

计及主配约束的分布式光伏承载力评估方法

李强*, 匡俊杰, 陈智豪, 蒋凯源, 李齐圣, 沈家宇

中国矿业大学(北京)机械与电气工程学院, 北京

收稿日期: 2026年5月9日; 录用日期: 2026年6月1日; 发布日期: 2026年6月12日

摘要

文章旨在建立计及主配电网协同约束的光伏承载力评估方法, 实现评估精度与效率的双重提升。通过构建含主配协同约束的评估模型, 以最大光伏承载力为目标, 将主网调峰缺口增量、净负荷最大波动率与配网电压、线损约束协同嵌入; 针对传统全局寻优中海量时序潮流计算导致耗时过长这一核心痛点, 提出了一种遗传算法(GA)与BP神经网络相结合的优化算法, 通过BP神经网络构建“光伏装机容量-多维度约束指标”高精度非线性映射模型, 通过模型预测与真实潮流计算验证, 从而替代大量物理仿真。33节点算例验证表明, 这种混合优化方法有效解决了优化过程中潮流计算耗时过长的问题, 实现了配网-主网协同约束下光伏装机容量的高效、准确优化。

关键词

BP神经网络, 遗传算法, 分布式光伏, 主配协同

A Distributed Photovoltaic Carrying Capacity Assessment Method for Calculating and Main Distribution Constraints

Qiang Li*, Junjie Kuang, Zhihao Chen, Kaiyuan Jiang, Qisheng Li, Jiayu Shen

School of Mechanical and Electrical Engineering, China University of Mining and Technology (Beijing), Beijing

Received: May 9, 2026; accepted: June 1, 2026; published: June 12, 2026

Abstract

The purpose of this paper is to establish a PV carrying capacity assessment method that takes into

*通讯作者。

文章引用: 李强, 匡俊杰, 陈智豪, 蒋凯源, 李齐圣, 沈家宇. 计及主配约束的分布式光伏承载力评估方法[J]. 智能电网, 2026, 16(3): 57-66. DOI: 10.12677/sg.2026.163007

account the synergistic constraints of the main and distribution networks, and to realize the double improvement of assessment accuracy and efficiency. By constructing an assessment model with main and distribution synergistic constraints, with the maximum PV carrying capacity as the goal, the main grid peak gap increment, the maximum fluctuation rate of the net load and the distribution network voltage and line loss constraints are embedded synergistically; for the core pain point of the traditional global optimization in which the calculation of the massive time-sequence currents leads to the long time-consuming calculation, this paper proposes an optimization algorithm combining genetic algorithm (GA) and BP neural network, and constructs a high-precision nonlinear mapping model of “photovoltaic installed capacity-multidimensional constraint index” through BP neural network, and verifies it through model prediction and real current calculation, thus replacing a large number of physical simulations. 33-node case validation shows that this hybrid optimization method effectively solves the time-consuming and lengthy problem of the current calculation in the optimization process, enabling efficient and accurate optimization of PV installed capacity under coordinated transmission-distribution network constraints.

Keywords

BP Neural Network, Genetic Algorithm, Distributed Photovoltaic, Master-Distributor Collaboration

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

近年来,分布式光伏(PV)凭借就近消纳的优势在配电网中实现了规模化接入[1]-[3]。然而,当光伏渗透率达到一定水平时,其固有的随机性与波动性不仅改变了配电网原有的单向潮流分布,而且显著增加了上级电网的调峰压力与爬坡需求[4]-[5]。此时,若仅评估配电网单一层级的接纳能力,往往无法反映系统的真实安全运行状态。因此,建立涵盖主配电网协同边界的光伏承载力评估体系,是现阶段新型电力系统规划亟待解决的关键问题。

目前,关于分布式光伏承载力评估的研究已取得一定成果,但多数研究仍主要聚焦于配电网内部的约束,如节点电压偏移与系统线损率,较少将主网侧的调峰缺口及净负荷波动率等全局调控指标纳入协同考量[6]-[8]。另一方面,在求解涵盖多维约束的全局寻优问题时,遗传算法(GA)等常规启发式算法需频繁调用长周期时序潮流计算以验证个体适应度。面对复杂的网络拓扑与海量迭代需求,纯物理仿真的计算模式会导致极高的时间成本,难以满足多场景评估的工程实用要求。

针对上述问题,本文提出一种计及主配协同约束的分布式光伏承载力高效评估方法[9][10]。首先,建立以全天光伏并网电量最大化为目标的评估模型,将主网侧调峰缺口增量、净负荷最大波动率与配网侧电压、线损协同嵌入约束集。其次,引入误差反向传播(BP)神经网络作为代理模型[11],构建“容量配置方案-多维约束指标”的高精度非线性映射,并提出一种混合驱动的GA-BP优化算法。在算法演化过程中,采用代理模型预测与真实潮流仿真验证的方法,在确保边界约束准确的前提下,有效替代了大量重复的物理计算。最后,通过IEEE 33节点系统的算例仿真,验证了所提方法在发掘全网最优承载力的有效性。

2. 计及主配约束的分布式光伏承载力评估模型

2.1. 目标函数

以一个完整的调度周期内分布式光伏并网电量最大化为优化目标函数,具体模型为:

$$f = \max \sum_{t=1}^m \sum_{i=1}^n (P_{PV,i} * X_i * P_{PV,time}(t)) \cdot \Delta t \quad (1)$$

式中, $P_{PV,i}(t)$ 为节点 i 在时刻 t 的光伏有功出力; X_i 表示节点 i 是否接入光伏(0 表示不接入, 1 表示接入), $P_{PV,time}(t)$ 为第 t 小时的光伏时序出力系数(0~1); m 为调度周期, n 为可接入光伏节点总数, Δt 指代调度步长。

2.2. 约束条件

2.2.1. 配电网侧协同约束

1) 电压平均偏移率约束

电压平均偏移率评估分布式光伏并网后电网的电压稳定性, 表示为:

$$\Delta U_{\text{avg}} = \frac{1}{24n} \sum_{t=1}^{24} \sum_{i=1}^n \left| \frac{U_i(t) - U_{Ni}}{U_{Ni}} \right| \times 100\% \leq U_{\text{avg}}^{\text{max}} \quad (2)$$

式中, ΔU_{avg} 为电压平均偏移率; $U_{\text{avg}}^{\text{max}}$ 为系统允许的最大电压平均偏移上限。

2) 平均线损率约束

平均线损率评估分布式光伏并网对配电网损耗的影响, 表示为:

$$R_{\text{loss}} = \frac{1}{24} \sum_{t=1}^{24} \frac{\sum_{j=1}^{n-1} P_{\text{loss},j}(t)}{P_{\text{load}}(t) + P_{\text{loss}}(t)} \leq R_{\text{loss,max}} \quad (3)$$

式中, R_{loss} 为平均线损率, $R_{\text{loss,max}}$ 为最大平均线损率。

2.2.2. 主电网侧协同约束

1) 调峰缺口增量约束

调峰缺口增量反映配网分布式光伏对主网调峰需求的叠加作用, 表示为:

$$\Delta G_{\text{pr}} = P_{\text{eqload,max}}(t_1) - P_{\text{eqload,min}}(t_2) \leq \Delta G_{\text{pr,max}} \quad (4)$$

式中, $P_{\text{eqload,max}}(t_1)$ 为净负荷的日最大值, 对应 t_1 时刻; $P_{\text{eqload,min}}(t_2)$ 为净负荷的日最小值, 对应 t_2 时刻, $\Delta G_{\text{pr,max}}$ 为调峰缺口增量上限值。

2) 净负荷最大波动率约束

净负荷波动率反映配网净负荷波动对主网爬坡需求的影响, 其值越小越好, 表示为:

$$R_{\text{NL}} = \frac{\max |\Delta P_{\text{eqload}}(t)|}{\Delta t} \leq R_{\text{NL,max}} \quad (5)$$

式中, Δt 为单位时间, 一般取 1 小时; $\Delta P_{\text{eqload}}(t)$ 为单位时间内净负荷变化量, 且 $\Delta P_{\text{eqload}}(t) = P_{\text{eqload}}(t) - P_{\text{eqload}}(t-1)$, $R_{\text{NL,max}}$ 为净负荷最大波动率。

3. 基于 GA-BP 代理模型的混合优化算法实现

3.1. 遗传算法与 BP 神经网络基本原理

针对该问题, 本文采用遗传算法(GA)作为全局寻优的宏观框架。GA 通过模拟生物进化的选择、交叉和变异机制, 能够在庞大的解空间中避免陷入局部最优[12]。与此同时, 优化过程中频繁调用 MATPOWER 进行时序潮流计算会导致极大的时间成本。为突破这一计算瓶颈, 本文借鉴文献[13]-[15]的思路引入误差反向传播(BP)神经网络。BP 神经网络具备强大的非线性映射能力, 在本文中“光伏节点容量配置方案”作为输入, 将时序潮流计算才能得出的“系统多维约束指标(如线损率、调峰缺口等)”作为输出, 训练出

一个能快速估算电网运行状态的代理模型。

3.2. 基于 GA + BP 的混合优化流程

考虑主配协同约束的光伏承载力优化问题，本文将 BP 神经网络嵌入到 GA 的适应度计算环节中。具体的混合优化流程如流程图 1 所示：

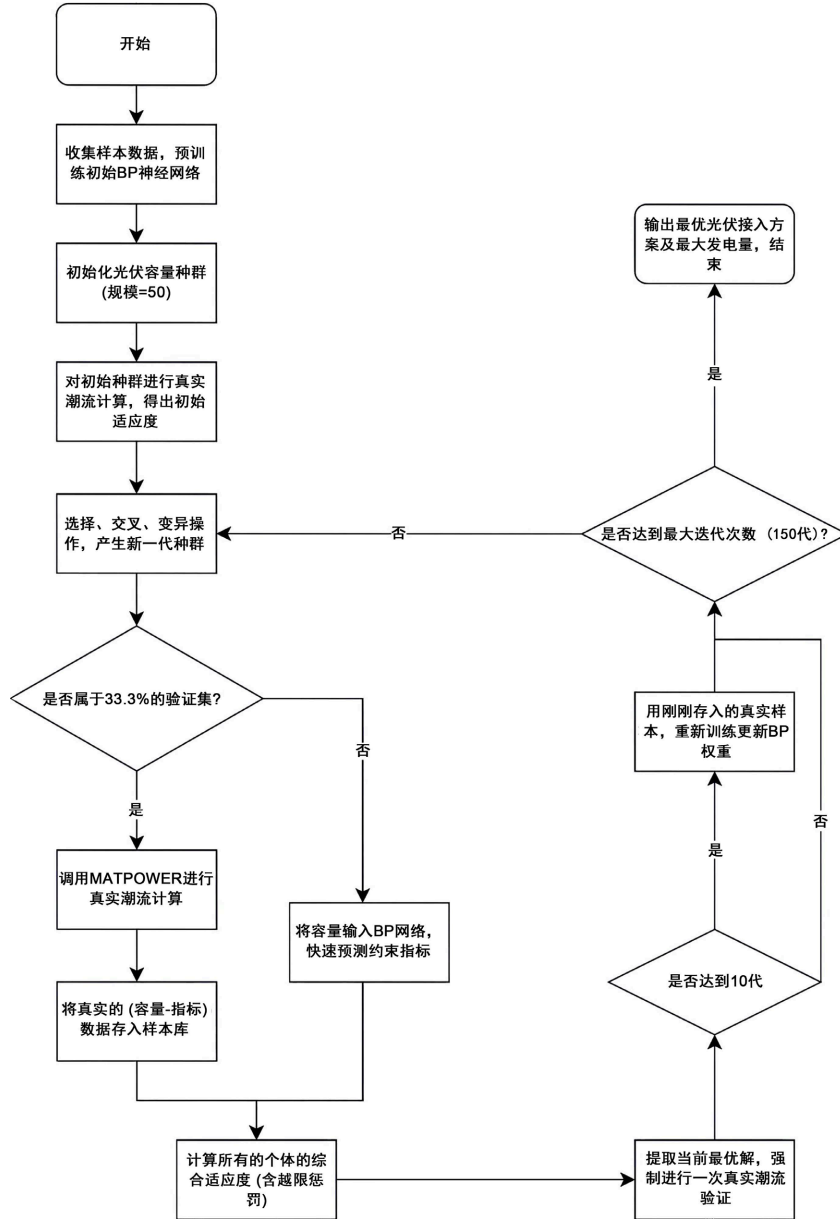


Figure 1. Flow chart of GA + BP optimization algorithm

图 1. GA + BP 优化算法流程图

- 第一步：首先随机生成一批光伏接入容量的样本数据，进行真实的潮流计算，得到对应的各项电网约束指标。用这批数据预先训练出一个初始的 BP 神经网络模型。
- 第二步：以 32 个节点的装机容量作为 GA 的决策变量，随机生成规模为 50 的初始容量种群。对这 50

个个体进行一次真实的潮流计算，求出它们的初始综合适应度。

- 第三步：根据上一代个体的适应度，按设定的概率执行选择、交叉和变异操作，产生新一代的光伏容量种群。
- 第四步：将新种群做 66.7% 预测 + 33.3% 验证工作。具体操作为，把其中 66.7% 个体的容量方案输入预训练好的 BP 神经网络，快速预测出对应的约束指标；对剩下的 33.3% 个体，则进行真实潮流计算验证。结合预测和验证的结果，计算这代种群所有个体的适应度(对不满足约束的方案加上惩罚值)。同时，把这 33.3% 真实计算得到的“容量 - 指标”数据存入样本库备用。
- 第五步：提取当前这代适应度最高的个体，强制让它进行一次真实潮流计算，防止 BP 神经网络产生预测误差。
- 第六步：若程序判定当前迭代次数达到 10 代，则提取样本库中的最新真实数据，对 BP 神经网络权重进行重新训练，以提升 BP 网络后续预测的准确度。
- 第七步：检查程序是否达到了最大迭代次数(设定为 150 代)。如果没有达到，就返回第三步继续下一次迭代循环；如果达到了 150 代，则结束程序，输出最终满足主配网约束的最优光伏接入方案以及全天最大并网发电量。

4. 算例分析

4.1. 算例背景设置

1) 本研究以 IEEE 33 节点系统进行仿真，并以 1 天为调度周期，1 小时作为调度步长。基准功率为 1 MVA，其平衡节点起始电压为 1.0 p.u.，单节点光伏装机容量约束范围为 0~0.6 MW。实验所用 24 小时负荷数据(P_load)与光伏出力系数(PV_load)均为实测标么值，实验过程需同时满足配网与主网双重约束：配网侧电压运行范围为 0.95~1.05 pu，日均线损率上限设定为 8%；主网侧净负荷最大波动率 ≤ 2 MW，调峰缺口增量 ≤ 3 MW。GA 与 BP 神经网络的具体寻优参数在最佳化迭代过程中自适应调整。系统结构图如图 2 所示：




Figure 2. Diagram of IEEE 33 distribution network system
图 2. IEEE 33 配电网系统图

2) 为深入探究主配电网协同约束对分散式光伏承载力的影响规律，以及验证本文算法的有效性，故设定以下三个对比模拟场景：

场景 A：分布式光伏共接入 20 个节点，接入位置为[2、4、5、6、7、9、14、15、16、17、18、20、22、24、25、29、30、31、32、33]，即接入固定节点；同时考虑主配电网协同约束。

场景 B：不固定节点(全网寻优)，同时考虑主配电网协同约束，寻找全局最优承载力。

场景 C: 不固定节点(全网寻优), 且仅考虑配电网约束(即不考虑主配调峰及波动性惩罚), 用于探究主配协同对电网的重要性。

4.2. 算例性能分析

为验证 GA + BP 算法中代理模型的替代有效性, 本文首先对训练完成的 BP 神经网络进行了多维度的精度分析, 具体结果(以场景 B: 全网寻优 + 主配电网协同约束为例)如图 3 所示。

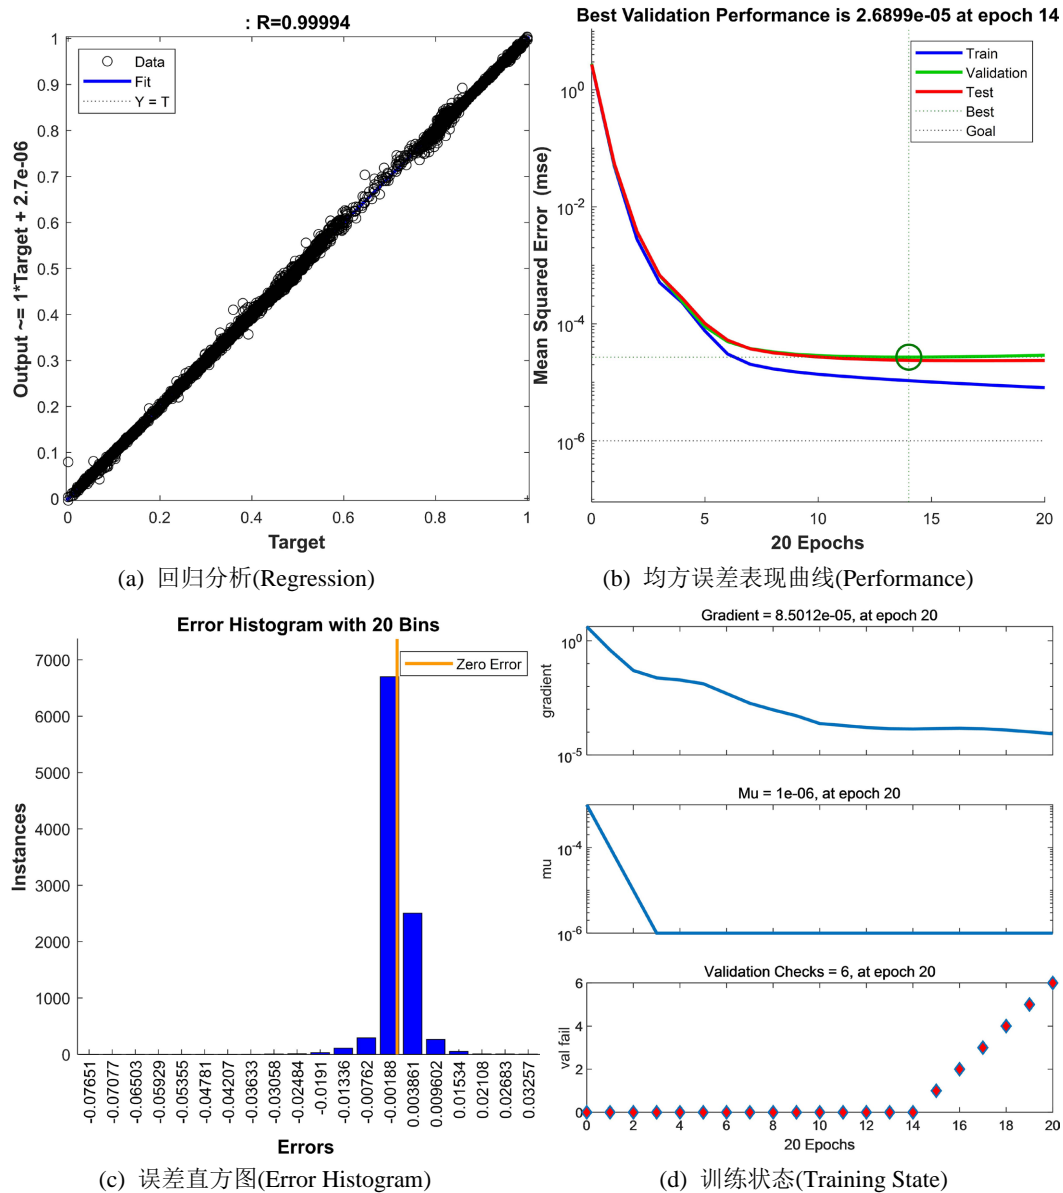


Figure 3. Training performance analysis of BP neural network
图 3. BP 神经网络训练效能分析

4.3. GA + BP 混合优化结果分析

4.3.1. 场景 A (主配协同 + 固定节点)

在固定节点模式下, 利用 GA + BP 混合最佳化演算法对 20 个预设光伏节点进行容量配置。运行结

果见表 1:

Table 1. Summary of optimal system indicators under fixed-node connection scenario

表 1. 固定节点接取场景下系统最佳化指标总表

评估指标	数值	约束限值	结论
光伏装机容量(MW)	5.8418	——	——
主网调峰缺口增量(MW)	2.9303	<3.0	合规
主网净负荷最大波动率(MW)	0.8826	<2.0	合规
节点电压范围(pu)	[0.9849, 1.037]	[0.95, 1.05]	合规
日均线损率(%)	1.2457	<8.0	合规

由表 2 可知, 所提算法结合 IEEE 33 节点系统的物理特性, 实现了分布式光伏容量的优化分配。这充分体现了该算法在满足系统全局约束的前提下, 可自动对局部节点电压安全进行限额保护, 保障配电网运行的安全性与稳定性。

Table 2. Optimal capacity allocation scheme for 20 fixed PV nodes

表 2. 20 个固定节点光伏装置容量最佳化分配方案

节点编号	容量/MW	节点编号	容量/MW	节点编号	容量/MW
2	0.2596	15	0.0238	25	0.5176
4	0.0589	16	0.0890	29	0.3005
5	0.5575	17	0.0039	30	0.5367
6	0.3599	18	0.1478	31	0.5843
7	0.1631	20	0.2565	32	0.3480
9	0.5946	22	0.2954	33	0.0442
14	0.3350	24	0.1655	/	/

4.3.2. 场景 B (考虑主网约束 + 全网寻优)

场景 B 下 IEEE 33 节点系统光伏承载力评估结果分布图如图 4 所示:




Figure 4. Distribution of PV hosting capacity evaluation results of IEEE 33-bus system under scenario B

图 4. 场景 B 下 IEEE 33 节点系统光伏承载力评估结果分布图

通过 GA + BP 算法进行全网址优化并引入主网约束后, 系统展现出了对局部电压约束的消解: 由表

3 所示, 通过优化 PV 接入位置, 可解决配网内部的电压越限问题, 此时最大电压仅为 1.0222 p.u., 远低于限值。

Table 3. Summary of PV optimization results of IEEE 33-bus system under scenario B

表 3. 场景 B 中 IEEE 33 节点系统 PV 优化结果总结

类别	类别	累积容量(MW)	说明
大容量节点(>0.5 MW)	29, 32	1.4109	系统核心消纳区域
中容量节点(0.1~0.3 MW)	2~10, 13, 15, 18~22	4.3642	均匀分布于主干与分支
低容量节点(<0.1 MW)	12, 23, 25, 27	0.1772	受限于电压波动
装机总容量	1~33	5.9523	GA + BP 优化后最大承载力

4.3.3. 场景 C (不考虑主网约束 + 全网寻优)

由表 4 可知, 该场景下分布式光伏总装机容量为 7.8900 MW。系统运行指标如下: 节点最大电压为 1.0237 p.u., 节点最小电压为 0.9850 p.u., 系统功率波动率为 1.1685 MW。但此时主网调峰缺口增量达到 4.2207 MW, 超出 3.0 MW 的约束上限, 主网难以承受。

Table 4. Summary of PV optimization results of IEEE 33-bus system under scenario C

表 4. 场景 C 中 IEEE 33 节点系统 PV 优化结果总结

统计指标	数值	结果分析
选定安装节点个数	29/32	剔除了 15、27、29 号节点以优化潮流分布
单点最大容量	0.5930 MW	位于 Bus 6 (靠近馈线中部的核心枢纽)
大容量区域(>0.5 MW)	2, 5, 6, 31, 33	呈现出“主干节点 + 支路末端的双重特征”
总装机容量	7.89 MW	远远大于固定节点装机容量

4.4. 优化结果的对比分析

通过对照实验来观察系统表现, 结果如表 5 所示:

Table 5. Comparison of system optimization results under different experimental scenarios

表 5. 不同场景下系统优化结果对比

实验场景	限制条件	评估装机总量	主网调峰缺口	全天发电量 (MW·h)	评估结论
场景 A	主配协同 + 固定节点	5.8418 MW	2.9303 MW	29.38 MW·h	调峰接近极限
场景 B	选址优化 + 主配协同	5.9523 MW	3.0000 MW	29.94 MW·h	全域最优解
场景 C	仅考虑配网限制 + 选址优化	7.8900 MW	4.2207 MW	39.69 MW·h	主网严重违规, 严重危害电网安全

4.4.1. 选址优化的必要性

对比场景 A 与 B 可知, 在均满足主配协同约束的前提下, 全网选址优化后的系统发电量由 29.38 MW·h 提升至 29.94 MW·h。尽管电量增幅仅为 1.9%, 但场景 B 的调峰缺口增量已精准收敛于 3 MW 约

束上限,表明主网调峰能力已成为限制承载力的核心瓶颈。此外,场景 B 呈现出的“多点微量”分散化布局,相较于场景 A 的集中接入,能更有效缓解局部电压越限,提升了配电网的安全运行裕度。

4.4.2. 主配协同的必要性

对比全网寻优下的场景 B 与 C 可见,若仅考虑配电网约束(场景 C),系统全天发电量虽高达 39.69 MW·h,但主网调峰缺口远超安全上限,给上级电网带来巨大风险。引入主配协同约束后(场景 B),发电量受全局安全边界限制收敛至 29.94 MW·h。这一显著差异证实,随着光伏渗透率提升,主网侧调节能力已成为承载力的刚性制约。因此,主配协同评估是保障全域运行安全、获取真实最大承载力的必要前提。

5. 结论

1) 在主配协同制约方面,主网调峰能力是制约分布式光伏承载力的关键因素。在完整引入主网调峰约束与净负荷最大波动率约束后,系统全天发电量精准收敛至安全边界内,有效避免了对上级电网造成调峰压力与运行风险。

2) 在接入空间分布方面,基于全网选址优化的光伏配置方案呈现出“多点微量”的分散化特征。这种空间分布上的优化能够有效消解局部节点的电压越限问题,在不增加主网调峰压力的前提下,最大程度地保障了配电网的安全稳定运行。

3) 局限性与展望:本研究目前主要基于 IEEE 33 节点这一小规模理想系统进行仿真分析,若将所提方法扩展至大规模真实电网,可能会面临维度灾难等计算挑战。未来的研究将致力于探索算法以适配大型电力网络。

基金项目

中国矿业大学(北京)大学生创新训练项目资助(202513063)和中央高校基本科研业务费资助。

参考文献

- [1] 陈喜军,艾琳,司俊龙. 2025 年中国光伏发电行业发展现状与展望[J]. 水力发电, 2026, 52(5): 1-6.
- [2] 周孝信,赵强,张玉琼,等. “双碳”目标下我国能源电力系统发展趋势分析: 绿电替代与绿氢替代[J]. 中国电机工程学报, 2024, 44(17): 6707-6721.
- [3] 卓振宇,张宁,谢小荣,等. 高比例可再生能源电力系统关键技术及发展挑战[J]. 电力系统自动化, 2021, 45(9): 171-191.
- [4] 何桂雄,曹年林,蒋利民,等. 风电富裕区域高载能负荷参与电网调峰研究[J]. 可再生能源, 2015, 33(4): 491-496.
- [5] 张宁,周天睿,段长刚,等. 大规模风电场接入对电力系统调峰的影响[J]. 电网技术, 2010, 34(1): 152-158.
- [6] 杨鸽星. 含分布式电源的新型配电网承载力评估及提升策略研究[D]: [硕士学位论文]. 福州: 福建理工大学, 2025.
- [7] 管廷辉,杨正强,杨志华,等. 新型电力系统下配网新能源承载力评估研究[J]. 电力设备管理, 2025(5): 157-159.
- [8] 王亚楠,郁华,曾恕程. 新能源并网下主动配电网新能源承载力评估指标研究[J]. 电力设备管理, 2025(3): 45-47.
- [9] 李敬如,白宇,王旭阳,等. 考虑主配协同的分布式光伏接入电网安全经济承载力计算方法[J]. 电力建设, 2025, 46(10): 113-121.
- [10] 张振伟,赵晋泉,韩佳兵,等. 考虑大量分布式电源接入的主配网协同优化控制[J]. 电网与清洁能源, 2017, 33(7): 110-115+122.
- [11] 张丽娜,周念成,徐军岳,等. 基于自适应代理模型的无功源协同规划方法[J]. 电工电能新技术, 2025, 44(9): 91-99.
- [12] 张艳,左雅,韩立芝,等. 计及多策略改进多目标遗传算法的电网智能规划[J]. 自动化技术与应用, 2026, 45(1): 41-45.

- [13] 冀东红, 张振, 王德文, 等. 基于改进 BP 神经网络的变电站集成式隔离断路器远程运维检测方法[J]. 微型电脑应用, 2025, 41(9): 142-145.
- [14] 左雅, 王华春, 周金双, 等. 基于神经网络模型的新型电力系统优化调度方法仿真[J]. 电气技术与经济, 2025(11): 110-113.
- [15] 裴宇豪, 张彤阳. 基于 BP 神经网络算法的变电站故障诊断方法[J]. 科技创新与生产力, 2025, 46(12): 100-102+105.