

文章编号:1006-2467(2022)05-0554-10

DOI: 10.16183/j.cnki.jsjtu.2022.040

面向高比例新能源并网场景的 风光-电动车协同调度方法

李林晏¹, 韩爽¹, 乔延辉¹, 李莉¹, 刘永前¹, 阎洁¹, 刘海东²

(1. 华北电力大学 新能源电力系统国家重点实验室; 新能源学院, 北京 102206;

2. 大唐(赤峰)新能源有限公司, 内蒙古自治区 赤峰 024000)

摘要: 风光-电动汽车协同调度能够有效降低风光出力和电动汽车无序充电等多重不确定性对电力系统的不利影响. 现有优化调度模型多以等效负荷波动最小为优化目标, 仅考虑了等效负荷的整体波动性, 无法衡量风光出力与负荷的匹配度且并未考虑不同出力场景下风光出力的差异性. 针对上述问题, 提出一种面向高比例新能源并网场景的风光-电动车协同调度方法. 构建基于蒙特卡罗模拟的电动汽车无序充电模型; 基于风光出力预测数据, 构建基于 Gap statistic 和 K-means++ 算法的风光出力典型日划分模型; 以等效负荷方差和负荷追踪系数最小为双优化目标, 构建风光-电动汽车协同调度模型, 并采用 NSGA-II 算法求解. 结果表明: 所提模型能够有效提升风光出力与负荷的匹配度, 降低等效负荷波动性, 从而缓解风光出力和电动汽车无序充电等多重不确定性对电力系统的不利影响.

关键词: 典型日划分; 源荷匹配度; 风光-电动汽车; 协同调度; NSGA-II 算法

中图分类号: TM 614; TM 615

文献标志码: A

A Wind-Solar-Electric Vehicles Coordination Scheduling Method for High Proportion New Energy Grid-Connected Scenarios

LI Linyan¹, HAN Shuang¹, QIAO Yanhui¹, LI Li¹

LIU Yongqian¹, YAN Jie¹, LIU Haidong²

(1. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources; School of New Energy, North China Electric Power University, Beijing 102206, China; 2. China Datang (Chifeng) New Energy Co., Ltd., Chifeng 024000, Inner Mongolia Autonomous Region, China)

Abstract: Wind-solar-electric vehicles coordinated optimization scheduling can effectively reduce the adverse effects of multiple uncertainties of wind-solar output and disorderly charging of electric vehicles on the power system. Most of the existing optimization scheduling models take the minimum equivalent load fluctuation as the optimization objective, which, only considering the overall fluctuation of equivalent load, cannot measure the matching degree of output-load, and do not consider the difference of output in different output scenarios. Therefore, a wind-solar-electric vehicles coordination scheduling method for high proportion new energy grid-connected scenarios is proposed. First, the disordered charging model of electric vehicles by Monte Carlo simulation is constructed. Then, a wind-solar output typical day

收稿日期: 2022-02-22

基金项目: 雅砻江流域风光水多能互补运行的优化调度方式研究(U1765201)

作者简介: 李林晏(1997-), 男, 山西省运城市人, 硕士生, 从事风光出力特性分析、风光互补系统优化调度研究.

通信作者: 李莉, 女, 副教授, 电话(Tel.): 010-61771855; E-mail: lili@ncepu.edu.cn.

classification model using Gap statistical and K -means++ is constructed based on the forecasting data of wind and solar power. Finally, taking the minimum equivalent load variance and load tracking coefficient as the double optimization objectives, a wind-solar-electric vehicles coordination optimization scheduling model is established, and the NSGA-II algorithm is used to solve it. The results demonstrate that the proposed model can effectively improve the matching degree of wind-solar output and load, and reduce the fluctuation of equivalent load, so as to reduce the adverse effects of multiple uncertainties of wind-solar output and disorderly charging of electric vehicles on the power system.

Key words: typical day; output-load matching; wind-solar-electric vehicles; coordination scheduling; NSGA-II algorithm

风电和光伏出力具有随机性、波动性和不可控性等固有属性,高比例新能源并网给电力系统的安全稳定运行带来严峻考验^[1-2].同时,随着电动汽车的大规模趋势性发展,电动汽车充电负荷需求增加,其无序充电的不确定性同样增加了电力系统调度的难度.但是,电动汽车充电负荷是具有可调度性的柔性负荷,加以引导变无序充电为有序充电能够起到平滑等效负荷波动性的目的^[3-4].因此,通过风光-电动汽车协同调度能够有效降低风光出力和电动汽车无序充电等多重不确定性对电力系统的不利影响^[5-6].

针对风光-电动汽车协同调度,国内外相关学者进行了相应研究. Song 等^[7]提出的充放电策略考虑了电动汽车与风力发电在平抑负荷波动方面的互补效应;侯建朝等^[8]以等效负荷方差和车主支付费用最小为优化目标,构建风电与电动汽车协同调度模型;冉忠等^[9]以电动汽车消纳后的风电弃风量最小为目标,建立电动汽车参与受阻风电消纳的源荷优化控制模型;葛少云等^[10]通过遗传算法求解以峰谷差率最小为目标的优化模型;郭春林等^[11]建立了电动汽车与可再生能源双层协调优化模型,上层模型以等效负荷波动最小和可再生能源渗透率最大为双优化目标,下层模型以实现电动汽车充放电负荷跟踪为目标,并采用遗传算法求解上下层的优化模型.同时,由于风电和光伏出力具有很强的随机不确定性,在不同典型出力场景下,风电和光伏出力特性及其之间的互补关系具有明显差异性,且对电力系统的影响规律不尽相同^[12-13],在含大规模新能源的电力系统中,风光出力的随机不确定性对电力系统的不利影响也愈发明显.利用典型日聚类方式从大量风电/光伏历史数据中提取典型出力场景集,以典型出力场景反映风光出力特性,并用于不同出力场景下优化调度的差异化建模分析,是目前电力系统调度分析常用的方法^[14-15].

综上所述,现阶段风光-电动汽车协同调度模型多以等效负荷波动最小为优化目标,仅考虑了等效负荷的整体波动性,无法衡量风光出力与负荷的匹配度,且优化调度模型在不同出力场景下的适用性和鲁棒性也并未展开分析.

针对上述问题,提出一种面向高比例新能源并网场景的风光-电动车协同调度方法.首先,通过分析电动汽车行驶规律,构建基于蒙特卡罗模拟的电动汽车无序充电模型;其次,基于风光出力预测数据,构建基于 Gap statistic 和 K -means++ 算法的风光出力典型日划分模型;再次,以等效负荷方差和负荷追踪系数最小为双优化目标,构建风光-电动汽车协同调度模型,并采用 NSGA-II 算法进行模型求解;最后,基于中国西北某省风光电站预测出力和电网预测负荷数据,验证所提方法的适用性和鲁棒性.

1 基于蒙特卡罗模拟的电动汽车无序充电模型

1.1 电动汽车行驶规律

电动汽车行驶规律主要包括车辆出发前往工作地点时间、返回住所时间、路程耗时和日行驶里程. 2017 年美国交通部对全美家庭出行调查结果^[16]反映了车辆一天中的行驶规律分布,考虑到中国与美国在工作时间上较为接近,均集中于 9:00—17:00,可以假定两国电动汽车具有相同的行驶规律.因此,基于上述调查结果对电动汽车充电曲线进行建模分析,得到电动汽车出发前往工作地点时刻符合混合高斯分布,概率密度表达式为

$$f_{T,H-W}(x) = \alpha_1 \frac{1}{\sqrt{2\pi}\sigma_1} \exp\left(-\frac{(x-\mu_1)^2}{2\sigma_1^2}\right) + (1-\alpha_1) \frac{1}{\sqrt{2\pi}\sigma_2} \exp\left(-\frac{(x-\mu_2)^2}{2\sigma_2^2}\right) \quad (1)$$

式中: x 为时刻; $\alpha_1 = 0.830\,3$, 为出发前往工作地点时刻,属于第一个高斯模型概率; $\mu_1 = 7.194\,4$ 和

$\mu_2 = 13.1477$ 分别为第一个和第二个高斯模型均值; $\sigma_1 = 1.5080$ 和 $\sigma_2 = 8.7192$ 分别为第一个和第二个高斯模型方差。

工作日电动汽车离开工作地点返回住宅区时刻符合高斯分布, 概率密度表达式为

$$f_{T,W-H}(x) = \begin{cases} \frac{1}{\sqrt{2\pi}\sigma_{T,W-H}} \exp\left(-\frac{(x-\mu_{T,W-H})^2}{2\sigma_{T,W-H}^2}\right), & 6 \leq x \leq 24 \\ \frac{1}{\sqrt{2\pi}\sigma_{T,W-H}} \exp\left(-\frac{(x+24-\mu_{T,W-H})^2}{2\sigma_{T,W-H}^2}\right), & 0 \leq x < 6 \end{cases} \quad (2)$$

式中: $\mu_{T,W-H} = 17.1972$, 为离开工作地点时刻均值; $\sigma_{T,W-H} = 2.6197$, 为离开工作地点时刻方差。

每日出发前往工作地点与从工作地返回住宅耗时均符合对数正态分布, 概率密度表达式为

$$f_T(x) = \frac{1}{x\sqrt{2\pi}\sigma_T} \exp\left(-\frac{(\ln x - \mu_T)^2}{2\sigma_T^2}\right) \quad (3)$$

式中: $\mu_T = -1.0526$, 为行程耗时期望均值; $\sigma_T = 0.7491$, 为行程耗时方差。

每日行驶里程符合对数正态分布, 概率密度表达式为

$$f_M(x) = \frac{1}{x\sqrt{2\pi}\sigma_M} \exp\left(-\frac{(\ln x - \mu_M)^2}{2\sigma_M^2}\right) \quad (4)$$

式中: $\mu_M = 2.8314$, 为日行驶里程期望均值; $\sigma_M = 1.0575$, 为日行驶里程方差。

1.2 假设条件

单台电动汽车充电需求主要受电动汽车种类、行驶规律和充电功率等3个方面影响。参考目前电动汽车发展情况, 对家用电动汽车作出如下假设:

(1) 百千米耗电为 $16.7 \text{ kW} \cdot \text{h}$ 。

(2) 电动汽车一天仅需充电一次, 电池容量为 $70 \text{ kW} \cdot \text{h}$ 。

(3) 在工作区, 如果时间允许, 电动汽车采用慢充方式充电, 否则采用快充方式充电; 在住宅区, 电动汽车采用慢充方式充电; 电动汽车充电过程为恒功率, 快充、慢充充电功率分别为 8 kW 和 60 kW 。

(4) 每次充电均充至满电量。

(5) 电动汽车每日出行时刻、出行耗时、日行驶里程均为独立分布。

1.3 基于蒙特卡罗方法的电动汽车无序充电模拟

假设待研究区域的电动汽车总数为40万辆, 在无任何经济措施诱导和限制时, 工作日有40%的电动汽车选择白天在办公区域进行充电, 60%的车辆选择夜晚回家充电, 用户均选择到达目的地后立刻

充电, 且每辆电动汽车在工作日的通勤规律一致。基于上述电动汽车行驶规律概率分布和假设条件, 采用蒙特卡罗模拟法^[17]进行电动汽车无序充电模拟, 单个用户具体模拟过程如下: ① 抽取出发前往工作地点时刻 $T1$; ② 抽取前往工作地点耗时, 计算到达工作地点时刻 $T2$; ③ 抽取从工作地点返家时刻 $T3$; ④ 抽取从工作地点返家耗时, 计算到家时刻 $T4$; ⑤ 抽取总行驶里程, 计算所需充电电量 Q ; ⑥ 抽取电动汽车充电地点, 判断电动汽车充电方式, 生成充电功率曲线。

2 基于 Gap statistic 和 K-means++ 算法的风光出力典型日划分模型

风电和光伏出力受风能、太阳辐射强度等多种因素影响, 不同典型日出力场景下风光出力特性及其对电力系统的影响规律不尽相同; 为分析不同典型日下, 所提模型和优化调度方法的适用性和鲁棒性, 基于风光出力预测数据, 提出基于 Gap statistic 和 K-means++ 算法的风光出力典型日划分方法, 并用于不同典型出力场景下风光-电动汽车协同调度的差异化建模分析。

2.1 Gap statistic 算法

Gap statistic 算法^[18]是通过计算聚类有效指标, 确定数据集最佳聚类数目的方法, 其结果可以应用到任何一种聚类算法中。算法通过比较平均分布的参考数据集期望值 $E_n^* \{\log W_k\}$ 和观测数据集的 $\log W_k$, 判断使得 $\log W_k$ 下降最快的 k 值为最优聚类数, 其中 W_k 为标准化的簇内平方误差和。具体计算方法如下。

(1) 对已知观测数据集进行聚类, 计算 W_k :

$$W_k = \left\{ \begin{aligned} & \sum_{k=1}^K \frac{1}{2n_k} D_k \\ & D_k = \sum_{x_i \in C_k} \sum_{x_j \in C_k} \|x_i - x_j\|^2 \end{aligned} \right\} \quad (5)$$

式中: D_k 为第 k 簇数据中组内点间的欧氏距离之和; n_k 为属于第 k 簇的数据的个数; x_i 和 x_j 为数据观测点; C_k 为第 k 簇数据集; $k = 1, 2, \dots, K$ 。

(2) 生成 B 个参考数据集, 并计算每个参考数据集的 $E_n^* \{\log W_k\}$, 计算参考测度值 $\text{Gap}(k)$:

$$\left\{ \begin{aligned} & \text{Gap}(k) = E_n^* \{\log W_k\} - \log W_k \\ & E_n^* \{\log W_k\} = \frac{1}{B} \sum_b \log W_{kb}^* \end{aligned} \right\} \quad (6)$$

式中: W_{kb}^* 为第 b 个参考数据集的簇内平方误差和; $E_n^* \{\log W_k\}$ 为 $\log W_k$ 的期望; $b = 1, 2, \dots, B$ 。

(3) 计算 $E_n^* \{\log W_k\}$ 的标准偏差, 满足下述条

件的最小 k 值即为最佳聚类数.

$$\left. \begin{aligned} \text{Gap}(k) &\geq \text{Gap}(k+1) - s_{k+1} \\ s_k &= \sqrt{1 + \frac{1}{B} s d_k} \\ s d_k &= \sqrt{\frac{1}{B} \sum_b \log W_{kb}^* - E_n^* \{\log W_k\}} \end{aligned} \right\} \quad (7)$$

式中: s_k 和 $s d_k$ 为中间变量.

2.2 K-means++算法

K-means++ 聚类算法^[19]是基于 K-means 的改进算法,能够有效克服 K-means 算法对孤立点较敏感,聚类结果易受初始聚类中心的影响等问题. K-means++ 算法基本思想为假设已选取 k 个初始聚类中心($1 < k < K$),则在选取第 $k+1$ 个聚类中心时,距离当前 k 个聚类中心越远的点会有更高的概率被选为第 $k+1$ 个聚类中心;随机选取第一个聚类中心($k=1$). K-means++ 算法的具体步骤如下:

(1) 给定含有 n 个样本的数据集 $X = (x_1, x_2, \dots, x_n)$, 从数据集中随机选取一个样本作为初始聚类中心.

(2) 计算每个样本与当前聚类中心之间的最短距离:

$$D_i^* = \min(\sqrt{(X_i - C_k)^2}) \quad (8)$$

(3) 计算每个样本被选为下一个聚类中心的概率:

$$P_i = D_i^* / \sum_i D_i^* \quad (9)$$

(4) 在 $[0, 1]$ 区间生成一个随机数 R , 用 R 依次减去 P_1, P_2, \dots, P_n , 取差值首次小于或等于 0 时对应的对象为下一个聚类中心.

(5) 重复(2)~(4)直至选取 K 个聚类中心.

(6) 计算每个其他样本数据对象与各类聚类中心的距离, 将其赋给最近的类.

(7) 计算每类数据对象的平均值, 将其作为每一类新的聚类中心.

(8) 重复(6)~(7)直至聚类中心不再发生变化, 从而得到最佳聚类结果.

2.3 风光出力典型日划分流程

基于 Gap statistic 和 K-means++ 算法的风光出力典型日划分的具体步骤如下:

(1) 数据采集及归一化处理. 基于风电场和光伏电站预测出力数据获取新能源预测出力数据, 采用最大最小归一化方法将其映射至 $[0, 1]$ 区间, 并将其处理为 $n_d \times 96$ 维新能源标准出力矩阵(n_d 为采样天数).

(2) 新能源出力特征值提取. 考虑到光伏仅在白天存在出力, 且新能源出力对夜间负荷影响较大, 将每天 6:00—18:00 划分为白天, 其余时间段划分为夜间, 选取白天和夜间新能源出力均值和出力标准差作为特征值, 得到两组 $n_d \times 2$ 维特征值矩阵.

(3) 基于 Gap statistic 算法确定最佳聚类数. 基于白天、夜间出力特征值矩阵, 用 Gap statistic 算法分别确定最佳聚类数.

(4) 基于 K-means++ 算法进行聚类分析. 根据最佳聚类数, 以白天、夜间出力特征值矩阵为输入, 采用 K-means++ 聚类算法分别对白天、夜间新能源出力进行聚类分析.

(5) 白天和夜间聚类结果融合. 采用时间对标法对白天和夜间聚类结果进行融合, 获取不同出力场景下新能源出力.

(6) 不同出力场景典型日确定. 由于融合后无法确定聚类中心位置, 所以本文通过计算不同类别内各样本与其余样本的欧氏距离, 以欧氏距离之和最小的样本序列为该类别的聚类中心, 即该出力场景下的典型日.

3 风光-电动汽车协同调度模型

3.1 优化目标

等效负荷方差通过计算等效负荷在调度周期内的离散程度来衡量等效负荷整体波动性, 负荷追踪系数通过比较新能源出力与负荷的时序波动特性来衡量新能源出力与负荷的匹配程度. 考虑等效负荷整体波动和风光出力与负荷的匹配度, 构建以等效负荷方差和负荷追踪系数最小为双优化目标的风光-电动汽车协同调度模型.

(1) 等效负荷方差(F_1). 等效负荷方差主要衡量等效负荷整体波动性:

$$\left. \begin{aligned} \min F_1 &= \frac{1}{n_1 - 1} \sum_{t=1}^{n_1} (L(t) - P(t) - \bar{P}_{av})^2 \\ \bar{P}_{av} &= \frac{1}{n_1} \sum_{t=1}^{n_1} (L(t) - P(t)) \\ L(t) &= P_L(t) + P_{ev}(t) \\ P(t) &= P_w(t) + P_s(t) \end{aligned} \right\} \quad (10)$$

式中: n_1 为一个调度周期内数据点个数; $L(t)$ 为 t 时刻负荷; $P(t)$ 为新能源在 t 时刻的实际出力; \bar{P}_{av} 为该调度周期内等效负荷均值; $P_L(t)$ 和 $P_{ev}(t)$ 分别为 t 时刻电网负荷和电动汽车充电负荷; $P_w(t)$ 和 $P_s(t)$ 分别为风电、光伏在 t 时刻的实际出力.

(2) 负荷追踪系数. 等效负荷方差仅能衡量等

效负荷整体波动性,无法衡量风光出力与负荷的匹配度.为了使风光互补发电系统能够更好地跟随负荷变化,保障系统安全稳定运行,从源荷匹配度角度出发,采用能够衡量风光出力与负荷匹配关系的负荷追踪系数^[20](F_2)为优化目标:

$$\left. \begin{aligned} \min F_2 &= \frac{1}{n_1-1} \sum_{t=1}^{n_1-1} |\alpha(t)| \\ \alpha(t) &= \Delta L'(t) - \Delta P'(t) \\ \Delta P'(t) &= P'(t+1) - P'(t) \\ \Delta L'(t) &= L'(t+1) - L'(t) \end{aligned} \right\} \quad (11)$$

式中: $P'(t)$ 和 $L'(t)$ 分别为最大最小归一化处理后 t 时刻的新能源出力和负荷; $\Delta P'(t)$ 和 $\Delta L'(t)$ 分别 t 时刻为新能源出力和负荷的波动量标么值; $\alpha(t)$ 为 t 时刻新能源出力与负荷变化量变化的一致性.负荷追踪系数越接近于0,表明新能源出力与负荷在调度周期内的变化特性越一致,新能源联合出力与负荷匹配性越好.

3.2 约束条件

系统运行需满足如下约束.

系统功率平衡约束:

$$P_G(t) + P(t) = L(t) \quad (12)$$

式中: $P_G(t)$ 为常规机组在 t 时刻出力.

新能源出力约束:

$$\left. \begin{aligned} 0 \leq P_w(t) \leq P_w^i(t) \\ 0 \leq P_s(t) \leq P_s^i(t) \end{aligned} \right\} \quad (13)$$

$$\alpha \geq X' \quad (14)$$

式中: $P_w^i(t)$ 和 $P_s^i(t)$ 分别为风电场、光伏电站在 t 时刻的预测出力;为保证新能源消纳率,系统设定新能源最低消纳率 X' ,本文设为0.95; α 为实际新能源消纳率.

电动汽车电量约束:

$$Q_{\min} \leq Q(t) \leq Q_{\max} \quad (15)$$

$$Q(t+1) = Q(t) + p_{ev}(t) \Delta t \quad (16)$$

式中: $Q(t)$ 为 t 时刻电动汽车电量; Q_{\min} 和 Q_{\max} 分别为电动汽车电池储存容量的上下限; $p_{ev}(t)$ 为 t 时刻电动汽车充电功率; Δt 为充电时长.

3.3 求解方法

所提风光-电动汽车协同调度模型为多目标优化问题,采用NSGA-II多目标优化算法进行模型求解.NSGA-II算法通过引入快速非支配排序技术,提高了算法的速度,具有结构简单、收敛速度快、鲁棒性能好的优点,算法具体实施步骤见文献[21].

在多目标优化问题中,一般不存在一组解使得所有目标函数值同时达到各自的最优值,只能求得

非支配解集或 Pareto 解集.因此,本文采用模糊隶属度函数^[22]分别表示每个 Pareto 解中各目标函数对应的满意度,通过满意度比较找出最优折衷解.

4 算例分析

基于中国西北某省 2019 年风光电站预测出力和电网预测负荷数据进行算例分析,数据时间长度为 1 年,时间分辨率为 15 min.风电、光伏以及电网负荷比约为 11 : 9 : 13,风电场并网装机容量为 11 160 MW,光伏电站并网装机容量为 9 180 MW,电网最大负荷为 12 900 MW,风光装机容量达全省总装机容量的 40%,属于高比例新能源电网;假定该省共有 40 万辆电动汽车可供调度.

4.1 典型日划分

K-means++算法需要事先确定聚类数目,对此采用 Gap statistic 算法分别确定白天、夜间新能源出力最佳聚类数,聚类范围选定为 1~10 类.白天、夜间不同聚类数下 Gap 值如图 1 所示.根据 Gap statistic 原理,当聚类数分别为 5 和 4 时,白天和夜间的 Gap 值第一次满足条件,因此确定白天和夜间最佳聚类数分别为 5 类和 4 类.




图 1 最佳聚类数选取结果

Fig. 1 Selection results of optimal cluster number

采用 K-means++算法对新能源出力特征值进行聚类分析,聚类结果如图 2 所示.新能源白天出力可划分为 5 类波动情况,夜间出力可划分为 4 类波动情况.从均值看,白天对应的低出力小波动、低出力波动、中出力波动、高出力波动、高出力大波动分别分布在(0.05, 0.22)、(0.21, 0.33)、(0.32, 0.43)、(0.44, 0.58)、(0.56, 0.75)区间;夜间对应的低出力小波动、低出力波动、中出力波动、高出力波动分别分布在(0, 0.13)、(0.11, 0.24)、(0.19, 0.32)、(0.30, 0.48)区间.从方差看,白天对应的低出力小波动、低出力波动、中出力波动、高出力波动、高出力大波动的方差逐渐增大,表明新能源出力波动越大;

夜间对应的低出力小波动、低出力波动、中出力波动方差逐渐增大,高出力波动时新能源出力波动性有所降低,表明夜间风电高出力时全省风电平滑效应

较好。
采用时间对标法对白天和夜间聚类结果进行融合,获取不同典型日对应的新能源出力,如图 3 所

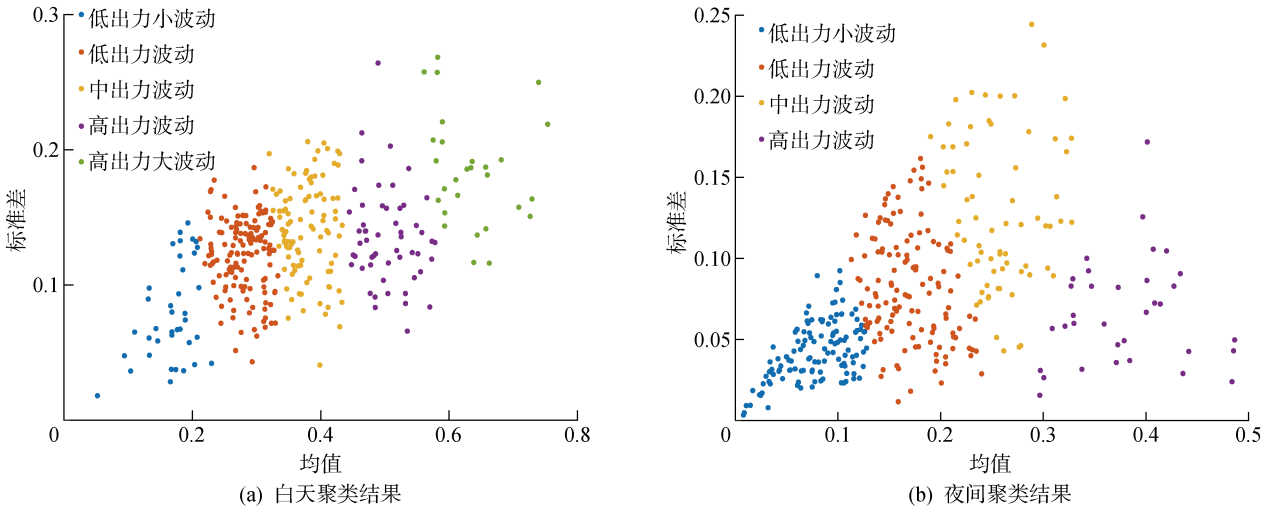


图 2 聚类结果图
Fig. 2 Results of clustering

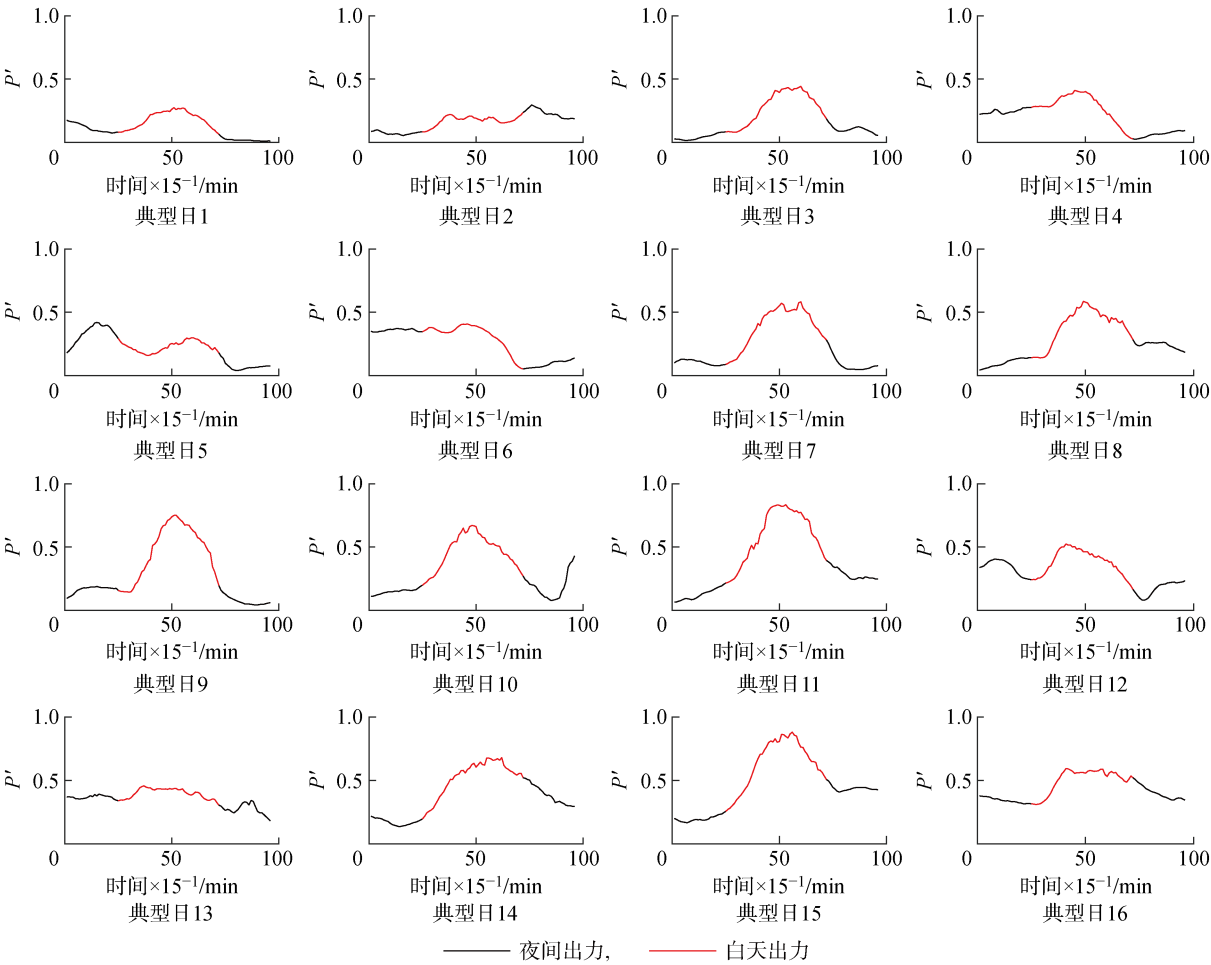


图 3 不同典型日下新能源出力
Fig. 3 New energy output on different typical days

示. 图中,时间分辨率为 15 min,全年共可划分为 16 类典型日,不同典型出力场景下新能源出力具有一定差异性,但同时具有一定相似性,且白天出力较大. 将其按照出力大小进行划分,主要可划分为全天低出力波动(典型日 1~4),主要包括白天、夜间低出力场景,出现率为 43.73%;白天低出力波动(典型日 5 和 6),主要包括白天低出力、夜间中出力场景,出现率为 5.29%;夜间低出力波动(典型日 7~10),主要包括夜间低出力和白天中、高出力场景,出现率为 27.30%;中出力波动(典型日 11~14),主要包括白天、夜间中出力场景,出现率为 15.04%;全天高出力波动(典型日 15 和 16),主要包括白天、夜间高出力波动场景,出现率为 8.64%;该地区新能源出力主要为全天低出力类型.

4.2 风光-电动汽车协同调度结果

为验证所提模型的适用性和鲁棒性,根据图 3 典型日划分结果,随机选取 5 种典型日出力场景,分别构建以等效负荷方差最小为单优化目标、以等效负荷方差和负荷追踪系数最小为双优化目标的风光-电动汽车协同调度模型,以等效负荷峰谷差(F_3)为指标评价不同优化结果. 单目标优化模型采用遗传算法进行求解,各项参数与 NSGA-II 算法具有相同设置. 5 种典型日出力场景下优化调度结果如表 1 所示. 不同典型日出力场景下,相比单目标优化调度模型,双目标优化调度模型的等效负荷峰谷差平均降低了 19%. 表明所提优化模型可以在降低等效负

荷整体波动性的基础上,提升新能源出力与电网负荷匹配度,缓解风光出力和电动汽车无序充电等多重不确定性对电力系统的不利影响,且在不同典型出力场景下均具有良好的适用性和鲁棒性.

为分析不同典型日对优化调度结果的影响,选取出力情况差异较大的典型日 5 和 15 进行具体分析,如图 4 所示,其中 P 为功率. 在图 4(a)和 4(b)中,从新能源预测出力曲线可知,典型日 5 在凌晨 2:00—5:00 出力较大;未进行调度时在 5:00 左右等效负荷波动存在低谷期. 对比图 4(a)和 4(b)新能源实际出力曲线可知,双目标优化时限电时刻更集中,主要发生于凌晨 3:00 左右;对比电动汽车有序充电曲线可知,二者整体趋势相似,均集中于凌晨进行充电.

图 4(c)和 4(d)中,从新能源预测出力曲线可知,典型日 15 新能源出力主要集中在白天 10:00—14:00;未进行优化调度时,受新能源出力影响,等效负荷在午间存在低谷期且该时段内波动较大. 对比图 4(c)和 4(d)可知,双目标优化限电主要集中于等效负荷低谷期;电动汽车充电时段尽可能集中于新能源出力最大时期,在全天其余时段,则尽可能平滑充电以降低对电网负荷的影响.

对比不同典型日双目标优化结果可知,新能源出力限电行为均主要发生在新能源出力较大和等效负荷波动较大的时刻;优化后电动汽车充电曲线根据典型日出力特性不同,随新能源出力变化而变化以降低新能源出力对电网负荷的影响.

为进一步分析出力场景对优化调度结果的影响,分别从典型日 5 和 15 中任选一天进行风光-电动汽车协同调度,与典型日优化调度结果进行对比分析,优化结果如图 5 所示.

图 5 中,不同出力场景下,优化后新能源限电行为均集中于出力较大时刻. 对比图 4(b)与图 5(a)可知,调度后电动汽车主要集中于夜间充电以降低新能源出力对电网负荷的不利影响;对比图 4(d)与图 5(b)可知,虽然新能源高出力时段存在差别,但电动汽车充电均集中于中午 12:00. 受新能源出力特性影响,在同一出力场景下,电动汽车充电效果具有很强的相似性;在不同出力场景下电动汽车充电效果具有明显的差异性.

综上所述,在不同出力场景下,电动汽车充电效果主要与此类典型日固有特征相关;所提优化调度模型在不同典型出力场景下均具有良好的适用性与鲁棒性.

表 1 不同典型日出力场景下优化调度结果
Tab.1 Optimal scheduling results of typical days in different output scenarios

典型日	优化目标	优化调度结果			
		F_2	F_1/MW^2	F_3/MW	$\alpha/\%$
4	单目标	0.10	3 395 218.02	16 110.13	95.06
	双目标	0.06	3 099 184.40	13 797.68	95.04
5	单目标	0.11	2 012 967.13	14 637.51	95.19
	双目标	0.07	1 832 434.89	14 463.81	95.03
9	单目标	0.08	6 138 278.51	24 960.08	95.01
	双目标	0.05	5 561 544.85	23 093.18	95.00
12	单目标	0.08	740 009.18	13 849.89	95.19
	双目标	0.05	475 042.78	11 241.12	95.03
15	单目标	0.09	1 481 212.29	20 593.76	95.01
	双目标	0.04	973 148.80	9 973.25	95.00




图 4 典型日优化结果
Fig. 4 Optimization results of typical days




图 5 非典型优化结果
Fig. 5 Results of atypical optimization

5 结论

提出一种面向高比例新能源并网场景的风光-电动车协同调度方法,所得结论如下:

(1) 基于 Gap statistic 和 K-means++ 算法的风光出力典型日划分模型能够实现白天和夜间新能源出力典型日的有效划分,新能源白天出力可划分为低出力小波动、低出力波动、中出力波动、高出力波动、高出力大波动共 5 类波动情况;夜间出力可划分为低出力小波动、低出力波动、中出力波动、高出力波动共 4 类波动情况,融合后共划分为 16 类典型出力场景。

(2) 以等效负荷方差和负荷追踪系数最小为双优化目标的源荷协同调度模型能够有效降低等效负荷波动性,提高新能源出力与电网负荷匹配度,从而减轻高比例可再生能源场景下风光出力和电动汽车无序充电不确定性对电力系统的不利影响。

参考文献:

- [1] 鲁宗相,李海波,乔颖. 含高比例可再生能源电力系统灵活性规划及挑战[J]. *电力系统自动化*, 2016, 40(13): 147-158.
LU Zongxiang, LI Haibo, QIAO Ying. Power system flexibility planning and challenges considering high proportion of renewable energy[J]. *Automation of Electric Power Systems*, 2016, 40(13): 147-158.
- [2] 游广增,汤翔鹰,胡炎,等. 基于典型运行场景聚类的电力系统灵活性评估方法[J]. *上海交通大学学报*, 2021, 55(7): 802-813.
YOU Guangzeng, TANG Xiangying, HU Yan, *et al.* Flexibility evaluation method for power system based on clustering of typical operating scenarios[J]. *Journal of Shanghai Jiao Tong University*, 2021, 55(7): 802-813.
- [3] 孙晓明,王玮,苏粟,等. 基于分时电价的电动汽车有序充电控制策略设计[J]. *电力系统自动化*, 2013, 37(1): 191-195.
SUN Xiaoming, WANG Wei, SU Su, *et al.* Coordinated charging strategy for electric vehicles based on time-of-use price[J]. *Automation of Electric Power Systems*, 2013, 37(1): 191-195.
- [4] JIAN L N, ZHENG Y C, SHAO Z Y. High efficient valley-filling strategy for centralized coordinated charging of large-scale electric vehicles[J]. *Applied Energy*, 2017, 186: 46-55.
- [5] SZINAI J K, SHEPPARD C J R, ABHYANKAR N, *et al.* Reduced grid operating costs and renewable

- energy curtailment with electric vehicle charge management[J]. *Energy Policy*, 2020, 136: 111051.
- [6] QUDDUS M A, KABLI M, MARUFUZZAMAN M. Modeling electric vehicle charging station expansion with an integration of renewable energy and Vehicle-to-Grid sources [J]. *Transportation Research Part E: Logistics and Transportation Review*, 2019, 128: 251-279.
- [7] SONG Y H, YANG X, LU Z X. Integration of plug-in hybrid and electric vehicles: Experience from China [C]// *IEEE PES General Meeting*. Minneapolis, MN, USA: IEEE, 2010: 1-6.
- [8] 侯建朝,胡群丰,谭忠富. 计及需求响应的风电-电动汽车协同调度多目标优化模型[J]. *电力自动化设备*, 2016, 36(7): 22-27.
HOU Jianchao, HU Qunfeng, TAN Zhongfu. Multi-objective optimization model of collaborative WP-EV dispatch considering demand response[J]. *Electric Power Automation Equipment*, 2016, 36(7): 22-27.
- [9] 冉忠,刘文颖,荣俊杰,等. 电动汽车参与受阻风电消纳的源荷优化控制方法[J]. *可再生能源*, 2020, 38(3): 358-365.
RAN Zhong, LIU Wenying, RONG Junjie, *et al.* Source-load optimization control method for electric vehicles participating in blocked wind power consumption[J]. *Renewable Energy Resources*, 2020, 38(3): 358-365.
- [10] 葛少云,黄镠,刘洪. 电动汽车有序充电的峰谷电价时段优化[J]. *电力系统保护与控制*, 2012, 40(10): 1-5.
GE Shaoyun, HUANG Liu, LIU Hong. Optimization of peak-valley TOU power price time-period in ordered charging mode of electric vehicle[J]. *Power System Protection and Control*, 2012, 40(10): 1-5.
- [11] 郭春林,杨晓言,徐轩,等. V2G 模式下电动汽车与可再生能源双层协调优化[J]. *电力系统及其自动化学报*, 2019, 31(9): 72-77.
GUO Chunlin, YANG Xiaoyan, XU Xuan, *et al.* Bi-level coordinated optimization of electric vehicles and renewable energy sources in V2G mode[J]. *Proceedings of the CSU-EPSA*, 2019, 31(9): 72-77.
- [12] 丁明,解蛟龙,刘新宇,等. 面向风电接纳能力评价的风资源/负荷典型场景集生成方法与应用[J]. *中国电机工程学报*, 2016, 36(15): 4064-4072.
DING Ming, XIE Jiaolong, LIU Xinyu, *et al.* The generation method and application of wind resources/load typical scenario set for evaluation of wind power grid integration[J]. *Proceedings of the CSEE*, 2016, 36(15): 4064-4072.

[13] 黎静华, 孙海顺, 文劲宇, 等. 生成风电功率时间序列场景的双向优化技术[J]. **中国电机工程学报**, 2014, 34(16): 2544-2551.
LI Jinghua, SUN Haishun, WEN Jinyu, *et al.* A two-dimensional optimal technology for constructing wind power time series scenarios[J]. **Proceedings of the CSEE**, 2014, 34(16): 2544-2551.

[14] 王开艳, 罗先觉, 贾嵘, 等. 充分发挥多能互补作用的风蓄水火协调短期优化调度方法[J]. **电网技术**, 2020, 44(10): 3631-3641.
WANG Kaiyan, LUO Xianjue, JIA Rong, *et al.* Short-term coordinated scheduling of wind-pumped-hydro-thermal power system with multi-energy complementarities[J]. **Power System Technology**, 2020, 44(10): 3631-3641.

[15] 温正楠, 刘继春. 风光水互补发电系统与需求侧数据中心联动的优化调度方法[J]. **电网技术**, 2019, 43(7): 2449-2460.
WEN Zhengnan, LIU Jichun. A optimal scheduling method for hybrid wind-solar-hydro power generation system with data center in demand side[J]. **Power System Technology**, 2019, 43(7): 2449-2460.

[16] Federal Highway Administration. National household travel survey (2017)[DB/OL]. (2019-04-23)[2020-12-17]. <http://nhts.ornl.gov>.

[17] 温剑锋, 陶顺, 肖湘宁, 等. 基于出行链随机模拟的电动汽车充电需求分析[J]. **电网技术**, 2015, 39(6): 1477-1484.
WEN Jianfeng, TAO Shun, XIAO Xiangning, *et al.* Analysis on charging demand of EV based on stochastic simulation of trip chain[J]. **Power System Technology**, 2015, 39(6): 1477-1484.

[18] TIBSHIRANI R, WALTHER G, HASTIE T. Estimating the number of clusters in a data set via the gap statistic[J]. **Journal of the Royal Statistical Society: Series B (Statistical Methodology)**, 2001, 63(2): 411-423.

[19] ARTHUR D, VASSILVITSKII S. K-Means ++: The advantages of careful seeding[C]//**Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms**. New Orleans, Louisiana, USA: ACM, 2007.

[20] 叶林, 屈晓旭, 么艳香, 等. 风光水多能互补发电系统日内时间尺度运行特性分析[J]. **电力系统自动化**, 2018, 42(4): 158-164.
YE Lin, QU Xiaoxu, YAO Yanxiang, *et al.* Analysis on intraday operation characteristics of hybrid wind-solar-hydro power generation system[J]. **Automation of Electric Power Systems**, 2018, 42(4): 158-164.

[21] DEB K. An efficient constraint handling method for genetic algorithms[J]. **Computer Methods in Applied Mechanics and Engineering**, 2000, 186(2/3/4): 311-338.

[22] 刘文颖, 文晶, 谢昶, 等. 考虑风电消纳的电力系统源荷协调多目标优化方法[J]. **中国电机工程学报**, 2015, 35(5): 1079-1088.
LIU Wenying, WEN Jing, XIE Chang, *et al.* Multi-objective optimal method considering wind power accommodation based on source-load coordination[J]. **Proceedings of the CSEE**, 2015, 35(5): 1079-1088.

(本文编辑:孙伟)