

基于场景分析的电力系统日前调度及其快速求解方法

要金铭,赵书强,韦子瑜,张 荟

(华北电力大学 新能源电力系统国家重点实验室,河北 保定 071003)

摘要:在含风光电力系统规模逐渐增大的背景下,提出一种基于场景分析的电力系统日前调度快速求解方法。考虑到不同时刻风光出力均具有显著相关性,基于多元正态分布和蒙特卡罗采样生成大量具有时间相关性的原始场景。利用改进的 k -means聚类算法对原始场景进行预分类,并采用基于Kantorovich概率距离的同步回代缩减算法对处理后的场景进行缩减,缩短场景分析的计算时间。建立基于场景分析的电力系统日前优化调度模型。为提高模型求解效率,引入包含风光预测误差向量信息的边界场景,在调度模型中考虑上下边界场景的备用容量约束,并建立考虑边界场景备用容量约束的优化调度模型。以某省级电网实测数据进行仿真分析,验证了所提模型及方法的有效性。

关键词:多元正态分布;蒙特卡罗抽样; k -means聚类;同步回代缩减算法;边界场景;备用容量

中图分类号:TM 734

文献标志码:A

DOI:10.16081/j.epae.202204022

0 引言

近年来,我国新能源装机容量保持快速增长,截至2020年底,全国风电装机容量达到 2.8×10^8 kW,光伏装机容量达到 2.5×10^8 kW^[1]。由于风光出力具有较强的随机性,传统的优化调度模型难以减少弃风、弃光现象,保证电网消纳能力^[2-3]。场景分析方法作为一种随机优化调度模型,通过对风光不确定变量进行抽样产生确定性的场景来表征不确定变量,具有较高的研究价值^[4-6]。

目前,国内外对场景分析方法已有较丰富的研究。在场景生成方面,相关研究主要是构造多元变量联合概率分布以及利用Copula函数获取相关性信息。文献[7]以多元标准正态分布表征单一风电场出力的波动性,较为合理地描述了风电功率的时间相关性。文献[8]建立混合藤Copula模型,对风光各自边缘分布进行连接,生成考虑空间相关性的风光联合出力场景。文献[9]基于地理位置和天气类型对光伏出力时间序列进行建模,保留了多座光伏电站在不同时间维度上的相关性。在场景缩减方面,主要研究方法有同步回代缩减算法、聚类算法等。文献[10]将目标风电场风速进行各场景等概率均分,将欧氏距离作为判断场景间概率距离的标准,具有一定的可信度。文献[11]采用基于Kantorovich概率距离的同步回代缩减算法对光伏出力场景进行缩减,可以较好地反映光伏出力的概率分布。文献[12-13]对 k -means聚类算法进行改进,将高密度区

域中的密度最大序列作为初始聚类中心,并通过最大最小距离原则选取其他聚类中心,提高了聚类中心选取的准确性。同步回代缩减算法的计算精度较高,但需要不断遍历原始场景集合,计算时间较长。 k -means聚类算法简单,收敛速度快,但不断迭代的聚类中心会解耦场景的时间相关性。文献[14]建立基于场景分析的前随机机组组合模型,通过忽略备用约束来提高模型的求解速度,但会降低系统的可靠性。文献[15]推导场景集的弃风电量期望和电量不足期望量化函数,针对每个场景均考虑备用不足造成的失负荷和弃风影响,将惩罚系数引入机组组合目标函数中,保证了系统安全运行,但增加了调度模型的计算量。

基于上述研究,本文提出一种考虑风光出力时间相关性的多场景电力系统日前优化调度快速求解方法。在场景生成与缩减方面,考虑到单一风光场站在相近时间区间内具有相关性,基于预测箱思想对风光出力的波动性进行建模,采用多元正态分布和逆变换抽样生成符合风光波动性的场景集合,为提高场景缩减效率,将改进的 k -means聚类算法和同步回代缩减算法相结合,利用改进的 k -means聚类算法将大量原始场景分成不同的类簇,并利用考虑Kantorovich距离的同步回代缩减算法将每个类簇内的场景集缩减为唯一的典型场景,所有典型场景的集合即为缩减后最有可能的场景集。在电力系统日前优化调度方面,建立风光火热多能源电力系统日前优化调度模型,为兼顾系统运行安全性和模型求解速度,提出包含风光预测误差向量信息的边界场景提取方法,通过上下边界场景的备用容量约束来考虑每个场景备用不足的情况。最后,通过算例验证了所提模型及方法的有效性。

收稿日期:2021-07-04;修回日期:2022-02-26

在线出版日期:2022-04-13

基金项目:国家重点研发计划项目(2017YFB0902200)

Project supported by the National Key Research and Development Program of China(2017YFB0902200)

1 考虑时间相关性的风光功率场景生成

1.1 风光功率波动性建模

风光功率在相邻时间断面不会任意波动,其波动幅度和范围均具有一定的概率。为得到可以描述跨时间断面风光出力的场景,需要对风光功率的波动性进行建模。

1.1.1 风电功率波动性建模

基于文献[16]中的预测箱思想,将风电功率数据进行分组。 t 时刻任意一组数据均包含风电功率的预测值 $P_{w,pre,t}$ 和实测值 $P_{w,act,t}$ 。文献[17]表明,对风电功率进行分组时,按区间大小等分效果更优。建立预测箱的具体步骤如下。

1) 找到风电功率预测值 $P_{w,pre,t}$ 的最大值 $P_{w,pre,max} = \max(P_{w,pre,t})$ 。

2) 将 $[0, P_{w,pre,max}]$ 等分为 K 个区间: $\left[0, \frac{1}{K}P_{w,pre,max}\right), \left[\frac{1}{K}P_{w,pre,max}, \frac{2}{K}P_{w,pre,max}\right), \dots, \left[\frac{K-1}{K}P_{w,pre,max}, P_{w,pre,max}\right]$ 。

3) 为每个区间构造对应数组,当 $P_{w,pre,t}$ 属于区间 k 时,将对应 $P_{w,act,t}$ 放入数组 k 。将所有数据分配完毕,得到 K 个数组,即 K 个预测箱。

预测箱的意义在于,同一预测箱内的风电功率预测值均十分接近,但其对应的风电功率实测值却存在很大差异,通过对数组内的风电功率实测值进行拟合,即可得到预测值在该区间时风电可能出力的概率分布曲线。由于同一预测箱内的风电功率预测值相近,所得风电可能出力的概率分布曲线同样可以表征风电功率预测误差的概率分布。需要指出的是,不同预测箱内风电功率实测值的概率分布是不同的,难以通过确定的解析分布模型进行拟合,本文采用文献[18]中非参数的经验分布函数来估计风电功率概率分布。非参数的经验分布函数 $F_e(p)$ 为:

$$F_e(p) = \frac{1}{e} \sum_{r=1}^e \theta(p - x_r) \quad (1)$$

$$\theta(p - x_r) = \begin{cases} 1 & p \geq x_r \\ 0 & p < x_r \end{cases} \quad (2)$$

式中: p 为任意给定的出力值,其累积概率分布可以通过将样本中比 p 小的出力的概率进行累加得到; $x_r (r=1, 2, \dots, e)$ 为第 r 个样本, e 为样本总数,对每个样本 x_r 赋予相同的概率 $1/e$ 。

1.1.2 光伏功率波动性建模

采取与上述风电出力相似的预测箱思想,与风电出力不同的是,周期为1d的光伏出力一般呈单峰曲线,若仍按照等分预测功率区间来建立预测箱,则根据光伏出力分布曲线特点得到的光伏出力场景往往会出现从零出力值陡升的情况,不满足光伏实际

出力较为平滑的单峰曲线特征^[19],为此,基于光伏低出力数据较多而中高出力数量较少且分布平均的特点,本文提出组距呈阶梯状递增的不等分光伏预测箱思想。光伏出力预测箱分组示意图如图1所示(图中出力为标么值)。




图1 光伏出力预测箱分组示意图

Fig.1 Schematic diagram of grouping for photovoltaic output prediction box

1.2 考虑时间相关性的场景生成

1.2.1 风光出力的逆变换采样

基于上述预测箱思想,找到每个时间断面风光功率预测值所属区间,即可对该区间对应的概率分布曲线进行抽样得到该时间断面的场景。对于存在相关性的连续时段风光功率,基于蒙特卡罗法的逆变换可以随机抽样大量具有时间相关性的风光样本。逆变换采样方式如式(3)所示。

$$P_t = F_e^{-1}(\phi(Z_t)) \quad (3)$$

式中: P_t 为 t 时刻的风光可能出力; $F_e^{-1}(\cdot)$ 为经验分布函数 $F_e(\cdot)$ 的反函数; Z_t 为服从标准正态分布的随机数,其标准正态分布函数值 $\phi(Z_t)$ 服从 $[0, 1]$ 之间的均匀分布。

风光出力的逆变换采样示意图如附录A图A1所示。生成大量服从 $[0, 1]$ 之间均匀分布的随机数,这些随机数即为随机变量 P_t 的累积概率分布曲线的纵轴数值,求取这些数值对应的经验分布函数的反函数值,即为横轴的风光可能出力值。

1.2.2 风光出力的多元正态分布

单一风电场或光伏电站的出力在相近时间断面内具有一定的相关性,该出力的随机过程可视为一个随时间变化的向量 $\mathbf{P} = [P_1, P_2, \dots, P_T]^T$, 其中 T 为运行调度时段总时刻数。为体现风光出力在各时间断面之间的相关性,设置 $\mathbf{P}$ 服从期望为 $\boldsymbol{\mu}_0$ 、协方差为 $\boldsymbol{\Sigma}$ 的多元正态分布 $\phi(\boldsymbol{\mu}_0, \boldsymbol{\Sigma})$, 其中 $\boldsymbol{\mu}_0$ 为 T 维零向量, $\boldsymbol{\Sigma}$ 的表达式如式(4)所示。

$$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_{1,1} & \sigma_{1,2} & \cdots & \sigma_{1,T} \\ \sigma_{2,1} & \sigma_{2,2} & \cdots & \sigma_{2,T} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{T,1} & \sigma_{T,2} & \cdots & \sigma_{T,T} \end{bmatrix} \quad (4)$$

$$\sigma_{f,g} = \text{cov}(P_f, P_g) \quad f, g = 1, 2, \dots, T \quad (5)$$

式中: $\sigma_{f,g}$ 为 f 时刻功率 P_f 和 g 时刻功率 P_g 之间的协方差。

多元正态分布由 Σ 唯一确定, Σ 中各元素对应各时间断面之间的相关性, 能表征风光出力的时间相关性。为确定多元正态分布的最佳协方差矩阵, 利用指数型协方差函数^[20]对协方差 $\sigma_{f,g}$ 进行建模:

$$\sigma_{f,g} = \text{cov}(P_f, P_g) = \exp\left(-\frac{|f-g|}{\varepsilon}\right) \quad f, g = 1, 2, \dots, T \quad (6)$$

式中: ε 为范围参数, 表征变量间相关性的强弱。

当范围参数 ε 已知时, 协方差矩阵 Σ 唯一确定。为得到范围参数 ε 的最优值, 设计最优参数辨识目标函数 $\min I_\varepsilon$ 如式(7)所示。

$$\min I_\varepsilon = \frac{1}{N} \sum_{b \in B} |f_{\text{cdf}}(b) - f'_{\text{cdf}}(b)| \quad (7)$$

式中: N 为预抽样规模; B 为等距抽样点的集合; $f_{\text{cdf}}(b)$ 、 $f'_{\text{cdf}}(b)$ 分别为多元正态分布预抽样场景和风光功率历史数据的预测误差经验分布函数值。当 I_ε 最小时, 可认为多元正态分布预抽样场景和风光功率历史数据的预测误差经验分布函数距离最近, 即 ε 最优, 由该范围参数确定的风光出力场景与历史数据的时间相关性最强。

1.3 场景快速缩减方法

生成的大量场景会增加调度模型的计算量, 导致计算时间过长, 场景缩减的目的是将原始场景集缩减到能最大限度代表原始场景集的少量场景集。本文提出基于改进的 k -means 聚类算法和同步回代缩减算法相结合的场景缩减方法。首先利用改进的 k -means 聚类算法将原始场景分成不同的类簇^[21], 然后采用考虑 Kantorovich 距离的同步回代缩减算法将各类簇内的场景集缩减为唯一的典型场景, 最终得到的各类簇场景集即为可代表原始场景集的缩减场景集。Kantorovich 距离 $D_k(S_c, S'_c)$ 见式(8)。

$$D_k(S_c, S'_c) = \min \left\{ \sum_{s_v \in S_c, s'_v \in S'_c} d(s_v, s'_v) \eta(s_v, s'_v) \right\} \quad (8)$$

$$\eta(s_v, s'_v) \geq 0, \sum_{s'_v \in S'_c} \eta(s_v, s'_v) = p_{s_v},$$

$$\sum_{s_v \in S_c} \eta(s_v, s'_v) = p_{s'_v}, s_v \in S_c, s'_v \in S'_c$$

式中: S_c 、 S'_c 分别为第 c 个类簇中的原始场景集和保留场景集; $d(s_v, s'_v)$ 为场景 s_v 和 s'_v 的欧氏距离; $\eta(s_v, s'_v)$ 为场景 s_v 和 s'_v 的概率乘积; p_{s_v} 为场景 s_v 在场景集 S_c 中的概率; $p_{s'_v}$ 为场景 s'_v 在场景集 S'_c 中的概率。

需要指出的是, 由于本文改进的 k -means 聚类算法不存在场景概率, 而同步回代缩减算法需要根据场景概率进行缩减, 因此在场景缩减中按照任一类簇场景集中所有场景概率之和为 1 进行计算。考虑到实际情况为原始场景集中所有场景具有相同的概率且每个类簇的场景集最终只保留 1 个典型场景, 将缩减后的各场景概率按式(9)进行修正。

$$p_c = N_c / N_s \quad (9)$$

式中: p_c 为第 c 个类簇中典型场景的概率; N_c 为第 c 个类簇中缩减前的场景数; N_s 为原始场景集 S 中的场景数。

本文场景分析流程图如图 2 所示。缩减后的少量确定性场景可表征风光预测出力的不确定性, 并在日前优化调度模型中作为输入, 对火电及热电机组开机容量进行优化。

2 考虑预测误差的边界场景提取

第 1 节所述场景分析方法生成的场景为少量最有可能发生的场景, 没有考虑到边界场景可能引起的弃风、弃光和切负荷情况。本文提出一种利用风光历史出力预测和实测数据获得包含风光预测误差向量信息的边界场景提取方法。具体步骤如下。

1) 计算每个时刻的风光预测误差, 即:

$$P_{\text{pe},t} = P_{\text{act},t} - P_{\text{pre},t} \quad (10)$$




图2 场景分析流程图

Fig.2 Flowchart of scenario analysis

式中: $P_{pe,t}$ 为 t 时刻风光出力预测误差; $P_{pre,t}$ 、 $P_{act,t}$ 分别为 t 时刻风光出力预测值和实际值。

2)找到 $P_{pre,t}$ 的最大值 $P_{pre,max} = \max(P_{pre,t})$ 和最小值 $P_{pre,min} = \min(P_{pre,t})$,并将 $[P_{pre,min}, P_{pre,max}]$ 等分为 U 个区间。

3)为每个预测值区间构造对应的预测误差向量,当 $P_{pre,t}$ 属于区间 u 时,将对应的 $P_{pe,t}$ 放入该区间对应的预测误差向量 u 中,将所有数据分配完毕,得到 U 组向量。利用式(11)对各区间预测误差向量 u 中的元素进行排序。

$$u = \text{sort}(u) \quad (11)$$

式中: $\text{sort}(\cdot)$ 为升序排列函数,用于将向量 u 中的元素按从小到大的顺序重新排列。

4)对区间 u 的预测误差向量 u 设置置信水平 β_u , t 时刻上下边界对应的预测误差和场景为:

$$P_{wc,s'',t} = u \left(\text{floor} \left(\text{size}(u) \left(\frac{1}{2} + \frac{\beta_u}{2} \right) \right) + 1 \right) \quad (12)$$

$$P_{wc,s',t} = u \left(\text{ceil} \left(\text{size}(u) \left(\frac{1}{2} + \frac{\beta_u}{2} \right) \right) - 1 \right) \quad (13)$$

$$P_{s'',t} = P_{pre,t} + P_{wc,s'',t} \quad (14)$$

$$P_{s',t} = P_{pre,t} + P_{wc,s',t} \quad (15)$$

式中: $P_{wc,s'',t}$ 、 $P_{wc,s',t}$ 分别为 t 时刻上边界场景 s'' 和下边界场景 s' 的预测误差; $\text{size}(\cdot)$ 为统计数据函数,用于统计向量 u 中元素的个数; $\text{floor}(\cdot)$ 为向下取整函数,用于求取小于等于指定数据的最大整数; $\text{ceil}(\cdot)$ 为向上取整函数,用于求取大于等于指定数据的最小整数; $P_{s'',t}$ 、 $P_{s',t}$ 分别为 t 时刻上边界场景 s'' 和下边界场景 s' 的功率。

以风电出力为例,本文所提考虑预测误差的边界场景提取原理图如图3所示。




图3 边界场景提取原理图

Fig.3 Principle diagram of boundary scenario extraction

3 基于场景分析的日前优化调度模型

3.1 风光出力场景与机组组合

在日前优化调度模型中,风光出力场景将作为输入数据确定机组组合的启停时序。由于存在风光多种随机变量场景集,模型计算规模会随着场景集数量的增加呈指数增长,采用按概率对应分配的原

则将风光生成场景进行组合。考虑到采用本文所提场景分析方法构建的缩减后风光最有可能发生的场景和上下边界场景可以保证场景覆盖面可控,将上述场景按等概率更新并输入调度模型,具体流程为:

1)将生成的风电与光伏场景集及缩减后的场景集按场景概率大小排序并对应组合;

2)将提取的风电与光伏上下边界场景对应组合;

3)将上述最有可能发生的场景与风光上下边界场景构成场景集 S ,将场景集 S 中的任意一组风光场景 s 的概率更新为 $1/N_s$,并将其输入优化调度模型中。

3.2 目标函数

日前随机机组组合是日前调度中的一个重要环节,在保证系统安全性的前提下,火电和热电机组的开机容量越小,风光消纳量越大。调度模型以火电和热电机组开机容量最小为目标函数,作为决策变量的机组启停状态可以满足场景集 S 中所有场景对应的约束。考虑到所提边界场景的日前优化调度模型可能无法求解,在目标函数中引入所有输入场景中切负荷的期望,保证调度模型可以进行求解。同时,为了降低切负荷在优化中的优先级,即仅在模型不可行时才进行切负荷,通过取较大的惩罚系数对切负荷量进行限制。目标函数 $\min F$ 如式(16)所示。

$$\min F = \min \left(\sum_{t=1}^T \sum_{i=1}^{N_{coal}} B_{i,t}^{N_{coal}} P_{i,max}^{N_{coal}} + \sum_{t=1}^T \sum_{j=1}^{N_{chp}} B_{j,t}^{N_{chp}} P_{j,max}^{N_{chp}} + \sum_{t=1}^T \omega E_s(P_{loss,t,s}^{load}) \right) \quad (16)$$

式中: N_{coal} 为参与调度的常规机组数; $B_{i,t}^{N_{coal}}$ 为 t 时刻常规机组 i 运行状态的二进制变量,其值为1表示机组正常运行,为0表示机组停止运行; $P_{i,max}^{N_{coal}}$ 为常规机组 i 的出力上限; N_{chp} 为参与调度的热电机组数; $B_{j,t}^{N_{chp}}$ 为 t 时刻热电机组 j 运行状态的二进制变量,其值为1表示机组正常运行,为0表示机组停止运行; $P_{j,max}^{N_{chp}}$ 为热电机组 j 热功率对应的电功率上限; ω 为切负荷的惩罚系数,本文取为 10^3 ; $P_{loss,t,s}^{load}$ 为 t 时刻场景 s 中系统的切负荷量; $E_s(P_{loss,t,s}^{load})$ 为场景集 S 中所有场景的切负荷量期望。

3.3 约束条件

基于场景分析法的电力系统日前优化调度模型约束条件总体分为每个最有可能发生的场景满足的约束条件和边界场景满足的约束条件两大类。每个最有可能发生的场景满足的约束条件包括常规机组最大、最小出力约束,最小启停时间约束,爬坡约束,网络安全约束,功率平衡约束。多个场景的联合约束预留了一定的备用容量,为对调度模型进行快速

求解,对上下边界场景考虑系统的备用容量约束。

3.3.1 火电机组约束

火电机组运行需满足功率上下限约束、最小启停时间约束和爬坡约束。具体约束如式(17)所示。

$$\begin{cases} B_{i,t}^{N_{\text{coal}}} P_{i,\min}^{N_{\text{coal}}} \leq P_{i,t,s}^{N_{\text{coal}}} \leq B_{i,t}^{N_{\text{coal}}} P_{i,\max}^{N_{\text{coal}}} \\ (B_{i,t}^{N_{\text{coal}}} - B_{i,t-1}^{N_{\text{coal}}})(T_{i,\text{on}}^{N_{\text{coal}}} - T_{i,t-1}^{N_{\text{coal}}}) \geq 0 \\ (B_{i,t-1}^{N_{\text{coal}}} - B_{i,t}^{N_{\text{coal}}})(T_{i,\text{off}}^{N_{\text{coal}}} + T_{i,t-1}^{N_{\text{coal}}}) \geq 0 \\ -R_{i,\text{down}}^{N_{\text{coal}}} \Delta t \leq P_{i,t,s}^{N_{\text{coal}}} - P_{i,t-1,s}^{N_{\text{coal}}} \leq R_{i,\text{up}}^{N_{\text{coal}}} \Delta t \end{cases} \quad (17)$$

式中: $P_{i,\min}^{N_{\text{coal}}}$ 为火电机组*i*的出力下限; $P_{i,t,s}^{N_{\text{coal}}}$ 为*t*时刻场景*s*中火电机组*i*的出力; $T_{i,\text{on}}^{N_{\text{coal}}}$ 为火电机组*i*的最小连续运行时间; $T_{i,t-1}^{N_{\text{coal}}}$ 为*t-1*时刻火电机组*i*已保持原状态的时间,原状态为运行状态时,其值为正,原状态为停机状态时,其值为负; $T_{i,\text{off}}^{N_{\text{coal}}}$ 为火电机组*i*的最小连续停机时间; Δt 为火电机组调度运行时间步长; $R_{i,\text{up}}^{N_{\text{coal}}}$ 、 $R_{i,\text{down}}^{N_{\text{coal}}}$ 分别为火电机组*i*时间步长内的最大向上、向下爬坡速率。

3.3.2 热电机组约束

热电机组主要有背压式和抽汽式2种,2种热电机组的运行特性如附录B图B1所示。热电机组运行约束包括供热能量平衡约束、机组热功率及电功率上下限约束、最小启停时间约束和爬坡约束。为保证所有区域供热平衡,对每个区域进行就近供热,同时以时间窗内热能总量平衡代替任一时刻热能平衡的供热约束条件。具体约束如式(18)所示。

$$\begin{cases} \sum_{t=y-h/2}^{y+h/2} \sum_{j=1}^{N_{\text{chp}}} H_{j,t,s}^{N_{\text{chp}}} = \sum_{t=y-h/2}^{y+h/2} H_t^{\text{load}} \\ B_{j,t}^{N_{\text{chp}}} H_{j,t,s}^{N_{\text{chp}}} \leq H_{j,t}^{N_{\text{chp}}} \leq B_{j,t}^{N_{\text{chp}}} H_{j,\max}^{N_{\text{chp}}} \\ P_{j,\min}^{N_{\text{chp}}} \leq P_{j,t,s}^{N_{\text{chp}}} \leq P_{j,\max}^{N_{\text{chp}}} \\ (B_{j,t}^{N_{\text{chp}}} - B_{j,t-1}^{N_{\text{chp}}})(T_{j,\text{on}}^{N_{\text{chp}}} - T_{j,t-1}^{N_{\text{chp}}}) \geq 0 \\ (B_{j,t-1}^{N_{\text{chp}}} - B_{j,t}^{N_{\text{chp}}})(T_{j,\text{off}}^{N_{\text{chp}}} + T_{j,t-1}^{N_{\text{chp}}}) \geq 0 \\ (P_{j,t,s}^{N_{\text{chp}}} + R_j H_{j,t,s}^{N_{\text{chp}}}) - (P_{j,t-1,s}^{N_{\text{chp}}} + R_j H_{j,t-1,s}^{N_{\text{chp}}}) \geq -P_{j,\text{down}}^{N_{\text{chp}}} \\ (P_{j,t,s}^{N_{\text{chp}}} + R_j H_{j,t,s}^{N_{\text{chp}}}) - (P_{j,t-1,s}^{N_{\text{chp}}} + R_j H_{j,t-1,s}^{N_{\text{chp}}}) \leq P_{j,\text{up}}^{N_{\text{chp}}} \end{cases} \quad (18)$$

式中: h 为时间窗长度; y 为长度为*h*的时间窗中的中点时刻; $H_{j,t,s}^{N_{\text{chp}}}$ 为*t*时刻场景*s*中热电机组*j*的热功率; H_t^{load} 为*t*时刻系统的总负荷; $H_{j,\max}^{N_{\text{chp}}}$ 、 $H_{j,\min}^{N_{\text{chp}}}$ 分别为*t*时刻热电机组*j*的热功率上限和下限; $P_{j,\min}^{N_{\text{chp}}}$ 为热电机组*j*热功率对应的电功率下限; $P_{j,t,s}^{N_{\text{chp}}}$ 为*t*时刻场景*s*中热电机组*j*热功率对应的电功率; $T_{j,\text{on}}^{N_{\text{chp}}}$ 为热电机组*j*的最小连续运行时间; $T_{j,t-1}^{N_{\text{chp}}}$ 为*t-1*时刻热电机组*j*已保持原状态的时间,原状态为运行状态时,其值为正,原状态为停机状态时,其值为负; $T_{j,\text{off}}^{N_{\text{chp}}}$ 为热电机组*j*的最小连续停机时间; R_j 为热电机组*j*在同进汽量

下抽取单位蒸汽量时电功率的减少量; $P_{j,\text{up}}^{N_{\text{chp}}}$ 、 $P_{j,\text{down}}^{N_{\text{chp}}}$ 分别为热电机组*j*在纯凝工况下最大向上、向下爬坡功率。

3.3.3 线路传输功率及负荷功率平衡约束

基于场景分析法的电力系统随机优化调度需保证每个场景下线路传输功率在安全限制内,且各电源总功率与负荷功率相等。具体约束如式(19)所示。

$$\begin{cases} -P_{l,\max} \leq P_{l,t,s} \leq P_{l,\max} \\ \sum_{i=1}^{N_{\text{coal}}} P_{i,t,s}^{N_{\text{coal}}} + \sum_{j=1}^{N_{\text{chp}}} P_{j,t,s}^{N_{\text{chp}}} + P_{w,t,s} + P_{v,t,s} + P_{\text{load},t,s} = P_t^{\text{load}} \end{cases} \quad (19)$$

式中: $P_{l,\max}$ 为线路*l*的最大传输功率; $P_{l,t,s}$ 为*t*时刻场景*s*中线路*l*的功率; $P_{w,t,s}$ 、 $P_{v,t,s}$ 分别为*t*时刻场景*s*中风电和光伏的出力; P_t^{load} 为*t*时刻的负荷功率。

3.3.4 系统备用容量约束

场景分析法通过确定的场景集表征风光出力的不确定性,通常不单独设置备用容量约束,但以边界场景运行时可能会导致切负荷现象的出现,影响系统稳定运行。由于对每个场景均设置备用容量约束会导致计算量大幅增加,严重影响计算效率,因此,本文提出一种针对边界场景的备用容量约束,对上边界场景考虑负备用容量,降低弃风、弃光量,对下边界场景考虑正备用容量,降低切负荷的风险,在保证电力系统安全运行的同时,提高模型的求解速度。具体约束如式(20)所示。

$$\begin{cases} \sum_{i=1}^{N_{\text{coal}}} P_{i,t,s'}^{N_{\text{coal}}} + \sum_{j=1}^{N_{\text{chp}}} P_{j,t,s'}^{N_{\text{chp}}} - \sum_{i=1}^{N_{\text{coal}}} B_{i,t}^{N_{\text{coal}}} P_{i,\min}^{N_{\text{coal}}} - \sum_{j=1}^{N_{\text{chp}}} B_{j,t}^{N_{\text{chp}}} P_{j,\min}^{N_{\text{chp}}} \geq S_n \\ \sum_{i=1}^{N_{\text{coal}}} B_{i,t}^{N_{\text{coal}}} P_{i,\max}^{N_{\text{coal}}} + \sum_{j=1}^{N_{\text{chp}}} B_{j,t}^{N_{\text{chp}}} P_{j,\max}^{N_{\text{chp}}} - \sum_{i=1}^{N_{\text{coal}}} P_{i,t,s''}^{N_{\text{coal}}} - \sum_{j=1}^{N_{\text{chp}}} P_{j,t,s''}^{N_{\text{chp}}} \geq S_p \end{cases} \quad (20)$$

式中: $P_{i,t,s'}^{N_{\text{coal}}}$ 、 $P_{j,t,s'}^{N_{\text{chp}}}$ 分别为*t*时刻下边界场景*s'*中火电机组*i*的出力 and 热电机组*j*热功率对应的电功率; $P_{i,t,s''}^{N_{\text{coal}}}$ 、 $P_{j,t,s''}^{N_{\text{chp}}}$ 分别为*t*时刻上边界场景*s''*中火电机组*i*的出力 and 热电机组*j*热功率对应的电功率; S_n 、 S_p 分别为系统的正、负备用容量。

本文所提考虑边界场景的优化调度模型与基于场景分析的传统模型的区别主要在于增加了系统备用容量约束,并将包含风光预测误差向量信息的边界场景作为备用容量约束,提高风光消纳量,降低切负荷风险,并且提高模型求解效率。所提优化调度模型包含多组二进制变量,是混合整数线性规划模型,可以采用优化规划软件CPLEX对模型进行求解。

4 算例分析

4.1 算例介绍

为验证所提基于场景分析的电力系统日前优化调度模型的可行性与有效性,采用我国西北某省网2019年12月实际运行数据进行分析。以15 min作为时间分辨率,即每15 min采样1次,一天共96个采样点。算例包含:60台常规机组,总装机容量为19.517 GW;68台热电机组,总装机容量为17.430 GW;246座风电场,总装机容量为19.412 GW;351座光伏电站,总装机容量为9.216 GW。本文所提调度模型主要针对火电机组和热电机组开机方式进行优化,水电机组采取实际运行数据进行优化。

4.2 算例结果分析

4.2.1 场景生成结果分析

边界场景预测误差置信水平取为0.96,采用所提考虑时间相关性的场景生成方法生成风电和光伏发电各800个原始场景,并采用所提改进的 k -means聚类算法和同步回代缩减算法相结合的场景缩减方法进行缩减,得到风电和光伏发电最有可能发生的各8个场景及上下边界场景,分别如附录C图C1和图C2所示。由图可知,生成的风光场景均处于上下边界范围内,且在保证一定差异性的同时,均能基本覆盖实际出力的波动范围。需要特别指出的是,区域3的风电实测数据和区域2的光伏发电实测数据分别在第45和56个采样点超出边界场景范围,即此时预测误差超出了选取的预测误差置信水平。为验证所提场景生成和缩减方法在表征风光功率波动时的合理性,绘制15 min时段内风光功率实测值及所提方法生成场景的风光功率波动高斯分布拟合曲线,如图4所示(图中波动量均为标幺值),相应高斯




图4 风光功率波动高斯分布拟合曲线

Fig.4 Gaussian distribution fitting curves of wind and photovoltaic power fluctuation

分布拟合参数如附录C表C1所示。

由图4可知:生成场景的光伏功率与光伏功率实测值波动的标准差相同,2条拟合曲线的腰部特征相近;生成场景的风电功率与风电功率实测值波动的标准差区别较小,生成场景的风电功率波动拟合曲线具有比风电功率实测值波动拟合曲线略扁平的腰部特征,但整体拟合参数较接近。因此,采用所提场景生成和缩减方法生成的场景可以较好地表征风光出力特性。

所提场景生成方法的计算时间如附录C表C2所示。由表可知,所提场景分析方法对风光出力均具有秒级的场景生成和缩减速度,具有较高的计算效率。

4.2.2 调度结果分析

采用所提场景分析方法对所提考虑备用容量约束的风光火热多能源电力系统日前优化调度模型进行求解。日前优化调度模型利用MATLAB 2016b和YALMIP工具箱联合搭建,采用CPLEX 12.8对时间范围为一周的常规机组和热电机组的开机容量进行优化。各电源出力如图5所示,图中火电机组和热电机组出力为各机组在所有场景下出力的期望。由图可知,火电机组和热电机组出力在所有电源出力中贡献度较高。




图5 不同电源出力

Fig.5 Output of different power sources

各采样点的负荷损失期望值如附录C图C3所示。由图可知,所提模型在调度时段内的任意时刻均没有出现切负荷现象,具有较高的安全性。

图6为系统净负荷以及火电机组和热电机组的总开机容量。由于算例采用的调度时间范围为一周,火电机组和热电机组的总开机容量具有较为明显的7个调度时段,其中,在净负荷低谷期火电机组和热电机组的总开机容量相应减少,在净负荷高峰期火电机组和热电机组的总开机容量相应增加,符合实际运行规律。火电机组和热电机组开机具有一定的互补特性,如图中第96、288、576个采样点所示。




图6 火电机组和热电机组的总开机容量以及系统净负荷

Fig.6 Total start-up capacity of thermal and combined heat and power units and system net load

4.2.3 模型有效性分析

为验证所提日前优化调度模型的有效性,基于上述生成的场景采用3种模型进行对比分析:模型1,完全不考虑备用容量约束的调度模型;模型2,对每个场景均考虑备用容量约束的调度模型;模型3,本文所提考虑上下边界场景备用容量约束的调度模型。

3种模型火电机组和热电机组的总开机容量如图7所示。由图可知:3种模型火电机组和热电机组总开机容量变化对应的采样点均相同,即对备用容量约束的优化没有改变调度模型对净负荷变化反应的灵敏度;本文所提模型火电机组和热电机组的总




图7 3种模型火电机组和热电机组的总开机容量

Fig.7 Total start-up capacity of thermal and combined heat and power units for three models

开机容量处于模型1和模型2总开机容量形成的上、下包络线内;随着备用约束条件的增加,模型总开机容量也随之增加。

3种模型的弃风和弃光总功率如图8所示。由图可知,所提模型的弃风和弃光总功率同样处于模型1和模型2弃风和弃光总功率形成的包络线内。3种模型的弃风、弃光电量如表1所示。由表可知,本文所提模型具有最少的弃光电量和较少的弃风电量,且其风光消纳率与模型1相近,比模型2提高了1.32%,可以较好地实现风光消纳。




图8 3种模型的弃风和弃光总功率

Fig.8 Total abandoned wind and photovoltaic power of three models

表1 3种模型的弃风、弃光电量

Table 1 Abandoned wind and photovoltaic energy of three models

模型	弃风电量 / (GW·h)	弃光电量 / (GW·h)	风光消纳率 / %
1	3.43000	14.52025	97.70
2	18.78525	14.89330	95.68
3	11.22750	12.15050	97.00

此外,模型1—3的求解时间分别为1069.21、2074.76、1183.25 s,本文所提模型的计算时间比模型2缩短了891.51 s,比模型1仅增加114.04 s,因此,本文所提模型具有较快的求解速度。

5 结论

针对风光出力的不确定性,本文提出一种基于场景分析的日前调度快速求解方法,对场景生成和缩减方法以及日前优化调度模型两方面进行改进。具体结论如下。

1)在场景生成中,以多元正态分布表征风光出力的时间相关性。在场景缩减中,利用改进的k-means聚类算法对原始场景进行预分类,并采用基于Kantorovich概率距离的同步回代缩减算法进行场景缩减,有效缩短了场景分析的计算时间。

2)提出通过计算风光预测误差向量来提取边界场景的方法,在所提风光火热多能源电力系统优化调度模型中考虑上下边界场景的备用容量约束。算例结果表明,所提模型具有与不考虑备用约束调度模型相近的风光消纳率,以及比全场景均考虑备用

容量约束的调度模型更高的计算效率,在保证电力系统安全运行的同时,大幅缩短了模型的求解时间。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 国家能源局. 国家能源局新闻发布会介绍2020年度相关能源情况[EB/OL]. [2021-03-30]. http://www.nea.gov.cn/2021-03/30/c_139846095.htm.
- [2] 李志伟,赵书强,刘金山. 基于机会约束目标规划的风-光-水-气-火-储联合优化调度[J]. 电力自动化设备,2019,39(8):214-223.
LI Zhiwei, ZHAO Shuqiang, LIU Jinshan. Coordinated optimal dispatch of wind-photovoltaic-hydro-gas-thermal-storage system based on chance-constrained goal programming[J]. Electric Power Automation Equipment, 2019, 39(8): 214-223.
- [3] 彭春华,温泽之,孙惠娟,等. 计及风电置信风险的源网协调多目标优化调度[J]. 电力自动化设备,2021,41(1):69-78.
PENG Chunhua, WEN Zezhi, SUN Huijuan, et al. Source-grid coordination multi-objective optimal scheduling considering confidence risk of wind power[J]. Electric Power Automation Equipment, 2021, 41(1): 69-78.
- [4] HU J X, LI H R. A new clustering approach for scenario reduction in multi-stochastic variable programming[J]. IEEE Transactions on Power Systems, 2019, 34(5): 3813-3825.
- [5] 李运龙,李志刚,郑杰辉. 考虑风电不确定性和相关性的多区域电网分布鲁棒经济调度[J]. 电力自动化设备,2021,41(8):97-104.
LI Yunlong, LI Zhigang, ZHENG Jiehui. Distributionally robust economic dispatch of multi-regional power grid considering uncertainty and correlation of wind power[J]. Electric Power Automation Equipment, 2021, 41(8): 97-104.
- [6] 马燕峰,李鑫,刘金山,等. 考虑风电场时空相关性的多场景优化调度[J]. 电力自动化设备,2020,40(2):55-65.
MA Yanfeng, LI Xin, LIU Jinshan, et al. Multi-scenario optimal dispatch considering temporal-spatial correlation of wind farms[J]. Electric Power Automation Equipment, 2020, 40(2): 55-65.
- [7] 张峰,张鹏,梁军. 考虑风电功率不确定性的风电场出力计划上报策略[J]. 电力自动化设备,2019,39(11):34-40.
ZHANG Feng, ZHANG Peng, LIANG Jun. Wind farm generation schedule strategy considering wind power uncertainty[J]. Electric Power Automation Equipment, 2019, 39(11): 34-40.
- [8] 邱宜彬,欧阳誉波,徐蓓,等. 基于混合藤Copula模型的风光联合发电相关性建模及其在无功优化中的应用[J]. 电网技术,2017,41(3):791-798.
QIU Yibin, OUYANG Yubo, XU Bei, et al. Modeling of multi-dimensional wind and PV farm output correlation based on mixture vine Copula structures and its application in reactive power optimization[J]. Power System Technology, 2017, 41(3): 791-798.
- [9] 王晶,黄越辉,李驰,等. 考虑空间相关性和天气类型划分的多光伏电站时间序列建模方法[J]. 电网技术,2020,44(4):1376-1384.
WANG Jing, HUANG Yuehui, LI Chi, et al. Time series modeling method for multi-photovoltaic power stations considering spatial correlation and weather type classification[J]. Power System Technology, 2020, 44(4): 1376-1384.
- [10] 雷若冰,徐箭,孙辉,等. 基于相关性分析的风电场群风速分布预测方法[J]. 电力自动化设备,2016,36(5):134-140.
LEI Ruobing, XU Jian, SUN Hui, et al. Wind speed distribution forecasting based on correlation analysis for wind farm group[J]. Electric Power Automation Equipment, 2016, 36(5): 134-140.
- [11] 娄素华,胡斌,吴耀武,等. 碳交易环境下含大规模光伏电源的电力系统优化调度[J]. 电力系统自动化,2014,38(17):91-97.
LOU Suhua, HU Bin, WU Yaowu, et al. Optimal dispatch of power system integrated with large scale photovoltaic generation under carbon trading environment[J]. Automation of Electric Power Systems, 2014, 38(17): 91-97.
- [12] 卜凡鹏,陈俊艺,张琪祁,等. 一种基于双层迭代聚类分析的负荷模式可控精细化识别方法[J]. 电网技术,2018,42(3):903-913.
BU Fanpeng, CHEN Junyi, ZHANG Qiqi, et al. A controllable refined recognition method of electrical load pattern based on bilayer iterative clustering analysis[J]. Power System Technology, 2018, 42(3): 903-913.
- [13] 田力,向敏. 基于密度聚类技术的电力系统用电量异常分析法[J]. 电力系统自动化,2017,41(5):64-70.
TIAN Li, XIANG Min. Abnormal power consumption analysis based on density-based spatial clustering of applications with noise in power systems[J]. Automation of Electric Power Systems, 2017, 41(5): 64-70.
- [14] 雷宇,杨明,韩学山. 基于场景分析的含风电系统机组组合的两阶段随机优化[J]. 电力系统保护与控制,2012,40(23):58-67.
LEI Yu, YANG Ming, HAN Xueshan. A two-stage stochastic optimization of unit commitment considering wind power based on scenario analysis[J]. Power System Protection and Control, 2012, 40(23): 58-67.
- [15] 艾小猛,塔伊尔江·巴合依,杨立滨,等. 基于场景集的含风电电力系统旋转备用优化[J]. 电网技术,2018,42(3):835-841.
AI Xiaomeng, TAYIERJIANG B, YANG Libin, et al. Optimizing the spinning reserve in wind power system using scenario method[J]. Power System Technology, 2018, 42(3): 835-841.
- [16] 徐箭,洪敏,孙元章,等. 基于经验Copula函数的多风电场出力动态场景生成方法及其在机组组合中的应用[J]. 电力自动化设备,2017,37(8):81-89.
XU Jian, HONG Min, SUN Yuanzhang, et al. Dynamic scenario generation based on empirical Copula function for outputs of multiple wind farms and its application in unit commitment[J]. Electric Power Automation Equipment, 2017, 37(8): 81-89.
- [17] 徐野驰,颜云松,张俊芳,等. 考虑预测误差与频率响应的随机优化调度[J]. 电网技术,2020,44(10):3663-3671.
XU Yechi, YAN Yunsong, ZHANG Junfang, et al. Stochastic optimal dispatching considering prediction error and frequency response[J]. Power System Technology, 2020, 44(10): 3663-3671.
- [18] MA X Y, SUN Y Z, FANG H L. Scenario generation of wind power based on statistical uncertainty and variability[J]. IEEE Transactions on Sustainable Energy, 2013, 4(4): 894-904.
- [19] 姚志力,王志新. 计及风光不确定性的综合能源系统两层级协同优化配置方法[J]. 电网技术,2020,44(12):4521-4531.
YAO Zhili, WANG Zhixin. Two-level collaborative optimal allocation method of integrated energy system considering wind and solar uncertainty[J]. Power System Technology, 2020, 44(12): 4521-4531.
- [20] PINSON P, GIRARD R. Evaluating the quality of scenarios of short-term wind power generation[J]. Applied Energy, 2012, 96: 12-20.
- [21] 程海花,寇宇,周琳,等. 面向清洁能源消纳的流域型风光水多能互补基地协同优化调度模式与机制[J]. 电力自动化设备,2019,39(10):61-70.
CHENG Haihua, KOU Yu, ZHOU Lin, et al. Collaborative op-

timal dispatching mode and mechanism of watershed-type wind-solar-water multi-energy complementary bases for clean energy absorption[J]. Electric Power Automation Equipment, 2019, 39(10): 61-70.

作者简介:

要金铭(1997—),男,硕士研究生,主要研究方向为新能源电力系统优化调度等(E-mail: yaojinming97@163.com);

赵书强(1964—),男,教授,博士研究生导师,博士,研究



要金铭

方向为电力系统分析与控制、电力系统规划与可靠性等(E-mail: zsqdl@163.com);

韦子瑜(1993—),男,硕士研究生,主要研究方向为新能源电力系统优化调度等(E-mail: weiziyuhtml113@163.com);

张 荟(1997—),女,硕士研究生,主要研究方向为新能源电力系统优化调度等(E-mail: jsycz0214@163.com)。

(编辑 王锦秀)

Day-ahead dispatch and its fast solution method of power system based on scenario analysis

YAO Jinming, ZHAO Shuqiang, WEI Ziyu, ZHANG Hui

(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Baoding 071003, China)

Abstract: Under the background of gradual increase in the scale of power system with wind and photovoltaic power, a fast solution method of day-ahead dispatch for power system is proposed based on scenario analysis. Considering the wind and photovoltaic power at different times are of significant correlation, a large number of original scenarios with time correlation are generated based on multivariate normal distribution and Monte Carlo sampling. An improved k -means clustering algorithm is used to pre-classify the original scenarios, and the simultaneous backward reduction algorithm based on Kantorovich probability distance is adopted to reduce the processed scenarios, which reduces the calculation time of scenario analysis. A day-ahead optimal dispatch model of power system based on scenario analysis is established. In order to improve the solution efficiency of the model, the boundary scenarios containing predicted error vector information of wind and photovoltaic power are introduced, the reserve capacity constraints of upper and lower boundary scenarios are considered in the dispatch model, and an optimal dispatch model considering the reserve capacity constraints of boundary scenarios is established. The measured data of a provincial power grid is taken for simulation and analysis, verifying the effectiveness of the proposed model and method.

Key words: multivariate normal distribution; Monte Carlo sampling; k -means clustering; synchronous backward reduction algorithm; boundary scenario; reserve capacity

(上接第56页 continued from page 56)

Bad data identification of power system based on WGAN-GP

ZANG Haixiang, GUO Jingwei, HUANG Manyun, WEI Zhinong, SUN Guoqiang, ZHAO Jiawei

(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: With the integration of new energy sources into the electric power grid and the input of a large number of power electronic devices, the data types of power system are becoming more and more complicated. Aiming at the problem of poor performance and low efficiency of bad data identification in large-scale power system, a bad data identification method based on WGAN-GP (Wasserstein Generative Adversarial Network with Gradient Penalty) is proposed. Based on the state quantities in the historical database, the normal measurement data of multiple sections are obtained and the WGAN-GP model is trained. The measurement information containing bad data is input into the trained WGAN-GP model to obtain the corresponding measurement reconstruction data and the final measurement reconstruction error. In order to avoid the subjectivity of determining the threshold value manually, a determination method of bad data threshold value based on C4.5 decision tree model is proposed. By inputting the measurement reconstruction error into the trained decision tree model, the location of bad data in a group of measurement information can be identified. The simulative results of IEEE standard systems and a real provincial power grid show that compared with the existing methods, the proposed method has better identification performance and higher identification efficiency.

Key words: electric power systems; bad data identification; data-driven; Wasserstein generative adversarial network; decision tree model

附录 A:




图 A1 逆变换采样原理图

Fig.A1 Principle diagram of inverse transformation sampling

附录 B:

热电机组主要有背压式和抽汽式两种。背压式机组电功率完全由热功率决定，无调峰能力；抽汽式机组电功率和热功率构成一个封闭集合，在满足供热需求的同时电功率可在范围内调节，但随着热功率的增加电功率可调范围呈现先不变后缩小的趋势。




图 B1 热电机组运行特性

Fig.B1 Operating characteristics of combined heat and power units

附录 C:




图 C1 风电生成场景

Fig.C1 Wind power generation scenarios




图 C2 光伏生成场景

Fig.C2 Photovoltaic generation scenarios

表 C1 风光功率波动高斯分布拟合参数

Table C1 Gaussian distribution fitting parameters of wind and photovoltaic power fluctuation

电源类型	场景分析类型	期望	标准差
风电出力	实测值	0.003 0	0.009 7
	生成场景	0.002 9	0.010 5
光伏出力	实测值	0.000 8	0.023 1
	生成场景	0.000 8	0.022 6

表 C2 场景分析计算时间

Table C2 Calculation time for scenario analysis

电源类型	场景分析类型	时间/s
风电出力	场景生成	1.98
	场景缩减	2.13
光伏出力	场景生成	1.75
	场景缩减	2.41




图 C3 负荷损失的期望

Fig.C3 Expectation of load loss