

DOI: 10.19783/j.cnki.pspc.241592

# 计及风光不确定性的综合能源系统容量配置双层优化

陆瑜<sup>1,2</sup>, 何兆磊<sup>3</sup>, 李琰<sup>1,2</sup>, 崔琳<sup>1</sup>, 徐天奇<sup>1,2</sup>

(1. 云南省高校电力信息物理融合系统重点实验室(云南民族大学电气信息工程学院), 云南 昆明 650504;  
2. 云南省无人自主系统重点实验室, 云南 昆明 650504; 3. 云南电网有限责任公司计量中心, 云南 昆明 650200)

**摘要:** 综合能源系统在能源结构转型中具有重要作用, 但风速和辐照强度的随机波动对系统容量配置与投资决策的影响显著, 现有方法难以兼顾波动适应性与全生命周期成本优化。为此, 提出了一种容量配置双层优化模型, 以全生命周期成本最小化为目标, 实现容量配置与运行调度的协调优化。上层优化通过遗传算法进行设备容量配置, 采用自适应核密度估计结合自回归模型生成精准的风光典型场景, 并基于 Wasserstein 距离进行场景削减, 提高场景代表性与计算效率。下层优化通过混合整数线性规划实现设备运行调度, 平衡经济性与鲁棒性, 并将调度结果传递至上层, 引导容量配置方案迭代更新, 形成双层交互优化机制。仿真结果表明, 与传统优化方法相比, 所提模型在降低全生命周期成本的同时, 提高了风光资源利用率和系统运行可靠性, 为综合能源系统优化配置提供了理论支撑与实践参考。

**关键词:** 综合能源系统; 风光不确定性; 双层优化; 随机优化; Wasserstein 距离

## Bi-level optimization for capacity allocation of integrated energy systems considering wind-solar uncertainty

LU Yu<sup>1,2</sup>, HE Zhaolei<sup>3</sup>, LI Yan<sup>1,2</sup>, CUI Lin<sup>1</sup>, XU Tianqi<sup>1,2</sup>

(1. Key Laboratory of Cyber-Physical Power System of Yunnan Colleges and Universities, School of Electrical and Information Engineering, Yunnan Minzu University, Kunming 650504, China; 2. Yunnan Key Laboratory of Unmanned Autonomous System, Kunming 650504, China; 3. Metering Center of Yunnan Power Grid Co., Ltd., Kunming 650200, China)

**Abstract:** Integrated energy systems play a crucial role in the energy transition, but the stochastic fluctuations of wind speed and solar irradiance significantly affect capacity planning and investment decisions. Existing methods struggle to balance adaptability and lifecycle cost optimization. To address this, a bi-level optimization model for capacity allocation is proposed, aiming to minimize the total lifecycle cost while coordinating optimization of capacity allocation and operation scheduling. In the upper-level optimization, a genetic algorithm is used for equipment capacity allocation. Typical wind and solar scenarios are generated using adaptive kernel density estimation combined with an autoregressive model, while Wasserstein distance ensures representativeness and computational efficiency through scenario reduction. The lower-level optimization employs mixed-integer linear programming for operation scheduling, balancing economic efficiency and robustness. The scheduling results are then fed back to the upper level, guiding iterative updates of capacity allocation and forming a bi-level interactive optimization loop. Simulation results show that, compared to traditional optimization methods, the proposed model reduces total lifecycle costs while improving wind and solar utilization and system reliability. This provides both theoretical support and practical reference for the optimal planning of integrated energy systems.

This work is supported by the National Natural Science Foundation of China (No. 62062068).

**Key words:** integrated energy system; wind-solar uncertainty; bi-level optimization; stochastic optimization; Wasserstein distance

**基金项目:** 国家自然科学基金项目资助(62062068); 云南省中青年学术和技术带头人后备人才项目资助(202305AC160077); 云南省教育厅科学研究基金项目资助(2023J0587)

## 0 引言

随着全球能源结构转型加速,综合能源系统(integrated energy system, IES)逐渐成为提升能源利用效率并推动实现“双碳”目标的关键<sup>[1-3]</sup>。IES依托能量枢纽连接各类能源网络与转换设备,以提升能源利用效率和系统灵活性,同时满足多样化用户需求,为构建低碳高效的现代能源体系提供技术支撑<sup>[4-6]</sup>。随着能源耦合程度的加深以及系统设备规模的扩大,尤其在高比例风电和光伏接入的情况下,能源供应和设备所固有的不确定性和波动性对系统的稳定运行提出了更高要求<sup>[7]</sup>。因此,如何在保障系统经济性和可靠性的前提下,有效应对可再生能源的不确定性,已成为关键挑战。此外,在总成本预算有限的条件下,通过优化配置 IES 各设备容量以提升系统的鲁棒性,增强对不确定性波动的适应能力,仍有待深入研究<sup>[8]</sup>。

IES 凭借其多能互补特性,可有效平抑可再生能源发电的波动性。然而,这需要合理的容量配置,否则会带来经济损失和高维护成本<sup>[9]</sup>。文献[10]提出一种实时优化方法建立瞬态能量分析模型,并基于 3E(efficiency, economy, environment) 和 3S(self-balancing, sufficiency, stability)指标优化系统性能。此方法在优化系统性能方面效果显著,但对系统规模、储能比例和持续时间等参数有较高的依赖性。文献[11]通过双层结构设计的联合优化框架,协调电价响应与容量配置、调度策略,在源负荷波动下平衡经济性和灵活性,显著提升需求响应与容量配置的匹配度。文献[12]基于 IES 典型结构优化光储设备的配置,结合冷-热-电-气能流模型设计了全生命周期碳排放奖惩机制,成功降低碳排放并提高经济性。文献[13]利用多阶段规划和 Pareto 解集策略优化供能配置,适用于不同园区的场景,显著提升了经济性,降低了碳排放,并提高了新能源利用比例。文献[14]提出的配置-运行一体化闭环优化方法,通过闭环控制有效降低了动态热、电偏差,并在高比例可再生能源接入时提高了系统的稳定性,但相应的经济成本有所增加。综上,文献[10-14]有关综合能源系统优化配置的研究中,普遍存在对风光发电等可再生能源的不确定性考虑不足,动态运行特性与全生命周期成本的优化分析不够全面的问题,限制了其方法的适用性和实际效果。

在不确定条件下优化 IES 配置,常用的方法包括随机优化<sup>[15]</sup>、鲁棒优化<sup>[16]</sup>、分布鲁棒优化<sup>[17]</sup>和区间优化等。文献[18]利用随机优化,将太阳辐射和风速的不确定性进行概率建模,假设其服从特定分

布(Beta 分布与 Weibull 分布),并通过蒙特卡洛采样和同步回代算法进行简化和双层优化,但该方法存在一定的局限性,即对太阳辐照和风速的概率分布假设较为单一,难以全面表征实际场景中的复杂特性,从而对建模的准确性与适用性产生一定影响。文献[19]提出的多目标随机鲁棒优化方法,通过用户、乡镇和用户-乡镇交互的三级系统,在技术、经济与环境三重目标协同下优化设备配置。然而,其多层建模使得计算复杂度高,从而限制了其适用性。文献[20]结合海上风电制氢的分布鲁棒低碳优化策略,构建源荷不确定性模型,利用强对偶理论实现快速求解,提升低碳效益,但该方法主要适用于海上风电,对其他新能源适应性不足。文献[21]提出的区间优化方法通过共享储能和精细化需求响应提升能源系统的不确定性适应能力。该方法利用区间数描述不确定性并优化负荷响应,实现协同优化。尽管能提高储能利用率和经济性,但计算复杂度高,依赖区间参数的设定,且优化结果的可操作性受限,方案稳定性不足。以上方法在应对风光发电等可再生能源的不确定性时,存在计算复杂度较高、适用范围有限以及优化结果的可操作性不足等问题。

针对风光发电波动性和不确定性对综合能源系统优化配置的影响,本文提出了一种改进的双层优化模型,旨在提升系统对不确定性波动的适应能力与全生命周期的经济性。首先通过自适应核密度估计结合自回归模型生成更加精准的风光发电场景,并引入基于 Wasserstein 距离的场景削减方法,在减少计算复杂度的同时保留场景的代表性。在此基础上,优化储能设备和能源转换设备的配置,提升综合能源系统在复杂环境下的稳定性与鲁棒性,实现对风光发电资源的高效利用和全生命周期成本的协同优化。

## 1 综合能源系统架构与建模

### 1.1 IES 系统构架

本文针对包含电、热、冷、气多类异质能源的 IES 展开研究,其内部的能量流动如图 1 所示。IES 中电、热、冷、气各类能源子系统包括能源供应、能量转换、能量消费等环节<sup>[22]</sup>。能源供应部分包括上级电网、上级气网、风机(wind turbine, WT)、光伏(photovoltaic, PV);能量转换设备包括冷热电联产机组(combined cooling, heating and power, CCHP)、燃气锅炉(gas boiler, GB)、P2G(power to gas);储能部分包括储气罐(gas storage tank, GST)、蓄热槽(thermal storage tank, TST)、电池储能(battery energy storage, BES)。

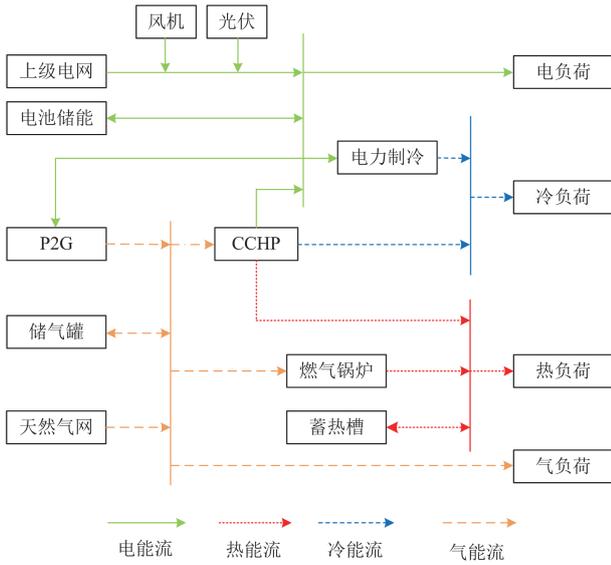


图1 综合能源系统架构

Fig. 1 Architecture of integrated energy system

## 1.2 系统设备数学模型

### 1.2.1 光伏

PV系统的电输出功率主要由照射到PV单元表面的辐照强度及其物理特性等因素共同决定。PV的输入输出关系<sup>[21]</sup>如式(1)所示。

$$P'_{PV} = f_{PV} E_{PV} \left( \frac{G_T}{G_{T,ST}} \right) \quad (1)$$

式中： $P'_{PV}$ 为 $t$ 时刻PV的电输出功率； $f_{PV}$ 为光伏系统的功率降额因数，用于表征因尘垢和老化等因素引起的输出功率下降，通常取值为0.9； $E_{PV}$ 为PV的峰值容量； $G_T$ 为实际辐照强度； $G_{T,ST}$ 表示标准测试条件下的辐照强度，通常取 $1 \text{ kW/m}^2$ 。

### 1.2.2 风机

WT的电输出功率主要取决于风速。WT的输入输出关系<sup>[4]</sup>如式(2)所示。

$$P'_{WT} = \begin{cases} 0 & v \leq v_{in} \text{ or } v \geq v_{out} \\ P_r \frac{v^3 - v_{in}^3}{v_r^3 - v_{in}^3} & v_{in} < v < v_r \\ P_r & v_r \leq v \leq v_{out} \end{cases} \quad (2)$$

式中： $P'_{WT}$ 为 $t$ 时刻WT的电输出功率； $P_r$ 为WT的额定功率； $v$ 为WT的实际风速； $v_r$ 为WT的额定风速，取值为 $13.5 \text{ m/s}$ ； $v_{in}$ 为WT的切入风速，取值为 $3 \text{ m/s}$ ； $v_{out}$ 为WT的切出风速，取值为 $25 \text{ m/s}$ 。

### 1.2.3 冷热电联产模型

CCHP通过消耗天然气生产电能、热能和冷能。CCHP的输入输出关系如式(3)所示。

$$\begin{cases} P'_{cchp,elec} = \eta_{cchp,elec} V'_{cchp,gas} H_{gas} / \nu \\ E'_{cchp,heat} = \eta_{cchp,heat} V'_{cchp,gas} H_{gas} / \nu \\ E'_{cchp,cold} = \eta_{cchp,cold} E'_{cchp,heat} \\ V'_{cchp,min} \leq V'_{cchp,gas} \leq V'_{cchp,max} \end{cases} \quad (3)$$

式中： $P'_{cchp,elec}$ 、 $E'_{cchp,heat}$ 、 $E'_{cchp,cold}$ 分别为 $t$ 时刻CCHP设备的电、余热、冷输出功率； $V'_{cchp,gas}$ 为 $t$ 时刻CCHP设备消耗的天然气的量； $H_{gas}$ 为天然气低位热值； $\nu$ 为电热转换系数； $V'_{cchp,max}$ 、 $V'_{cchp,min}$ 分别为输入CCHP天然气的上、下限； $\eta_{cchp,elec}$ 、 $\eta_{cchp,heat}$ 分别为燃气轮机的电、余热效率； $\eta_{cchp,cold}$ 为吸收式制冷设备的冷输出效率。为简化CCHP模型，本文忽略了CCHP变工况特性。

### 1.2.4 电转气模型

P2G通过消耗电能来生产气能，输入输出关系如式(4)所示。

$$\begin{cases} V'_{P2G,gas} = \frac{\eta_{P2G} P'_{P2G,elec}}{H_{gas}} \\ P'_{P2G,elec,min} \leq P'_{P2G,elec} \leq P'_{P2G,elec,max} \end{cases} \quad (4)$$

式中： $P'_{P2G,elec}$ 为输入P2G的电功率； $V'_{P2G,gas}$ 为 $t$ 时刻P2G的输出气量； $\eta_{P2G}$ 为P2G的能量转换效率； $P'_{P2G,elec,max}$ 、 $P'_{P2G,elec,min}$ 分别为输入P2G的电功率上、下限。

### 1.2.5 电制冷模型

EC通过消耗电能来制冷，模型如式(5)所示。

$$\begin{cases} E'_{ec,cold} = \eta_{ec,cold} P'_{ec,elec} \\ P'_{ec,elec,min} \leq P'_{ec,elec} \leq P'_{ec,elec,max} \end{cases} \quad (5)$$

式中： $E'_{ec,cold}$ 为 $t$ 时刻EC输出的冷功率； $P'_{ec,elec}$ 为 $t$ 时刻输入EC的电功率； $\eta_{ec,cold}$ 为EC的能量转换效率； $P'_{ec,elec,max}$ 、 $P'_{ec,elec,min}$ 分别为输入EC的电功率上、下限。

### 1.2.6 储能模型<sup>[23]</sup>

$$V'_i = \eta_i V_i^{t-1} + \left( \eta_{i,char} P'_{i,char} - \frac{P'_{i,dischar}}{\eta_{i,dischar}} \right) \Delta t \quad (6)$$

式中： $V'_i$ 为 $t$ 时刻第 $i$ 个储能设备的剩余容量； $\eta_i$ 为第 $i$ 个储能设备的能量损失系数； $P'_{i,char}$ 、 $P'_{i,dischar}$ 分别为 $t$ 时刻第 $i$ 个储能设备的充、放能功率； $\eta_{i,char}$ 、 $\eta_{i,dischar}$ 分别为第 $i$ 个储能设备的充、放能效率； $\Delta t$ 为系统调度间隔，本文取 $1 \text{ h}$ 。

### 1.2.7 燃气锅炉模型

GB通过消耗天然气能来制热，模型如式(7)所示。

$$\begin{cases} E'_{\text{gb,heat}} = \eta_{\text{gb}} V'_{\text{gb,gas}} H_{\text{gas}} / \nu \\ V'_{\text{gb,gas,min}} \leq V'_{\text{gb,gas}} \leq V'_{\text{gb,gas,max}} \end{cases} \quad (7)$$

式中:  $V'_{\text{gb,gas}}$  为  $t$  时刻输入 GB 的天然气的量;  $E'_{\text{gb,heat}}$  为  $t$  时刻 GB 输出的热能;  $\eta_{\text{gb}}$  为 GB 的能量转换效率;  $V'_{\text{gb,gas,max}}$ 、 $V'_{\text{gb,gas,min}}$  分别为输入 GB 的天然气的量上、下限。

## 2 风光场景分析

### 2.1 AKDE-AR 的风光场景生成

在实际应用中, 风速和辐照强度通常不遵循特定的分布。核密度估计(kernel density estimation, KDE)作为一种非参数方法<sup>[24]</sup>, 通过核函数对数据分布进行平滑处理, 能够更灵活地逼近实际风速与辐照强度的概率分布, 显著增强模型对不确定性的刻画能力。对于给定的序列数据集  $Q$ , 本文采用高斯核函数, 则 KDE 模型表达式如式(8)所示。

$$\hat{f}(q|Q) = \frac{1}{Bh\sqrt{2\pi}} \sum_{b=1}^B \exp\left(-\frac{(q-q_b)^2}{2h^2}\right) \quad (8)$$

式中:  $Q = \{q_1, q_2, \dots, q_B\}$  为观测数据集;  $q$  为待估计点;  $q_b$  为第  $b$  个数据样本点;  $B$  为样本总数;  $h$  为带宽参数, 决定了核函数的尺度。当  $h$  较小时,  $\hat{f}(q|Q)$  能更精确地描绘数据的细节, 但可能会导致过拟合; 而当  $h$  较大时,  $\hat{f}(q|Q)$  则更加平滑, 但可能会导致欠拟合。选择合适的带宽, 在高密度区域采用较小值以捕捉细节特征, 在低密度区域则使用较大值以抑制噪声干扰。因此, 本文采用自适应核密度估计<sup>[25]</sup>(adaptive kernel density estimation, AKDE)方法对风速和辐照强度的不确定性进行概率密度估计, 并利用时间序列交叉验证优化带宽参数<sup>[26]</sup>, 以最大化对数似然值, 最优带宽表达式如式(9)所示。

$$\hat{h} = \arg \max_{h \in \mathcal{H}} \left( \frac{1}{A} \sum_{\lambda=1}^A \frac{1}{B_{\lambda}} \sum_{q \in Q_{\text{val},\lambda}} \ln \hat{f}_h(q|Q_{\text{train},\lambda}) \right) \quad (9)$$

式中:  $\mathcal{H}$  为候选带宽的搜索空间;  $A$  为交叉验证的折数;  $B_{\lambda}$  为第  $\lambda$  折  $Q_{\text{val},\lambda}$  数中的元素数量;  $Q_{\text{train},\lambda}$ 、 $Q_{\text{val},\lambda}$  分别为第  $\lambda$  折的训练集、验证集;  $\hat{f}_h(q|Q_{\text{train},\lambda})$  为给定第  $\lambda$  折训练集数据  $Q_{\text{train},\lambda}$  的情况下, 使用带宽  $h$  估计的核密度函数, 最优带宽  $\hat{h}$  使得平均对数似然分数达到最大。该模型采用时间序列交叉验证自适应带宽选择方法, 从而能够更精确地捕捉不同数据序列的分布变化。

自回归模型(autoregressive model, AR)是用于描述时间序列自相关性的经典模型。设序列数据为

$X_{\tau}$ , 本文采用最小二乘法估计 AR 模型参数, 则模型如式(10)所示。

$$\begin{cases} X_{\tau} = \alpha + \phi X_{\tau-1} + \varepsilon_{\tau} \\ \hat{\phi} = \frac{\sum_{\tau=2}^{\Gamma} (X_{\tau} - \bar{X})(X_{\tau-1} - \bar{X})}{\sum_{\tau=2}^{\Gamma} (X_{\tau-1} - \bar{X})^2} \\ \hat{\alpha} = \bar{X} - \hat{\phi} \bar{X}_{\tau-1} \\ \hat{\sigma} = \sqrt{\frac{1}{N-1} \sum_{\tau=2}^{\Gamma} (X_{\tau} - \hat{\phi} X_{\tau-1} - \hat{\alpha})^2} \end{cases} \quad (10)$$

式中:  $\alpha$  为偏置项,  $\hat{\alpha}$  为偏置项估计值;  $\phi$  为自回归系数, 满足  $|\phi| < 1$ , 以保证过程的平稳性;  $\hat{\phi}$  为自回归系数估计值;  $\varepsilon_{\tau}$  为均值为 0、方差为  $\sigma^2$  的白噪声, 用于引入随机扰动;  $\hat{\sigma}$  为噪声标准差的估计值;  $\Gamma$  为样本总数;  $\bar{X}$  和  $\bar{X}_{\tau-1}$  分别为  $X$  和  $X_{\tau-1}$  的样本均值。

拉丁超立方抽样(Latin hypercube sampling, LHS)是一种高效的抽样方法, 用于在多维空间中生成均匀的样本点<sup>[28]</sup>, 保证全面覆盖一般场景和极端场景。设  $U = \{u^j | j=1, 2, \dots, G\}$  为在区间[0,1]内生成的  $G$  个 LHS 样本, 随后将均匀分布的 LHS 样本转换为场景实际值, 具体表达式如式(11)所示。

$$s_t^j = \begin{cases} F_t^{-1} u_t^j, t=1 \\ F_t^{-1} \left[ \Phi \left( \frac{\hat{s}_t^j - \alpha_t - \phi s_{t-1}^j}{\sigma_t} \right) \right], t>1 \end{cases} \quad (11)$$

式中:  $\hat{s}_t^j$  为  $t$  时刻的场景预测值;  $F_t^{-1}$  为 AKDE 模型的累积分布函数的逆;  $u_t^j$  为第  $j$  个样本在  $t$  时刻的均匀分布值;  $\Phi$  为标准正态分布的累积分布函数;  $\alpha_t$  为  $t$  时刻的偏置项;  $\sigma_t$  为  $t$  时刻的误差项的标准差, 通过结合 AR 的动态特性和 AKDE 的静态分布特性, AKDE-AR-LHS 模型可以生成更符合实际的原始场景集  $S = \{s_j | j=1, 2, \dots, G\}$ ,  $s_j$  表示第  $j$  个完整时间序列场景, 由  $s_t^j$  构成。

### 2.2 基于 Wasserstein 距离的风光场景削减

尽管通过大量生成场景增强了对不确定性特征的刻画, 但也显著增加了优化模型的计算复杂度, 并可能弱化关键特征的表达。因此, 需要通过场景削减提取具有代表性的场景, 在降低计算复杂性的同时, 确保准确保留不确定性特征。

本文目标是找到一个具有代表性的场景集合  $S' \subseteq S$ , 使得  $|S'| = A$ , 本文提出了一种基于 Wasserstein 距离<sup>[28]</sup>的风光场景削减方法, 该方法通

过最大化场景多样性, 以提高场景集在能源系统优化的应用效果。定义 Wasserstein 距离矩阵  $W_D$  如式(12)所示。

$$W_D = [w_D(s_{a1}, s_{a2})]_{a1, a2=1}^G \quad (12)$$

式中:  $w_D(s_{a1}, s_{a2})$  表示场景  $s_{a1}$  与场景  $s_{a2}$  之间的 Wasserstein 距离, 显然  $w_D(s_{a1}, s_{a1}) = 0$ , 且  $W_D$  为对称矩阵。定义场景多样性分数  $\text{score}(s_j)$  如式(13)所示。

$$\begin{cases} \text{score}(s_j) = \beta w_D^{\min}(s_j) - (1 - \beta)c(s_j) \\ w_D^{\min}(s_j) = \min_{s'_i \in S'} w_D(s_j, s'_i) \\ c(s_j) = \frac{1}{|S'|} \sum_{s'_i \in S'} w_D(s_j, s'_i) \end{cases} \quad (13)$$

式中:  $\beta$  为多样性因子, 取值为[0,1];  $s'_i$  为典型场景集  $S'$  中的场景;  $|S'|$  为典型场景集中的场景数量;  $w_D^{\min}(s_j)$  为最小距离, 其反映了  $s_j$  与典型场景集中最近场景的距离;  $c(s_j)$  为平均相似性分数, 其提供了  $s_j$  与典型场景集平均距离的度量。这两种度量被联合用于评估各场景的得分, 以选择哪些纳入典型场景集, 其目的是为了最大化该集合的多样性与代表性。基于 Wasserstein 距离选择多样性最大的典型场景集流程如图 2 所示。

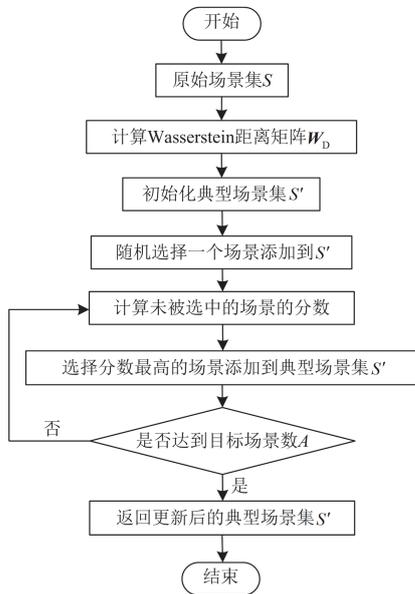


图 2 场景削减流程图

Fig. 2 Scenario reduction flowchart

场景削减流程如下。

1) 根据 AKDE-AR-LHS 模型, 即式(8)、式(10)和式(11)生成风速和辐照强度原始场景集  $S$ 。

2) 根据式(12)计算场景集内每对场景之间的 Wasserstein 距离, 并生成距离矩阵  $W_D$ 。

3) 初始化典型场景集  $S'$ , 并从原始场景集  $S$  随机选择一个场景  $s_j$  添加到典型场景集  $S'$  中。

4) 对于每个未被选中的场景  $s_j$ , 计算其与  $S'$  中所有场景的最小距离  $w_D^{\min}(s_j)$  和平均相似性分数  $c(s_j)$ , 从而计算场景  $s_j$  多样性分数, 如式(13)所示。

5) 根据贪心策略, 选择多样性分数最高的场景  $s_j$  并将其添加到  $S'$  中。

6) 若  $S'$  中的场景数量达到目标场景数  $A$ , 则返回更新后的典型场景集  $S'$ 。否则, 重复步骤 4) 和步骤 5), 直到达到目标场景数。

7) 返回最终选择的代表性典型场景集  $S'$ 。

### 3 双层优化配置模型

#### 3.1 上层规划

##### 3.1.1 目标函数

为实现系统经济低碳运行, 从使系统全生命周期成本最小化的角度构建优化目标函数, 如式(14)所示, 上层规划决策变量为各类能源设备的安装容量。

$$\min F_C = \sum_{x', y'} C_{\text{inv}} + C_{\text{ope}} \quad (14)$$

式中:  $F_C$  为全生命周期综合成本;  $x'$ 、 $y'$  分别为包含模型所涉及的连续型变量和二元变量;  $C_{\text{inv}}$  为系统各设备的投资成本;  $C_{\text{ope}}$  为下层模型中的系统年运行费用。各设备的总投资成本  $C_{\text{inv}}$  的计算方式如式(15)所示。

$$C_{\text{inv}} = \sum_{k=1}^K c_{\text{inv},k} \Omega_{r,k} \frac{r(1+r)^Y}{(1+r)^Y - 1} \quad (15)$$

式中:  $k$  为设备类型;  $K$  为设备类型数目;  $c_{\text{inv},k}$  为设备  $k$  的单位容量投资成本;  $\Omega_{r,k}$  为设备  $k$  的安装容量;  $r$  为年利率, 本文取值 5%;  $Y$  为规画年限, 本文预计规划 20 年。

##### 3.1.2 约束条件

鉴于实际场地条件、投资总额等因素, 需对设备的安装容量和初始投资予以限制, 如式(16)所示。

$$\begin{cases} C_k^{\min} \leq C_k \leq C_k^{\max} \\ \sum_k C_k^{\text{cost}} C_k \leq I_{\max} \end{cases} \quad (16)$$

式中:  $C_k^{\max}$ 、 $C_k^{\min}$  分别为设备  $k$  的最大、最小安装容量;  $C_k$  为设备  $k$  的实际安装容量;  $C_k^{\text{cost}}$  为设备  $k$  的安装成本;  $I_{\max}$  总投资预算。

#### 3.2 下层运行

##### 3.2.1 目标函数

下层运行模型以 IES 的年运行费用  $C_{\text{ope}}$  最低为

优化目标, 如式(17)所示。

$$\min C_{\text{ope}} = C_{\text{buy}} + C_{\text{om}} + C_{\text{carbon}} + C_{\text{cur}} \quad (17)$$

式中:  $C_{\text{buy}}$  为系统购能费用;  $C_{\text{om}}$  为系统各设备的运行维护成本;  $C_{\text{carbon}}$  为系统碳排放成本;  $C_{\text{cur}}$  为系统弃风弃光惩罚成本。

#### 1) 系统购能费用

$$C_{\text{buy}} = \sum_{s'=1}^{S'} \sum_{t=1}^T (P_{\text{elec}}^t P_{\text{grid,elec}}^t + P_{\text{gas}}^t V_{\text{grid,gas}}^t) \Delta t \quad (18)$$

式中:  $T$  为系统调度周期, 本文取 24 h;  $P_{\text{elec}}^t$ 、 $P_{\text{gas}}^t$  分别为  $t$  时刻从上级电网、气网购入电能、气量价格;  $P_{\text{grid,elec}}^t$ 、 $V_{\text{grid,gas}}^t$  分别为  $t$  时刻从上级电网、气网购入电能、气量。此外, 本文暂不考虑 IES 向电网售电。

#### 2) 运行维护成本

$$C_{\text{om}} = \sum_{s'=1}^{S'} \sum_{t=1}^T \left( \sum_u p_{\text{cchp},l}^t P_{\text{cchp},l}^t + \sum_e p_e^t P_e^t + \sum_g p_g^t |P_g^t| \right) \quad (19)$$

式中:  $u$  表示 CCHP 设备的电、冷、热能量流;  $e$  表示 WT、PV、GB、EC、P2G 设备;  $g$  表示储电、储热、储气设备;  $p_{\text{cchp},l}^t$ 、 $P_{\text{cchp},l}^t$  分别为  $t$  时刻 CCHP 设备电、冷、热输出的单位运维成本及功率;  $p_e^t$ 、 $P_e^t$  分别为  $t$  时刻 WT、PV、GB、EC、P2G 设备单位运维成本及输出功率;  $p_g^t$ 、 $|P_g^t|$  分别为  $t$  时刻储电、储热、储气设备单位运维成本及输出功率。

#### 3) 碳排放成本

$$C_{\text{carbon}} = p_{\text{carbon}} \sum_{s'=1}^{S'} \sum_{t=1}^T \left[ (\varepsilon_{\text{elec}} P_{\text{grid,elec}}^t + \varepsilon_{\text{gas}} V_{\text{grid,gas}}^t) \right] \quad (20)$$

式中:  $p_{\text{carbon}}$  为碳税价格;  $\varepsilon_{\text{elec}}$ 、 $\varepsilon_{\text{gas}}$  分别为电能和天然气的碳排放因子。

#### 4) 弃风弃光惩罚成本

$$C_{\text{cur}} = p_{\text{cur}} \sum_{s'=1}^{S'} \sum_{t=1}^T (P_{\text{WT,th}}^t - P_{\text{WT}}^t + P_{\text{PV,th}}^t - P_{\text{PV}}^t) \quad (21)$$

式中:  $p_{\text{cur}}$  为弃风弃光单位功率成本;  $P_{\text{WT,th}}^t$ 、 $P_{\text{PV,th}}^t$  分别为  $t$  时刻理论风、光完全出力。

### 3.2.2 约束条件

#### 1) 功率平衡约束

IES 中电、热、冷、气能量流平衡如式(22)所示。

$$\begin{cases} P_{\text{WT}}^t + P_{\text{PV}}^t + P_{\text{cchp,elec}}^t + P_{\text{BES,dischar}}^t + P_{\text{grid,elec}}^t = \\ P_{\text{load,elec}}^t + P_{\text{P2G,elec}}^t + P_{\text{ec,elec}}^t + P_{\text{BES,char}}^t \\ V_{\text{P2G,gas}}^t + V_{\text{GST,dischar}}^t + V_{\text{grid,gas}}^t = \\ V_{\text{load,gas}}^t + V_{\text{cchp,gas}}^t + V_{\text{gb,gas}}^t + V_{\text{GST,char}}^t \\ E_{\text{cchp,heat}}^t + E_{\text{gb,heat}}^t + E_{\text{TST,dischar}}^t = E_{\text{load,heat}}^t + E_{\text{TST,char}}^t \\ E_{\text{cchp,cold}}^t + E_{\text{ec,cold}}^t = E_{\text{load,cold}}^t \end{cases} \quad (22)$$

式中:  $P_{\text{load,elec}}^t$ 、 $V_{\text{load,gas}}^t$ 、 $E_{\text{load,heat}}^t$ 、 $E_{\text{load,cold}}^t$  分别为  $t$  时刻电、气、热、冷负荷;  $P_{\text{BES,char}}^t$ 、 $P_{\text{BES,dischar}}^t$  分别为  $t$  时刻电池储电、供电量;  $V_{\text{GST,char}}^t$ 、 $V_{\text{GST,dischar}}^t$  分别为  $t$  时刻储气罐储气、供气量;  $E_{\text{TST,char}}^t$ 、 $E_{\text{TST,dischar}}^t$  分别为  $t$  时刻蓄热槽储热、供热量;  $P_{\text{grid,elec}}^t$ 、 $V_{\text{grid,gas}}^t$  分别为  $t$  时刻上级购电、购气量。

#### 2) 能量转换设备约束

$$\begin{cases} \delta_k^t R_{k,\min} \leq P_k^t \leq \delta_k^t R_{k,\max} \\ P_{k,\min}^t \leq P_k^t \leq P_{k,\max}^t \end{cases} \quad (23)$$

式中:  $P_k^t$  为设备  $k$  在  $t$  时刻的实际出力;  $R_{k,\max}$ 、 $R_{k,\min}$  分别为设备  $k$  最大、最小负荷率;  $P_{k,\max}^t$ 、 $P_{k,\min}^t$  分别为  $t$  时刻设备  $k$  的额定功率上、下限;  $\delta_k^t$  为设备运行状态的二元变量, 设备  $k$  在  $\delta_k^t = 1$  时投入运行, 在  $\delta_k^t = 0$  时退出运行。

#### 3) 网络约束

为了保证系统稳定运行, 且由于传输网络的限制, IES 与上级电网和上级气网的交互功率应在合理的范围内。

$$\begin{cases} 0 \leq P_{\text{grid,elec}}^t \leq P_{\text{grid,elec,max}}^t \\ 0 \leq V_{\text{grid,gas}}^t \leq V_{\text{grid,gas,max}}^t \end{cases} \quad (24)$$

式中:  $P_{\text{grid,elec,max}}^t$ 、 $V_{\text{grid,gas,max}}^t$  分别为  $t$  时刻 IES 从上级电网、气网进行购电和购气的流通上限。

### 3.3 求解算法

#### 3.3.1 双层优化策略

本文的双层优化配置算法流程如图 3 所示, 通过结合上层遗传算法与下层混合整数线性规划 (mixed-integer linear programming, MILP) 模型, 实现综合能源系统容量配置的全局最优。算法流程包括初始场景生成与筛选、上层优化求解、下层精确评估, 通过迭代交互不断接近最优解。

初始场景生成阶段采用 AKDE 结合 AR, 并利用 LHS 生成包含风速与辐照强度不确定性的初始场景集。为提高计算效率, 使用 Wasserstein 距离削减场景集, 形成典型场景集  $S'$ 。

上层优化采用遗传算法, 以全生命周期成本最小化为目标, 采用实数编码表示设备容量配置。算法通过初始化种群、评估适应度值、选择优良个体, 并结合拉普拉斯交叉与幂变异生成新方案。每个候选方案被编码为个体, 并输入下层进行评估。

下层评估基于典型场景建立 MILP 模型, 计算运行维护、购能、碳排放及弃风弃光损失成本。使用 Cplex 求解器进行求解, 并将计算得到的各项成

本反馈至上层作为适应度值, 指导遗传算法进化。

在上下层交互过程中, 上层根据适应度值进行锦标赛选择, 保留优良个体, 并结合交叉与变异生成新种群。该过程持续迭代, 直至适应度值收敛或达到最大迭代次数。最终, 算法输出的设备容量配置方案在典型场景下实现经济性与性能的最优平衡。

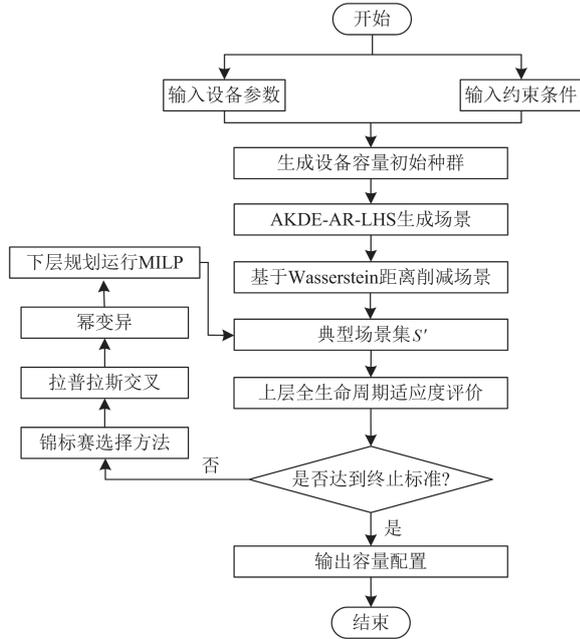


图3 双层优化配置算法流程图

Fig. 3 Flow chart of the bi-level optimal configuration algorithm

### 3.3.2 实数编码遗传算法流程

如图3所示, 本文采用实数编码遗传算法 (mixed integer-laplace crossover and power mutation, MI-LXM)<sup>[29]</sup>求解混合整数优化问题。该算法的核心步骤包括初始种群生成、适应度评估、个体选择、交叉操作、变异操作以及终止条件的判定。具体过程如下。

1) 种群初始化: 初始种群的构建需保证其包含一个可行解, 以确保算法在初始阶段能够具备一定质量的解基础。同时, 其余种群个体通过随机生成, 以增加种群的多样性。具体生成方法为

$$z_m^1 = z_{lb}^1 + U_{init,m} \cdot (z_{ub}^1 - z_{lb}^1) \quad (25)$$

式中:  $z_m^1$  为初始种群中的第  $m$  个个体;  $z_{ub}^1$ 、 $z_{lb}^1$  分别为初始种群搜索空间的上、下限;  $U_{init,m}$  为区间  $[0,1]$  内的一组随机数, 其维度与种群维度相同。

2) 适应度评估: 对于每一代种群, 代入 MILP 模型进行优化求解, 以评估其在典型场景下的成本期望值, 即对应个体的适应度函数值, 可表示为

$$\mathbb{E}[f_s(z, \xi)] = \frac{1}{|S'|} \sum_{x,y} \min_{x,y} f_s(z, x, y, \xi) \quad (26)$$

式中:  $z$  表示设计过程中决定的连续型变量;  $x$  和  $y$  分别为运行过程中涉及的连续型变量与二元变量;  $f_s$  为考虑不确定性的成本函数;  $\xi$  为不确定性参数, 包括风速、太阳辐照强度。

对于不满足约束条件的情况, 采用无参数惩罚函数对个体的适应度进行修正, 从而得到第  $m$  个个体  $z_m$  的适应度值  $\text{fitness}(z_m)$ , 如式(27)所示。

$$\text{fitness}(z_m) = \begin{cases} f(z_m), & z_m \text{ 为可行解} \\ f_{\text{worst}} + \frac{1}{N} \sum_{n=1}^N \varphi_n(z_m), & z_m \text{ 为不可行解} \end{cases} \quad (27)$$

式中:  $f_{\text{worst}}$  为当前种群中最差可行解的目标函数值, 若种群中无可行解, 则令  $f_{\text{worst}} = 0$ , 从而提升对不可行解的鲁棒性;  $N$  为约束条件的总数;  $\varphi_n(z_m)$  为第  $n$  条约束未满足部分的惩罚值。

3) 选择: 为平衡局部优化与全局搜索能力, 采用锦标赛选择策略从当前种群中筛选个体构建下一代, 表示为

$$Z_{\text{new}} = \{z^* | z^* = \arg \max \text{fitness}(Z_n), L \subseteq Z, |L| = e\} \quad (28)$$

式中:  $Z_{\text{new}}$  为通过锦标赛选择策略构建的新种群, 包含若干个体;  $z^*$  为每次锦标赛选择中, 随机抽取的子集  $L$  中适应度值最大的个体;  $e$  表示每次锦标赛选择中, 从种群  $Z$  中随机抽取的个体数量。

4) 交叉: 拉普拉斯交叉利用拉普拉斯分布的随机扰动, 在父代个体间生成新解, 既增强局部搜索能力, 又保持全局探索性。具体实现步骤如下。

首先, 生成均匀分布随机数  $\mu_m \in [0,1]$ , 从而得到满足拉普拉斯分布的随机数  $\gamma_m$ , 表达式为

$$\gamma_m = \begin{cases} a - d \ln(\mu_m), & \mu_m \leq 1/2 \\ a + d \ln(\mu_m), & \mu_m > 1/2 \end{cases} \quad (29)$$

式中:  $a$  为位移参数;  $d$  为比例参数,  $d > 0$ 。

随后, 根据  $\gamma_m$  生成两个子代个体  $z_1^c$  和  $z_2^c$ , 其分量表达为

$$\begin{cases} z_{1,m}^c = z_{1,m}^p + \gamma_m |z_{1,m}^p - z_{2,m}^p| \\ z_{2,m}^c = z_{2,m}^p + \gamma_m |z_{1,m}^p - z_{2,m}^p| \end{cases} \quad (30)$$

式中:  $z_{1,m}^p$  和  $z_{2,m}^p$  表示父代个体;  $z_{1,m}^c$  和  $z_{2,m}^c$  表示交叉操作生成的子代个体。

5) 变异: 幂变异可通过调节扰动幅度, 既支持精细局部搜索, 又可实现大范围跳跃, 有助于算法跳出局部最优。具体变异方法如下: 生成一个服从幂分布的随机变量  $\zeta$ , 即  $\zeta = (\zeta_1)^p$ , 其中  $\zeta_1$  为  $[0,1]$  区间内均匀分布的随机数,  $p$  为变异指数, 则变异后的个体  $z'_m$  可表示为

$$z'_m = \begin{cases} z_m^g - \zeta \cdot (z_m^g - z_{lb}), \rho_m < \kappa \\ z_m^g + \zeta \cdot (z_{ub} - z_m^g), \rho_m \geq \kappa \end{cases} \quad (31)$$

式中： $z_m^g$ 表示第  $m$  个个体在当前代的位置； $\rho_m$ 表示个体  $z_m$ 在解空间内的相对位置， $\rho_m = \frac{z_m^g - z_{lb}}{z_{ub} - z_{lb}}$ ； $\kappa$ 为[0,1]区间均匀分布的随机数，用于表示随机化变异方向。

6) 终止判定：当算法的迭代次数达到预设的最大值(或种群中每代的最优适应度值趋于收敛且变化幅度极小)时，则视为算法已达到优化极限，算法停止运行。

## 4 算例分析

### 4.1 算例及风光场景分析

为证明本文所提优化方法的有效性，按照图 1 所示的 IES 进行仿真，能源参数如表 1 所示；IES 设备参数如表 2 所示。方案一采用确定性优化，方案二采用鲁棒优化，方案三采用常规随机优化，方案四采用分布鲁棒优化，方案五采用本文改进随机优化方法。

本文所采用的年风速与年辐照强度数据如图 4 所示，电冷热气年负荷如图 5 所示。

表 1 能源参数

Table 1 Energy parameters

能源种类	价格	时段
电/(元/kWh)	1.04	10:00—14:00
		19:00—22:00
	0.315	00:00—07:00
		23:00—24:00
0.63	其他	
天然气/(元/m <sup>3</sup> )	2.37	00:00—24:00
碳税/(元/t)	230	00:00—24:00

表 2 IES 设备参数

Table 2 IES device parameters

设备	投资费用/(元/kW)	维护费用/(元/kW)	转换性能	生命周期年限/年
CCHP	9120	0.06	电: 35%	25
			热: 1.72(COP)	
			冷: 1.89(COP)	
GB	1250	0.02	94%	20
EC	1050	0.02	4.1(COP)	20
P2G	3000	0.02	40%	20
BES	1050	0.02	充电: 95%	20
			放电: 95%	
TST	500	0.01	—	20
GST	1000	0.01	—	20
PV	6500	0.035	—	25
WT	5500	0.030	—	25

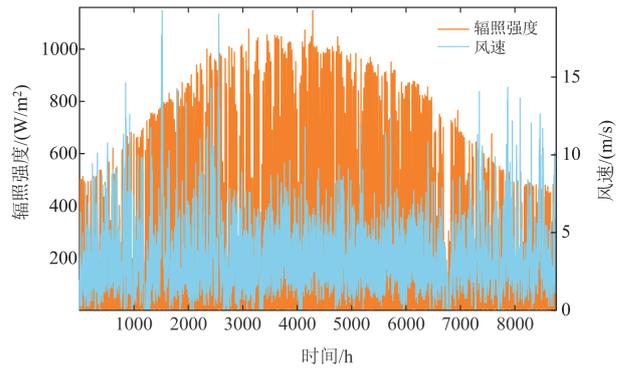


图 4 年风速与年辐照强度

Fig. 4 Annual wind speed and irradiation intensity

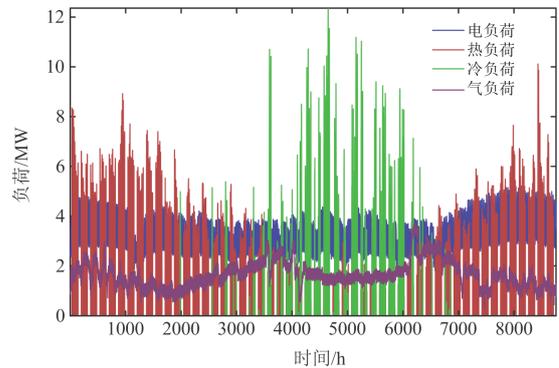


图 5 电冷热气年负荷

Fig. 5 Annual load of electric, cooling, heating and gas

利用 AKDE-AR-LHS 模型生成场景，同时，利用基于 Wasserstein 距离的削减方法进行场景削减，并采用箱线图对削减结果进行分析，结果如图 6 和图 7 所示。

由图 6 可以看出，削减前后风速分布在大部分时段保持高度一致。从中位数、四分位距和异常值分布来看，削减场景与原始数据差异较小，表明削减后的数据能准确保留风速的变化特征。具体而言，在 01:00—05:00、10:00—12:00、16:00—18:00 和 22:00—00:00，削减场景的中位数与四分位距几乎与原始数据一致，保真性较高。而在 13:00 和 20:00，

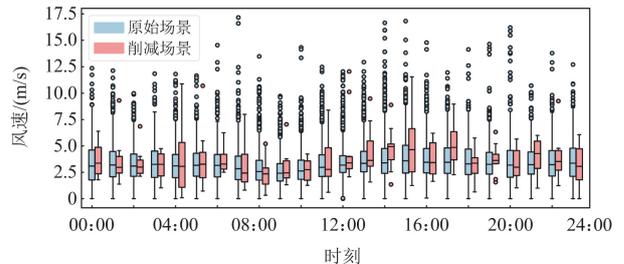


图 6 风速原始-削减场景箱线图

Fig. 6 Boxplot of wind speed primitive-cut scene

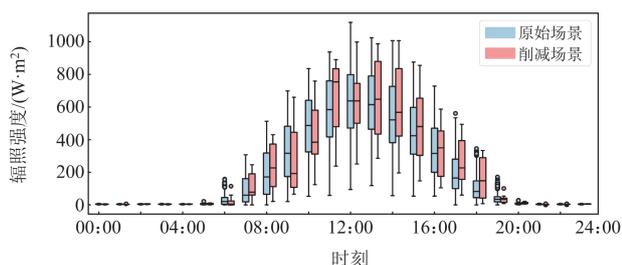


图 7 辐照强度原始-削减场景箱线图

Fig. 7 Boxplot of irradiation intensity original-cut scene

中位数略低, 异常值数量减少, 主要由于在削减过程中过滤了高风速异常值。整体来看, 削减方案在保留风速分布特征的同时, 有效降低了异常值的影响。

削减后的辐照强度数据在大部分时段与原始数据保持高度一致。从中位数、四分位距和异常值分布来看, 削减场景与原始场景差异较小, 表明削减数据能较好地反映辐照强度的变化特征。此外, 削减前后的辐照强度分布均呈现明显的日照周期性, 特别是在 09:00—16:00, 中位数和分布范围几乎重合, 表明削减方案在关键时段具有较高准确性。

#### 4.2 优化配置结果分析

5 种方案的容量优化配置对比如表 3 所示, 各个方案的全生命周期成本以及各项成本如表 4 所示。

表 3 设备容量优化配置结果

Table 3 Optimal configuration result of device capacity

设备	容量优化配置				
	方案一	方案二	方案三	方案四	方案五
CCHP	2838	2241	2293	2391	2294
GB	2902	3204	2980	2793	2980
P2G	433	525	146	177	144
BES	776	2596	1217	1218	1216
TST	1760	1013	1219	1845	1220
GST	959	486	599	989	599
PV	2650	2265	3992	2285	3993
WT	9000	5000	9000	7000	9000

表 4 方案成本对比

Table 4 Comparison of solution costs

方 案	全生命周期成本	元				
		投资成本	运维成本	碳排放成本	弃风弃光成本	
一	200 139 935	48 096 360	128 333 421	1 388 056	22 322 098	
二	306 927 332	42 226 220	252 729 179	1 267 469	10 704 463	
三	182 753 316	49 576 010	105 290 593	1 317 562	26 569 150	
四	218 493 919	41 631.570	155 762 477	1 530 672	19 569 199	
五	168 029 762	49 584.080	103 391 755	1 330 247	13 723 680	

由表 3 和表 4 可以看出: 方案五在应对风光发电不确定性和全生命周期成本优化方面表现较优。

方案一采用确定性优化策略, 基于预测的场景进行优化配置。该方法在风电容量配置上较为积极, 但光伏容量配置偏保守, 同时对储能与转换设备的配置不足。由于未考虑发电的随机性和波动性, 其运行阶段出现较多弃风弃光现象, 运行成本显著增加, 尽管初始投资成本较低, 但全生命周期成本仍然较高。

方案二基于鲁棒优化方法, 通过减少风电和光伏容量的配置, 并提高储能设备的配置水平来应对不确定性。该方案在降低弃风弃光损失方面有一定的效果, 但由于容量配置策略的保守性, 资源利用率较低, 发电侧未能充分发挥作用。同时, 该方案的运行成本高于其他方法, 尽管初始投资成本较低, 但全生命周期成本仍较高。

方案三采用常规随机优化方法, 基于特定概率分布和聚类分析进行优化配置。光伏容量有所提升, 风电维持较高水平, 储能与转换设备较为均衡, 减少了运行阶段的弃风弃光。然而, 受场景生成方法的简化假设限制, 未能准确反映风光发电的波动特性, 优化效果受限, 全生命周期成本未能进一步降低。

方案四采用分布鲁棒优化, 在应对风光发电不确定性方面具有优势。通过降低风电容量、增加储能与转换设备, 优化了容量配置, 减少了弃风弃光成本。该方案投资成本较低, 但运行成本较高, 导致全生命周期成本未达到最优, 且在资源利用率和运行效率上仍有改进空间。

方案五采用改进的随机优化方法, 以全生命周期成本最小化为优化目标, 并通过双层优化模型协调设备容量配置与运行调度。该方案能更精准地捕捉风光发电的不确定性, 实现风电、光伏与储能设备之间的高效容量配置, 提高可再生能源的消纳能力, 从而降低运行阶段的弃风弃光成本。此外, 该方案兼顾投资成本与运行成本, 使总成本得到合理的控制。因此, 相较于其他方案, 方案五的全生命周期成本最低。

#### 4.3 优化调度结果

对于 IES 下层优化调度, 本文选取供能结构复杂的供热季进行研究, 24 h 电、热、气调度情况如图 8—图 10 所示。

在电力调度中, 00:00—06:00 负荷较低, 主要依靠风电和外部购电供电, 储能系统充电为后续高峰储备能量。06:00—09:00 负荷逐步上升, 光伏发电开始供电, 储能系统放电支持负荷增长, 风电仍是主要电源, 外部购电减少。09:00—15:00 光伏发电达到峰值, 与风电共同满足负荷需求, 储能系统

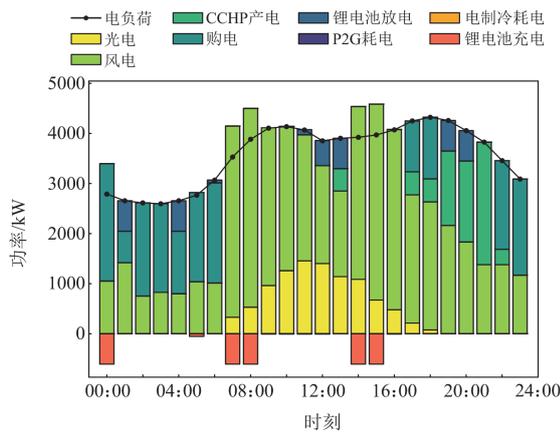


图 8 电能平衡调度

Fig. 8 Power balance scheduling

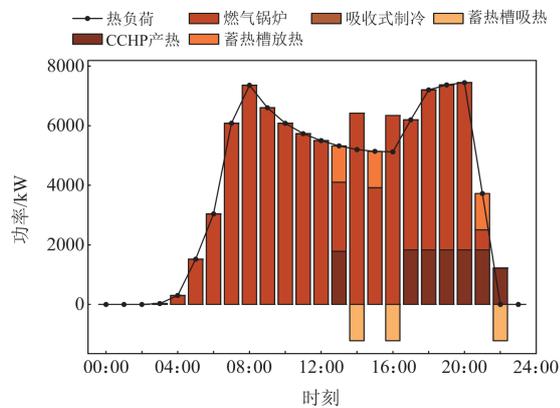


图 9 热能平衡调度

Fig. 9 Thermal energy balance scheduling

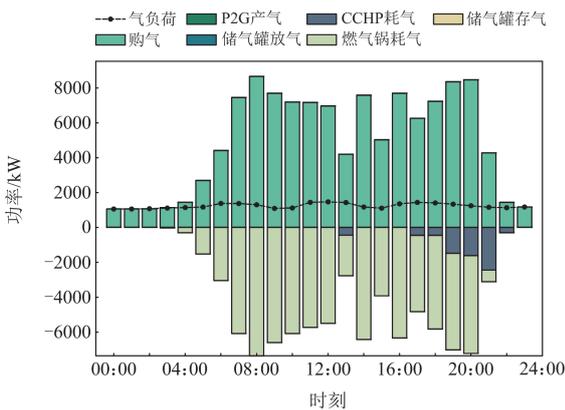


图 10 气能平衡调度

Fig. 10 Gas energy balance scheduling

充电为高峰时段做准备。15:00—21:00 负荷进入全天峰值，光伏发电减弱，储能系统加大放电力度，外部购电显著增加，风电与 CCHP 支撑供电。21:00—24:00 负荷降低，风电恢复主导，储能系统放电供

能，外部购电比例减少。

热能调度结果显示，供热需求主要集中在 06:00—21:00，表现出日间供热特性。CCHP 作为主要供热源，通过热电联产满足基础热能需求，而燃气锅炉在供热高峰时段提供辅助供热。蓄热装置在 00:00—6:00 时段储存热能，并于高负荷时段释放，优化热能供需平衡。

气体能源调度结果表明，燃气锅炉和 CCHP 是气体消耗的主要来源。在 15:00—21:00 时段，天然气消耗达到峰值，以满足系统在电力和热力上的双重需求。

## 5 结论

本文针对计及风光发电不确定性的 IES 优化配置问题，提出了一种双层优化模型，并通过仿真分析验证了该方法的有效性与适用性。研究表明：

1) 所提双层优化配置模型能够有效处理风速和辐照强度的随机波动。该模型通过合理配置储能设备和其他能源转换设备，降低了系统成本的波动，并提高了系统对不确定性波动的适应能力。

2) 在有限的总成本预算条件下，本文模型优化了 IES 各设备容量，增强了对不确定性波动的适应能力。算例结果表明，与确定性优化、鲁棒优化和分布鲁棒优化方法相比，本文方法在实现全生命周期经济性最优的同时，也保障了风光发电的高效利用与资源的协同优化。

3) 本文采用的改进随机优化方法在场景生成和削减方面进行了优化，通过 AKDE-AR-LHS 生成风光发电场景，并引入基于 Wasserstein 距离的场景削减方法，提高了对风光发电波动性特征的描述能力，并在减少计算复杂度的同时保留了场景的代表性。

未来研究可在现有基础上探索更高维度的概率建模，以提升场景生成能力。引入深度生成模型，捕捉风速、辐照强度及时空相关性，生成更精确的典型场景。同时，结合动态调度优化技术，提高综合能源系统的实时响应能力。

## 参考文献

[1] 张沈习, 王丹阳, 程浩忠, 等. 双碳目标下低碳综合能源系统规划关键技术及挑战[J]. 电力系统自动化, 2022, 46(8): 189-207.  
ZHANG Shenxi, WANG Danyang, CHENG Haozhong, et al. Key technologies and challenges of low-carbon integrated energy system planning for carbon emission peak and carbon neutrality[J]. Automation of Electric

- Power Systems, 2022, 46(8): 189-207.
- [2] 李崎勇, 郑一飞, 刘斌, 等. 基于主从博弈的含碳捕集与热电联产综合能源系统优化运行[J]. 电测与仪表, 2024, 61(6): 10-19.
- LI Jiyong, ZHENG Yifei, LIU Bin, et al. Optimal operation of an integrated energy system with carbon capture system and combined heating and power based on a master-slave game[J]. Electrical Measurement & Instrumentation, 2024, 61(6): 10-19.
- [3] 杨佳霖, 赵鹏翔, 窦真兰, 等. 计及经济性与可靠性的综合能源系统优化调度[J]. 供用电, 2024, 41(1): 90-99.
- YANG Jialin, ZHAO Pengxiang, DOU Zhenlan, et al. Optimal scheduling of integrated energy systems considering economy and reliability[J]. Distribution & Utilization, 2024, 41(1): 90-99.
- [4] JIA J D, LI H Q, WU D, et al. Multi-objective optimization study of regional integrated energy systems coupled with renewable energy, energy storage, and inter-station energy sharing[J]. Renewable Energy, 2024, 225.
- [5] 李红伟, 吴佳航, 王佳怡, 等. 计及P2G及碳捕集的风光氢储综合能源系统低碳经济调度[J]. 电力系统保护与控制, 2024, 52(16): 26-36.
- LI Hongwei, WU Jiahang, WANG Jiayi, et al. Low-carbon economic dispatch of a wind, solar, and hydrogen storage integrated energy system considering P2G and carbon capture[J]. Power System Protection and Control, 2024, 52(16): 26-36.
- [6] 鲁玲, 苑涛, 杨波, 等. 计及烟效率和多重不确定性的区域综合能源系统双层优化[J]. 中国电力, 2025, 58(1): 128-140.
- LU Ling, YUAN Tao, YANG Bo, et al. Two-layer optimization of regional integrated energy system considering exergy efficiency and multiple uncertainties[J]. Electric Power, 2024, 40(8): 18-25, 35.
- [7] MA T, CHEN J, MA X, et al. Multi-objective optimal configuration of off-grid residential hybrid renewable energy system based on hypervolume-improved non-dominated sorting genetic algorithm III[J]. International Journal of Hydrogen Energy, 2024, 87: 277-289.
- [8] 汪飞, 龚丹丹, 郭慧, 等. 计及动态氢价和不确定性的区域综合能源系统规划—运行两阶段优化[J]. 电力系统保护与控制, 2022, 50(13): 53-62.
- WANG Fei, GONG Dandan, GUO Hui, et al. Two-stage optimization of regional integrated energy system planning-operation with dynamic hydrogen pricing and uncertainties[J]. Power System Protection and Control, 2022, 50(13): 53-62.
- [9] 杨欢红, 赵峰, 黄文焘, 等. 考虑设备变工况特性的园区综合能源系统双层优化[J]. 电力系统保护与控制, 2024, 52(17): 115-127.
- YANG Huanhong, ZHAO Feng, HUANG Wentao, et al. Two-level optimization for a community integrated energy system considering the off-design condition of equipment[J]. Power System Protection and Control, 2024, 52(17): 115-127.
- [10] MA T, LI M, FAN C, et al. A novel real-time dynamic performance evaluation and capacity configuration optimization method of generation-storage-load for integrated energy system[J]. Applied Energy, 2024, 374.
- [11] WU X, YANG L, ZHENG B. Joint capacity configuration and demand response optimization of integrated energy system considering economic and dynamic control performance[J]. Energy, 2024, 301.
- [12] 张靖, 李勇, 曹一家, 等. 计及需求侧管理与碳排放的综合能源系统光-储设备优化配置方法[J]. 电力自动化设备, 2024, 44(7): 189-197.
- ZHANG Jing, LI Yong, CAO Yijia, et al. Optimal configuration approach of PV-ESS for integrated energy system considering demand-side management and carbon emission[J]. Electric Power Automation Equipment, 2024, 44(7): 189-197.
- [13] 李天格, 胡志坚, 谈竹奎, 等. 基于鲁棒增广约束法的综合能源系统多目标多阶段供能优化配置方法[J]. 电网技术, 2024, 48(7): 2723-2733.
- LI Tiange, HU Zhijian, TAN Zhukui, et al. Multi-objective and multi-stage energy supply configuration method for integrated energy system based on AUGMECON-R[J]. Power System Technology, 2024, 48(7): 2723-2733.
- [14] 郑丙乐, 吴啸. 考虑闭环动态的离网型综合能源系统配置-运行一体优化方法[J]. 中国电机工程学报, 2023, 43(4): 1303-1313.
- ZHENG Bingli, WU Xiao. Integrated configuration and operation optimization of off-grid integrated energy system considering closed-loop dynamic characteristics[J]. Proceedings of the CSEE, 2023, 43(4): 1303-1313.
- [15] WU M, YAN R J, ZHANG J, et al. An enhanced stochastic optimization for more flexibility on integrated energy system with flexible loads and a high penetration level of renewables[J]. Renewable Energy, 2024, 227.
- [16] 毕锐, 王孝滢, 袁华凯, 等. 考虑供需双侧响应和碳交易的氢能综合能源系统鲁棒调度[J]. 电力系统保护与控制, 2023, 51(12): 122-132.
- BI Rui, WANG Xiaogan, YUAN Huakai, et al. Robust dispatch of a hydrogen integrated energy system considering double sideresponse and carbon trading mechanism[J]. Power System Protection and Control, 2023, 51(12):

- 122-132.
- [17] 王蓬蓬, 宋运忠. 计及最恶劣场景概率和供需灵活性的综合能源系统分布鲁棒低碳优化调度[J]. 电力系统保护与控制, 2024, 52(13): 78-89.  
WANG Pengpeng, SONG Yunzhong. Distributed robust low-carbon optimal scheduling of an integrated energy system considering worst-case scenario probability and flexibility of supply and demand[J]. Power System Protection and Control, 2024, 52(13): 78-89.
- [18] 鲁明芳, 李咸善, 李飞, 等. 季节性氢储能-混氢燃气轮机系统两阶段随机规划[J]. 中国电机工程学报, 2023, 43(18): 6978-6991.  
LU Mingfang, LI Xianshan, LI Fei, et al. Two-stage stochastic programming of seasonal hydrogen energy storage and mixed hydrogen-fueled gas turbine system[J]. Proceedings of the CSEE, 2023, 43(18): 6978-6991.
- [19] WANG J, ZHAO L, LU H, et al. Multi-objective stochastic-robust based selection-allocation-operation cooperative optimization of rural integrated energy systems considering supply-demand multiple uncertainties[J]. Renewable Energy, 2024, 233.
- [20] 张智泉, 陈晓杰, 符杨, 等. 含海上风电制氢的综合能源系统分布鲁棒低碳优化运行[J]. 电网技术, 2025, 49(1): 41-51.  
ZHANG Zhiquan, CHEN Xiaojie, FU Yang, et al. Distributionally robust low-carbon optimal operation for integrated energy system including hydrogen production from offshore wind power[J]. Power System Technology, 2025, 49(1): 41-51.
- [21] ZENG L, GONG Y, XIAO H, et al. Research on interval optimization of power system considering shared energy storage and demand response[J]. Journal of Energy Storage, 2024, 86.
- [22] HUA L, XIA J, XIANG G, et al. Scenario-based stochastic optimization on the variability of solar and wind for component sizing of integrated energy systems[J]. Renewable Energy, 2024, 237.
- [23] 卢炳文, 魏震波, 魏平桢, 等. 考虑多重区间不确定性的用户侧综合能源系统双层优化配置[J]. 中国电力, 2022, 55(3): 193-202.  
LU Bingwen, WEI Zhenbo, WEI Pingan, et al. Two-level optimal configuration of user-side integrated energy system considering interval uncertainties[J]. Electric Power, 2022, 55(3): 193-202.
- [24] 徐询, 谢丽蓉, 叶林, 等. 基于非参数核密度估计的风电场有功功率双层优化模型[J]. 电力系统自动化, 2022, 46(2): 43-55.  
XU Xun, XIE Lirong, YE Lin, et al. Bi-level optimization model of active power for wind farm based on nonparametric kernel density estimation[J]. Automation of Electric Power Systems, 2022, 46(2): 43-55.
- [25] ZÁMEČNÍK S, HOROVÁ I, KATINA S, et al. An adaptive method for bandwidth selection in circular kernel density estimation[J]. Computational Statistics, 2024, 39(4): 1709-1728.
- [26] ZENG L, XU J, WANG Y, et al. Day-ahead interval scheduling strategy of power systems based on improved adaptive diffusion kernel density estimation[J]. International Journal of Electrical Power & Energy Systems, 2023, 147.
- [27] 付文杰, 王喻玺, 申洪涛, 等. 基于拉丁超立方抽样和场景消减的居民用户基线负荷估计方法[J]. 电网技术, 2022, 46(6): 2298-2307.  
FU Wenjie, WANG Yuxi, SHEN Hongtao, et al. Residential customer baseline load estimation based on latin hypercube sampling and scenario subtraction[J]. Power System Technology, 2022, 46(6): 2298-2307.
- [28] 董晓狮, 孙英云, 蒲天骄, 等. 一种基于 Wasserstein 距离及有效性指标的最优场景约简方法[J]. 中国电机工程学报, 2019, 39(16): 4650-4658, 4968.  
DONG Xiaochong, SUN Yingyun, PU Tianjiao, et al. An optimal scenario reduction method based on Wasserstein distance and validity index[J]. Proceedings of the CSEE, 2019, 39(16): 4650-4658, 4968.
- [29] 左逢源, 张玉琼, 赵强, 等. 计及源荷不确定性的综合能源生产单元运行调度与容量配置两阶段随机优化[J]. 中国电机工程学报, 2022, 42(22): 8205-8214.  
ZUO Fengyuan, ZHANG Yuqiong, ZHAO Qiang, et al. Two-stage stochastic optimization for operation scheduling and capacity allocation of integrated energy production unit considering supply and demand uncertainty[J]. Proceedings of the CSEE, 2022, 42(22): 8205-8214.

收稿日期: 2024-11-29; 修回日期: 2025-02-17

作者简介:

陆瑜(2002—), 男, 硕士研究生, 研究方向为综合能源系统规划与运行; E-mail: 17787349525@163.com

徐天奇(1978—), 男, 通信作者, 博士, 教授, 硕士生导师, 研究方向为电力系统保护与控制、新能源并网、配网自动化、电力信息物理系统等。E-mail: xu.tianqi@ymu.edu.cn

(编辑 许威)