

考虑可再生能源不确定性成本的低碳电力系统机组组合调度

王靖傲¹, 孙秋野^{2†}, 刘子铭¹, 赵慧冰¹, 刘鑫蕊¹

(1. 东北大学信息科学与工程学院, 沈阳 110819; 2. 流程工业综合自动化全国重点实验室, 沈阳 110819)

摘要: 可再生能源 (Renewable energy sources, RES) 在电力系统中渗透率的不断提升, 其固有的波动性及碳排放传播路径的复杂性, 给低碳经济调度带来了严峻挑战. 现有方法难以精确量化 RES 不确定性成本, 传统碳定价机制亦无法有效追溯 RES 波动引发的间接碳排放. 为此, 本研究提出一种融合信息论不确定性成本建模与动态碳流分配的多目标优化框架. 首先, 设计了基于信息熵的 RES 不确定性成本模型, 通过 Shapley 值公平分摊不确定性风险, 解决了 RES 近乎零边际成本参与机组组合的难题. 其次, 建立了碳流驱动的动态节点碳强度分摊模型, 精确追踪 RES 功率偏差引致的额外碳排放传播路径. 进而, 提出了多模态 NSGAIII (Multi modal NSGAIII, MMNSGAIII) 算法, 协调信息论不确定性成本模型与动态碳分配机制之间的权衡. 该算法采用动态参考点和多模态策略, 有效应对 RES 导致的决策空间碎片化问题, 确保在同时最小化不确定性成本和碳排放传播方面获得帕累托最优解.

关键词: 可再生能源; 信息熵; 不确定性成本; 碳排放流分摊; 多目标优化; 机组组合调度

中图分类号: 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0666

引用格式: 王靖傲, 孙秋野, 刘子铭, 等. 考虑可再生能源不确定性成本的低碳电力系统机组组合调度 [J]. 控制与决策, xxxx, x(x): xxxx-xxxx.

Low-carbon unit commitment scheduling considering renewable energy source uncertainty cost

WANG Jing-ao¹, SUN Qiu-ye^{2†}, LIU Zi-ming¹, Zhao Hui-bing¹, Liu Xin-rui¹

(1. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China; 2. National Key Laboratory of Comprehensive Automation for Process Industries, Shenyang 110819, China)

Abstract: The increasing penetration of renewable energy sources (RES) in power systems poses significant challenges for low-carbon economic dispatch due to their inherent variability and the complexity of carbon emission propagation paths. Existing methods struggle to accurately quantify RES uncertainty costs, and traditional carbon pricing mechanisms fail to effectively trace the indirect carbon emissions induced by RES fluctuations. To address these issues, this study proposes a multi-objective optimization framework integrating uncertainty cost modeling based on information theory and dynamic carbon flow allocation. Firstly, an information entropy-based RES uncertainty cost model is designed. This model resolves the challenge of RES participation in unit commitment due to their near-zero marginal costs by equitably allocating uncertainty risks via Shapley value. Secondly, a carbon flow-driven dynamic bus carbon intensity allocation model is developed to precisely trace the propagation paths of additional carbon emissions caused by RES power deviations. Thirdly, an Multi Modal NSGAIII (MMNSGAIII) algorithm is proposed to coordinate the trade-offs between the uncertainty cost model and the dynamic carbon allocation mechanism. This algorithm employs dynamic reference points and multi-modal strategies to effectively navigate RES-induced fragmented decision spaces, ensuring pareto solutions that simultaneously minimize uncertainty costs and emission propagation.

Keywords: RES generation; information entropy; uncertainty cost; carbon flow allocation; multi-objective optimization; unit commitment

0 引言

随着“碳达峰, 碳中和”目标的提出, 可再生能

收稿日期: xxxx-xx-xx; 录用日期: xxxx-xx-xx.

基金项目: 国家自然科学基金重点项目 (62433013), 国家自然科学基金联合基金项目 (U25B20190).

责任编委: 齐霁.

[†]通信作者. E-mail: sunqiuye@ise.neu.edu.cn.

本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

源 (Renewable energy sources, RES) 在电力系统发电中的占比越来越高, 这给低碳经济调度带来了极大的复杂性^[1,2]. 虽然 RES 能提供较高的环境效益, 其固有不确定性给系统运行带来了较大的成本^[3,4]. 同时, 尽管 RES 减少了系统的总体碳排放, 其高度不确定性会间接导致其它发电设备的碳排放增加^[5]. 因此, 需要量化 RES 的不确定性对系统经济性的影响, 并明确其碳排放责任, 这对于确保高比例可再生能源系统的低碳高效运行至关重要.

目前 RES 的不确定性处理方式大致分为两种: 不确定性建模和算法处理不确定性^[6]. 算法处理不确定性方法, 如随机规划和鲁棒优化方法等, 采用场景削减或机会约束构建不确定性边界, 或将不确定性转换为确定性问题, 进而通过算法直接求解. 相比之下, 不确定性建模技术通过概率密度函数对 RES 发电进行概率建模, 增强了可解释性. 然而这些方法缺乏 RES 不确定性大小的量化指标, 无法定量研究其对系统经济性和环保性的影响.

在不确定性建模技术中, 最常见的方法是在获得 RES 概率密度函数的基础上定义其成本或价格. 这种方法使得 RES 能够参与竞价. 文献 [7] 利用概率密度函数描述 RES 的短缺特性, 进而计算 RES 的不确定性成本. 文献 [8] 提出了一种风险分配机制, 制定了一个策略定价博弈框架, 在消费者之间依概率分配与可再生能源相关的风险. 文献 [9] 根据 RES 的概率密度函数, 将发电和输电备用成本推导为 RES 的不确定性成本. 然而这些方法并没有量化评估 RES 的不确定性大小, 并且难以量化其对系统的影响.

另一方面, 为了实现电力系统低碳经济调度, 需要对系统中设备的碳排放进行量化、评估和溯源. 碳排放权^[10]和绿证^[11]方法通过分配碳排放配额或评估碳减排贡献, 将碳排放与成本解耦, 从而明确了碳排放责任. 然而这些方法依赖于主观定义的碳排放限额, 其往往不能与电网的实际动态完全匹配. 另一种方法是将碳排放转换为排碳成本或定义碳价格, 以激励脱碳^[12]. 但传统的静态碳价格机制无法解决成本和碳排放的时空异质性, 即当可再生能源渗透率较高时, 其短时剧烈波动导致高碳排放机组紧急调动, 引发突发的碳排和成本骤增. 这种时空不匹配随着 RES 占比的增加而增大, 因为静态价格无法捕捉由 RES 不确定性引起的常规机组边际成本波动, 忽略了碳生产者和消费者之间的互动.

利用碳排放流 (Carbon emission flow, CEF) 方法能有效动态评估碳排在系统中的产生和流动^[13,14],

并能确定碳产生和排放的主要对象. 文献 [15,16] 提出了 CEF 模型, 该模型可以跟踪能源使用者的二氧化碳排放量. 然而这种方法只在传统电力系统的背景下考虑了常规机组的碳排放, 当高比例可再生能源接入时, 忽略了 RES 不确定性对碳排放的影响, 使得可再生能源在任意条件下满发, 使得常规机组在 RES 不确定性较大时频繁调节, 导致碳排放效率降低.

针对以上不足, 本文提出了三个主要贡献: 首先, 提出了一种基于信息论的 RES 不确定性成本, 通过基于信息熵的偏差分析以及 Shapely 分摊量化了 RES 的不确定性的影响, 该模型解决了 RES 发电成本近零而无法参与机组组合调度的问题; 其次, 提出了一种新的碳排放分摊模型, 该模型基于碳排放流, 定义了由 RES 出力偏差导致的碳排放责任的分配方法, 促进了在碳排放视角下机组组合中 RES 和常规机组出力的合理分配; 最后, 提出了一种多模态 NSGAIH(Multi modal NSGAIH, MMNSGAIH) 算法, 用于解决非连通区域的覆盖问题以及探索-利用不平衡问题, 该方法适用于解决受机组启停的离散状态变量引起解空间离散的多目标机组组合问题.

1 系统描述和问题表述

本节介绍了低碳电力系统的可再生能源均衡成本和碳排放模型, 包括与可再生能源波动和不确定性相关的偏差成本和与节点碳强度和基于碳排放流的节点碳强度分摊模型, 其框架如图 1 所示.

1.1 RES 不确定性成本

尽管可再生能源 (RES) 是清洁能源, 但其不可控与不可预测的特性使其调度难度较大. 在传统电力系统中, 为促进其消纳, 通常认为可再生能源的发电成本为零^[17]. 然而, 这阻碍了可再生能源机组与传统机组同台竞价, 导致难以执行机组组合决策. 为解决此问题, 本文提出可再生能源不确定性成本的概念, 该成本包括基于实际功率波动的偏差成本和基于发电预测不确定性的调节成本.

1.1.1 RES 偏差成本

偏差成本代表电力短缺或溢出的可能性, 其定义为:

$$C_d(P_{\text{RES}}) = \delta \int_0^{P_{\text{RES}}} f(P_{\text{RES}})(\hat{P}_{\text{RES}} - P_{\text{RES}})dP_{\text{RES}}. \quad (1)$$

其中 P_{RES} 代表可再生能源的实际功率; \hat{P}_{RES} 代表 RES 的上报功率; δ 代表市场电价, 其为一定值. 上报功率 \hat{P}_{RES} 由历史数据预测, 是在调度任务之前确定的固定值. 利用多元线性回归预测方法, \hat{P}_{RES} 定义

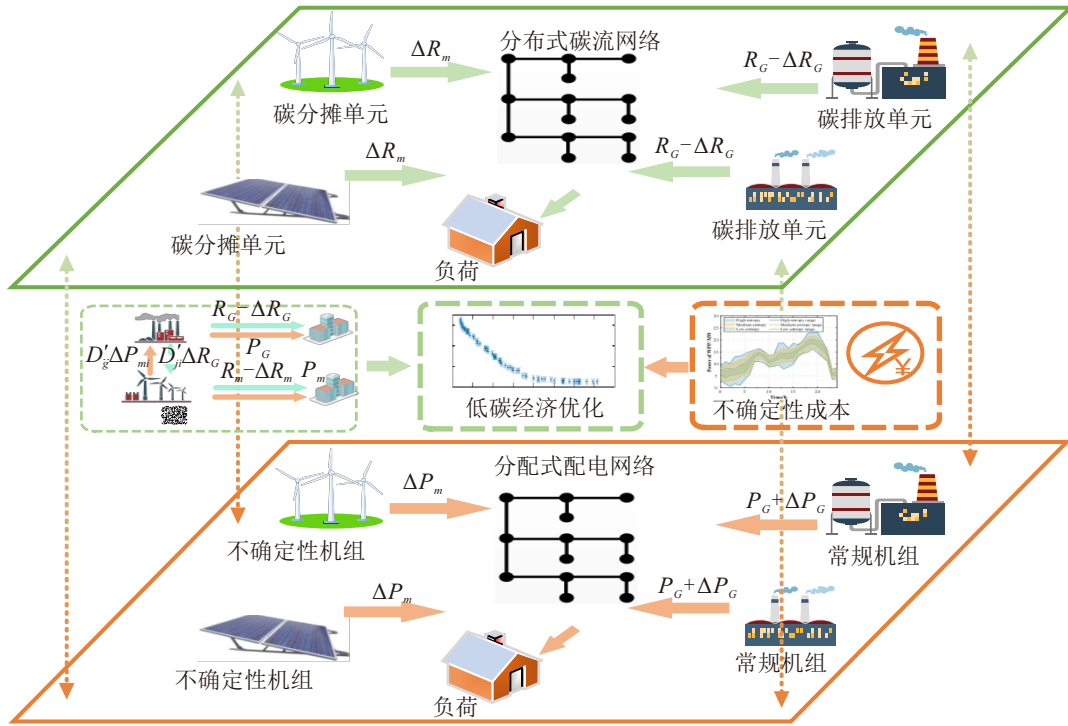


图1 可再生能源不确定性成本评估与碳分配框架

为:

$$\hat{P}_{RES} = \beta_0 + \beta_1 P_{RES,1} + \beta_2 P_{RES,2} + \dots + \beta_n P_{RES,n}. \quad (2)$$

其中, P_{RES} 和 \hat{P}_{RES} 的关系为 $P = \hat{P}_{RES} + \Delta P_{RES}$.

RES 发电的概率密度可以根据历史数据通过核密度估计求得, 定义为:

$$f(P_{RES}) = f_h(P_{RES}) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{P_{RES} - P_{RES,i}}{h}\right). \quad (3)$$

其中 n 是历史数据的样本数量; h 是样本带宽; K 是核密度函数; $P_{RES,i}$ 是第 RES 发电功率的第 i 个历史数据.

利用最大熵原理获得已知约束条件下不确定性最大的概率分布, 其能保持最大的信息量和最小的主观偏差. 对于由 RES 的核密度估计的概率密度函数, 可以通过最大熵原理确定其最混乱的分布边界, 定义为^[17]:

$$f_{\max}(P_{RES}) = p(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \sim \mathcal{N}(\mu, \sigma^2). \quad (4)$$

其中 e 是自然常数; μ 和 σ^2 分别为历史数据的均值和方差. 该最大熵分布形式为正态分布 $\mathcal{N}(\mu, \sigma^2)$.

由于上述分布边界是在没有获得任何信息情况下, RES 的概率密度函数, 所以它独立于核密度估计获得的概率密度函数. 因此, 可以用贝叶斯条件概率公式来修正原来的概率密度函数.

$$f_{Y|X}(y|x) = \frac{f_{X|Y}(x|y)f_Y(y)}{\int_{-\infty}^{\infty} f_{X|Y}(x|y)f_Y(y)dy}. \quad (5)$$

其中 $f_{Y|X}(y|x)$ 是通过贝叶斯定理, 利用观测数据 X 更新先验信息的后验概率密度函数; $f_{X|Y}(x|y)$ 为似然函数; $f_Y(y)$ 为先验概率密度函数; $\int_{-\infty}^{\infty} f_{X|Y}(x|y)f_Y(y)dy$ 为边际似然函数, 用于表示纳入新观测证据前对参数 Y 的初始信息或既有认知.

把分布边界作为先验分布, 把原始概率密度函数作为似然函数代入公式 (5). 利用贝叶斯条件概率公式修正原始概率密度, 定义如下:

$$f(P_{RES} | H_{\max}) = \frac{f_h(P_{RES}) \cdot f_{\max}(P_{RES})}{\int f_h(P_{RES}) \cdot f_{\max}(P_{RES}) dP_{RES}}. \quad (6)$$

将修正后的概率密度函数代入公式 (1), 可以得到具有最大熵边界的 RES 偏差成本, 定义如下:

$$\begin{aligned} C_{\text{dev}} = C_d(P_{RES} | H_{\max}) = & \delta \int_0^{P_{RES}} f(\hat{P}_{RES} | H_{\max})(P_{RES} - \hat{P}_{RES}) dP_{RES} = \\ & \delta \int_0^{P_{RES}} \frac{f_h(\hat{P}_{RES}) \cdot f_{\max}(\hat{P}_{RES}) dP_{RES}}{\int f_h(\hat{P}_{RES}) \cdot f_{\max}(\hat{P}_{RES}) dP_{RES}} \\ & \Delta P_{RES} dP_{RES}. \end{aligned} \quad (7)$$

1.1.2 RES 调节成本

为了应对 RES 的不确定性, 常规机组需要提供额外的调节服务. 由此产生的额外成本应根据不确定性的大小按比例分摊给 RES. 这一成本可以定义

为 RES 调节成本。

为了测量 RES 的不确定性, 引入信息熵 H 来消除不确定性. 随机变量 X 的信息熵定义如下^[18]:

$$H(X) = - \int_{-\infty}^{\infty} p(x) \log p(x) dx, \quad (8)$$

其中 $p(x)$ 为随机事件 X 的概率密度函数; x 是 X 的随机可能取值. 信息熵 H 的引入量化了消除随机事件 X 不确定性所需信息量的大小.

通过 RES 的概率密度函数可以求得其信息熵, 概率密度函数可以通过核密度估计方法求得, 定义如下:

$$H_{RES,i} = \int f_h(P_{RES,i}) \log f_h(P_{RES,i}) dP_{RES,i}. \quad (9)$$

由于功率平衡约束引发的电网耦合、区域天气模式驱动的可再生能源时空关联特性, 以及基于常规机组成本模型的协调调节机制, 任意两节点功率输出均存在相互依存关系, 其信息熵不可代数相加计算, 而须遵守互信息熵公式, 定义为:

$$H(Y | X) = H(X) + H(Y) - H(X; Y). \quad (10)$$

其中 $H(Y | X)$ 是在事件 X 发生的条件下事件 Y 的信息熵 $H(X; Y)$ 是 X 和 Y 之间的互信息熵.

因此, 如果将系统视为单输入单输出模型, 对来自所有 RES 节点的历史数据进行求和, 进而通过核密度估计求得系统内 RES 的总体概率密度函数, 进而可以得到系统的总信息熵, 定义如下:

$$H_{RES}^{tot} = \int f_h \left(\sum_{i=1}^N P_{RES,i} \right) \log f_h \left(\sum_{i=1}^N P_{RES,i} \right) dP_{RES,i}. \quad (11)$$

根据功率平衡方程, 当负载功率需求恒定时, RES 有功输出的波动由平衡机组承担, 定义如下:

$$\sum_{m=1}^M \Delta P_{res,m} = \sum_{k=1}^K \Delta P_{G,k}. \quad (12)$$

其中 $\Delta P_{res,m}$ 和 $\Delta P_{G,k}$ 分别表示第 m 个可再生能源机组和第 k 个常规机组的功率波动量; M 和 K 分别为对应类型节点的数量; m 和 k 对应为其索引.

因此, 定义调节成本为常规机组用于调节 RES 功率波动而产生的额外成本, 这部分成本应该归因于 RES, 其定义如下:

$$C_{reg} = \sum_{k=1}^K [\mathbf{F}_k(P_{G,k} + \Delta P_{G,k}) - \mathbf{F}_k(P_{G,k})]. \quad (13)$$

其中 C_{reg} 是 RES 调节成本; $F(\cdot)$ 是常规机组的成本函数.

考虑到可再生能源不确定性的不同, 调节成本应根据其不确定性进行分配, 定义如下:

$$C_{reg,m} = \frac{\phi_m(H)}{\sum_{m=1}^M \phi_m(H)} C_{reg}. \quad (14)$$

其中 $C_{reg,m}$ 表示第 m 个 RES 的调节成本; $\phi_m(H)$ 为第 m 个可再生能源节点的分摊比例系数.

为了保证分摊的公平性, 本文引入了基于信息熵的夏普利调节成本分配方法. Shapley 分配是一种基于合作博弈理论的公平分配方法, 它根据每个参与者对集体的边际贡献来确定每个参与者的份额. 将 RES 接入系统的边际熵增作为其对系统信息熵的贡献, 进而通过其求得对应的 Shapley 值, 该值决定了节点分摊调节成本的比例. RES 节点的 Shapley 值定义如下:

$$\phi_i(H) = \frac{1}{n!} \sum_{S \subseteq M \setminus \{i\}} |S|!(n-|S|-1)! \Delta H_i(S). \quad (15)$$

其中 M 是所有节点的集合, S 是不包含节点 i 的子集. $\Delta H_i(S)$ 是节点 i 对系统总熵集 S 的边际贡献. $|S|!$ 和 $(n-|S|-1)!$ 分别代表有无节点 i 的集合的子集个数.

随着 RES 机组数量 n 的增加, 公式 (15) 中 Shapley 值的精确计算面临计算量骤增问题, 其复杂度为 $\mathcal{O}(n!)$. 为克服此问题, 我们采用了蒙特卡洛近似方法:

$$\hat{\phi}_i(H) = \frac{1}{Q} \sum_{q=1}^Q [H(S_{\pi_q} \cup \{i\}) - H(S_{\pi_q})]. \quad (16)$$

其中, 我们对节点集 M 进行 Q 次随机排列采样, 得到排列序列 $\pi_1, \pi_2, \dots, \pi_Q$; S_{π_q} 表示在排列 π_q 中位于节点 i 之前的所有节点构成的集合. 该近似方法将计算复杂度从阶乘级 $\mathcal{O}(n!)$ 降低至 $\mathcal{O}(Q \cdot n)$, 在保持无偏估计的同时, 使误差以 $\mathcal{O}(1/\sqrt{Q})$ 收敛. 近似值 $\hat{\phi}_i(H)$ 可直接用于替代调节成本分摊公式 (14) 中的 $\phi_i(H)$.

由于 RES 节点的信息熵不能直接相加, 其对系统总熵的边际贡献 $\Delta H_i(S)$ 必须通过计算总线接入前后的信息熵变化来确定. $\Delta H_i(S)$ 定义如下:

$$\begin{aligned} \Delta H_i(S) &= H(S \cup \{i\}) - H(S) = \\ &= \int f_h \left(\sum_{S \subseteq M \setminus \{i\}} P_{RES,i} \right) \log f_h \left(\sum_{S \subseteq M \setminus \{i\}} P_{RES,i} \right) dP_{RES,i} - \\ &= \int f_h \left(\sum_{S \subseteq M} P_{RES,i} \right) \log f_h \left(\sum_{S \subseteq M} P_{RES,i} \right) dP_{RES,i}. \end{aligned} \quad (17)$$

其中 $H(S \cup \{i\})$ 是包含节点 i 的信息熵; $H(S)$ 是不包含节点 i 的信息熵.

1.2 节点碳强度分摊模型

RES 波动导致常规机组的功率调整, 进而导致其产生额外的碳排放. 通过碳排放流模型, 可以将传

统机组为调节不确定性而产生的额外碳排放分摊给 RES.

1.2.1 可再生能源功率偏差的影响

根据功率平衡, RES 节点的功率通过潮流转移到常规节点, 其功率平衡等式定义如下:

$$\sum_{m=1}^M P_{res,m} = \sum_{k=1}^K P_{G,k}. \quad (18)$$

其中 $P_{res,m}$ 和 $P_{G,k}$ 分别是 RES 节点和常规节点的功率.

定义相邻节点 i 和 j 之间的节点功率分布因子为 A_{ij} , 用来表示从起始节点到相邻目标节点的功率流^[19], 定义如下:

$$A_{ij} = \frac{P_{ij}}{P_{\Sigma i}}. \quad (19)$$

其中 P_{ij} 是从节点 i 通过支路 $i-j$ 流向相邻节点 j 的有功潮流流; $P_{\Sigma i}$ 为注入节点 i 的有功功率总和.

定义不相邻的节点 i 和 j 之间的路径功率分布因子为 D_{ij} , 用于表示在给定路径下, 起始节点的潮流对流入目标节点的网络潮流的总贡献吗, 其定义如下:

$$D_{ij} = \sum_{l \in \Gamma} \left(\prod_{(r,s) \in L(l)} A_{rs} \right). \quad (20)$$

其中 Γ 是节点 i 到 j 的路径集合; $L(l)$ 是构成路径 l 的子路径 r 和 s 的集合; r 和 s 是路径 l 上相邻节点的索引.

当负载功率需求恒定时, RES 有功输出的波动功率由常规机组调节, 定义如下:

$$\sum_{m=1}^M \Delta P_{res,m} = \sum_{k=1}^K \Delta P_{G,k}. \quad (21)$$

将低碳电力系统中的所有偏差功率视为一个潮流网络, 其节点功率分布因子 A'_{ij} 和路径功率分布因子 D'_{ij} 定义如下:

$$A'_{ij} = \frac{\Delta P_{ij}}{\Delta P_{\Sigma i}}. \quad (22)$$

和

$$D'_{ij} = \sum_{l \in \Gamma} \left(\prod_{(r,s) \in L(l)} A'_{rs} \right). \quad (23)$$

其中 ΔP_{ij} 是由节点 i 通过支路 $i-j$ 流向相邻节点 j 的有功功率偏差; $P_{\Sigma i}$ 是流入节点 i 的有功功率偏差之和.

根据潮流的叠加特性, 第 k 个常规节点的功率可以定义如下:

$$P_{G,k} + \Delta P_{G,k} = P_{G,k} + \sum_{m=1}^M D'_{mk} \Delta P_{res,m}. \quad (24)$$

其中 D'_{mk} 是节点 m 到节点 k 的路径输出分布因子.

1.2.2 常规机组的额外碳排放

对于常规机组, 碳排放强度和输出功率之间的关系如^[20,21]所示. 常规机组在低功率运行时需要燃烧石油来维持温度, 导致单位发电产生的二氧化碳更多. 而在高功率运行时, 只需要燃烧煤, 单位发电产生的二氧化碳更少. 定义 $P_g^{\text{ope,tp}}$ 为转折点, 代表是否需要石油燃烧的点. 在转折点的右侧, 随着功率输出的降低, 碳排放强度呈现出近似线性的增加.

一般来说, 系统的效率与功率输出成正相关, 而碳排放强度与功率输出成负相关, 其关系可以定义如下:

$$e_g^{G,\text{ope}}(P_g^t) = aP_g^t + b, \quad (a < 0) \quad P_g^{\text{ope,tp}} \leq P_g^t \leq P_g^{\text{ope,max}}. \quad (25)$$

其中 $e_g^{G,\text{ope}}(P_g^t)$ 是碳排放函数; a 和 b 是 $e_g^{G,\text{ope}}(P_g^t)$ 的参数; $P_g^{\text{ope,max}}$ 是机组的最大功率.

当功率降低到燃料燃烧阈值时, 常规机组需要过渡到石油燃烧, 以满足储备供应或调峰的需求. 因此, 碳排放强度急剧上升, 并与功率输出呈反比关系, 可定义为:

$$e_g^{G,\text{ope}}(P_g^t) = \frac{c}{P_g^t + d} \quad P_g^{\text{ope,min}} \leq P_g^t \leq P_g^{\text{ope,tp}}. \quad (26)$$

其中 c 和 d 为 $e_g^{G,\text{ope}}(P_g^t)$ 的参数; $P_g^{\text{ope,min}}$ 表示机组的最小功率.

除此之外, 还要考虑机组启动和关闭而产生的碳排放. 为了快速提高启动时机组的温度, 燃烧石油来加速加热过程, 导致碳排放增加. 机组启动阶段产生的碳排放定义如下:

$$e_g^{G,\text{up}} = u_{g,t}(1 - u_{g,t-1})E_{\text{up},g}. \quad (27)$$

由于辅助设备在机组停止运行后在一定时间内仍然保持运行, 这也会产生碳排放. 因此定义机组停止阶段的碳排放如下:

$$e_g^{G,\text{down}} = u_{g,t-1}(1 - u_{g,t})E_{\text{down},g}. \quad (28)$$

因此, 常规机组的碳排放函数定义如下:

$$e_g^G = \begin{cases} e_g^{G,\text{up}} + e_g^{G,\text{down}} + aP_g^t + b & P_g^{\text{ope,tp}} \leq P_g^t \leq P_g^{\text{ope,max}} \\ e_g^{G,\text{up}} + e_g^{G,\text{down}} + \frac{c}{P_g^t} + d & P_g^{\text{ope,min}} \leq P_g^t < P_g^{\text{ope,tp}} \end{cases} \quad (29)$$

因此, 常规机组因功率波动而产生的额外碳排放可定义如下:

$$\Delta R_G = |(P_G + \Delta P_G)e_g^G(P_G + \Delta P_G) - P_G \cdot e_g^G(P_G)|. \quad (30)$$

1.2.3 RES 分摊碳排放

将 RES 节点的碳强度定义为所有常规节点因 RES 导致的功率波动而产生的额外碳强度之和, 定义如下:

$$\Delta R_{m,i} = \frac{\Delta P_{m,i}}{\Delta P_{\Sigma i}} \sum_j D'_{ji} \Delta R_G. \quad (31)$$

其中 $R_{m,i}$ 表示第 i 个 RES 节点的碳排放量; $\Delta P_{m,i}$ 为该节点的 RES 注入功率.

因此, 将波动产生的碳强度分摊给 RES 节点后, 常规节点的碳强度修正值定义如下:

$$R'_{G,i} = R_{G,j} - \Delta R_{G,i}. \quad (32)$$

由于 RES 节点没有初始碳强度, 其修正后的碳强度定义如下:

$$R'_{m,i} = \Delta R_{m,i}. \quad (33)$$

2 多目标低碳经济机组组合模型及求解

2.1 目标函数与约束条件

2.1.1 系统总成本

低碳电力系统机组组合的经济目标是最小化系统的总成本, 定义如下:

$$f_1 = C_{\text{tot}} = C_{\text{dev}} + C_{\text{reg}} + C_{\text{con}}. \quad (34)$$

其中 C_{tot} 表示系统总成本; C_{con} 为常规机组所在的节点成本, 包含其启停成本及运行成本, 定义如下:

$$C_{g,\text{up}} = u_{g,t-1}(1 - u_{g,t})c_{\text{up}}, \quad (35)$$

$$C_{g,\text{down}} = u_{g,t-1}(1 - u_{g,t})c_{\text{down}}. \quad (36)$$

其中 $C_{g,\text{up}}$ 和 $C_{g,\text{down}}$ 分别为常规机组的启停成本; $u_{g,t-1}$ 和 $u_{g,t}$ 分别为 $t-1$ 和 t 时刻的启停变量. c_{up} 和 c_{down} 分别为机组单次启动或停止的成本.

因此, 定义常规机组的运行成本如下:

$$C_{\text{op}} = C_{g,\text{up}} + C_{g,\text{down}} + x + yP_G + zP_G^2. \quad (37)$$

其中 C_{op} 是运行成本; x , y 和 z 分别是运行成本中的参数.

2.1.2 系统总碳强度

低碳电力系统机组组合的碳排放目标是最小化系统总碳强度, 定义如下:

$$f_2 = \sum_{i=1}^n E_i. \quad (38)$$

其中 E_i 是第 i 个节点的碳强度.

2.1.3 优化问题描述

上述多目标优化问题可以用如下形式描述:

$$\begin{aligned} \min_{\mathbf{x}} \mathbf{F}(\mathbf{x}) &= [f_1(\mathbf{x}), f_2(\mathbf{x})]^T \\ \text{s.t. } \mathbf{x} &\in \Omega. \end{aligned} \quad (39)$$

其中, \mathbf{x} 为决策变量向量, 包含机组启停状态 $u_{g,t-1}$ 、

$u_{g,t}$ 和有功出力 P 等; $\mathbf{F}(\mathbf{x})$ 为目标函数向量, f_1 和 f_2 分别由式 (25) 和 (27) 定义; Ω 为约束条件, 包括公式 (12-15)、(17)、(20)、(23)、(28-29).

2.2 MMNSGAI 算法框架与改进策略

2.2.1 多目标优化求解

在 RES 不确定性较大的情况下, 需要频繁调整常规机组以平抑其不确定性. 当存在多个调节成本相近的可调度机组时, 将出现大量总成本和碳排放差异极小的近优解, 导致决策空间碎片化, 难以确定 pareto 前沿.

传统 NSGAI 等算法在处理由高比例可再生能源接入及机组离散决策变量引发的决策空间碎片化问题时存在固有局限. 其核心瓶颈在于 NSGAI 所依赖的拥挤度距离与 Pareto 排序机制主要致力于维持种群在目标空间中的分布性与收敛性, 却难以有效辨识与保留在决策空间中迥异、而在目标空间中性能相近的等效解. 当存在多个调度方案对应相似的经济性与环保性指标时, NSGAI 倾向于过早丢失决策空间中的潜在模态, 导致最终解集多样性不足, 无法为决策者提供丰富且灵活的调度选择. 这一局限性在高维、多模态的复杂优化场景下尤为突出, 因而亟需一种能同时在目标空间与决策空间进行多样性保持的先进多目标优化框架. 考虑到上述问题, 本研究采用基于参考点的 NSGAI 框架并进行多模态改进, 以系统性地引导搜索并有效获取在目标空间与决策空间均分布良好的帕累托最优解集.

算法 1 展示了 MMNSGAI 的主要流程. 该算法集成了编码、解码、自适应遗传操作、参考点动态生成等核心模块. 通过多代进化, 逐步优化种群在目标空间和决策空间的分布特性, 最终获得高质量的多模态帕累托解集. 算法采用自适应遗传算子选择策略, 根据种群分布状态动态调整交叉算子, 有效平衡了局部开发和全局探索能力. 其中, d_{high} 和 d_{low} 为预设的拥挤度阈值, 用于判断种群分布状态; G_{max} 为最大进化代数; η_c 为 SBX 交叉算子的分布指数; α 为 BLX- α 交叉算子的扩展参数.

Algorithm 1 MMNSGAI 主流程

Require: 结构化参考点 Z^s 或偏好参考点 Z^a , 种群大小 N , 最大代数 G_{max}

Ensure: 帕累托最优解集 P_{final}

1: 初始化种群: $P_0 \leftarrow \emptyset$

2: **for** $i = 1$ to N **do**

3: $\text{individual} \leftarrow$ 编码过程() \triangleright 使用算法3

4: $P_0 \leftarrow P_0 \cup \{\text{individual}\}$

```

5: end for
6: for  $t = 1$  to  $G_{max}$  do
7: 计算目标值: 对  $P_t$  中每个个体执行解码过程 ▷ 使用算法4
8: 计算平均拥挤度:  $ACD \leftarrow$  平均拥挤度距离( $P_t$ )
9: if  $ACD > d_{high}$  then ▷ 种群分布稀疏
10: 使用SBX交叉 ( $\eta_c = 20$ ) ▷ 增强局部搜索
11: else if  $ACD < d_{low}$  then ▷ 种群分布密集
12: 使用BLX- $\alpha$ 交叉 ( $\alpha = 0.5$ ) ▷ 增强全局探索
13: else
14: 随机选择SBX或BLX- $\alpha$  ▷ 平衡搜索能力
15: end if
16: 生成子代:  $Q_t \leftarrow$  重组与变异( $P_t$ )
17: 合并种群:  $R_t \leftarrow P_t \cup Q_t$ 
18: 非支配排序: ( $F_1, F_2, \dots$ )  $\leftarrow$  非支配排序( $R_t$ )
19: repeat
20:  $S_t \leftarrow S_t \cup F_i, i \leftarrow i + 1$ 
21: until  $|S_t| \geq N$  ▷ 直到选择足够个体
22: 标记最后前沿:  $F_t \leftarrow F_i$ 
23: if  $|S_t| = N$  then
24:  $P_{t+1} \leftarrow S_t$  ▷ 恰好选择N个个体
25: else
26:  $P_{t+1} \leftarrow \bigcup_{j=1}^{i-1} F_j$  ▷ 选择前i-1层
27:  $K \leftarrow N - |P_{t+1}|$  ▷ 需要从  $F_i$  中选择的个体数
28: 归一化目标函数( $\mathbf{f}^n, S_t, Z^r, Z^s, Z^a$ )
29: 生成动态参考点:  $Z^r \leftarrow Z^r \cup$  生成动态参考点( $F_i$ )
30: 关联操作:  $[\pi(s), d(s)] \leftarrow$  关联( $S_t, Z^r$ )
31: for 每个参考点  $j \in Z^r$  do
32: 计算小生境计数:  $\rho_j \leftarrow \sum_{s \in S_t \setminus F_i} \mathbb{I}[\pi(s) = j]$ 
33: end for
34: 小生境保留: 小生境操作( $K, \rho_j, \pi, d, Z^r, F_t, P_{t+1}$ )
35: end if
36: end for
37: return 最终种群  $P_{G_{max}}$ 

```

算法2展示了关联操作过程. 该过程计算每个个体到所有参考方向的最小垂直距离, 并确定其归属的参考点. 这一步骤建立了种群个体与参考点之间的对应关系, 为小生境保留提供依据. 其中, $\pi(s)$ 表示个体 s 关联的最近参考点; $d(s)$ 表示个体 s 到其关联参考点的垂直距离; $\mathbf{f}^n(s)$ 为个体 s 的归一化目标向量; $\|\cdot\|$ 表示欧几里得范数. 通过精确的距离计算, 算法能够准确评估个体在目标空间中的位

置关系, 为多样性保持奠定基础.

Algorithm 2 关联操作(S, Z^r)

```

1: 输入: 种群  $S$ , 参考点集  $Z^r$ 
2: 输出: 每个个体  $s$  的最近参考点  $\pi(s)$  和垂直距离  $d(s)$ 
3: for 每个参考点  $\mathbf{z} \in Z^r$  do
4:  $\mathbf{w} \leftarrow \mathbf{z}$  ▷ 参考方向向量
5: end for
6: for 每个个体  $s \in S$  do
7: 初始化最小距离:  $d_{min} \leftarrow \infty$ 
8: for 每个参考方向  $\mathbf{w} \in Z^r$  do
9: 计算垂直距离:  $d^\perp \leftarrow \|\mathbf{f}^n(s) - \frac{\mathbf{f}^n(s) \cdot \mathbf{w}}{\|\mathbf{w}\|^2} \mathbf{w}\|$ 
10: if  $d^\perp < d_{min}$  then
11:  $d_{min} \leftarrow d^\perp$ 
12:  $\pi(s) \leftarrow \mathbf{w}$  ▷ 记录最近参考点
13: end if
14: end for
15:  $d(s) \leftarrow d_{min}$  ▷ 存储最小距离
16: end for

```

算法3展示了编码过程. 该过程采用混合编码方式, 每个个体包含所有机组的启停状态和出力水平. 启停状态采用二进制编码, 出力水平采用实数编码, 完整表征了一个可行的机组组合方案. 其中, N_g 为机组数量; u_i 表示机组 i 的启停状态; P_i 表示机组 i 的出力水平; P_i^{\min} 和 P_i^{\max} 分别为机组 i 的出力下限和上限; P_{RES} 为可再生能源预测出力; P_{load} 为负荷需求. 通过随机初始化生成多样化的初始种群, 为后续进化过程提供丰富的搜索起点. 编码过程确保生成的个体满足基本的功率平衡约束, 为后续优化过程奠定基础.

Algorithm 3 编码过程

```

1: 输入: 机组参数, 负荷需求, 可再生能源预测
2: 输出: 编码后的个体  $\mathbf{x}$ 
3: for 每个机组  $i = 1$  to  $N_g$  do
4: 生成启停状态:  $u_i \leftarrow$  随机选择  $\{0, 1\}$ 
5: if  $u_i = 1$  then ▷ 机组运行
6: 生成出力水平:  $P_i \leftarrow$  随机数  $[P_i^{\min}, P_i^{\max}]$ 
7: else
8:  $P_i \leftarrow 0$  ▷ 机组停机
9: end if
10: 将  $(u_i, P_i)$  编码到个体向量  $\mathbf{x}$  中
11: end for
12: 添加可再生能源约束: 确保  $\sum P_i + P_{RES} \geq P_{load}$ 

```

13: **return** 编码个体 \mathbf{x}

算法 4 展示了解码过程. 该过程将编码个体转换为具体的目标函数值, 包括总发电成本和碳排放量. 算法通过调用发电成本计算函数和碳排放计算函数来评估每个调度方案的经济性和环保性. 其中, \mathbf{u} 为机组启停状态向量; \mathbf{P} 为机组出力向量; P_{RES} 为可再生能源预测出力; P_{load} 为负荷需求; λ 为约束违反惩罚系数. 算法还检查功率平衡约束和机组出力约束, 对不满足约束的解决方案施加惩罚项, 确保搜索在可行域内进行. 这种设计保证了优化过程始终关注实际可行的调度方案, 同时为算法提供准确的适应度评估.

Algorithm 4 解码过程

```

1: 输入: 编码个体  $\mathbf{x}$ 
2: 输出: 目标函数值  $\mathbf{f} = [f_1, f_2]$ 
3: 解析机组状态: 从  $\mathbf{x}$  中提取各机组  $u_i$  和  $P_i$ 
4: 计算总发电成本:  $f_1 \leftarrow$  发电成本计算函数( $\mathbf{u}, \mathbf{P}$ )
5: 计算碳排放量:  $f_2 \leftarrow$  碳排放计算函数( $\mathbf{u}, \mathbf{P}$ )
6: 检查功率平衡约束:
7: if  $\sum P_i + P_{RES} < P_{load}$  then  $\triangleright$ 功率不平衡
8: 施加惩罚项:  $f_1 \leftarrow f_1 + \lambda \cdot |P_{load} - \sum P_i - P_{RES}|$ 
9:  $f_2 \leftarrow f_2 + \lambda \cdot |P_{load} - \sum P_i - P_{RES}|$ 
10: end if
11: 检查机组出力约束:
12: for 每个机组  $i = 1$  to  $N_g$  do
13: if  $u_i = 1$  且  $(P_i < P_i^{\min}$  或  $P_i > P_i^{\max})$  then
14: 施加惩罚项:  $f_1 \leftarrow f_1 + \lambda \cdot$  约束违反量
15:  $f_2 \leftarrow f_2 + \lambda \cdot$  约束违反量
16: end if
17: end for
18: return 目标向量  $\mathbf{f} = [f_1, f_2]$ 

```

MMNSGAI 算法通过上述创新性改进, 包括混合编码机制、动态参考点生成、自适应遗传算子和复合选择策略, 有效解决了高比例可再生能源环境下机组组合问题的多模态优化挑战. 算法不仅在目标空间中保持了良好的收敛性和分布性, 同时在决策空间中维持了充分的多样性, 为决策者提供了丰富且多样的调度方案选择, 增强了算法在实际工程应用中的实用性和可靠性.

3 实验结果分析

在本节中, 通过改进的 14 节点低碳电力系统验证了基于信息论的 RES 不确定性成本模型和基于

碳流动力学的 RES 等效碳排放模型的有效性, 同时严格测试了所提出的 MMNSGAI 算法的性能.

3.1 实验环境

本文采用 Intel Core i7-13 700@2.1 GHz 处理器 (16GB 内存) 运行 MATLAB 2022b 平台, 对所提方案的有效性和算法性能进行评估. 实验采用改进的 14 节点测试系统, 以确保研究的基础性与可比性. 常规机组的关键参数中, 最小/最大出力为 $P_{\min} = 0$ MW, $P_{\max} = 200$ MW、运行成本系数为 $x = 1000$ 元, $y = 50$ 元/MWh, $z = 0.005$ 元/MW²h. 碳排放特性函数转折点设置为 $P^{\text{opc}} = 80$ MW, 对应函数参数为 $a = -0.0003$ t/MW²h, $b = 0.85$ t/MWh, $c = 12.5$ t, $d = 5.0$ MW. , 这些参数主要参考了针对火电机组低碳运行与灵活性改造的相关研究^[21,28]. 基准市场电价 δ_0 设定为 450 元/兆瓦时^[29]. 系统中光伏机组和风电机组分别接入 3 号母线和 6 号母线以模拟不确定性可再生能源. 将两类发电数据的信息熵归纳为三种场景, 其平均发电偏差分别为 2 MW、5 MW 和 10 MW. 基于不同应用场景的运行策略, 为目标函数设置了三组偏好权重, 对应三种不同场景 (S1: 0.2&0.8; S2: 0.4&0.6; S3: 0.5&0.5).

3.2 算法对比

3.2.1 算法性能对比

本节将我们提出的算法与两种带有局部搜索的多目标算法 (MOEA/D-ALNS^[22] 和 MEPSOLA^[23]) 与三种经典多目标优化框架 (Epsilon-NSGAI^[24]、NSGAI^[25] 和 NSGAI^[26]) 进行了全面的性能对比评估. 为保障对比的公平性, 所有算法均设置相同的终止条件, 即最大进化代数为 1200 代, 确保各算法在相同的计算预算下进行性能评估. 该比较分析采用集合覆盖率和反转世代距离两个核心指标.

集合覆盖率 (SCR) 用于衡量一个算法所获得的 Pareto 解集覆盖另一个算法解集的比例, 反映了解集的全面性和多样性. 其定义为^[25,30]:

$$\text{SCR}(A, B) = \frac{|\{b \in B \mid \exists a \in A : a \preceq b\}|}{|B|}. \quad (40)$$

其中 A 和 B 分别为两个算法的解集, $a \preceq b$ 表示解 a 支配或等于解 b .

反转世代距离 (IGD) 用于衡量真实 Pareto 前沿上的点到算法所求得 Pareto 解集之间的平均距离, 同时反映解集的收敛性和多样性. 其定义为^[27,30]:

$$\text{IGD}(A, P^*) = \frac{1}{|P^*|} \sqrt{\sum_{p^* \in P^*} \min_{a \in A} d(p^*, a)^2}. \quad (41)$$

其中 P^* 为真实 Pareto 前沿, $d(p^*, a)$ 为真实前沿点

p^* 与解集 A 中最近解之间的欧几里得距离。

各个算法的对比结果如图2和图3所示。通过实证检验,各算法在解集质量和收敛特性方面的相对有效性得以展现,这两个指标共同量化了算法在保持种群多样性与逼近真实帕累托前沿方面的表现。




图2 不同算法的集合覆盖率收敛曲线对比




图3 不同算法的反转世代距离收敛曲线对比

在集合覆盖率方面,本文的 SCR 相对于标准 NSGAI 算法进行计算。如图2所示,尽管所有对比算法最终都能实现对 NSGAI 解集的高比例覆盖,但 MMNSGAI 展现出显著的收敛速度优势。具体而言,MMNSGAI 在进化早期便能快速达到较高的覆盖率水平,并率先趋于稳定。相比之下,MOEA/D-ALNS、MEPSOLA 等算法在整个进化过程中覆盖率提升缓慢,其收敛曲线始终位于 MMNSGAI 下方,这一结果证明,MMNSGAI 所采用的动态参考点与混合交叉算子能更高效地引导种群逼近并覆盖优质解集区域,从而在机组组合中实现更快的搜索效率。

在反转世代距离方面,如图3所示,MMNSGAI 相比 MOEA/D-ALNS、MEPSOLA、Epsilon-NSGAI 和 NSGAI,展现出更快的收敛速度和更强的逼近真实 Pareto 前沿的能力。其自适应选择机制能够根据种群分布状态动态调整搜索策略,在高比例可再生能源波动导致的复杂决策空间中仍保持高效。

3.2.2 算法结果对比

为全面评估各算法在解决低碳经济调度问题中的性能,本文对比了 NSGA-II、NSGA-III、Epsilon-NSGA-III、MEPSOLA、MOEA/D-ALNS 以及所提出的 MMNSGA-III 算法在相同实验设置下所获得的

Pareto 前沿。对比结果如图4所示。不同算法所得到的 Pareto 前沿在目标空间中呈现出明显的性能差异。NSGA-II 所得解集分布较为松散,且整体偏离原点较远,表明其解集的最优性较差;NSGA-III 和 Epsilon-NSGA-III 在收敛性上有所改善,但解集在目标空间中的分布仍不够均匀,尤其是在高成本-高排放区域存在明显的解缺失现象;MEPSOLA 和 MOEA/D-ALNS 虽然在一定程度上提升了解集的分布性,但其 Pareto 前沿仍未能充分逼近真实前沿。




图4 不同权重下的 Pareto 曲线

相比之下,本文所提出的 MMNSGA-III 算法在所有对比算法中表现最优,其 Pareto 前沿明显更接近坐标原点,表明在同时最小化系统总成本和总碳排放方面具有显著优势。具体而言,MMNSGA-III 所得解集在目标空间中的分布更为均匀,覆盖了从低成本-低排放到低成本-高排放的完整权衡区间,为决策者提供了更多样化、更灵活的调度选择。

3.2.3 改进策略的算法消融实验

为量化评估 MMNSGAI 算法中每个改进组件(动态参考点、自适应交叉、复合距离)的贡献,本实验对比了完整 MMNSGAI 与多个变体算法的性能。各变体描述如下:MMNSGAI 为本文所提完整算法;变体 A 禁用动态参考点生成,仅使用初始结构化参考点 Z^* ;变体 B 禁用自适应交叉,固定使用 SBX 算子;变体 C 禁用复合距离度量,小生境选择仅使用目标空间垂直距离;同时 NSGAI 原始算法作为基准。所有算法在相同条件下运行,统计结果如表2所示。

表2 MMNSGAI 消融实验性能对比

算法版本	世代距离(GD)	超体积(HV)	运行成本(万元)	碳排放(吨)
MMNSGA-III	0.0085	0.812	12.56	388.5
变体A	0.0123	0.784	13.32	405.7
变体B	0.0102	0.793	12.98	396.2
变体C	0.0091	0.801	12.71	392.4
NSGA-III	0.0157	0.772	13.59	412.8

实验结果如表2所示,消融实验结果清晰展示了各改进组件的贡献:动态参考点的贡献主要体现在

在提升解集的分布性上,其缺失导致 HV 值从 0.812 下降至 0.784(降幅 3.5%),这是因为固定参考点难以覆盖由 RES 不确定性导致的碎片化决策空间;自适应交叉算子的贡献主要体现在收敛速度上,其缺失使 GD 值从 0.0085 恶化至 0.0102(增幅 20%),这表明自适应机制能有效应对不同搜索阶段的需求,平衡探索与开发;复合距离度量的贡献在于同时改善了解的收敛性和多样性,其缺失虽对 GD 和 HV 影响相对较小,但会导致碳排放从 388.5 吨增加至 392.4 吨(增幅 1.0%),这证明考虑决策空间多样性有助于发现更环保的调度方案.完整 MMNSGAIII 算法在所有性能指标上均优于基准 NSGAIII,其运行成本(12.56 万元)和碳排放(388.5 吨)均为最优,显著优于 NSGAIII 的 13.59 万元和 412.8 吨,验证了所有改进策略组合的有效性.

3.3 有效性分析

图 5 所示的仿真结果表明,在不同偏好权重配置下,所提算法经过 800 次迭代优化所产生的全部解均密集聚集在帕累托前沿附近.通过三种不同偏好权重场景下的机组组合策略对比评估,本文所提框架的有效性得到了严格验证.




图5 不同权重下的 pareto 曲线

通过对 Pareto 最优解集分析可知,系统总成本模型(公式(34))与传统模型本质不同: C_{tot} 除常规机组运行成本 C_{con} 外,还包含可再生能源波动引发的偏差成本 C_{dev} 与调节成本 C_{reg} . 同时,机组碳排放强度与输出功率呈非线性关系(公式(29)),低负荷运行时效率降低导致边际碳排放强度升高.当调度策略倾向于更低碳排放时,需大幅降低火电机组出力并优先消纳可再生能源,虽降低燃料成本,但可再生能源功率偏差 ΔP_{RES} 增大会使偏差成本与调节成本显

著增加,可能完全抵消燃料成本节约,且火电机组偏离高效运行区间导致单位发电碳排放强度升高.因此,极端减排场景下出现“碳排放略降、总成本剧增”现象.为客观选取最佳折衷解,本文采用理想点法,通过量化解与理想点距离提供决策依据.其方法大致流程如下:

首先,确定目标空间的理想点与 Nadir 点.设 $F^* = (f_1^*, f_2^*)$ 为理想点,其中各分量由 Pareto 解集中各目标函数的最小值构成:

$$f_i^* = \min\{f_i^{(j)} | j \in \text{Pareto Set}\}, i = 1, 2. \quad (42)$$

同时,设 $F^{nad} = (f_1^{nad}, f_2^{nad})$ 为 Nadir 点,其各分量由解集中各目标函数的最大值构成:

$$f_i^{nad} = \max\{f_i^{(j)} | j \in \text{Pareto Set}\}, i = 1, 2. \quad (43)$$

随后,为消除量纲差异,对解集中每个解的目标值进行线性归一化处理:

$$\tilde{f}_i^{(j)} = \frac{f_i^{(j)} - f_i^*}{f_i^{nad} - f_i^*}, i = 1, 2. \quad (44)$$

继而,计算每个归一化后的解与理想点(归一化空间中原点)的欧几里得距离:

$$d_j = \sqrt{(\tilde{f}_1^{(j)})^2 + (\tilde{f}_2^{(j)})^2}. \quad (45)$$

最终,选择具有最小欧几里得距离的解作为最佳折衷解:

$$j^* = \arg \min_{j \in \text{Pareto Set}} d_j. \quad (46)$$

本文第 3 节中各对比表格所呈现的具体数据,均为由此客观准则选取出的结果,有效避免了决策的主观性,保证了结果的可重复性与科学性.

如表 3 所示:场景 S1 采用碳排放与运行成本均衡权重(均为 0.5),在经济效益与环境目标间实现平衡,总成本为 14,559 元,碳排放量为 488.56 吨;场景 S2 以成本最小化为优先目标(排放权重 0.4,成本权重 0.6),总成本降低至 28,680 元,但碳排放量增加至 372.88 吨;场景 S3 侧重碳减排(排放权重 0.2,成本权重 0.8),碳排放量显著降至 312.24 吨,但成本激增至 35,127 元.这种非线性的成本-排放权衡关系揭示了随着环境目标强化,碳减排的边际成本呈指数级上升,反映极端场景下多目标冲突的加剧.

表3 不同权重下的成本和碳排放

偏好权重	碳排放(吨)	成本(元)
S1: 0.5&0.5	488.56	14,559
S2: 0.6&0.4	372.88	28,680
S3: 0.8&0.2	312.24	35,127

图 6、图 7 和图 8 展示了各场景下的运行策略.

在 S1 场景中, 常规机组以额定容量的 65%-75% 运行, 同时可再生能源利用率达 85%, 通过协调发电调整维持系统平衡. S2 场景采用成本驱动策略, 将常规机组出力提升至额定容量的 85%-95%, 同时将可再生能源利用率降至 72%, 优先保障高效机组的基荷运行. S3 场景通过激进的可再生能源削减策略及优化调度实现减排目标, 将常规机组出力限制在额定容量的 40%-50%, 避免低效运行工况.

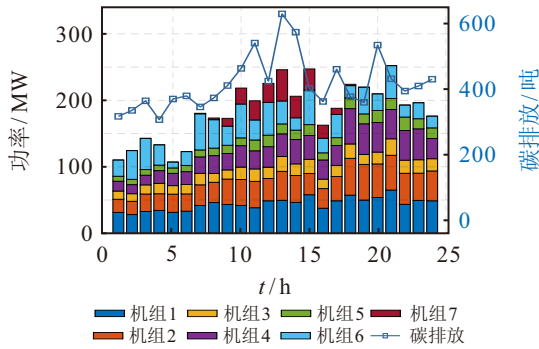


图6 S1 的调度图




图7 S2 的调度图




图8 S3 的调度图

碳流分摊模型能有效追踪可再生能源不确定性引发的排放传递效应. 在 S3 情景中, 82% 的减排量源自可再生能源弃电与机组优化调度, 剩余 18% 则来自中负荷区域发电效率的提升.

综上所述, 所提出的框架能在偏好权重动态变化的情况下, 实现经济目标与环境目标的动态平衡. 通过融合信息论不确定性成本与碳流分配机制, 该框架确保了成本与排放的透明化归因; 同时, 基于

MMNSGAI 的优化方法, 有效提升了在以可再生能源不确定性为主导、且存在离散运行约束的多模态优化场景中的决策稳定性.

3.4 不同不确定性条件下对比

为量化分析 RES 不确定性水平对系统调度的影响, 本节基于其预测出力偏差的概率分布, 定义了高、中、低三种不确定性场景. 低不确定性场景设定 RES 预测出力的相对偏差服从均值为 0、标准差为 5% 的正态分布, 即 $\mathcal{N}(0, (0.05)^2)$; 中不确定性场景下偏差分布标准差增至 10%, 即 $\mathcal{N}(0, (0.10)^2)$; 高不确定性场景进一步将标准差提升至 15%, 即 $\mathcal{N}(0, (0.15)^2)$. 上述偏差分布可基于第 1.1.1 节所述的核密度估计方法从历史数据中获取, 并用于生成表征不确定性的典型场景集. 不同场景下的波动强度差异, 直接影响其信息熵值 (见公式 8) 及后续的不确定性成本分摊结果. 表 4 汇总了两种场景下系统碳排放量与运行成本, 揭示了受可再生能源不确定性影响的规律. 如表 4 所示, 在高不确定性情景下, 系统产生 462.41 吨碳排放, 总成本为 38,720 元; 而在低不确定性情景下, 碳排放量降低至 387.65 吨, 总成本也下降至 26,830 元.

表4 不同不确定性场景下的碳排放和成本

不确定性等级	碳排放 (吨)	成本 (元)
高不确定性	462.41	38,720
低不确定性	387.65	26,830

所提出的框架在低不确定性条件下展现出双重优势. RES 波动性的降低减少了常规机组频繁调节功率的需求——调控成本由此下降 58%, 这与公式 (13) 的理论相符: 当可再生能源功率偏差 ΔP_{RES} 减小时, 机组功率调整量 $\sum \Delta P_{G,k}$ 随之降低. 与此同时, 运行稳定性的提升使常规机组能够主要工作在高效区间 (如图 9 和图 10 所示), 有效规避了高碳排放的低功率运行状态. 这种能效优化效果在表 5 和表 6 中得到量化验证: 关键支路 (6,5) 的碳流量减少 63%,




图9 高不确定性调度图

既反映了优化后的电力调度模式, 也表明通过主要输电线路的碳排放传播得到显著抑制.




图10 低不确定性调度图

表5 不同不确定性场景下的节点碳强度对比

节点编号	高不确定性下的碳强度	中不确定性下的碳强度	低不确定性下的碳强度
1	130.97	79.03	77.06
2	72.38	64.06	57.23
3	85.84	27.23	27.18
6	243.95	53.13	80.57
8	67.12	66.75	33.96

表6 不同不确定性场景下的支路碳流

支路(节点 <i>i</i> 到 <i>j</i>)	高不确定性碳流	中不确定性碳流	低不确定性碳流	基准值
(1,5)	13.43	3.27	5.00	2.67
(2,1)	1.31	23.13	18.68	15.57
(2,3)	2.76	8.81	7.38	35.48
(2,4)	27.39	48.08	37.76	32.19
(2,5)	15.05	27.51	24.50	18.62
(4,3)	2.13	7.37	2.78	3.92
(4,9)	3.23	19.02	13.77	12.71
(5,4)	4.34	7.53	5.87	5.02
(6,5)	11.03	102.51	43.01	68.8
(6,11)	49.88	90.23	37.71	60.42
(6,12)	43.71	42.14	17.45	28.10
(6,13)	20.37	106.62	44.78	71.12
(7,4)	51.62	9.56	4.86	6.36
(8,7)	1.40	2.84	2.39	1.89

碳流分摊模型能够精准追踪碳排放的传播动态. 高不确定性会加剧碳流通过主干输电线路的传输, 而低不确定性则将电力流向重新分配至对排放敏感性较低的路径. 这一现象源于公式 (24) 中 D'_{mk} 值的降低, 该变化削弱了可再生能源出力波动对常规机组的影响. 此外, 在低不确定性条件下, 可再生能源利用率从 68% 提升至 89%, 进一步替代了高碳强度机组的发电份额.

综上所述, 可再生能源 (RES) 不确定性的降低通过以下途径同时提升了经济与环境效益: 最小化常规机组调节需求、优化碳流分布、减少可再生能源

不确定性并提高其利用率. 所提出的框架成功将不确定性成本与碳排放解耦, 为平衡运行灵活性与脱碳目标提供了系统性解决方案.

3.5 不同成本-碳排分析方法对比

为验证本文所提框架的有效性, 本节将其与基准方法进行对比, 其调度图如图 11 和图 12 所示. 该基准方法采用传统的调度策略: 在成本模型中, RES 基于近乎零的边际成本参与竞价, 其不确定性引发的偏差成本与调节成本未被量化与分摊; 在碳排放核算中, 仅计算常规机组的直接碳排放, 并采用静态、按功率比例的方式分摊至各节点, 未能追踪并分配由 RES 波动引起的额外碳排放. 通过与其对比, 可以清晰地量化本文所提出的信息论不确定性成本模型与动态碳流分配机制的实际贡献.

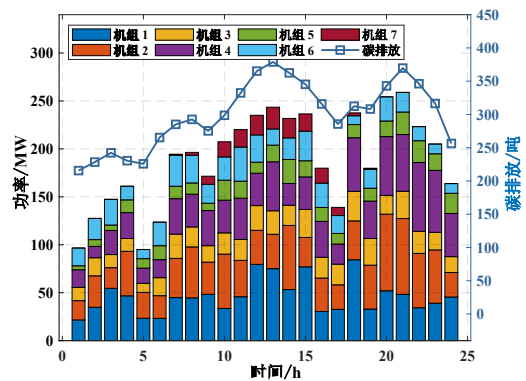


图11 中不确定性场景调度结果




图12 基准方法与本文方法调度对比

在中等不确定性条件下 (以平均发电偏差 5 兆瓦为特征), 该方法在降低碳排放、提升可再生能源利用率及减少运行成本方面展现出显著优势. 如表 5 所示, 该框架成功将碳排放量溯源至可再生能源节点, 解决了传统模型系统性低估可再生能源相关排放的关键缺陷.

如表 5 所示, 采用本方法时, 3 号节点的碳排放强度达 27.23 吨, 而基线方法因未考虑可再生能源引

发的碳传播效应, 其排放量显示为零. 这一改进得益于碳流分配机制——该机制通过公式 25 定义的路径分布因子动态追踪排放传播路径. 高排放常规机组 (如 6 号节点机组) 在本框架下的碳排放强度从高不确定性工况下的 243.95 吨降至 53.13 吨.

碳流在关键输电支路间的重新分配进一步凸显了该框架的有效性. 如表 6 所示, 在采用所提方法后, 骨干支路 (如 6-5 支路) 的碳流从 102.51 吨骤降至 15.03 吨. 这一减排效果是通过具备不确定性感知能力的调度机制与自适应潮流调节技术实现的, 可有效平抑可再生能源波动, 有效平抑了可再生能源波动. 与之相反, 外围支路 (如 2-4 支路) 的碳流在该框架下呈现增长态势, 从 32.19 吨增至 48.08 吨, 这反映了通过碳感知路径分配因子调整实现的电力转移, 即将电能优先导向碳排放敏感度较低的传输路径. 此类调整不仅实现了系统碳强度最小化, 同时提升了系统稳定性.

调度策略进一步凸显了所提框架的优越性. 传统方法因缺乏对 RES 不确定性的显性成本分摊机制, 被迫让常规机组在 40–50% 额定容量区间运行以补偿未管理的 RES 不确定性 (如图 11 和图 12 所示). 相比之下, 所提框架能将常规机组维持在 70–85% 容量水平运行, 从而规避公式 (26) 所述的碳密集型石油燃烧临界点.

如表 7 所示, 经济与环境指标的双重改善源于 RES 不确定性成本的内部化及动态碳分配机制的引入. 通过公式 14 将调节成本明确分摊至 RES 后, 碳排放和系统成本均得到了改善.

表7 不同方法下的碳排放和成本对比

方法	碳排放 (吨)	成本 (元)
本文方法	379.83	28,856
基准方法	432.41	32,376

4 结论

本文提出了 RES 不确定性成本建模与动态碳流分配方法, 构建了面向低碳电力系统的多目标优化框架, 以应对可再生能源波动性与等效碳排放问题. 该研究方法基于信息论原理量化了可再生能源的不确定性, 并运用 Shapely 分配理论实现了风险的公平分配, 同时追踪了网络节点间的碳排放责任归属. 结合自适应多目标优化策略, 该框架在平衡经济与碳排放目标、提升可再生能源消纳能力及应对运行复杂性的同时, 为不确定性条件下的电力系统脱碳提供了系统性解决方案.

参考文献 (References)

- [1] Sun Q Y, Yu X H, Wang J A, et al. Discussion on challenges and countermeasures of “double high” distribution system[J]. *Proceedings of the CSEE*, 2024, 44(18): 7115-7135.
- [2] Liu Z M, Huang B N, Wang J A, et al. Information-energy coupling optimization of low-carbon integrated energy system based on entropy theory[J]. *Automation of Electric Power Systems*, 2025, 49(19): 49-61.
- [3] Liu Z M, Huang B N, Hu X G, et al. Blockchain-based renewable energy trading using information entropy theory[J]. *IEEE Transactions on Network Science and Engineering*, 2024, 11(6): 5564-5575.
- [4] Sun Q Y, Ren Y P, Liu Z M, et al. Review on impossible trinity of comprehensive energy system based on entropy theory[J]. *Control and Decision*, 2023, 38(8): 2106-2121.
- [5] Liu X X, Niu Q, Dong S L, et al. How does renewable energy consumption affect carbon emission intensity? Temporal-spatial impact analysis in China[J]. *Energy*, 2023, 284: 128690.
- [6] Li Y, Li J Z, Wang Y. Privacy-preserving spatiotemporal scenario generation of renewable energies: A federated deep generative learning approach[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(4): 2310-2320.
- [7] Zhang Y J, Gu C H, Yan X H, et al. Cournot oligopoly game-based local energy trading considering renewable energy uncertainty costs[J]. *Renewable Energy*, 2020, 159: 1117-1127.
- [8] Jia Y B, Wan C, Cui W K, et al. Peer-to-peer energy trading using prediction intervals of renewable energy generation[J]. *IEEE Transactions on Smart Grid*, 2023, 14(2): 1454-1465.
- [9] Yang Y, Wu W C, Xu S W, et al. Allocating cost of uncertainties from renewable generation in stochastic electricity market: General mechanism and analytical solution[J]. *IEEE Transactions on Power Systems*, 2024, 39(2): 4224-4239.
- [10] Lin Y J, Xiong H B, Lin Y M, et al. Optimal decentralized coordinated dispatch of electricity-carbon considering impacts of bi-level carbon emission trading market[J]. *Automation of Electric Power Systems*, 2025, 49(12): 31-44.
- [11] (Zhang Y M, Li J R, Ji X Q, et al. Park electricity-carbon-green certificate trading and optimal scheduling for carbon border adjustment Mechanism[J]. *Automation of Electric Power Systems*, 2025: 1-17.
- [12] Lu Z L, Bai L Q, Wang J X, et al. Peer-to-peer joint electricity and carbon trading based on carbon-aware distribution locational marginal pricing[J]. *IEEE Transactions on Power Systems*, 2023, 38(1): 835-852.
- [13] Kang C Q, Du E S, Li Y W, et al. Key scientific problems and research framework for carbon perspective research of new power systems[J]. *Power System*

- Technology, 2022, 46(3): 821-833.
- [14] Zhou T R, Kang C Q, Xu Q Y, et al. Analysis theory of carbon emission flow in power system[J]. Automation of Electric Power Systems, 2012, 36(7): 38-43.
- [15] Li Y W, Zhang N, Du E S, et al. Research and Benefit Analysis of Low-carbon Demand Response Mechanism in Power System Based on Carbon Emission Flow[J]. Proceedings of the CSEE, 2022, 42(8): 2830-2841.
- [16] Zhou T R, Kang (C /Z)Q, Xu Q Y, et al. Preliminary study on calculation method of carbon emission flow in power system[J]. Automation of Electric Power Systems, 2012, 36(11): 44-49.
- [17] Abdalla A N, Nazir M S, Tao H, et al. Integration of energy storage system and renewable energy sources based on artificial intelligence: An overview[J]. Journal of Energy Storage, 2021, 40: 102811.
- [18] Shannon C E. The Mathematical Theory of Communication (Reprinted)[J]. M D Computing, 1997, 14(4): 306-317.
- [19] Cheng Y H, Zhang N, Wang Y, et al. Modeling carbon emission flow in multiple energy systems[J]. IEEE Transactions on Smart Grid, 2019, 10(4): 3562-3574.
- [20] Dong Y L, Jiang X, Liang Z H, et al. Coal power flexibility, energy efficiency and pollutant emissions implications in China: A plant-level analysis based on case units[J]. Resources, Conservation and Recycling, 2018, 134: 184-195.
- [21] Sun X C, Bao M L, Ding Y, et al. Modeling and evaluation of probabilistic carbon emission flow for power systems considering load and renewable energy uncertainties[J]. Energy, 2024, 296: 130768.
- [22] Noori M S, Sahbudin R K Z, Sali A, et al. Multi-objective multi-exemplar particle swarm optimization algorithm with local awareness[J]. IEEE Access, 2024, 12: 125809-125834.
- [23] Lin K Y, Musa S N, Yap H J. Adaptive multi-objective algorithm for the sustainable electric vehicle routing problem in medical waste management[J]. Transportation Research Record: Journal of the Transportation Research Board, 2024, 2678(7): 413-433.
- [24] Geng H T, Zhou Z L, Shen J Y, et al. A dual-population-based NSGA-III for constrained many-objective optimization[J]. Entropy, 2023, 25(1): 13.
- [25] Deb K, Jain H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part I: Solving problems with box constraints[J]. IEEE Transactions on Evolutionary Computation, 2014, 18(4): 577-601.
- [26] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.
- [27] He Z N, Yen G G, Zhang J. Fuzzy-based Pareto optimality for many-objective evolutionary algorithms[J]. IEEE Transactions on Evolutionary Computation, 2014, 18(2): 269-285.
- [28] Yuan R S, Liu M, Chen W X, et al. CO₂ emission characteristics modeling and low-carbon scheduling of thermal power units under peak shaving conditions[J]. Fuel, 2024, 373: 132339.
- [29] Yan J Y, Yang Y, Elia Campana P, et al. City-level analysis of subsidy-free solar photovoltaic electricity price, profits and grid parity in China[J]. Nature Energy, 2019, 4(8): 709-717.
- [30] Fan Q Q, Li M, Huang W T, et al. A research survey of dynamic multi-objective evolutionary algorithms from spatiotemporal perspective[J]. Control and Decision, 2024, 39(1): 1-16.

作者简介

王靖傲 (2001-), 男, 博士研究生, 主要研究方向为低碳电力系统调度、可再生能源不确定性分析等, E-mail: wangjingao@stumail.neu.edu.cn;

孙秋野 (1977-), 男, 教授, 博士, 主要研究方向为能源互联网的建模与优化运行、新能源并网运行、电力电子化的电力系统、多智能体协调控制、人工智能及其在能源系统中的应用, E-mail: sunqiuye@ise.neu.edu.cn;

刘子铭 (1995-), 男, 博士研究生, 主要研究方向为信息熵理论、电力系统信息物理耦合优化、电力市场和区块链技术, E-mail: liuzimingee@stumail.neu.edu.cn;

赵慧冰 (2000-), 女, 博士研究生, 主要研究方向为可再生能源不确定性、需求响应等, E-mail: 2210405@stu.neu.edu.cn;

刘鑫蕊 (1981-), 女, 教授, 博士, 主要研究方向为交直流微电网控制、配电网故障分析及自愈控制、综合能源系统优化, E-mail: liuxinrui@ise.neu.edu.cn.