分钟级时间窗口的气象数据频域相似度,从而拟合气象数据的趋势和短时波动特性。归一化预处理

$$\text{Cos sim}\left(\text{FFT}\left(x_i^{\text{ntp}}\right), \text{FFT}\left(\mu_k^{\text{ntp}}\right)\right) = \frac{\lambda_{\min} \sum_{\min} \left|F_i(x) \cdot F_k(\mu)\right|}{\sqrt{\sum_{\min} \left|F_i(x)\right|^2} \cdot \sqrt{\sum_{\min} \left|F_k(\mu)\right|^2}} + \frac{\lambda_h \cdot \sum_h \left|F_i(x) \cdot F_k(\mu)\right|}{\sqrt{\sum_h \left|F_i(x)\right|^2} \cdot \sqrt{\sum_h \left|F_k(\mu)\right|^2}} \quad (9)$$

其中, $F(\)$ 保留主频成分; h 和 \min 分别表示小时级和分钟级气象采集数据傅里叶变换后的主频数据集合, λ_h 和 λ_{\min} 分别表示小时级频域数据和分钟级频域数据的权值; $\text{Cos sim}\left(x_i^{\text{ntp}}, \mu_k^{\text{ntp}}\right)$ 越大, 表示 x_i^{ntp} 与 μ_k^{ntp} 在频域上相似度越高。

基于时频分组的 K-Shape 聚类优化算法, 可以使光伏出力历史数据基于日曲线波动特征和气象数据变化差异划分为多个相似簇, 同一簇内, 光伏出力曲线数据和气象数据存在一一对应的关系。相较于时域数据, 基于频域特征便于识别数据在一段时间内的周期性、规律性变化特征, 从而在开展日前光伏预测时, 可基于下一日光伏设备最大功率和气象预测数据, 匹配至对应分簇, 基于分簇内一一对应的分布式光伏出力曲线样本数据, 构建分布式光伏出力预测模型, 从而获取下一日的光伏出力预测曲线数据。

基于上述获取的时频分类样本数据, 本文采用 MoE 构建分布式光伏出力预测模型, 提升模型对出力波动性的预测准确性。

如图 2 所示, MoE 是在 Transformer 的架构基础上进行改进, 输入第 t 日气象数据、第 $t-1$ 日光伏出力曲线数据、分布式光伏设备额定功率, 位置编码映射层 (position embedding) 对输入数据进行时间标记和时序位置编码, 获取映射向量数据; 随后, 映射向量数据经过归一化处理, 输入 6 层解码器, 每层内含掩码自注意力 (masked self-attention), 用于计算全局时序数据间的依赖关系并生成编码向量。

解码器首先采用归一化对编码向量进行处理, 不同于 Transformer, MoE 采用路由器 (Router) 和 K 个专家网络 (Experts) 代替前馈网络 (Feed Forward Network, FFN), Experts 属于前馈网络, 但与 Transformer 中的网络相比参数及体量更小, 在训练过程中, 不同的分簇样本集对各自的专家网络进行训练, 训练完成后, 在不同的分钟时段, 由 Router 根据时序时段选择不同的专家, 即在不同的分钟时段开始前, Router 采用式 (6) 生成气象频域特征相似性评估值, 选择最大相似专家网络, 如在 $n-1$ 时段根据气象数据相似性评

后的气象数据 x_i^{ntp} 和 μ_k^{ntp} 基于 Matlab 的内置的 FFT 函数实现快速傅里叶变换, 完成数据从时域到频域的转化, 分别表示为

$$F_i(x) = \text{FFT}\left(x_i^{\text{ntp}}\right) \quad (7)$$

$$F_k(\mu) = \text{FFT}\left(\mu_k^{\text{ntp}}\right) \quad (8)$$

则余弦相似度为

估值选择对应的 a 专家网络进行预测, 鉴于其波动突变性, 在 n 时段 Router 根据气象数据相似性评估值选择对应的 b 专家网络进行预测, 最后将各个时段的预测数据进行拼接, 获取分布式光伏日出力预测数据, 从而可有效拟合光伏出力的波动性及多样性。

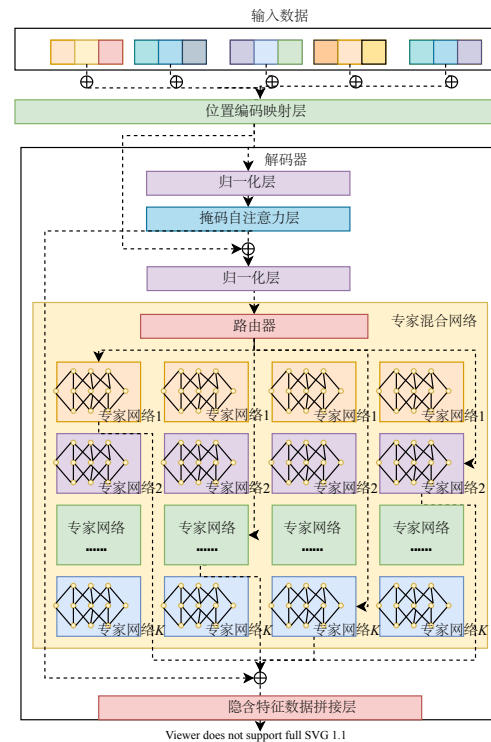


图 2 基于 MoE 构建分布式光伏出力预测模型结构图

Figure 2 Composition structure of distributed photovoltaic output prediction model based on MoE

Router 为采用时频分类环节设定选择最合适的专家网络, 不参与模型训练过程, 这一环节在保障充分利用先验知识的同时, 降低模型训练难度。

MoE 采用 Router 和多个 Experts 代替 FFN, 这使得 MoE 训练及预测速度更快、资源占用更少, 且可以充分实现光伏出力的波动差异性预测。

最后, Experts 输出拼接时段编码数据 (3 072 维)

通过残差连接与层归一化处理,通过两层 GELU 激活函数的全连接层,输出各时段的分布式光伏出力预测数据。

为了防止模型仅仅依赖部分专家网络,通过残差网络反馈每一时段的梯度损失函数至对应专家网络进行反馈调参,直至每个专家网络预测输出低于设定阈值。其中,定义损失函数如下

$$\text{Loss}_{1,k} = -\frac{1}{N} \sum_{i=1}^N \sum_{t=1}^T \left[y_i^t \log p_{i,k}^t + (1-y_i^t) \log (1-p_{i,k}^t) \right] \quad (10)$$

$$\text{Loss}_2 = \sum_{k=1}^K \gamma_k \cdot \text{Loss}_{1,k} \quad (11)$$

其中, γ_k 表示第 k 个专家网络的权重系数,可通过提高反馈权重系数,保障对部分小样本分簇样本集的充分训练; K 表示专家网络总个数,其值与分簇类别数量一致; N 表示分簇样本集中一个批次训练的样本数量; T 表示时间为 16 h (光照最大时段), t 表示时段; y_i^t 表示在 t 时段第 i 个样本的光伏出力实际值, $p_{i,k}^t$ 表示在 t 时段第 i 个样本数据经过第 k 个专家网络获取的光伏出力预测值; $\text{Loss}_{1,k}$ 通过残差反馈至第 k 个专家网络进行反馈调参, Loss_2 通过反馈至整个网络进行反馈调参。

1.2.2 基于多指标约束的调控滚动优化目标

本文基于滑动时间窗口滚动机制调控区域分布式光伏电压及电量输出,具体目标是在各时间窗口内使关键节点电压接近额定电压、最大限度地提升分布式光伏有功功率输出,并避免逆变器频繁调控导致功率输出下降的问题,同时为后续一段时间内的逆变器对关键节点电压调控留有足够裕度空间,构建的目标函数如下:

$$J_{\min} = \min (J_a + J_b + J_c) \quad (12)$$

$$J_a = \lambda_a \sum_{i=1}^{N_i} |U_{\text{ref}} - u|$$

$$= \lambda_a \cdot \sum_{i=1}^{N_i} \left\{ \begin{array}{l} \frac{\psi_i + \sum_{j=1}^m a_{ij} \psi_j}{d_i l_u k_i Q_{\text{res},i}}, \quad \psi_i' \leq \max \psi_i \\ U_{\text{ref}} - \frac{\xi_i \cdot p_i^t}{I_{\text{refp},i}}, \quad \psi_i' > \max \psi_i \end{array} \right. \quad (13)$$

$$J_b = \lambda_b \sum_{i=1}^{N_i} \sum_{t=1}^m |P_{\text{ref},i} - \xi_i \cdot p_i^t| \quad (14)$$

$$J_c = \lambda_c \sum_{i=1}^{N_i} \sum_{t=1}^m C_i^t \quad (15)$$

其中, J_a 表示调控后关键节点电压与目标电压的差值,其值越小说明该区域电压越接近目标电压; ξ_i 表示在 t 时刻的有功功率降额输出比例; J_b 表示区域输出有功功率与额定有功功率的差额,其值越小说明台

区光伏出力效率越高、弃光现象越少, $P_{\text{ref},i}$ 表示第 i 个 DPVI 所服务分布式光伏的额定有功功率值, p_i^t 表示第 i 个 DPVI 所服务分布式光伏在第 t 时间步的预测有功功率输出值; J_c 表示最小调控操作累计值,其值表示第 i 个 DPVI 的电压调控频度,避免频繁调控 (频繁调控会导致有功功率损失 3%~5%); C_i^t 表示分布式光伏 i 在第 t 时间步是否参与电压调控的二元变量表征值,为 0 或 1; N_i 表示调控时间步数量, $t \in [1, N_i]$; λ_a 、 λ_b 、 λ_c 分别表示区域电压、有功出力和电压调控频度的权重系数,该参数直接影响台区电能质量和光伏出力量。

此外,约束条件设定如下。

电压约束:

$$U_i^{\min} \leq u_{i,t} \leq U_i^{\max} \quad (16)$$

其中, U_i^{\max} 、 U_i^{\min} 分别为第 i 个 DPVI 的电压幅值允许的最大、最小值,表示电压应维持在台区电网安全运行允许范围内,超过最大值时,则分布式光伏设备停机。

分布式光伏电源出力约束:

$$0 \leq p_{i,t} \leq u_{i,t}^{\text{on}} P_i^{\max} \quad (17)$$

$$0 \leq q_{i,t} \leq u_{i,t}^{\text{on}} Q_i^{\max} \quad (18)$$

$$|p_i^t - p_i^{t-1}| \leq \Delta t \cdot R_i \quad (19)$$

其中, $p_{i,t}$ 、 $q_{i,t}$ 分别为第 i 个 DPVI 所服务分布式光伏电源 i 在时步 t 的有功、无功出力; P_i^{\max} 为分布式光伏电源 i 的最大有功出力; Q_i^{\max} 为分布式光伏电源 i 最大无功出力; R_i 为分布式光伏电源 i 的最大爬坡速率; $u_{i,t}^{\text{on}}$ 表示分布式光伏电源 i 在时步 t 是否并网出力的二元变量表征值。式(17)和式(18)分别表示分布式光伏电源有功、无功出力不超过其上、下限;式(19)为分布式光伏电源爬坡约束。

剩余容量利用率约束:

$$\psi_i' \leq \max \psi_i \quad (20)$$

由式(4)得出,在剩余容量利用率超过 DPVI 允许的最大化无功功率调控量时,则说明仅采用无功功率调控难以实现目标降压,此时启动降低 DPVI 的有功功率输出比例以实现目标降压,具体通过 J_a 与 J_b 迭代滚动优化,实现目标函数最小化;若后续无功功率调控可满足电压调控时,最小化 J_b 会约束降低有功输出的降压调控方式,从而回到无功功率调压方式。

调控频率约束:

考虑光伏单元控制器的调控频率响应约束,调控指令应不超过响应约束允许的上限。因此调控频率约束为

$$\sum_{1s} C_i^t \leq \frac{1\ 000}{\Delta t} \leq \Delta f \quad (21)$$

$$\forall g \in G, i \in N, ij \in L, t \in T, w \in W \quad (22)$$

其中, Δf 为光伏单元控制器允许的最大频率值; Δt 表示时间步, 单位是 ms; $\sum_{1s} C_i^t$ 表示第 i 个 DPVI 在 1 s 内的累计调控操作次数。

其中, 迭代滚动优化具体实现过程如下:

(1) 基于当前时刻监测及预测值形成调控目标

在当前时刻 t , 通过电能质量监测装置获取关键节点电压值 u_t 、分布式光伏出力预测模型获取当前光伏出力预测数据 p_t^i , 代入式(13)、(14), 此时式(12)形成目标函数, 从而将优化问题与实际物理状态关联。

(2) 计算未来 N_t 个时刻目标函数的最优解

基于当前时刻 t 的目标函数, 通过调节 DPVI 的在 t 时刻的剩余容量利用率 $\psi_{i,t}^t$ 、有功功率降额输出比例 ξ_t 、参与电压调控操作表征 C_i^t (即具体调控操作), 从而控制光伏有功及无功功率输出量, 获取式(12) J_{\min} 不同目标函数值, 及下一时刻 $t+1$ 的关键节点电压预估值 u_{t+1} , 上述调控操作均受电压约束、分布式光伏电源出力约束、剩余容量利用率约束、调控频率约束等约束条件制约。接着通过分布式光伏出力预测模型获取从 $t+1$ 时刻开始的一段未来时间段 N_t 内的光伏出力预测数据 $p_{t+1}^i, p_{t+2}^i, \dots, p_{t+N_t}^i$, 重复上述过程获取预估值 $u_{t+2}^i, u_{t+3}^i, \dots, u_{t+N_t}^i$, 不同调控操作获取不同的目标函数值, J_{\min} 最小值对应的 N_t 个调控操作即为最优调控序列:

$$[\psi_{i,t}^t, \xi_t, C_i^t], [\psi_{i,t+1}^t, \xi_{t+1}, C_i^{t+1}], \dots, [\psi_{i,t+N_t}^t, \xi_{t+N_t}, C_i^{t+N_t}] \quad (23)$$

该序列是未来时间段 N_t 的关键节点电压值与目标电压偏差累计最小、有功功率输出累计最大及调控操作次数累计最小的最优求解操作序列, 即后续 N_t 个时刻目标函数值尽可能地接近了期望目标。

(3) 仅执行第 t 时刻的调控操作 (即第一个)

基于 t 时刻获取的 N_t 个最优控制序列, MPC 只执行第一个控制量 $[\psi_{i,t}^t, \xi_t, C_i^t]$ 进行调控操作。

(4) 时间向前滚动, 重复求解过程

执行第一个控制量 $[\psi_{i,t}^t, \xi_t, C_i^t]$ 后, 在第 $t+1$ 时刻可能存在其他扰动作用, 通过电能质量监测装置获取关键节点电压值 u_{t+1} 、分布式光伏出力预测模型获取光伏出力预测数据 p_{t+1}^i , 更新目标函数, 重复步骤(1)~(3)即完成迭代滚动优化。

1.2.3 基于调控能力边界动态感知及反馈校正

在模型预测控制区, 本文以关键节点电压、光伏出力、DPVI 调控频率构建目标函数, 对台区级电网电压进行 N_t 步预测控制, 每求解一次目标函数, 便得到一组控制序列。将具有目标函数最小值的一组控制序列作为最优控制序列, 并将其第一个控制量作用于

各个 DPVI 开展调控, 台区级电网更新一次当前关键节点电压状态。在下一个时刻, 将当前时刻光伏特征状态量作为预测模型的输入, 获取下一时刻光伏出力预测量, 结合上一时刻的实际关键节点电压共同更新目标函数的输入, 从而有效利用外部环境及模型误差信息, 重复上一时刻的目标函数求解过程, 并将下一时刻获取最优控制序列的第一个控制量作用于各个 DPVI, 如此重复迭代滚动优化。

鉴于分布式光伏出力存在快速变化的情况, 采用 MPC 远程在线生成调控策略并下发, 难以满足调控响应高时效要求, 故本文基于调控反馈数据构建精简模式, 从而进一步提升台区级分布式光伏调控效率, 本文设定调控边界感知规则, 在分布式光伏出力预测模型输出后、开展模型预测控制前, 通过时频分类将光伏出力时序预测数据和气象数据 (后续简称预测数据) 进行归类, 结合归类类别规则判断本次调控操作所处能力区。

经验回放区: 根据调控操作后反馈的关键节点电压值、有功功率输出值及调控频率, 对历史调控策略执行进行评估, 若反馈数据电压波动在 $\pm 2\%$ 内 ($\pm 2\%$ 内说明调控执行有效) 且后续维持时段高于设定时间阈值 T_{Aware} (说明不会触发频繁调控操作), 则本次电压调控操作是有效的, 所以会作为历史样本 (包含本次操作前的电压越限数据、光伏出力预测数据及本次调控策略) 存储在经验回放区。当前输入的电压越限数据和光伏出力预测数据, 与经验回放区中存放的某一历史样本类别的聚类中心达到评估相似性阈值 $d(i, k)_{\text{Aware}}$, 则触发精简模式, 直接调用最相似样本的历史调控策略执行。其中, 评估相似性根据式(6)归一化互相关系数计算; 经验回放区用于存储历史调控中满足上述设定各阈值的历史样本数据。

模型预测控制区: 若预测数据与经验回放区中各类曲线的聚类中心数据超过相似性阈值 $d(i, k)_{\text{Aware}}$, 或调控后电压波动在 $\pm 2\%$ 内的维持时段低于设定时间 T_{Aware} , 则触发模型预测控制模式, 即通过滚动优化生成调控策略, 作用于本次调控。

通过多次验证模型对同类问题的处理稳定性, 确保其设定的调控边界感知规则可靠。核心奖励机制如下:

$$R_{\text{Aware}}(d(i, k)_{\text{Aware}}, T_{\text{Aware}} | i) = \begin{cases} +a_1, & \text{经验回放区} \\ +a_1, & \text{模型预测控制区} \\ -a_2, & \text{边界误判惩罚} \end{cases} \quad (24)$$

其中, a_1/a_2 表示奖励/惩罚系数, 引导校准认知边界; R_{Aware} 表示感知分区奖励/惩罚得分, 奖励值越高, 边

界划分准确率越高。

本文为了规避随着时间推移导致经验回放区存储历史样本产生数据迁移的问题,故将经验回放区各类聚类中心样本数据作为分组相似度判别的对比样本,从而以动态阈值替代人工预设的固定阈值。为更新经验回放区各类聚类中心样本数据,即表示离线的分布式光伏出力预测模型产生了预测偏移,故本文构建监测反馈校正环节,监测模型输出准确度,具体如下:

$$E = \frac{1}{T_n} \sum_{t=1}^{T_n} |p(t) - \hat{p}(t|t-1)| \quad (25)$$

其中, E 表示 T_n 个时间步的光伏出力预测模型平均误差,若达到设定阈值则需重新训练模型; $p(t) - \hat{p}(t|t-1)$ 表示当前时刻 t 光伏出力预测模型的预测误差; $p(t)$ 表示当前时刻 t 的实际光伏出力值; $\hat{p}(t|t-1)$ 表示在 $t-1$ 时刻模型对 t 时刻的光伏出力预测值。

2 算例仿真验证与分析

本文以位于某市某村光伏项目为案例,通过低压汇集线路实现光伏出力汇总,升压变压器将余电接入电网,并在分布式光伏设备侧安装高精度传感器,用以在10:00~16:00之间实现分钟级光伏出力数据采集,其他时间段采用15 min级数据采集。全村112个光伏项目,每户村民房顶平均安装单晶540 W光伏组件48块,共2.9 MW被分成28个单元,所发电能除自发自用外,每4组邻近单元剩余电量集中汇流,最后并入1台专用升压变压器,通过10 kV线路并入电网。本文旨在通过提高响应效率、保障电压平稳,提升分布式光伏并网电能质量,实验结果为累计10次实验数据的均值,具体过程如下。

2.1 算例拓扑关联设计

本文选取上述台区中4个区域的节点分布拓扑进行示例,4组邻近单元节点拓扑关联分布如图3所示,每个区域均配备4个具有DPVI的分布式光伏电源,组1包含节点4、6、7、8,组2包含节点9、11、12、13,组3包含节点15、18、20、21,组4包含节点24、26、29、32。采用式(1)选定4个关键节点,分别位于节点6、节点11、节点18和节点28,用于控制4个区域的电压一致性。表1给出了该台区分布式光伏配备的DPVI参数值,算例仿真中的各DPVI取相同的参数,其中低压台区基准电压为220 V,为提升算例图表数据对比的可视性,将电压控制目标归一化为1.0 p.u.

如表1所示,分布式光伏电压控制目标1.0 p.u.。本文基于Matlab/Simulink搭建32节点的拓扑关联分布图,各节点均接入用电负荷,其中16个节点接入配备DPVI的分布式光伏电源,基于此搭建模型并进行算例仿真验证。

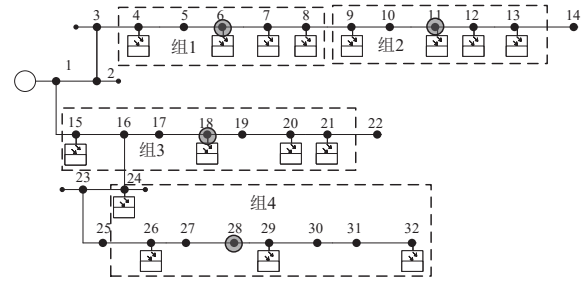


图3 4组邻近单元节点拓扑关联分布示例

Figure 3 Example of topological distribution among four groups of adjacent unit nodes

表1 台区配备DPVI的各参数值

Table 1 The parameter values of each DPVI equipped in the substation area

DPVI参数	值
容量	28.8 kV·A
有功出力	25.92 kW
额定电压	220 V
电压控制目标	1.0 p.u.
频率	50 Hz

2.2 光伏出力预测对调控策略的影响分析

由于分布式光伏出力具有波动性和不确定性,若实际出力与预测值偏差较大,会对台区电压调控产生显著影响,尤其在光照充足时,调控精度不足或时效滞后均易导致台区电压波动,甚至超上限触发停机。针对这一问题,本文基于国网某省用电信息采集系统,获取该光伏项目在2024年6月1日到9月30日的10:00~16:00之间的分钟级光伏出力采集数据,每分钟为一个数据样本,剔除异常值后共计获取可用样本数据33 120例,采用Matlab多项式插值函数进行数据曲线拟合,获取秒级光伏出力拟合数据,按照7:3比例随机分为训练集23 184例和测试集9 936例。为对比说明本文采用时频分类结合MoE实现分布式光伏出力预测的有效性,选取4种消融方案进行对比。

方案1:采用时序数据k-means聚类代替时频分类,采用LSTM代替MoE,构建分布式光伏出力预测模型;

方案2:采用时序数据k-means聚类代替时频分类,结合MoE构建分布式光伏出力预测模型;

方案3:采用LSTM代替MoE,基于时频分类结合LSTM构建分布式光伏出力预测模型;

方案4:采用Transform代替MoE,基于时频分类结合Transform构建分布式光伏出力预测模型。

2.2.1 模型预测准确度对比分析

基于上述训练样本集数据分别完成模型训练后,采用测试样本集获取不同方案的预测准确率对比如图4所示。基于图4测试准确率,对不同方案输出数

据进行统计,结果如表2所示。




图4 分布式光伏出力预测准确率对比

Figure 4 Comparison of accuracy rates in distributed photovoltaic output prediction

表2 分布式光伏出力预测准确率对比

Table 2 Comparison of accuracy rates in distributed photovoltaic output prediction

对比方案	均值/%	标准差/%	最大偏离/%	波动范围/%
方案1	95.38	3.87	10.07	14.02
方案2	98.00	2.18	-4.94	9.13
方案3	97.62	2.63	-7.44	11.78
方案4	96.54	2.47	-9.04	11.12
本文方法	99.29	0.71	1.89	3.27

由图4和表2可以看出,相比其他方案,方案1预测准确率各类对比数据均最差,这是由于k-means时序数据聚类结合LSTM,侧重于短期时序数据预测,难以捕获全局多变量之间的关联关系;方案2采用时序数据k-means聚类代替时频分类,相对于本文方法准确率各测试参数指标有一定下降,但由于MoE可针对不同分组完成差异化定向预测训练,故预测准确率相对其他方案仍较高,但波动范围相对本文方法仍较大,说明频域数据聚类可以提升预测鲁棒性和稳定性;方案3采用LSTM代替MoE,由于时频分类可为LSTM提供全局多维度关联数据,同时LSTM相对Transformer,对训练样本数据量需求较小,故可完成相对充分的模型训练,其预测准确率均值比方案4高,但标准差和波动范围均大于方案4,进一步验证LSTM相较于Transformer,对全局特征关联捕捉能力较弱;方案4由于采用Transform代替MoE,其模型参数量成倍增加,一方面分类样本数据不满足Transform充分训练的要求,另一方面Transform缺乏明确的专业化预测分工,故效果仅相对高于方案1;本文方法通过时频数据分类,捕获多维全局特征关联信息,提升类内数据相似度,并根据类别动态选择适配的专家

模块,通过MoE完成分布式光伏出力定向预测,从而实现精准预测。

2.2.2 对生成调控策略的影响分析

本文基于电能质量监测装置实时监测电压有效值,支持10 ms级的快速电压变化事件记录,并根据电压波动监测数据进行调控策略生成。鉴于本文分布式光伏有功功率出力监测是秒级,同时考虑到逆变器频繁调控可能触发保护机制导致降额运行或停机,故以200 ms为一个调控步长,每个出力预测窗口提供5个调控步长,同一个预测窗口内5个调控操作基于秒级有功功率预测拟合值计算均值获取,MPC预测步数为50个步长,即10 s。本文模型预测控制基于上述5个方案获取的分布式光伏有功功率预测值生成电压滚动调控策略,测试时长共计20 s,其中在第8 s时各组关键节点电压越上限7%,如图5所示。




图5 模型预测控制生成电压调控策略作用过程图示

Figure 5 The execution process of the voltage regulation strategy generated by model predictive control

对不同方案调控压降操作进行验证跟踪统计,电压调控偏差如图5所示。其中,正值表示调控电压量超过基线所需的电压调控量,易产生电压过低的问题;负值表示调控电压量低于基线所需的电压调控量,易产生电压越线的问题,如表3所示。

本文为展示对比性,在20 s内仅生成一次调控策略,整体调控过程也按此执行。由图5和表3可以看出,方案1由于预测准确率误差最大,在11.6 s即触发关键节点电压越下限2%(简称场景1)的二次调控策略生成,在16 s即触发关键节点电压越下限7%(简称场景4),皆因预测不准确导致过度削减有功功率,造成发电量损失;方案2由于预测准确率误差较小,调控过程未触发二次调控策略生成,仅最大偏离电压高于本文方法;方案3在15.6 s即触发场景1的二次调控策略生成,同样因预测不准确导致过度削减有功

表3 电压调控策略作用过程数据对比说明

Table 3 Comparison of accuracy rates in distributed photovoltaic output prediction

对比方案	二次调控 触发时间/s	电压越上限 触发时间/s	最大 偏离/%	调控事件记录
方案1	11.6	16	7.17	发电量损失
方案2	—	—	1.97	—
方案3	15.6	—	4.19	发电量损失
方案4	9.4	19.4	-8.32	电压持续越限
本文方法	—	—	1.42	—

注:“—”表示一次调控后,在20 s内未产生关键节点电压越下限2%事件。

率,造成发电量损失,但整体调控效果优于方案1和方案4;方案4在9.4 s即触发关键节点电压越上限2%(简称场景2)的二次调控策略生成,在19.4 s即触发关键节点电压越上限7%(简称场景3),主要因有功功率削减不足,无法有效降低电压,后续甚至存在电压持续越限导致停机的可能;本文方法对比上述方案,整体调控过程电压控制偏差均在 $\pm 2\%$ 以内,未频繁引发调控策略生成,充分说明了本文生成调控策略的稳定性和可用性。

2.3 电压控制效果对比分析

为验证并对比说明本文所述分布式电压控制策略的有效性 with 适用性,设置3种场景进行仿真分析。

场景1:负荷突增导致关键节点电压越下限2%~10%;

场景2:分布式光伏电源出力波动导致关键节点电压越上限2%~7%;

场景3:分布式光伏电源出力波动导致关键节点电压越上限7%~10%。

选取当前主流的分布式光伏电源电压控制方法作为对比,具体有如下3种方法。

方法1:将电压调控转换为最小电压控制偏差目标函数,基于哈密顿-雅克比-贝尔曼方程进行函数值求解,采用执行-评价的双神经网络迭代获得电压调控值^[15]。

方法2:采用多分布式光伏逆变器协同调控区域电压波动,以最小化单步收敛因子目标确定区域调控领导者,构建领导-跟随模式进行节点电压协同一致控制^[14]。

方法3:通过上下分层模型预测控制实现电压调控,上层整体规划各组DPVI整体调控指标,下层结合非参数核密度估计预测分布式光伏电源出力,以滑动窗口更新电压滚动优化决策^[16]。

2.3.1 场景1:负荷突增导致关键节点电压越下限2%~10%

根据历史监测数据获取仿真样本数据,仿真时间

设置为15 s,在 $t=7.5$ s时组1有功功率负荷增加30 kW、无功功率19.2 kvar。组1内DPVI通过输出无功功率调整关键节点电压变化如表4所示。

表4 各组控制前后输出功率

Table 4 Comparison of regulated output power

分组编号	有功输出/kW	无功输出/kvar	
		控制前	控制后
1	93.30	22.43	36.77
2	93.31	21.25	24.06
3	93.32	21.11	22.18
4	93.36	23.28	23.67

如表4所示,在7.5 s时由于组1负荷突然增加,关键节点电压跌落,组内DPVI通过输出无功功率将关键节点电压快速提升至1.0 p.u.附近。

如图6所示,调控前分组1的关键节点6在7.5 s时突然越下限,故组内4个具备光伏逆变器的节点通过输出无功功率来提升电压,4种方法调控后各节点电压均稳定于控制目标1.0 p.u.。其中,方法1在7 s内完成电压调控任务,由于其采用执行-评价的对抗学习迭代求解,该过程相对其他3种方法易出现调控不稳定的问题,如图在11.2 s其电压调控波动较大,存在越上限风险;方法2同样在7 s内完成电压调控任务,由于其采用领导-跟随模式进行节点电压协同一致控制,未能提前预测未来时刻的分布式光伏出力情况,而采取基于当前时刻出力数据的保守调控操作,故调控完成时间是本文方法的2.8倍;方法3在6 s内完成电压调控任务,由于采用分层控制策略,在初始阶段调控响应速度相对其他方法滞后约2 s,后期由于采用具备前瞻性的模型预测控制,调控完成速度快于方法1、2;本文方法基于上述研究基础,在2.5 s内即完成了电压调控任务,由于其在分布式光伏预测方面进行了改进,提高了预测准确性与稳定性,并引入模型预测控制实现前瞻性调控,同时通过历史调控响应情况触发经验回放精简模式,进一步提高调控响应效率,在保证电压调控稳定的前提下,在负荷突增导致关键节点电压越下限-7%~-2%范围内,电压调控完成速度比其他方法快2.4倍以上。

2.3.2 场景2:分布式光伏电源出力波动导致关键节点电压越上限2%~7%

根据日常监测数据获取仿真样例数据,仿真时间设置为15 s,在 $t=5$ s时光照强度增加,导致各组关键节点电压越上限2%,各组DPVI通过吸收无功功率对各节点电压进行调控,如表5所示。

如表5所示,在5 s时由于分布式光伏电源出力增加,各组关键节点电压均越上限2%,各组DPVI通过吸收无功功率将关键节点电压快速降至1.0 p.u.




图6 电压越下限调控对比

Figure 6 Comparison of regulation effects when voltage is below the minimum limit

表5 各组控制前后输出功率

Table 5 Comparison of regulated output power

分组编号	有功输出/kW	无功输出/kvar	
		控制前	控制后
1	93.32	25.31	7.09
2	93.31	23.53	7.06
3	93.31	24.26	5.82
4	93.33	25.52	5.61

附近。

如图7所示,本文以分组2为例,进行电压越上限2%调控前后对比说明,分组2的关键节点11在5s越上限2%,故组内4个DPVI通过吸收无功功率来降低电压,4种方法调控后各节点电压均稳定于控制目标1.0 p.u.。其中,方法1在7.2s内完成降压调控,由于其缺乏预判前瞻性且存在降压调控偏差,故电压调控波动较大;方法2在7.8s内完成降压调控,其采用保守调控速度比本文方面慢1.8s左右;方法3在7s内完成降压调控,同样初始调控响应速度比其他方法滞后,调控完成时间比本文慢1.5s左右;本文基于上述研究基础,在6s内完成降压调控,实验表明,分布式光伏出力波动导致的关键节点电压越上限2%~7%,本文方法相比其他方法调控完成时间更短且更稳定。

2.3.3 场景3:分布式光伏电源出力波动导致关键节点电压越上限7%~10%

根据监测数据获取仿真样本数据,仿真时间设置为10s,在 $t=4s$ 时光照强度增加,导致各组关键节点电压越上限7%~10%(电压越上限10%,DPVI启动过压保护停机),各组DPVI通过采用本文方法降低有功功率输出对关键节点电压进行调控,如表6所示。

如表6所示,在5s时由于分布式光伏出力增加,关键节点电压越上限超过7%,各组DPVI通过降低有功功率将关键节点电压快速降至1.0 p.u.附近,其中,




图7 电压越上限2%调控对比

Figure 7 Comparison of regulation effects when the voltage exceeds the upper limit by 2%

表6 各组控制前后输出功率

Table 6 Comparison of regulated output power

分组编号	额定有功功率输出/kW	有功功率输出/kW	
		调控前	调控后
1	93.31	87.02	89.87
2	93.31	87.10	89.77
3	93.31	87.04	89.77
4	93.31	87.12	89.98

在采用本方法调控前,传统方式有功功率输出减少约6.7%,采用本方法调控后,有功功率输出减少约3.7%,统计日有功功率输出增加约3%。

如图8所示,同样以分组2为例,进行电压越上限8%调控前后对比说明,分组2的关键节点11在5s时电压越上限至8%,故组内4个DPVI通过降低有功功率输出来降低电压,4种方法调控后各节点电压均稳定于控制目标1.0 p.u.。其中,方法1在3.6s内完成电压调控,比本文方法慢1.6s,是本文方法调控时间的1.8倍,同时整体调控波动较大;方法2在4.8s内完成降压调控,其采用保守方式的调控完成时间比本文方法慢2.8s,是本文调控时间的2.4倍,虽然电压波动最小但调控完成时间最长;方法3在3.8s内完成降压调控,比本文方法慢1.8s,是本文方法调控时间的1.9倍,且在初始阶段调控响应速度相对其他方法存在一定滞后性,且由于反应不及时,电压仍持续上涨,调控响应速度比本文方法慢0.2s,存在一定的越限停机风险;本文基于上述研究基础,在2s内即完成了降压调控,波动性相对较小,且调控响应反应速度最快,实验表明,分布式光伏出力波动导致的关键节点电压越上限7%~10%,本文方法相比其他方法响应速度快、调控完成时间短且调控更稳定,同时有功功率输出对比调控前提升约3%。




图8 电压越上限8%调控前后压降效果对比

Figure 8 Comparison of regulation effects with voltage exceeding the upper limit by 8%

3 结论

针对分布式光伏规模化发展导致台区电压波动,进而影响用户及配电网设备安全稳定运行的问题,提出了一种计及台区电能质量的分布式光伏电源电压调控策略。首先,基于用户负荷及光伏分布构建分布式光伏-负荷节点拓扑图,据此筛选关键节点以协同多逆变器,旨在通过调整输出电流进行电压调控,从而形成区域约束调控目标;随后,构建基于时频分类结合混合专家网络的分布式光伏预测模型,并以模型预测控制生成前瞻式的滚动优化调控策略,完成台区各区域电压协同调控;最后,基于历次电压调控操作反馈数据,提炼调控边界感知规则,形成回放精简模式,以提升调控响应速度,并通过监测反馈校正更新分布式光伏预测模型输出准确度。算例仿真验证了该方法生成调控策略的稳定性和有效性。

目前鉴于逆变器设备计算资源受限,虽然在分布式光伏设备侧配备的电能质量监测装置支撑 10 ms 级电压数据监测,但数据仅短期存储在设备侧,难以实时上传至云端。故台区级分布式光伏电源电压调控策略是基于历史上传的分钟级冻结数据,在实验室环境完成验证,后续随着端侧计算资源提升,可将电压调控方法下发至设备完成调控策略生成,从而提升调控响应速度及性能。

参考文献

[1] Dong Fugui, Shi Mengyu, Kang Keyi. Review of existing policies and prospects for green power and green certificates in a dual-carbon context[J]. Energy for Sustainable Development, 2025, 88: 101819.
[2] Varetsky Y, Fedorczak-Cisak M, Kushka B. Studying voltage fluctuations in the MV distribution grid with a renew-

able energy source[J]. Energies, 2025, 18(16): 4217.
[3] 叶建盈, 万威, 刘昭启, 等. 基于 P-V 特性曲线的光伏系统 MPPT 控制方法[J]. 太阳能学报, 2025, 46(9): 490-500. Ye Jianying, Wan Wei, Liu Zhaoqi, et al. Mpppt control method for photovoltaic systems based on P-V characteristic curve[J]. Acta Energiæ Solaris Sinica, 2025, 46(9): 490-500. (in Chinese)
[4] 黄婧杰, 胥日升, 周野, 等. 低碳电源结构规划的能源-技术-环境模型及贝叶斯随机优化方法[J/OL]. 中国电机工程学报, 1-15[2025-09-10]. <https://link.cnki.net/urlid/11.2107.tm.20250909.1745.019>. Huang Jingjie, Xu Risheng, Zhou Ye, et al. Energy-technology-environment model and Bayesian stochastic optimization method for structural planning of low-carbon power supply[J/OL]. Proceedings of the CSEE, 1-15[2025-09-10]. <https://link.cnki.net/urlid/11.2107.tm.20250909.1745.019>.
[5] 张鑫灏, 周泓宇, 姚伟, 等. 面向电网电压主动支撑的光伏场站双模式协调控制[J]. 电网技术, 2025, 49(9): 3577-3588. Zhang Xinhao, Zhou Hongyu, Yao Wei, et al. Dual-mode coordinated control strategy of photovoltaic stations for active grid voltage support[J]. Power System Technology, 2025, 49(9): 3577-3588. (in Chinese)
[6] 李海啸, 程强, 周林, 等. 大型可再生能源电站系统电压分布式非凸优化方法[J]. 电工技术学报, 2025, 40(22): 7399-7417. Li Haixiao, Cheng Qiang, Zhou Lin, et al. Distributed non-convex optimization method for system-wide voltage of large-scale renewable energy power plants[J]. Transactions of China Electrotechnical Society, 2025, 40(22): 7399-7417. (in Chinese)
[7] 王允祥, 刘友波, 廖红兵, 等. 基于双层强化学习的有源配电网中低压协同趋优运行策略[J]. 电力系统自动化, 2025, 49(24): 41-50. Wang Yunxiang, Liu Youbo, Liao Hongbing, et al. Medium-and low-voltage collaborative optimal operation strategy in active distribution network based on double-layer reinforcement learning[J]. Automation of Electric Power Systems, 2025, 49(24): 41-50. (in Chinese)
[8] Zhang Yangrui, Zhu Yakui, Zhang Chao, et al. Multi-time scale optimal control of voltage fluctuation at PV grids considering load changes[J]. Journal of Electrical Engineering & Technology, 2025, 20(3): 1283-1291.
[9] 吴忠强, 谢宗奎, 王国勇, 等. 一种基于改进羊群算法的光伏系统最大功率跟踪策略[J]. 电子学报, 2020, 48(10): 2017-2024.

- Wu Zhongqiang, Xie Zongkui, Wang Guoyong, et al. A maximum power point tracking strategy for photovoltaic system based on improved sheep behaviors optimization[J]. Acta Electronica Sinica, 2020, 48(10): 2017-2024. (in Chinese)
- [10] 郭子跃, 全惠敏, 彭子舜, 等. 一种基于 Si/SiC 级联 H 桥逆变器的高性能模型预测控制方法[J]. 电子学报, 2024, 52(9): 3000-3009.
- Guo Ziyue, Quan Huimin, Peng Zishun, et al. A high-performance model predictive control strategy based on Si/SiC cascaded H-bridge inverter[J]. Acta Electronica Sinica, 2024, 52(9): 3000-3009. (in Chinese)
- [11] Tripathi A K, Aruna M, Elumalai P V, et al. Advancing solar PV panel power prediction: A comparative machine learning approach in fluctuating environmental conditions[J]. Case Studies in Thermal Engineering, 2024, 59: 104459.
- [12] Pajares A, Vivas F J, Blasco X, et al. A novel energy management system based on move-blocking based predictive control for use in microgrid control[J]. Energy Conversion and Management, 2025, 345: 120400.
- [13] He Ning, Cheng Zihao, Qian Cheng, et al. Dual-layer optimized scheduling for solar-energy-integrated system based on auto-tuned MPC and event-triggering mechanism[J]. Journal of Building Engineering, 2025, 112: 113837.
- [14] 胡蓉, 殷雪莉, 徐梦, 等. 基于分布式一致性的新型配电系统电能质量综合治理研究[J]. 电测与仪表, 2025, 62(8): 49-61.
- Hu Rong, Yin Xueli, Xu Meng, et al. Research on comprehensive power quality management of new distribution network based on distributed consensus[J]. Electrical Measurement & Instrumentation, 2025, 62(8): 49-61. (in Chinese)
- [15] 王睿, 孙秋野, 张化光. 微电网的电流均衡/电压恢复自适应动态规划策略研究[J]. 自动化学报, 2022(2): 479-491.
- Wang Rui, Sun Qiuye, Zhang Huaguang. Research on current sharing/voltage recovery based adaptive dynamic programming control strategy of microgrids[J]. Acta Automatica Sinica, 2022(2): 479-491. (in Chinese)
- [16] 顾雪平, 魏佳俊, 白岩松, 等. 基于分层模型预测控制的含风电电力系统恢复在线决策方法[J]. 电工技术学报, 2025, 40(5): 1471-1486.
- Gu Xueping, Wei Jiajun, Bai Yansong, et al. Online decision-making method for wind power integrated power system restoration based on hierarchical model predictive control[J]. Transactions of China Electrotechnical Society, 2025, 40(5): 1471-1486. (in Chinese)

作者简介



管永明 男, 1984 年 1 月出生于山东省济南市。2009 年于山东大学计算机软件与理论专业获得硕士学位, 其后在地纬智能科技股份有限公司从事智能电网应用、数据挖掘工作, 现为山东大学软件学院博士研究生。主要研究方向为智能电网大数据分析及应用。

E-mail: guanyongming@dareway.com.cn



史玉良 男, 1978 年 10 月出生于山东省威海市。2006 年于复旦大学计算机软件与理论专业获得博士学位, 现为山东大学软件学院教授、博士生导师。主要研究方向为大数据、人工智能等理论研究与应用转化。中国电子学会会员编号: E190159875M。

E-mail: shiyuliang@sdu.edu.cn



王继虎 男, 1992 年 2 月出生于山东省菏泽市。现为山东大学控制科学与工程学院博士后。主要研究方向为智能电网、人工智能应用。

E-mail: wangjihou@sdu.edu.cn



吕 梁 男, 1985 年 7 月出生于山东省济南市。2010 年于中国海洋大学信号与信息处理专业获得硕士学位, 其后在地纬智能科技股份有限公司从事电力系统设计与分析工作, 现为山东大学软件学院博士研究生。主要研究方向为人工智能数据分析及应用。

E-mail: ll@dareway.com.cn



陈志勇 男, 1970 年 2 月出生于山东省禹城市。2011 年毕业于山东大学计算机软件与理论专业。现为山东大学软件学院副教授。主要研究方向为数据融合及应用。

E-mail: chenzy@sdu.edu.cn



李 晖 女, 1967 年 4 月出生于江苏省南京市。2010 年毕业于山东大学计算机软件专业。现为山东大学软件学院副教授。主要研究方向为数据安全、数据脱敏。

E-mail: lih@sdu.edu.cn