

基于CCP-AGABP双层综合能源系统调度策略

肖龙海¹, 付明², 金海¹

(1. 国网浙江省电力有限公司海宁市供电公司, 浙江 海宁 314400;

2. 国电南瑞科技股份有限公司, 江苏 南京 210000)

摘要:针对综合能源系统(IES)中可再生能源与电热冷负荷因不确定影响引起功率偏差问题,实现IES优化调度,将机会约束规划(CCP)的随机模型和自适应遗传算法改进的反向传播神经网络(AGABP)的预测模型相结合,提出了双层IES优化调度策略。上层利用CCP对日前优化调度中的不确定性问题进行处理,缓解因可再生能源与多能负荷预测误差引起的功率较大偏差的问题,下层基于AGABP的预测模型进行日内优化,对日前优化调度偏差进行修正。针对随机优化模型难以求解的问题,采用确定性等价类的方法,将模型中的机会约束等价转换为确定性约束,并通过交替方向乘子法(ADMM)对改进的模型进行优化求解。最后,通过算例仿真验证了所提调度策略的有效性。

关键词:综合能源系统;机会约束规划;反向传播神经网络;交替方向乘子法;双层优化调度

中图分类号:TM732 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed24218

Optimal Scheduling Strategy of Dual-level Integrated Energy System Based on CCP-AGABP

XIAO Longhai¹, FU Ming², JIN Hai¹

(1. State Grid Haining Electric Power Supply Company, Haining 314400, Zhejiang, China;

2. NARI Technology Development Co., Ltd., Nanjing 210000, Jiangsu, China)

Abstract: Aiming at the problem of power deviation caused by uncertain influence of renewable energy and electric heating and cooling loads in the integrated energy system (IES) to realize integrated energy system optimal dispatch, a double-layer IES optimal dispatch strategy was proposed by combining the stochastic model of chance constrained programming (CCP) and the prediction model of back propagation neural network improved by adaptive genetic algorithm (AGABP). The upper layer used chance constrained programming to deal with the uncertainty problem in the day-ahead optimal dispatch to relieve the problem of large power deviation caused by the forecast error of renewable energy and multi-energy load, and the lower layer performed intra-day optimization based on the prediction model improved by adaptive genetic algorithm to correct the deviation of day-ahead optimal dispatch. To solve the problem that the stochastic optimization model is difficult to solve, the deterministic equivalence class method was used to transform the chance constraints in the model into deterministic constraints, and then the alternating direction multiplier method (ADMM) was used to optimize the improved model. Finally, an example simulation verified the effectiveness of the proposed scheduling strategy.

Key words: integrated energy system (IES); chance constrained programming (CCP); back propagation neural network; alternating direction multiplier method (ADMM); double-layer optimal dispatch

随着一次能源的日渐衰竭、环境恶化等问题加重,可再生能源的合理开发与高效利用愈加重要^[1]。综合能源系统(integrated energy system, IES)是一种以冷、热、气等多种能源相耦合的新型系统,在满足多种用户侧需求的同时,促进了多种能源间的相互转换与利用,降低了系统运行

维护成本,进而提高了能源的利用效率与经济性^[2]。然而,在IES运行过程中,可再生能源与多能负荷的不确定性使系统的灵活调度面临着巨大的挑战^[3]。因此,有效应对系统中的不确定性对IES优化运行具有重要研究意义。

当前,国内外很多专家学者对系统调度中存

基金项目:国家重点研发计划(2018YFB0905000)

作者简介:肖龙海(1972—),男,硕士,高级工程师,Email:xiao_longhai@zj.sgcc.com.cn

在的相关不确定性问题展开了研究。文献[4]建立了微电网优化模型,采用风光荷的预测值来处理不确定性问题,直接代入模型求解,但此方法所得到的结果因预测误差的存在而不准确。文献[5]针对风电出力的波动性问题,采用场景生成和削减技术,生成不同的典型性场景,然而该方法获得的场景并不精确,存在一些误差问题。文献[6]为了减少可再生能源与负荷不确定性的影响,构建了min-max-min结构的鲁棒优化模型,得到了在最恶劣的情景下最优成本的调度计划,但鲁棒优化所得到的结果过于保守。文献[7]针对风电波动性的影响,在调度模型中,设置一定比例风电的预测值作为系统的旋转备用来维护系统的安全,然而此方法有一定的保守,会造成备用的多余。针对以上问题,本文采用机会约束规划(chance constrained programming, CCP)对不确定性问题进行处理,采用机会约束使其满足一定风险的情形下为风光荷的预测偏差保留一定的备用容量,使IES能够安全稳定调度运行。

尽管CCP在处理不确定方面有一定的作用,但对日内实际情形不能进行准确调度,系统日前长期调度结果与日内短期实际调度结果存在偏差。因此,本文通过改进的神经网络预测模型获取最新的预测信息来修正调度偏差。目前在预测方面开展了如下研究:文献[8]利用改进的自回归积分滑动平均模型进行负荷出力预测;文献[9]考虑天气、时间、负荷等因素,采用粒子群算法和广义回归神经网络模型进行超短期负荷预测。在已有的预测算法方面,熟悉的有时间序列法、反向传播神经网络等。然而,时间序列法对随机性较强的负荷预测精度较低,反向传播神经网络存在收敛速度慢等缺陷^[10]。

基于上述研究现状,本文提出了一种考虑可再生能源发电、多能负荷预测的不确定性和调度计划结果与系统实际运行存在偏差的双层IES优化调度策略。该调度策略的上层优化模型增加了机会约束条件,以解决系统内源荷不确定性的问题,提高了策略的可靠性;下层模型通过基于自适应遗传算法改进的反向传播神经网络(back propagation neural network improved by adaptive genetic algorithm, AGABP)预测模型获取最新的日内预测信息进行优化,以改善日前优化调度与实际调度偏差问题,使调度结果更贴近系统实际运行情况。

1 IES基本结构及其建模

1.1 IES基本结构

IES可以使多种能源转换设备协调优化与互补运行,从而满足系统中多元负荷的需求。IES的基本结构如图1所示。其中,供电单元包括光伏阵列(photovoltaic, PV)、风力发电机(wind turbine, WT)、燃气轮机(gas turbine, GT)、电储能设备(electric energy storage, ESS)以及电网(grid)等;供热单元主要为燃气锅炉(gas boiler, GB)、热储能设备(hot energy storage, HSS);供冷单元为电制冷机(electrical chiller, EC)、吸收式制冷机(absorption chiller, AC)和冷储能设备(cooling energy storage, CSS);系统还包含电转气设备(power-to-gas, P2G)。




图1 综合能源系统结构图

Fig.1 Structural diagram of IES

1.2 IES的能量转换设备模型

1)燃气轮机模型如下:

$$\begin{cases} P_t^{GT} = P_t^{GT, gas} \cdot \eta^{GT, e} \\ H_t^{GT} = P_t^{GT, gas} \cdot \eta^{GT, h} \end{cases} \quad (1)$$

式中: P_t^{GT} 为 t 时刻 GT 输出的电功率; $P_t^{GT, gas}$ 为 t 时刻输入 GT 的气功率; $\eta^{GT, e}$, $\eta^{GT, h}$ 分别为 GT 的产电效率、热效率; H_t^{GT} 为 t 时刻 GT 输出的热功率。

2)燃气锅炉模型如下:

$$H_t^{GB} = P_t^{GB, gas} \cdot \eta^{GB, h} \quad (2)$$

式中: H_t^{GB} 为 t 时刻 GB 输出的热功率; $P_t^{GB, gas}$ 为 t 时刻输入 GB 的气功率; $\eta^{GB, h}$ 为 GB 的产热效率。

3)电制冷机模型如下:

$$C_t^{EC} = P_t^{EC} \cdot \eta^{EC} \quad (3)$$

式中: C_t^{EC} 为 t 时刻 EC 设备输出的冷功率; P_t^{EC} 为 t 时刻输入 EC 的电功率; η^{EC} 为 EC 的制冷效率。

4)吸收式制冷机模型如下:

$$C_t^{\text{AC}} = H_t^{\text{AC}} \cdot \eta^{\text{AC}} \quad (4)$$

式中: C_t^{AC} 为 t 时刻 AC 设备输出的冷功率; H_t^{AC} 为 t 时刻输入 AC 的热功率; η^{AC} 为 AC 的制冷效率。

5) 电转气模型如下:

$$P_t^{\text{P2G,g}} = P_t^{\text{P2G,e}} \cdot \eta^{\text{P2G}} \quad (5)$$

式中: $P_t^{\text{P2G,g}}$ 为 t 时刻电转气设备产生的气功率; $P_t^{\text{P2G,e}}$ 为 t 时刻输入 P2G 设备的电功率; η^{P2G} 为 P2G 设备的产气效率。

2 双层优化调度模型

为了解决日前调度时间尺度较长、可再生能源和负荷存在不确定性因素以及日前优化调度计划与日内运行实际情况存在较大偏差等问题, 本文构建双层优化调度模型, 主要包括日前基于 CCP 优化调度计划和日内基于 AGABP 滚动优化调度计划两部分, 如图 2 所示。




图2 调度策略流程图

Fig.2 Flow chart of scheduling strategy

在上层调度模型中, 为了有效规避 IES 运行时所受到风电/光伏/负荷波动等影响, 基于 CCP 构建了功率波动机会约束。通过制定恰当的置信水平 α , 合理设置备用容量 I_t^{sc} , 使系统可以有效灵活处理各种不确定情况。由于模型中含有机

会约束, 直接对其求解较为困难, 并且求解效率低, 故基于确定性等价类对机会约束进行等价转换。然后采用交替方向乘子法 (alternating direction multiplier method, ADMM) 对转换后模型进行求解, 得到日前最佳调度策略。

在下层调度模型中, 为避免日前长期与日内短期调度计划结果存在较大偏差所带来的影响, 以日前调度结果与日内调度结果偏差最小化为目标函数, 建立基于 AGABP 日内滚动优化模型。为获取最新又准确的预测信息, 利用改进的遗传算法优化反向传播神经网络进行预测。然后利用 ADMM 求解调度模型, 得到修正后的日内调度策略。

2.1 上层模型: 基于 CCP 日前优化调度

2.1.1 目标函数

上层优化目标为日前预测情况下的 IES 总成本最小, 包括系统相关设备运行维护成本、与外界能源交互成本和系统备用成本, 如下式:

$$\min(C_{\text{total}}) = \sum_{t=1}^{T_1} (\sum_{i=1}^N C_t^i + C_t^{\text{eng}} + C_t^{\text{sc}}) \quad (6)$$

其中

$$C_t^i = C_{\text{om}}^i \times W_t^i \quad (7)$$

$$C_t^{\text{eng}} = C_t^{\text{grid}} + C_t^{\text{gas}} \quad (8)$$

$$C_t^{\text{grid}} = C_t^{\text{prgr}} \times P_t^{\text{grid}} \quad (9)$$

$$C_t^{\text{gas}} = (C_t^{\text{prga}}/m) \times P_t^{\text{gas}} \quad (10)$$

$$C_t^{\text{sc}} = K^{\text{sc}} \times I_t^{\text{sc}} \quad (11)$$

式中: C_{total} 为 IES 运行成本; T_1 为上层模型的调度时段总数; N 为 IES 内部设备总数; C_t^i , C_t^{eng} , C_t^{sc} 分别为 t 时刻设备 i 的运行成本、与外界能源交互成本和系统备用成本; C_{om}^i 为设备 i 单位功率运维成本; W_t^i 为 t 时刻设备 i 的功率, 属于电功率、热功率、冷功率中的一种; C_t^{grid} , C_t^{gas} 分别为 t 时刻的购/售电、天然气成本; C_t^{prgr} 为 t 时刻的购/售电价格; P_t^{grid} 为 t 时刻的购/售电功率, 大于 0 时表示购电, 小于 0 时表示售电; C_t^{prga} 为 t 时刻的购/售气价格; P_t^{gas} 为 t 时刻的购气功率; m 为天然气价与电功率换算值; K^{sc} 为单位备用容量惩罚成本系数; I_t^{sc} 为 t 时刻的总备用容量。

2.1.2 系统运行的约束条件

1) 电功率平衡约束条件:

$$\begin{aligned} P_t^{\text{l}} + \sum_{i=1}^{N_{\text{EC}}} P_{t,i}^{\text{EC}} + \sum_{i=1}^{N_{\text{P2G}}} P_{t,i}^{\text{P2G,e}} + P_t^{\text{ESS,ch}} + \Delta P_t^{\text{sc}} \\ = \sum_{i=1}^{N_{\text{PV}}} P_{t,i}^{\text{PV}} + \sum_{i=1}^{N_{\text{WT}}} P_{t,i}^{\text{WT}} + \sum_{i=1}^{N_{\text{CT}}} P_{t,i}^{\text{CT}} + P_t^{\text{ESS,dis}} + P_t^{\text{grid}} \end{aligned} \quad (12)$$

式中: P_t^l 为 t 时刻的电负荷; N_{EC}, N_{P2G} 分别为 EC 和 P2G 设备的数目; $P_t^{ESS, ch}$ 为 t 时刻 ESS 充电功率; ΔP_t^{SC} 为备用电容量; $P_{t,i}^{PV}, P_{t,i}^{WT}, P_{t,i}^{GT}$ 分别为设备 i 在 t 时刻 PV, WT 和 GT 机组 i 的预测值; N_{PV}, N_{WT}, N_{GT} 分别为 PV, WT 和 GT 设备的数目; $P_t^{ESS, dis}$ 为 t 时刻 ESS 放电功率。

2) 热功率平衡约束条件:

$$H_t^l + H_t^{HSS, ch} + \sum_{i=1}^{N_{AC}} H_{t,i}^{AC} + \Delta H_t^{SC} = \sum_{i=1}^{N_{GT}} H_{t,i}^{GT} + \sum_{i=1}^{N_{GB}} H_{t,i}^{GB} + H_t^{HSS, dis} \quad (13)$$

式中: H_t^l 为 t 时刻的热负荷; $H_t^{HSS, ch}$ 为 t 时刻 HSS 充电功率; N_{AC}, N_{GB} 分别为 AC 和 GB 设备的数目; ΔH_t^{SC} 为备用热容量; $H_t^{HSS, dis}$ 为 t 时刻 HSS 放热功率。

3) 冷功率平衡约束条件:

$$C_t^l + C_t^{CSS, ch} + \Delta C_t^{SC} = \sum_{i=1}^{N_{EC}} C_{t,i}^{EC} + \sum_{i=1}^{N_{AC}} C_{t,i}^{AC} + C_t^{CSS, dis} \quad (14)$$

式中: C_t^l 为 t 时刻的冷负荷; $C_t^{CSS, ch}$ 为 t 时刻 CSS 充电功率; ΔC_t^{SC} 为备用冷容量; $C_t^{CSS, dis}$ 为 t 时刻 CSS 放电功率。

4) 气功率平衡约束条件:

$$P_t^{gas} + \sum_{i=1}^{N_{P2G}} P_{t,i}^{P2G, g} = \sum_{i=1}^{N_{GT}} P_{t,i}^{GT, gas} + \sum_{i=1}^{N_{GB}} P_{t,i}^{GB, gas} \quad (15)$$

5) 能量转换设备出力约束条件:

$$\begin{cases} 0 \leq P_{t,i}^{GT} \leq P_{max}^{GT} \\ 0 \leq H_{t,i}^{GB} \leq H_{max}^{GB} \\ 0 \leq P_{t,i}^{P2G, g} \leq P_{max}^{P2G, g} \\ 0 \leq C_{t,i}^{EC} \leq C_{max}^{EC} \\ 0 \leq C_{t,i}^{AC} \leq C_{max}^{AC} \end{cases} \quad (16)$$

式中: P_{max}^{GT} 为 GT 输出电功率最大值; H_{max}^{GB} 为 GB 输出热功率最大值; $P_{max}^{P2G, g}$ 为 P2G 设备输出气功率最大值; C_{max}^{EC} 为 EC 输出冷功率最大值; C_{max}^{AC} 为 AC 输出冷功率最大值。

6) 联络线传输功率出力约束条件:

$$\begin{cases} P_{min}^{grid} \leq P_t^{grid} \leq P_{max}^{grid} \\ P_{min}^{gas} \leq P_t^{gas} \leq P_{max}^{gas} \end{cases} \quad (17)$$

式中: P_{max}^{grid} 为电联络线购电功率最大值; $P_{min}^{gas}, P_{max}^{gas}$ 分别为气联络线购气功率最小值和最大值^[11]。

$P_{min}^{grid} < 0$ 时, $|P_{min}^{grid}|$ 为电联络线售电功率最大值。

7) 能量存储 (ESS, HSS, CSS) 约束条件:

$$\begin{cases} I_{min}^i \leq I_t^i \leq I_{max}^i \\ I_{t=1}^i = I_{t=T}^i \end{cases} \quad (18)$$

式中: I_{min}^i, I_{max}^i 分别为设备 i 存储量的最小值与最大值; I_t^i 为 t 时刻设备 i 的存储量; $I_{t=1}^i, I_{t=T}^i$ 分别为 $t=1, t=T$ 时刻设备 i 的存储量。

8) 系统备用容量约束:

$$\sum_{i=1}^{N_{PV}} \Delta P_{t,i}^{PV} + \sum_{i=1}^{N_{WT}} \Delta P_{t,i}^{WT} - \Delta P_t^l \leq \Delta P_t^{SC} \quad (19)$$

式中: $\Delta P_{t,i}^{PV}, \Delta P_{t,i}^{WT}, \Delta P_t^l$ 分别为在 t 时刻光伏、风电机组 i 出力与负荷波动的预测误差。

然而, 仅凭日前调度时段的风电、光伏与负荷需求预测误差相关信息, 难以直接得到系统备用容量。若系统备用容量值设定过大, 虽然系统受到不确定影响会减小, 提高了系统可靠性, 但是扩大了备用容量的范围, 使 IES 日前调度计划过于保守, 牺牲了系统一定的经济性。因此, 如何恰当地设定不同时段系统备用容量的大小, 以适应不确定变量的变化是研究的关键所在。

本文利用机会约束规划^[12-13]原理, 构建系统功率波动风险约束, 根据预测偏差的动态变化情况, 为日前每个时段制定最小系统备用容量, 从而实现对功率波动的控制, 避免随机变量的偏差过大导致功率缺额的状态, 使系统具有一定抵制功率波动的能力。在恰当的置信水平下, 系统电功率备用容量满足电功率波动的机会约束条件为

$$Pr(\sum_{i=1}^{N_{PV}} \Delta P_{t,i}^{PV} + \sum_{i=1}^{N_{WT}} \Delta P_{t,i}^{WT} - \Delta P_t^l \leq \Delta P_t^{SC}) \geq \alpha_0 \quad (20)$$

式中: $Pr(\cdot)$ 为 $(\cdot)$ 中事件成立的概率; α_0 为事先设定的满足约束条件的置信水平。

本文所涉及的热冷负荷需求波动的机会约束模型与电负荷类似, 此处不再赘述。

2.2 下层模型: 基于 AGABP 日内优化调度

2.2.1 基于 AGABP 预测模型

反向传播 (back propagation, BP) 神经网络是一种应用较为广泛的预测模型, 通过对网络进行训练, 调整权值, 使实际输出值接近期望输出值。但 BP 神经网络模型存在易形成局部极小点与收敛速度慢的缺陷^[14]。针对上述 BP 网络的缺陷, 可以采用遗传算法 (genetic algorithm, GA) 来找到它的最优初始阈值和权值。GA 是利用自然遗传与生物规律对种群进行选择、交叉和变异达到优化效果的一种算法^[15-16]。但标准的 GA 利用确定的交叉与变异概率值, 在运用中会存在不易调节至最佳状态的情况, 致使算法具有较大的随机性, 影响最终结果。

针对上述缺陷, 本文采用自适应遗传算法 (adaptive genetic algorithm, AGA), 通过个体根据在种群中所处的环境自适应地调整交叉与变异

概率来优化BP神经网络^[17-18]。AGABP算法的基本步骤如下:

1)初始化。给定最大迭代次数 N_0 ,设置种群规模为 M ,随机产生 M 个个体的初始种群,并在给定的数据范围内利用线性插值的方式生成一个以实数编码的向量作为AGA的一个染色体。

2)个体评价。确定一个BP网络参数,把步骤1)中产生的染色体赋值给权值与阈值,输入样本对网络进行训练,把训练产生的误差平方和当作个体适应度。

3)选择。使用模拟赌盘选择算子,即利用适应度比选择每一代的染色体,选择概率为

$$p_m = f_m / \sum_{m=1}^M f_m \quad m = 1, 2, \dots, M \quad (21)$$

式中: f_m 为适应度值的倒数。

4)交叉。基于实数编码,将种群中两个个体采用自适应交叉概率进行实数交叉,产生的新个体分别为

$$\begin{cases} w_{kj} = w_{kj}(1-a) + w_{lj}a \\ w_{lj} = w_{lj}(1-a) + w_{kj}a \end{cases} \quad (22)$$

式中: w_{kj}, w_{lj} 分别为第 k 和第 l 个基因的第 j 位; a 为 $[0, 1]$ 里的随机数。

5)变异。在种群中对个体随机采用自适应变异概率得到新个体为

$$w_{ij} = \begin{cases} w_{ij} + (w_{ij} - w_{\max})f(g) & r \geq 0.5 \\ w_{ij} + (w_{\min} - w_{ij})f(g) & r < 0.5 \end{cases} \quad (23)$$

其中

$$f(g) = r_2(1 - g/N_0) \quad (24)$$

式中: $w_{\max}, w_{\min}$ 分别是基因 w_{ij} 取值的上、下限; r, r_2 均为 $[0, 1]$ 里的随机数; g 为当前迭代次数。

6)预测。把AGA得到的最优个体进行解码,获取BP神经网络初始的权值与阈值,建立AGABP模型,经训练后,输出模型预测最优值。

上述中自适应交叉和变异概率具体公式为

$$P_c = \begin{cases} \frac{k_1(f_{\max} - f')}{f_{\max} - f_{\text{avg}}} & f' \geq f_{\text{avg}} \\ k_2 & f' < f_{\text{avg}} \end{cases} \quad (25)$$

$$P_m = \begin{cases} \frac{k_3(f_{\max} - f)}{f_{\max} - f_{\text{avg}}} & f \geq f_{\text{avg}} \\ k_4 & f < f_{\text{avg}} \end{cases} \quad (26)$$

式中: f' 为两个待交叉的个体适应度较大的值; $f_{\max}$ 为最大适应度; f_{avg} 为种群平均适应度; f 为变异个体的适应度; $k_1 \sim k_4$ 为自适应控制参数,本文设定 $k_1=0.05, k_2=0.2, k_3=0.15, k_4=0.95$ 。

2.2.2 日内滚动优化模型

在IES实际运行中,由于存在各种不确定因素,需要对调度策略进行更精确的修正,在每个调度周期内,根据优化目标,求解最优的一个调度计划。滚动优化的目标函数具体如下:

$$\min(f_0) = \sqrt{\sum_{t=1}^{T_2} [\mathbf{Z}(t) - \mathbf{Z}_0(t)]^T [\mathbf{Z}(t) - \mathbf{Z}_0(t)]} \quad (27)$$

式中: f_0 为日内滚动优化的目标函数; $\mathbf{Z}(t), \mathbf{Z}_0(t)$ 分别为在 t 时刻的日内调度结果和日前调度结果; T_2 为下层模型调度时段总数。

2.3 优化调度模型转换与求解策略

2.3.1 模型转换

在本小节中,基于确定性等价类,将系统备用容量满足功率波动的机会约束等价转换为确定性约束,从而将随机优化模型转换为确定性模型。

根据相关文献研究^[19-22],PV,WT机组的出力波动和负荷波动的预测误差量服从正态分布。本文假设PV,WT机组的出力波动和负荷波动的预测误差相互独立。

$$\text{令机会约束不等式(式(20))中} \sum_{i=1}^{N_{\text{PV}}} \Delta P_{i,d}^{\text{PV}} + \sum_{i=1}^{N_{\text{WT}}} \Delta P_{i,d}^{\text{WT}} - \Delta P_t^{\text{L}} = \Delta p(t), \text{即}$$

$$Pr(\Delta p(t) \leq \Delta P_t^{\text{SC}}) \geq \alpha_0 \quad (28)$$

依据概率论中正态分布的有关结论,多个相互独立的正态分布随机变量线性组合仍然服从正态分布^[23],则 $\Delta p(t)$ 也服从正态分布。

本文采用确定性等价类^[13]方法对机会约束不等式(式(28))进行等价转换,具体形式为

$$\Delta P_t^{\text{SC}} \geq \Phi^{-1}(\alpha_0) \quad (29)$$

式中: $\Phi^{-1}(\cdot)$ 为随机变量 $\Delta p(t)$ 的概率分布函数。

2.3.2 基于ADMM的模型求解策略

依据文献[16, 24-25]中的ADMM算法原理,采用如下所述的交替迭代步骤对上层IES优化模型进行求解:

$$\begin{cases} \min C_{\text{total}}(\mathbf{X}) + G(\mathbf{Y}) \\ \text{s.t. } \mathbf{X} - \mathbf{Y} = \mathbf{0} \end{cases} \quad (30)$$

$$\begin{cases} \mathbf{X}^{k+1} = \underset{\mathbf{X}}{\operatorname{argmin}} [C_{\text{total}}(\mathbf{X}) + \frac{\rho}{2} \|\mathbf{X} - \mathbf{Y}^k + \mathbf{u}^k\|_2^2] \\ \mathbf{Y}^{k+1} = \underset{\mathbf{Y}}{\operatorname{argmin}} [G(\mathbf{Y}) + \frac{\rho}{2} \|\mathbf{X}^{k+1} - \mathbf{Y} + \mathbf{u}^k\|_2^2] \\ \mathbf{u}^{k+1} = \mathbf{u}^k + (\mathbf{X}^{k+1} - \mathbf{Y}^{k+1}) \end{cases} \quad (31)$$

式中: X 为 $C_{\text{total}}(X)$ 的优化向量; $G(Y)$ 为方便求解构造的辅助函数; Y 为辅助变量; ρ 为惩罚系数, $\rho > 0$; u^k 为第 k 次迭代过程中的拉格朗日乘子向量^[26]。 X 的第 $k+1$ 次迭代采用了 Y 的第 k 次迭代结果, Y 的迭代采用了 X 的第 k 次迭代结果。

依据ADMM原理,当其原始残差与对偶残差一同满足算法的收敛精度时,它的求解迭代过程就会停止^[15],即

$$\begin{cases} \|X^{k+1} - Y^{k+1}\|_2 \leq \varepsilon^{\text{primal}} \\ \|\rho(Y^{k+1} - Y^k)\|_2 \leq \varepsilon^{\text{dual}} \end{cases} \quad (32)$$

式中: $\varepsilon^{\text{primal}}$, $\varepsilon^{\text{dual}}$ 分别为原始残差和对偶残差的收敛精度^[27]。

3 算例分析

3.1 算例介绍

为了验证所提出的双层调度模型的优越性,本文根据图1所示的IES架构进行仿真试验,选取的算例包含光伏、风电机组各2台,系统内其余的能量转换设备各1台。系统内所有储能设备的初始储能状态设置为0.1。选取我国某地典型日的有关数据,对可再生能源的出力以及电、热、冷负荷的需求进行预测,其结果如图3所示。




图3 可再生能源出力及负荷预测曲线

Fig.3 Forecast curves of renewable energy output and load

本文针对风电荷不确定性,设置一定的置信水平来灵活调整功率偏差,通过计算出来的备用容量大小反映出IES的稳定运行性能。为研究不同的置信水平对系统运行所造成的影响,基于本文的算例数据,取置信水平的范围为 $[0.5, 1]$,逐次递增0.05,将它们进行比较,在不同的置信水平下得到不同的备用容量和总运行成本,如图4所示。随着置信水平 α 的上升,系统的备用总容量及运行总成本不断增大,系统运行稳定性提高。

置信水平 α 在 $[0.8, 0.85]$ 取值时,备用容量增大,运行总成本较其他区间没有显著增大,故本文认为 α 取0.85时,置信水平最优。




图4 备用容量、总成本随置信水平的变化

Fig.4 Chart of total standby capacity and cost with confidence level

3.2 仿真结果及分析

3.2.1 上层模型的优化调度分析

供电优化调度结果如图5所示,可知,在谷时段(23:00—次日07:00),电网电价与天然气价格较低,所以此时段系统向电网购买较多的电量与天然气。为了满足电能供应平衡,主要通过向电网购电与燃气轮机来发电。由于夜间电负荷需求相对较少,系统将多余的电量对电储能设备进行充电,同时通过电转气设备将其转化为天然气。在峰时段(11:00—15:00, 19:00—20:00),电网电价与天然气价格较高,所以该时段系统购电量较其它时段低,燃气轮机产电量较低。由于该时段电负荷需求也较多,因而使用电储能设备进行放电来达到电能供需平衡,以获得更多的经济效益。其余时段,经燃气轮机组供电和向外界电网购买电能来满足系统内电负荷需求。为了满足冷负荷的需求,电制冷机组设备需全天消耗电能稳定运行。




图5 供电优化调度结果

Fig.5 Optimal dispatching results of power supply

供热优化调度结果如图6所示。由图可知,

在热能供应方面,燃气锅炉起主要作用。在谷时段(03:00—07:00),燃气轮机供电的同时,也伴随着供热。同时,在满足该时段热负荷需求时,储热设备将系统内剩余的热能进行存储。在热负荷需求低的时段,吸收式制冷设备通过消耗热能产生冷能来满足系统较大的冷负荷需求。在热负荷需求高的时段,不足的热能供应由热储能设备通过放热来满足。




图6 供热优化调度结果

Fig.6 Optimal scheduling results of heating supply

供冷优化调度结果如图7所示。由图可知,在冷能供应方面,电制冷机为主要供冷设备。在冷负荷需求较低时,将多余的冷能通过冷储能设备进行存储。在冷负荷需求较大时,吸收式制冷机与电制冷机共同产生冷能,同时,冷储能设备放冷来满足系统不足的冷能供应。




图7 供冷优化调度结果

Fig.7 Optimal scheduling results of cooling supply

综上所述,基于CCP的上层优化模型考虑了风、光、荷不确定性导致的功率波动问题,增加了系统备用容量,使得系统各设备的出力增加,而IES经过电、热、气、冷能量耦合,充分发挥了它们的特性,实现了能量的高效转换,从而保障了系统安全稳定运行。

3.2.2 下层模型的优化调度分析

在日内优化运行时,为了仿真真实系统运行

的场景,本文采用AGABP神经网络对可再生能源出力和多能负荷的较精确的短期预测值作为系统场景的实际值,如图8所示。




图8 可再生能源出力及负荷短期预测曲线

Fig.8 Short-term forecasting curves of renewable energy output and load

日内调度以15 min为间隔,为了使IES调度更贴合实际场景,减少系统运行时产生的功率偏差,在电能供应方面,由燃气轮机组、电网与储能设备一同应对功率波动;在热能供应方面,由燃气锅炉、燃气轮机和热储能设备共同承担;在冷能供应方面,由电制冷机、热吸收式制冷机和冷储能设备一同供应。采用下层日内滚动优化修正日前的能量转换设备的输出调度计划,日内优化更新后的能量转换设备的输出调度计划如图9~图11所示。




图9 电能供应修正调度结果

Fig.9 Modified scheduling results of power supply




图10 热能供应修正调度结果




图11 冷能供应修正调度结果

Fig.11 Modified scheduling results of cooling supply

可以看出,基于下层模型对日内的电、热、冷能供应调度结果都进行了修正。在电能供应修正调度方面,系统在谷时段的购电量明显增加,燃气轮机的产电量减少,系统的总成本下降。在热、冷能供应修正调度方面,日内的优化调度更为精确,耦合设备的出力得到了微小变动。综上,经过日内优化修正,减少了系统因不确定性所带来的功率偏差,进而使系统的经济性得到了显著提高,且能更稳定地运行。

3.3 调度策略的对比分析

为了体现出所提调度策略的优势,本文将基于CCP-AGABP的双层调度策略(记为策略1)与确定性调度策略^[7](记为策略2)进行对比。两种调度策略下的系统运行成本如表1所示。

表1 不同调度策略下系统运行成本对比

Tab.1 Comparison of system operating costs under different scheduling strategies 元

调度策略	维护成本	购能成本	备用成本	总成本
策略1	25 737.39	23 536.45	416.71	49 690.55
策略2	27 347.45	25 263.24	1 211.88	53 822.57

由表1对比可知,两种调度策略都采用了可再生能源与多能负荷的预测值作为调度的输入,并考虑了预测误差的存在,因而都存在备用成本。策略1采用CCP得到最佳备用容量,策略2采取了较保守的方式,使备用容量最大化,所以策略1比策略2的备用成本低。为了使系统更贴近实际运行过程,在策略1中加入了优化的神经网络预测模型,利用最新的日内信息来对日前调度结果进行修正,因而策略1的运行总成本比策略2低。通过策略1与策略2的对比可以得出采用本文所提出的策略1的经济性较好的结论。

3.4 优化算法的对比分析

为了验证本文采用的优化算法的优越性,将本文算法ADMM(记为算法1)与传统的粒子群算法(记为算法2)及线性递减惯性权重^[28]的粒子群算法(记为算法3)作对比。本文所设粒子群参数如下:粒子数500,迭代次数1 000,惯性权重0.6,自知、社会学习因子均取2,线性递减惯性权重初始值为0.9,终止值为0.4。不同优化算法的对比结果如表2所示。

表2 不同优化算法的对比

Tab.2 Comparison of different optimization algorithms

优化算法	系统成本/元	计算时间/s	收敛次数/次
算法1	49 690.55	38.658	15
算法2	53 921.73	218.058	467
算法3	50 369.71	208.164	576

从表2中可以发现,在求解系统最优成本的情况下,本文所用的算法1比算法2与算法3得到的结果低。在计算时间方面,算法1明显优于算法2与算法3。在收敛次数上,算法1比算法2与算法3更快收敛。综合考虑以上方面,在保证最优解合理精度的前提下,本文所用的算法1比算法2与算法3更加合理和优越,能够准确、快速地求解本文的调度问题。

4 结论

本文考虑了在IES的经济稳定运行下可再生能源与多能负荷不确定影响,提出了基于CCP-AGABP的双层IES优化策略。经仿真,该策略能

够根据日内实际信息进行偏差修正,使系统的调度结果更加符合真实的运行状态。所提出的调度策略与传统的确定性调度策略相比较,系统总成本下降了7.68%,体现了所提出调度策略的经济性更好。最后,将粒子群及线性递减惯性权重的粒子群算法与本文优化算法进行了对比,结果表明,本文采用的ADMM算法大幅度减少了系统成本、计算时间及收敛次数,为IES的双层调度提供了有效便捷的方法。

本文所提出的调度策略对解决IES中不确定问题提供了参考。下一步的研究工作将考虑具体负荷的实际需求情况,进一步完善IES优化调度策略。

参考文献

- [1] 周星球,郑凌蔚,杨兰,等.考虑多重不确定性的综合能源系统日前优化调度[J].电网技术,2020,44(7):2466-2473.
ZHOU Xingqiu, ZHENG Lingwei, YANG Lan, et al. Day-ahead optimal dispatch of an integrated energy system considering multiple uncertainty[J]. Power System Technology, 2020, 44(7):2466-2473.
- [2] 余晓丹,徐宪东,陈硕翼,等.综合能源系统与能源互联网简述[J].电工技术学报,2016,31(1):1-13.
YU Xiaodan, XU Xiandong, CHEN Shuoyi, et al. A brief review to integrated energy system and energy internet[J]. Transactions of China Electrotechnical Society, 2016, 31(1):1-13.
- [3] 孔德政,张靖,何宇,等.区域综合能源系统IGDT-MPC双层能量优化调度[J].电网技术,2022,46(10):3970-3979.
KONG Dezheng, ZHANG Jing, HE Yu, et al. IGDT-MPC bi-layer energy optimal scheduling of regional integrated energy system[J]. Power System Technology, 2022, 46(10):3970-3979.
- [4] 彭春华,张金克,陈露,等.计及差异化需求响应的微电网源荷储协调优化调度[J].电力自动化设备,2020,40(3):1-7.
PENG Chunhua, ZHANG Jinke, CHEN Lu, et al. Source-load-storage coordinated optimal scheduling of microgrid considering differential demand response[J]. Electric Power Automation Equipment, 2020, 40(3):1-7.
- [5] XU Lizhong, YANG Guangya, XU Zhao, et al. Combined scheduling of electricity and heat in a microgrid with volatile wind power[J]. Automation of Electric Power Systems, 2011, 35(9):53-60.
- [6] 刘一欣,郭力,王成山.微电网两阶段鲁棒优化经济调度方法[J].中国电机工程学报,2018,38(14):4013-4022,4307.
LIU Yixin, GUO Li, WANG Chengshan. Economic dispatch of microgrid based on two stage robust optimization[J]. Proceedings of the CSEE, 2018, 38(14):4013-4022,4307.
- [7] 王彩霞,乔颖,鲁宗相.考虑风电效益的风火互济系统旋转备用确定方式[J].电力系统自动化,2012,36(4):16-21.
WANG Caixia, QIAO Ying, LU Zongxiang. A method for determination of spinning reserve in wind-thermal power systems considering wind power benefits[J]. Automation of Electric Power Systems, 2012, 36(4):16-21.
- [8] ZHANG Jinliang, WEI Yiming, LI Dezhi, et al. Short-term electricity load forecasting using a hybrid model[J]. Energy, 2018, 158:774-781.
- [9] GUO Zhifeng, ZHOU Kaile, ZHANG Xiaoling, et al. A deep learning model for short-term power load and probability density forecasting[J]. Energy, 2018, 160:1186-1200.
- [10] 朱瑞金,郭威麟,龚雪娇.考虑天然气和电负荷之间相关性的短期电负荷预测[J].电力系统及其自动化学报,2019,31(8):27-32.
ZHU Ruijin, GUO Weilin, GONG Xuejiao. Short-term power load forecasting considering correlations between natural gas and power load[J]. Proceedings of the CSU-EPSCA, 2019, 31(8):27-32.
- [11] 刘蓉晖,李阳,孙改平,等.考虑含多种可控负荷的社区冷热电联供系统协同优化调度[J].可再生能源,2019,37(9):1317-1324.
LIU Ronghui, LI Yang, SUN Gaiping, et al. Coordinated optimal dispatch of community CCHP system considering multiple controllable loads[J]. Renewable Energy Resources, 2019, 37(9):1317-1324.
- [12] 武中,邹鹏.含机会约束的两阶段电动汽车充电基础设施随机规划[J].智能电网,2017,5(4):356-362.
WU Zhong, ZOU Peng. A chance constrained two-stage stochastic program for the planning of electric vehicle charging infrastructures[J]. Smart Grid, 2017, 5(4):356-362.
- [13] 刘宝碇,赵瑞清.随机规划与模糊规划[M].北京:清华大学出版社,1998:74-85.
LIU Baozhi, ZHAO Ruiqing. Stochastic programming and fuzzy programming[M]. Beijing:Tsinghua University Press, 1998:74-85.
- [14] 李松,刘力军,解永乐,等.遗传算法优化BP神经网络的短时交通流混沌预测[J].控制与决策,2011,26(10):1581-1585.
LI Song, LIU Lijun, XIE Yongle, et al. Chaotic prediction for short-term traffic flow of optimized BP neural network based on genetic algorithm[J]. Control and Decision, 2011, 26(10):1581-1585.
- [15] 李岩,袁弘宇,于佳乔,等.遗传算法在优化问题的应用综述[J].山东工业技术,2019,4(12):242-243,180.
LI Yan, YUAN Hongyu, YU Jiaqiao, et al. Application of genetic algorithm in optimization problems[J]. Journal of Shandong Industrial Technology, 2019, 4(12):242-243,180.
- [16] 邝凯旋,张赞宁.基于ADMM算法的微电网多目标优化调度[J].电力科学与工程,2019,35(8):54-59.
KUANG Kaixuan, ZHANG Yunning. Multi-objective optimal dispatching of microgrid based on ADMM algorithm[J]. Electric Power Science and Engineering, 2019, 35(8):54-59.
- [17] SRINIVAS M, PATNAIK L M. Adaptive probabilities of crossover and mutation in genetic algorithms[J]. IEEE Transactions

- on Systems Man & Cybernetics, 2002, 24(4): 656-667.
- [18] 陈闯, RYAD Chellali, 邢尹. 改进遗传算法优化BP神经网络的语音情感识别[J]. 计算机应用研究, 2019, 36(2): 344-346, 361.
CHEN Chuang, RYAD Chellali, XING Yin. Speech emotion recognition based on improved genetic algorithm optimized BP neural network[J]. Application Research of Computers, 2019, 36(2): 344-346, 361.
- [19] BO Rui, LI Fangxing. Impact of load forecast uncertainty on LMP[C]//IEEE/PES Power Systems Conference and Exposition, Seattle, WA, USA, 2009: 1-6.
- [20] 江千军, 王磊, 桂前进, 等. 考虑多时间尺度灵活性的含大规模风电电力系统机组组合研究[J]. 智慧电力, 2021, 49(1): 35-41.
JIANG Qianjun, WANG Lei, GUI Qianjin, et al. Power system unit commitment with large-scale wind power considering multi-time scale output flexibility[J]. Smart Power, 2021, 49(1): 35-41.
- [21] 苏磊, 李振坤, 张智泉, 等. 基于机会约束规划的综合能源微网群协调运行策略研究[J]. 电力系统保护与控制, 2021, 49(14): 123-131.
SU Lei, LI Zhenkun, ZHANG Zhiquan, et al. A coordinated operation strategy for integrated energy microgrid clusters based on chance-constrained programming[J]. Power System Protection and Control, 2021, 49(14): 123-131.
- [22] KARGARIAN Amin, FU Yong, WU Hongyu. Chance-constrained system of systems-based operation of power systems[J]. IEEE Transactions on Power Systems, 2016, 31(5): 3404-3413.
- [23] 张玮, 荀超, 黄夏楠, 等. 计及价格弹性负荷及风电的随机安全约束经济调度[J]. 智慧电力, 2021, 49(6): 116-123.
ZHANG Wei, XUN Chao, HUANG Xianan, et al. Stochastic safety constrained economic dispatch considering price elastic load and wind power[J]. Smart Power, 2021, 49(6): 116-123.
- [24] BOYD S, PARIKH N, CHU E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers[J]. Foundations and Trends in Machine Learning, 2010, 3(1): 1-122.
- [25] 夏世威, 邹唯薇, 张茜, 等. 基于交替方向乘子法的电力系统分散式经济调度[J]. 电力系统自动化, 2019, 43(6): 100-106.
XIA Shiwei, ZOU Weiwei, ZHANG Qian, et al. Decentralized economic dispatch for power system based on alternating direction method of multipliers[J]. Automation of Electric Power Systems, 2019, 43(6): 100-106.
- [26] 史佳琪, 胡浩, 张建华. 计及多个独立运营商的综合能源系统分布式低碳经济调度[J]. 电网技术, 2019, 43(1): 127-136.
SHI Jiaqi, HU Hao, ZHANG Jianhua. Distributed low-carbon economy scheduling for integrated energy system with multiple individual energy-hubs[J]. Power System Technology, 2019, 43(1): 127-136.
- [27] 曾方迪, 李更丰, 别朝红, 等. 考虑跨区联络线交易计划的多区域互联系统分散调度方法[J]. 电力系统自动化, 2018, 42(16): 32-40.
ZENG Fangdi, LI Gengfeng, BIE Zhaozhong, et al. Decentralized dispatch method for multi-area interconnected power systems considering cross-area tie-line transaction strategy[J]. Automation of Electric Power Systems, 2018, 42(16): 32-40.
- [28] SHI Y, EBERHART R. A modified particle swarm optimizer [C]//1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No. 98TH8360), Anchorage, AK, USA, 1998: 69-73.

收稿日期: 2022-03-04

修改稿日期: 2022-03-30