

基于优化 Kriging 代理模型的场景分析法求解机组组合问题

崔承刚¹, 郝慧玲¹, 杨宁¹, 奚培锋²

(1. 上海电力大学自动化工程学院, 上海 200090; 2. 上海市智能电网需求响应重点实验室, 上海 200063)

摘要: 由于风电具有很强的波动性和不确定性, 为机组组合(Unit Commitment, UC)问题带来许多问题和挑战。因此, 提出了一种基于优化 Kriging 代理模型的场景分析法来处理风电的不确定性。首先通过“预测箱”方法生成大量场景, 然后由序列优化的 Kriging 代理模型估计各场景所对应的经济成本。同时, 根据风电不确定性及运行成本对系统的影响, 采用重要性采样法削减场景。通过考虑功率平衡和风电爬坡约束的随机机组组合(Stochastic Unit Commitment, SUC)模型验证了该方法的有效性。算例分析结果表明, 序列优化 Kriging 代理模型可以使用较少的场景预测场景运行成本。与 Kantorovich 距离法相比, 该方法的削减结果选择了较为重要的场景, 其求解结果具有更好的经济性和可靠性。

关键词: 场景分析法; 序列优化 Kriging 代理模型; 重要性采样法; 机组组合; 两阶段随机规划

Scenario analysis based on the optimization Kriging model for solving unit commitment problems

CUI Chenggang¹, HAO Huiling¹, YANG Ning¹, XI Peifeng²

(1. School of Automation Engineering, Shanghai Electric Power University, Shanghai 200090, China;

2. Shanghai Key Laboratory of Smart Grid Demand Response, Shanghai 200063, China)

Abstract: Because wind power has high volatility and uncertainty, it may bring many problems and challenges to the Unit Commitment (UC) problems. Therefore, a scenario analysis method based on the sequence Kriging model is proposed to solve wind power uncertainty. It generates a large number of scenarios by a “forecast bin” method. Then the operational cost of the corresponding scenarios is estimated by a sequence optimization Kriging model. At the same time, an important sampling method is adopted to reduce scenarios given the influence of wind uncertainty combined with the operational cost. The effectiveness of this method is verified by a stochastic unit commitment model considering power balance and wind ramping constraints. It is shown that the sequence optimization Kriging model can use fewer points to estimate the operational cost of the scenario set. Compared to the Kantorovich distance method, the result of the proposed method is more representative, and the resulting solution has better economy and reliability.

This work is supported by Youth Science Fund of National Natural Science Foundation of China (No. 51607111).

Key words: scenario analysis; sequence optimization Kriging model; importance sampling method; unit commitment; two-step stochastic programming

0 引言

随着风电渗透率不断提高, 其间歇性和随机性的特点给电力系统的安全稳定运行和调度提出一系列挑战^[1-2]。风速的随机变化会引起风电输出功率的随机波动, 从而导致电网频率波动剧烈, 使电力系统较难满足新能源的大规模并网和消纳要求, 并对其稳定性造成一定威胁^[3-4]。目前, 建立 SUC 模型

成为解决风电不确定性的有效方法。在该模型中, 由于场景分析法通过组合多个确定性场景问题来处理考虑不确定性因素的电力系统规划和运行问题^[5], 不仅可以得到更好的统计结果, 而且可以清晰地反映风电不确定性的概率特征, 因此通常使用该方法生成大量场景来表示风电的不确定性^[6]。

在场景分析法中, 第一种方法是采样法, 即先从设计空间中选择大量场景, 然后根据给定分布获取采样值或场景的概率。最常用的方法是蒙特卡洛采样法^[7], 以及时间序列采样、条件采样、分层采样法和拉丁超立方体采样法等^[8-9]。但是如果样本集

太小, 这类方法则无法表示原始概率, 可能会影响采样结果。第二种方法是聚类法, 即将原始场景集合减少到聚类集合中包含的场景数。其中包括 k 均值聚类、随机聚类和条件聚类等方法结合场景削减技术来削减场景^[10-13]。最后一种方法是场景生成和削减技术, 即首先生成大量场景, 然后根据 Kantorovich 距离法、前向和后向削减技术等来削减场景^[14-16]。

SUC问题与其他随机优化问题不同, 它需要在保证一定可靠性的基础上追求经济效益^[17]。该问题中存在一些小概率事件, 传统的场景分析法难以包含如极端爬坡事件等的场景, 这将导致系统运行约束的越限, 造成强迫弃风弃光或失负荷, 从而影响系统的稳定性和安全性^[18]。因此, 研究人员提出了一种从原始场景集合中根据场景重要性指标选择场景的重要性采样法。这些指标表示每个场景的重要性程度, 因此该方法可以通过一些低概率场景生成更稳定和可靠的解决方案^[19]。文献[20]通过建立两层决策模型研究电网的优化配置策略, 并通过多场景概率法使模型最优。在文献[21]中, 提出了一种类似的场景削减方法, 该方法通过损失函数的影响比较场景之间的相似性度量。文献[22]提出了一种前向聚类法, 根据灵敏度指数估计场景的重要性。文献[23]提出了采用 Wasserstein 距离指标和 K-means 聚类场景削减技术生成最优场景, 以实现有功网损最小、电压偏差最小的目标。

本文提出了一种结合优化 Kriging 代理模型的重要采样方法。首先根据少量场景建立 Kriging 代理模型; 其次, 通过该模型估计所有场景对应的运营成本; 再次, 考虑风电不确定性及运行成本对系统的影响, 采用重要性采样法削减场景, 并通过两阶段随机规划方法求解削减场景下的最优 UC 以提升能源利用效率^[24]。最后, 通过一个 10 火电机组和 1 台风机的 SUC 模型验证了本文方法的经济性和可靠性。

1 含风电的随机机组组合模型

1.1 目标函数

UC 问题的目标是确定一定负载水平下机组的启动、停止状态以及启动机组的运行点, 其目标函数如式(1)。

$$\begin{aligned} \min F = \min E_s [& \sum_{i \in I} \sum_{t \in T} (C^p(i, s, t) \cdot z(i, t) + C^l(s, t)) + \\ & \sum_{i \in I} \sum_{t \in T} [C^u(i, t) \cdot z(i, t) \cdot z(i, t-1) + C^d(i, t) \cdot z(i, t-1) \cdot z(i, t)] \end{aligned} \quad (1)$$

式中: i, s, t 为运行机组集合, 时间段集合以及场景集合; E_s 为所有场景燃料成本的估计值; $C^p(i, s, t)$ 为传统火电机组的发电成本; $C^l(s, t)$ 为弃风与切负荷的损失成本; $C^u(i, t)$ 和 $C^d(i, t)$ 分别为机组 i 的开机和停机成本; $z(i, t)$ 为机组 i 的启停状态, 如果机组 i 在时刻 t 开机, 则为 1, 否则为 0。

1.2 系统运行约束

1) 功率平衡约束

$$\sum_{i \in I} P(i, s, t) + P^w(s, t) - P^{\text{curt}}(s, t) = P^{\text{load}}(t) - P^{\text{ll}}(s, t) \quad (2)$$

式中: $P^w(s, t)$ 为风机的总输出功率; $P^{\text{load}}(t)$ 为总负荷需求。

2) 发电机功率约束

$$P^{\min}(i, s, t) \cdot z(i, t) \leq P(i, s, t) \leq P^{\max}(i, s, t) \cdot z(i, t) \quad (3)$$

式中, $P^{\min}(i, s, t)$ 和 $P^{\max}(i, s, t)$ 分别为机组 i 在时刻 t 的场景 s 中的最小和最大输出功率。

3) 机组爬坡约束

$$\begin{aligned} P(i, s, t) - P(i, s, t-1) & \leq RU_i \cdot z(i, t) \\ P(i, s, t-1) - P(i, s, t) & \leq RD_i \cdot z(i, t) \end{aligned} \quad (4)$$

式中: RU_i 和 RD_i 分别为机组 i 在时刻 t 上/下爬坡速率。

4) 机组最短开机/关机时间

$$\begin{aligned} T_i^{\text{on}} & \geq MU_i \\ T_i^{\text{off}} & \geq MD_i \end{aligned} \quad (5)$$

式中, MU_i , MD_i 为机组 i 的最短开停机时间; T_i^{on} , T_i^{off} 为机组 i 已开机/停机时间。

5) 旋转备用约束

$$\sum_{i \in I} P(i, s, t) \geq P^{\text{load}}(t) + R(t) \quad (6)$$

式中, $R(t)$ 为时刻 t 的系统旋转备用容量。

6) 网络潮流约束

$$P_l^{\min} \leq P(s, t, l) = \sum_{m=1}^M g_l^m \cdot P(s, t, m) \leq P_l^{\max} \quad (7)$$

式中: $P(s, t, l)$ 为场景 s 在线路 l 上流过的有功功率; g_l^m 为网络节点 m 对支路 l 的功率转移因子; $P(s, t, m)$ 为场景 s 在 t 时刻对节点 m 的有功注入功率; P_l^{\min} 、 P_l^{\max} 为支路 l 的最大传输容量和最小传输容量。

1.3 模型求解

系统净负荷变化的随机性为电力系统在机组调度问题中带来了一些困难和挑战^[25]。机组组合是电力系统运行调度中的关键环节, 对制定电网日前

发电调度计划具有重要指导作用。两阶段随机规划能够较好地解决日前及实时的UC问题。该方法将发电机组的启停决策及其机组的发电计划制定视为两个阶段的决策问题, 第一阶段决策机组启停状态, 旨在寻求给定条件下具有最小启停成本的UC方式; 第二阶段决策则用于已制定机组启停计划所对应次日机组的运行成本, 最终确定出机组的最佳组合方式^[26]。两阶段随机规划流程图如图1所示。

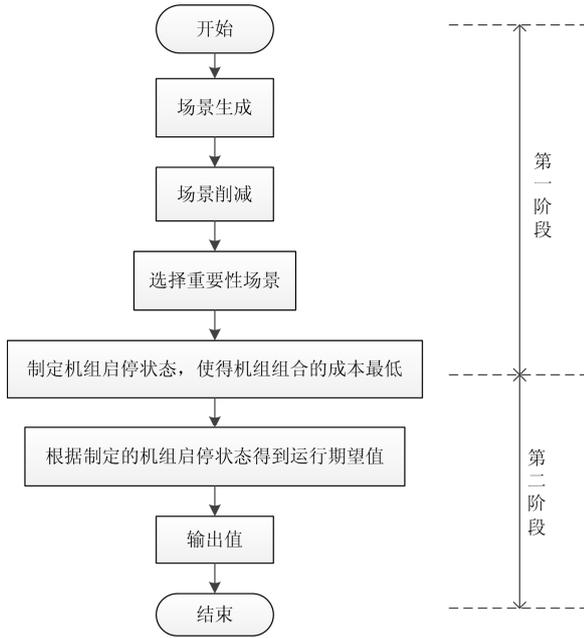


图 1 两阶段随机规划求解 UC 问题

Fig. 1 Two-step stochastic programming of UC

2 重要性采样法

蒙特卡罗法根据随机变量的概率密度函数进行采样, 为减少其计算量, 本文采用一种重要性采样法。在该方法中, 根据每个场景对应的运营成本与所有场景下的平均运营成本之比来选择一组场景^[27]。首先给定场景集合 $\Omega_s = \{s^1, s^2, \dots, s^M\}$ 以及场景概率分布 p , 则重要性度量值 q 被定义为特定输出值与期望值的比值, 其表示对目标函数 C (即运营成本) 权重的无偏估计。理想情况下, q 代表了场景调度结果对预期值的影响, 其定义为

$$q^*(s) = \frac{p(s)C(s)}{E_p C} \quad (8)$$

式中: p 为场景的概率分布; q 为场景的重要性度量值; q^* 为场景的理想重要性度量值; E_p 为场景概率分布 p 的期望。

由于 $E_p C$ 是最终的计算量, 因此 $q^*(s)$ 通过少

量场景的结果计算近似估计度量 q 。假设场景集合为 Ω_s , 原始测量 p 为均匀分布在 Ω_s 上, 所以 $p(s) = M^{-1}$, 其中 $s \in \Omega_s$; 每个场景相对于确定性问题的目标函数为 $C(s)$ 。该重要性度量值充分反映了场景对问题的重要性或对问题解和目标的影响, 该技术在减少计算量的同时, 还可以通过低基数的场景集合产生稳定的解。

3 序列优化 Kriging 代理模型

3.1 采样

拉丁超多维数据集采样方法(LHS)可保持样本之间的独立性, 并使所选样本更具代表性, 因此本文采用 LHS 进行数据采样。

3.2 建模

Kriging 代理模型由一个参数模型和一个非参数随机过程联合构成。

$$y(x) = F(\beta, x) + z(x) = \mathbf{f}(x)^T \beta + z(x) \quad (9)$$

式中: β 为回归系数; $F(\beta, x)$ 为多项式函数的线性组合; $\mathbf{f}(x)$ 为 x 的多项式矩阵, 在设计空间中提供模拟的全局近似; $z(x)$ 为模拟的局部近似, 均值为 0, 方差为 σ^2 , 协方差非零。

因此采样得到的样本集根据数值分析得到其对应的响应值, 基于样本及其响应值建立 Kriging 代理模型。具体建模过程如下:

- 1) 将场景对应确定性优化问题的所有约束条件转换为一个约束函数。
- 2) 计算采样自变量对应确定性优化问题的目标函数值和约束条件值, 形成目标函数和约束条件样本集合。
- 3) 分别对目标函数和约束函数建立与自变量之间 Kriging 代理模型。
- 4) 通过求取该代理模型的标准差用来判断 Kriging 代理模型估计是否有效。

3.3 多点加点准则

多点加点准则的思想是在每次迭代过程中增添多个新采样点, 其中包含预测均方差较大的点。首先, 给定一个大样本集, 选择具有较大均方差的采样点作为候选点。然后, 计算每个点之间的相关性, 并根据最优筛选准则删除候选样本集中的相关样本, 直到没有相关样本保留^[28]。各点之间的相关性计算如式(10)所示。

$$R(\theta, x^i, x^j) = \prod_{l=1}^L \exp[-\theta_l (x_l^i - x_l^j)^2] \quad (10)$$

如果任何两个候选点之间的相关性大于给定值

$R_{ih} \in (0,1)$ ，则这两个样本点被视为相关。当 R_{ih} 较大时，则要删除的点较少，反之亦然。本文采用一种最优删除方法，可保留数量较少、更重要且不相关的样本点。基于多点加点准则的选点过程及最优删除准则流程分别如图 2、图 3 所示。

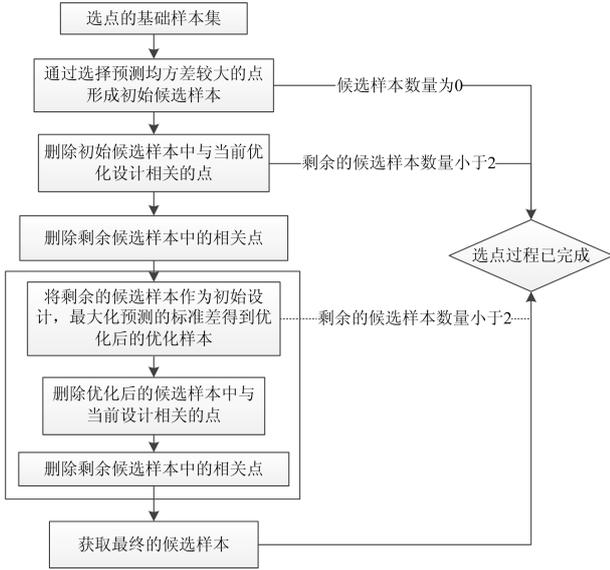


图 2 多点加点准则的选点过程

Fig. 2 Process of multi-point sampling criterion

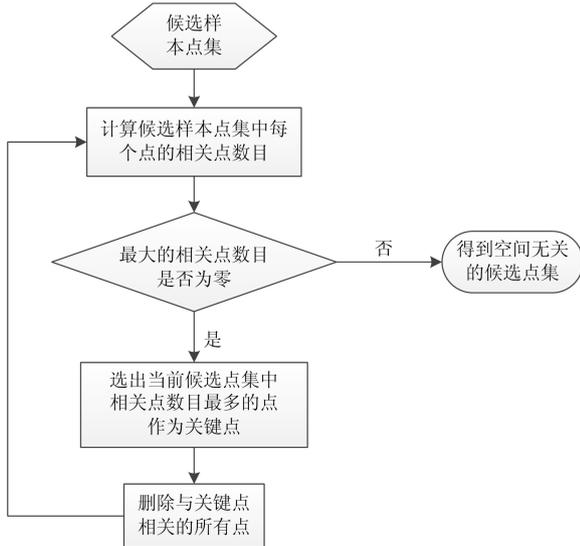


图 3 最优删除准则流程

Fig. 3 Process of optimal elimination method

3.4 收敛性判据

$$|\hat{f}_m(x_k) - f_m(x_k)| \leq \varepsilon, m = -1, 2, \dots, q \quad (11)$$

基于 Kriging 代理模型的序列优化过程如下：

- 1) 采用 LHS 获取初始样本集和相应输出值。
- 2) 使用 Matlab 的 DACE(计算机实验设计与分

析)工具箱^[29]，由 Step1 中得到的数据构建代理模型。

3) 获取要计算样本集对应的目标函数值。

4) 计算仿真值和相应的估计值之间的差异。如果满足收敛条件，则停止；否则，继续执行下一步。

5) 从样本空间中选择候选样本，根据多点加点准则以及最优筛选准则删除所选样本中的相关点。

6) 将最终候选样本添加到样本集中并返回 2)，重复此过程，直到收敛条件满足要求。

4 仿真及结果分析

本文以图 4 所示的 IEEE-39 节点 10 机系统为例，建立包括 10 台传统火电机组和 1 台风机的 SUC 模型进行验证，其中机组参数与负荷需求均来自爱尔兰岛电力公司网站^[30]，其数据详见表 1 和表 2，装机容量为 200 MW 的风电场接入母线 8。本文对风电数据进行了标幺化。求解步骤为：首先，通过“预测箱”法生成 1 000 个风电场景；其次，采用序列优化 Kriging 代理模型估计每个场景的目标函数值；然后结合重要性采样法进行场景削减。最后，利用商业软件 GAMS(一般代数建模系统)求解模型的最低成本问题。

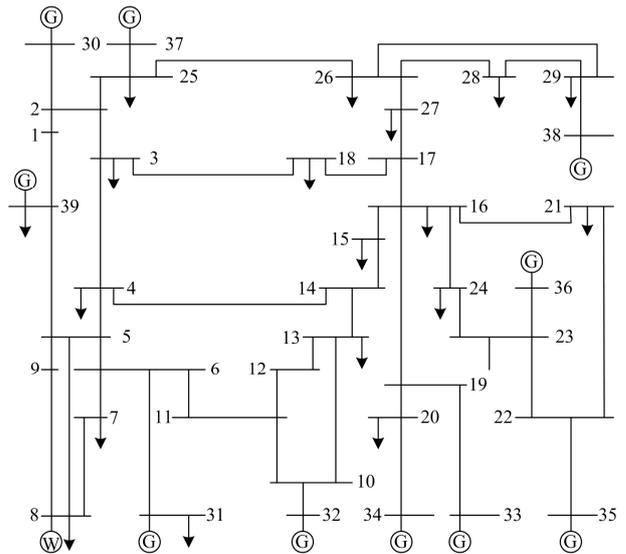


图 4 IEEE-39 节点系统单线图

Fig. 4 Single line diagram of IEEE-39 bus system

4.1 使用不同削减方法削减至不同数量场景时的运行期望值

本文分别采用 Kantorovich 距离法、Kriging 代理模型以及序列优化 Kriging 代理模型结合重要性采样法进行场景分析，分别将场景削减至 10 个、20 个、50 个和 100 个，并将其作为日内动态经济的输入，比较各方法下的运营成本，结果如表 3 所示。

表 1 火电机组参数

Table 1 Parameters of thermal power units

机组	最大出力/ MW	最小出力/ MW	成本常数 项/(美元/h)	成本一次项/ (美元/MW·h)	成本二次项/ (美元/MW ² ·h)	最小关 机时间	最小开 机时间	热启动 成本/\$	冷启动 成本/\$	已运行 时间/h	初始 状态/h
1	455	150	1 000	16.19	0.000 48	8	8	4 500	9 000	5	8
2	455	150	970	17.26	0.000 31	8	8	5 000	10 000	5	8
3	130	20	700	16.60	0.002	5	5	550	1 100	4	-5
4	130	20	680	16.50	0.002 11	5	5	560	1 120	4	-5
5	162	25	450	19.70	0.003 98	6	6	900	1 800	4	-6
6	80	20	370	22.26	0.007 12	3	3	170	340	2	-3
7	85	25	480	27.74	0.007 9	3	3	260	520	2	-3
8	55	10	660	25.92	0.004 13	1	1	30	60	0	-1
9	55	10	665	27.27	0.002 22	1	1	30	60	0	-1
10	55	10	670	27.92	0.001 73	1	1	30	60	0	-1

表 2 24 h 负荷情况

Table 2 Load demand of 24 hours

时刻	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8	t_9	t_{10}	t_{11}	t_{12}
负荷/MW	700	750	850	950	1 000	1 100	1 150	1 200	1 300	1 400	1 450	1 500
时刻	t_{13}	t_{14}	t_{15}	t_{16}	t_{17}	t_{18}	t_{19}	t_{20}	t_{21}	t_{22}	t_{23}	t_{24}
负荷/MW	1 400	1 300	1 200	1 050	1 000	1 100	1 200	1 400	1 300	1 100	900	900

表 3 基于三种方法削减至不同数量场景的运营成本

Table 3 Operating value of different number of reduced scenarios in the three methods

场景数量	Kantorovich 距离法	Kriging 代理模型	序列优化 Kriging 代理模型
10 个	544 990.372	542 175.596	542 171.560
20 个	543 456.971	543 369.984	543 403.813
50 个	559 798.535	556 215.246	536 410.580
100 个	566 783.032	566 359.611	565 780.443

由表 3 可知, 基于序列优化 Kriging 代理模型结合重要性采样法进行的场景分析法与其他两种方法相比, 该方法运营成本更低, 经济性更好。在削减至相同的场景数量时, 本文所提出方法得到的运营成本比 Kantorovich 距离法可减少 0.2%~4%, 比 Kriging 代理模型结合重要性采样法可减少 0.1%~3.6%。进一步, 在削减至 10 个、20 个和 50 个场景时, 本文所提方法下的运营成本标准差为 3 049, 波动较小, 而 Kantorovich 距离法与 Kriging 代理模型结合重要性采样法的标准差分别为 7 368 和 6 355, 波动较大且较不稳定。因此, 基于序列优化 Kriging 代理模型结合重要性采样法进行的场景分析法具有较强的经济性与可靠性。

4.2 序列优化 Kriging 代理模型的精确性分析

本文选取了 150 个风电场景及其对应的目标函数值进行分析。其中, 120 个场景被选为训练集,

其余 30 个场景作为测试集。通过计算目标函数预测值与实际值之间的误差, 证明序列优化 Kriging 代理模型计算量小且预测精度高的优势。代理模型的精度误差对比如表 4 所示。代理模型的预测误差及每次建立模型的样本数如图 5 所示。

由结果表明, 基于 100 个场景建立 Kriging 代理模型进行预测的误差为 0.61%, 而基于 35 个场景建立序列优化 Kriging 代理模型的预测误差便可达到 0.60%。同理, 基于 120 个场景建立 Kriging 代理模型进行预测的误差为 0.51%, 基于 37 个场景建立序列优化 Kriging 代理模型的预测误差便可达到 0.55%。结果表明序列优化 Kriging 代理模型可以使用较少的点来预测目标函数值并减少计算量, 且该模型的精确性基本保持不变。

表 4 以不同场景数量建立模型的预测误差

Table 4 Prediction error of the model is established based on the different number of scenarios

场景数量	基于 Kriging 代理模型的预测误差/%	场景数量	基于序列优化 Kriging 代理模型的预测误差/%
10 个	1.24	10 个	1.22
20 个	1.19	14 个	1.15
50 个	0.84	20 个	0.84
100 个	0.61	35 个	0.60
120 个	0.51	37 个	0.55

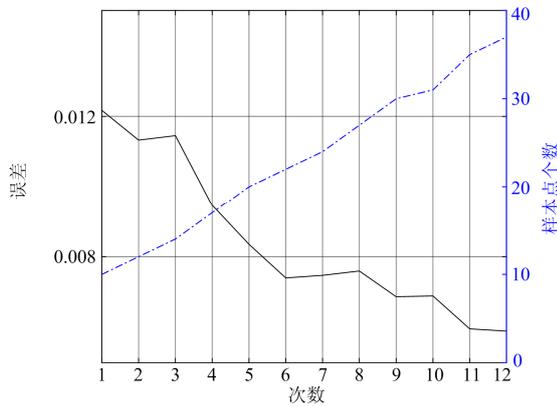


图 5 序列优化 Kriging 代理模型的预测误差及每次建立模型的样本数

Fig. 5 Prediction error of sequence Kriging model and the sample number of each model established

4.3 建立序列优化 Kriging 代理模型后削减至不同数量场景时的运营成本

为了分析建模场景数量对序列优化 Kriging 代理模型场景重要性估计的影响, 本文分析了不同建模场景数量对不同场景削减数量 UC 问题运行成本的影响。由 4.2 小节可知, 序列优化 Kriging 代理模型可由较少的场景数建立模型, 因此表 3 给出了基于 10 个、20 个和 40 个场景分别建立基于多点加点的 Kriging 代理模型, 并将 1 000 个场景分别削减至 10 个、20 个、50 个和 100 个, 运行期望值对比结果如表 5 所示。

表 5 基于不同场景数量建立模型进行场景削减得到的运行期望值

Table 5 Operating expectation obtained from the models established based on different number of scenarios

剩余场景数 \ 建模场景数	建模场景数		
	10 个	20 个	40 个
10 个	542 171.646	541 983.116	542 171.560
20 个	546 368.172	546 403.892	546 403.813
50 个	536 410.506	536 410.506	536 410.580
100 个	565 780.535	565 780.764	565 780.443

结果表明, 基于不同场景数量建立的 Kriging 代理模型削减至相同的场景数量时, 得到的运行成本波动较小, 其标准差分别为 88.85、29.13、0.06 和 0.23, 表明序列优化 Kriging 代理模型结合重要性采样法的场景分析法削减后的场景集合之间差异较小, 使得运行成本较稳定; 且剩余场景数量越多, 其所得运行成本越稳定。因此, 本文所提出的方法不仅可以使使用较少的场景数估计目标函数值, 并且基于重要性度量值进行削减后的场景作为日内经济

动态的输入, 其得到的成本更加稳定。

4.4 不同方法下的日前经济调度结果分析

UC 是电力系统运行的重要组成部分, 在保证安全运行的前提下, 确保最低运行成本。提前一天的 UC 决策可以为当天的动态经济调度提供各机组的启停状态信息, 且该结果的合理性将直接影响电力系统运行的经济性和可靠性。本文分别将 Kantorovich 距离法、Kriging 代理模型结合重要性采样法以及序列优化 Kriging 代理模型结合重要性采样法解决 UC 问题的经济性进行比较。

由表 6 可知, 本文所提出的方法与基于 Kantorovich 距离法的场景分析法相比具有更好的经济性, 尤其是燃料成本与切负荷成本经济效果较为显著。与基于 Kriging 代理模型结合重要性采样法的场景分析法对比可知, 尽管其解决经济调度问题所得结果一致, 即启停成本、燃料成本等均相同, 但建立序列优化 Kriging 代理模型时可减少计算量, 提高计算效率。

表 6 基于三种不同方法解决经济调度问题

Table 6 Economic dispatching problem solved based on three different methods

费用/元	Kantorovich 距离法	Kriging 代理模型	序列优化 Kriging 代理模型
启停成本	420	420	420
燃料成本	543 086.055	539 663.728	539 663.728
弃风成本	0	0	0
切负荷成本	91 032.477	66 032.477	66 032.477
总成本	634 538.532	606 116.205	606 116.205

5 结论

本文提出一种基于序列优化 Kriging 代理模型的场景分析法刻画风电的不确定性。该方法首先根据少量场景及其目标函数值建立序列优化 Kriging 模型。其次, 通过该模型估计所有场景运营成本。然后, 考虑风电不确定性及运行成本对系统的影响, 通过重要性采样法削减场景, 并采用两阶段规划法求解 UC 问题。仿真结果表明, 序列优化 Kriging 代理模型可以使用较少的场景数估计其目标函数值, 且精度基本保持不变。将重要性采样法与序列优化 Kriging 代理模型结合依据场景的重要性度量值进行场景削减, 使得削减后的场景更能反映其对机组运行的影响, 且基于不同场景数建立的代理模型削减得到的场景集合差异较小, 因此所得的运行成本较稳定。与 Kantorovich 距离法相比, 本文所提出的方法具有更好的经济性和稳定性。

参考文献

- [1] 段贵钟, 秦文萍, 逯瑞鹏, 等. 考虑风电接入与负荷不确定性的静态电压稳定性分析[J]. 电力系统保护与控制, 2018, 46(12): 114-120.
DUAN Guizhong, QIN Wenping, LU Ruipeng, et al. Static voltage stability analysis considering wind power access and load uncertainty[J]. Power System Protection and Control, 2018, 46(12): 114-120.
- [2] 孙勇, 魏敏, 王磊, 等. 基于系统调峰约束的电网风电消纳水平研究[J]. 电力系统保护与控制, 2019, 47(19): 107-112.
SUN Yong, WEI Min, WANG Lei, et al. Study on power grid wind power consumption level based on system peak regulation constraint[J]. Power System Protection and Control, 2019, 47(19): 107-112.
- [3] 郭亦文, 刘茜, 刘畅, 等. 火电机组深度调峰一次调频优化控制策略[J]. 热力发电, 2018, 47(11): 135-139.
GUO Yiwen, LIU Qian, LIU Chang, et al. Optimal control strategy for depth peak-adjusting and primary frequency modulation of thermal power units[J]. Thermal Power Generation, 2018, 47(11): 135-139.
- [4] 侯玉婷, 李晓博, 刘畅, 等. 火电机组灵活性改造形势及技术应用[J]. 热力发电, 2018, 47(5): 8-13.
HOU Yuting, LI Xiaobo, LIU Chang, et al. Situation and technology application of flexibility transformation of thermal power units[J]. Thermal Power Generation, 2018, 47(5): 8-13.
- [5] 边巧燕. 考虑概率分布不确定性的含风电场电力系统规划与运行问题研究[D]. 杭州: 浙江大学, 2015.
BIAN Qiaoyan. Study on the planning and operation of power system with wind power plant considering the uncertainty of probability distribution[D]. Hangzhou: Zhejiang University, 2015.
- [6] 谢上华. 随机机组组合问题中情景生成与削减技术研究[D]. 长沙: 湖南大学, 2013.
XIE Shanghua. Research on scenario generation and reduction in stochastic unit combination problem[D]. Changsha: Hunan University, 2013.
- [7] PARPAS P, USTUN B, WEBSTER M, et al. Importance sampling in stochastic programming: a Markov Chain Monte Carlo approach[J]. Informs Journal on Computing, 2015, 27(2): 358-377.
- [8] LI H P, ZANG C Z, ZENG P, et al. Scenario-based stochastic programming strategy for microgrid energy scheduling considering uncertainties[J]. Applied Mechanics & Materials, 2014, 13: 672-674.
- [9] YU H, CHUNG C Y, WONG K P, et al. Probabilistic load flow evaluation with hybrid Latin hypercube sampling and Cholesky decomposition[J]. IEEE Transactions on Power Systems, 2009, 24(2): 661-667.
- [10] KAUFMAN L, ROUSSEUW P J. Finding groups in data: an introduction to cluster analysis[M]. New York: Wiley, 1990.
- [11] SUTIENE K, MAKACKAS D, PRANEVICIUS H. Multistage K-means clustering for scenario tree construction[J]. Informatica, 2010, 21(1): 123-138.
- [12] GLPINAR N, RUSTEM B, SETTERGREN R. Simulation and optimization approaches to scenario tree generation[J]. Journal of Economic Dynamics & Control, 2004, 28(7): 1291-315.
- [13] LATORRE J M A, CERISOLA S, RAMOS A. Clustering algorithms for scenario tree generation: application to natural hydro inflows[J]. European Journal of Operational Research, 2007, 181(3): 1339-1353.
- [14] SHARMA K C, BHAKAR P J, ROHIT. Wind power scenario generation and reduction in stochastic programming framework[J]. Electric Power Components & Systems, 2013, 41(3): 271-285.
- [15] DUPACOVA J, GROWE-KUSKA N, ROMISCH W. Scenario reduction in stochastic programming: an approach using probability metrics[J]. Mathematical Programming, 2003, 95(3): 493-511.
- [16] MORALES J M, PINEDA S, CONEJO A J, et al. Scenario reduction for futures market trading in electricity markets[J]. IEEE Transactions on Power Systems, 2009, 24(2): 878-888.
- [17] NAREJO G B, AZEEM F, AMMAR M Y. A survey of control strategies for implementation of optimized and reliable operation of renewable energy based microgrids in islanded mode[C] // Power Generation System & Renewable Energy Technologies, June 10-11, 2015, Islamabad, Pakistan.
- [18] KUZNETSOVA E, RUIZ C, LI Y F, et al. Analysis of robust optimization for decentralized microgrid energy management under uncertainty[J]. International Journal of Electrical Power & Energy Systems, 2015, 64: 815-832.
- [19] PAPAVALIOU A, OREN S S. Multiarea stochastic unit commitment for high wind penetration in a transmission constrained network[J]. Operations Research, 2013, 61(3): 578-592.
- [20] LI J, XUE Y, TIAN L, et al. Research on optimal configuration strategy of energy storage capacity in grid-connected microgrid[J]. Protection and Control of Modern Power Systems, 2017, 2(4): 389-396. DOI:

- 10.1186/s41601-017-0067-8.
- [21] WANG Yan. Scenario reduction heuristics for a rolling stochastic programming simulation of bulk energy flows with uncertain fuel costs[D]. Ames: Iowa State University, 2010.
- [22] FENG Y, RYAN S M. Solution sensitivity-based scenario reduction for stochastic unit commitment[J]. Computational Management Science, 2016, 13(1): 29-62.
- [23] 吴丽珍, 蒋力波, 郝晓弘. 基于最优场景生成算法的主动配电网无功优化[J]. 电力系统保护与控制, 2017, 45(15): 152-159.
WU Lizhen, JIANG Libo, HAO Xiaohong. Reactive power optimization of active distribution network based on optimal scenario generation algorithm[J]. Power System Protection and Control, 2017, 45(15): 152-159.
- [24] 胡康, 陈群. 电-热综合能源系统整体能效及灵活性改造方案分析[J]. 热力发电, 2018, 47(5): 14-21.
HU Kang, CHEN Qun. Analysis of the overall energy efficiency and flexibility of the electrical-thermal integrated energy system[J]. Thermal Power Generation, 2008, 47(5): 14-21.
- [25] PAPPALA V S, ERLICH I, ROHRIG K, et al. A stochastic model for the optimal operation of a wind-thermal power system[J]. IEEE Transactions on Power Systems, 2009, 24(2): 940-950.
- [26] 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. Two-stage stochastic optimization of wind power system combination based on scenario analysis[J]. Power System Protection and Control, 2012, 40(23): 58-67.
- [27] LEE S, KIM J H. An adaptive importance sampling method with a Kriging metamodel to calculate failure probability[J]. Journal of Mechanical Science and Technology, 2017, 31(12): 5769-5778.
- [28] 高月华, 王希诚. 基于 Kriging 代理模型的多点加点序列优化方法[J]. 工程力学, 2012, 29(4): 90-95.
GAO Yuehua, WANG Xicheng. Multi-point point sequence optimization method based on Kriging agent model[J]. Engineering Mechanics, 2012, 29(4): 90-95.
- [29] LOPHAVEN S N, NIELSEN H B, SONDERGAARD J. DACE-A Matlab Kriging toolbox[R]. Lyngby: Technical University of Denmark, 2002.
- [30] HE Xiaodong, CUI Chenggang, YANG Ning. The Kriging model based scenario generation and its application in the Energy Internet with high wind penetration[C] // Proceedings of 2017 IEEE Conference on Energy Internet and Energy System Integration (EI2), November 26-28, 2017, Beijing, China: 1-6.

收稿日期: 2019-12-09; 修回日期: 2020-02-05

作者简介:

崔承刚(1981—), 男, 博士, 副教授, 主要研究方向为分布式能源系统、微电网、能源系统预测与优化调度等;
E-mail: cgcai@shiep.edu.cn

郝慧玲(1996—), 女, 通信作者, 硕士研究生, 研究方向为电力系统优化调度; E-mail: haohuilin96@163.com

杨宁(1976—), 男, 博士, 教授, 主要研究方向为状态监测、人员定位、数据融合。E-mail: yangning@shiep.edu.cn

(编辑 葛艳娜)