

# 基于随机模型预测控制的含大规模风电接入的 电力系统优化调度

王锐<sup>1</sup>, 张彦<sup>1†</sup>, 王冬<sup>2</sup>, 张涛<sup>1</sup>, 刘亚杰<sup>1</sup>

(1. 国防科技大学 系统工程学院, 长沙 410073; 2. 陆军勤务学院 国防经济系, 重庆 400041)

**摘要:** 风电是重要的清洁可再生能源, 将其引入智能电网中对节能减排有着重要的意义. 为降低大规模风电不确定性给电网调度带来的影响, 提出一种基于随机模型预测控制的风电与传统机组协调调度方法. 考虑了部分传统机组需要人工调度而无法频繁、连续操作的情况, 并引入可调负荷以增加系统可调度能力. 构建基于混合整数二次规划(MIQP)的风电调度目标函数, 以及包括机组最大可调节次数、最小运行/停机时间、可调度负荷总能量需求一致性、风电切负荷比例等约束. 提出两阶段场景缩减方法以实现典型场景的快速筛选. 通过与传统开环调度方法的性能对比表明所提出方法的可行性与有效性, 并在此基础上进一步分析机组启停次数和可调度负荷对系统运行的影响.

**关键词:** 风力发电; 随机模型预测控制; 离散化约束; 混合整数二次规划

中图分类号: TP273

文献标志码: A

## Optimization and scheduling of power system stochastic model predictive control based optimization and scheduling for power system with large scale wind integrated

WANG Rui<sup>1</sup>, ZHANG Yan<sup>1†</sup>, WANG Dong<sup>2</sup>, ZHANG Tao<sup>1</sup>, LIU Ya-jie<sup>1</sup>

(1. College of System Engineering, National University of Defense Technology, Changsha 410073, China; 2. Department of National Defense Economy, Army Logistics University of PLA, Chongqing 400041, China)

**Abstract:** Wind power is an important clean and renewable energy. Integrating it into smart grid is significant to the energy conversion and emission reduction. In order to reduce the negative impact introduced by uncertainties and randomness of large scale wind power integration, a stochastic model predictive control (SMPC) based optimization and scheduling approach is proposed to coordinate to the wind power and traditional fossil generators. The discrete generation regulation constraints of some traditional generators without the automatic generation control(AGC) function are considered, and schedulable loads are introduced to make the system more flexible. A mixed integer quadratic programming (MIQP) based energy management model is constructed, and the regulation frequency constraints, minimum up/down time constraints and discrete output constraints are all considered. A two-stage scenario cutting method is proposed to efficiently choose typical scenarios. Experimental results show that the approach proposed is flexible and efficient by comparing with the traditional scheduling approach. Furthermore, the impact of start-up/shut-down times and schedulable loads is discussed.

**Keywords:** wind power; stochastic model predictive control; discretized constraints; mixed integer quadratic programming

## 0 引言

能源是社会发展的基础, 是人类生活与生产的重要的能量来源<sup>[1]</sup>. 目前, 国际能源供应形势持续进展, 大力开发清洁、可持续的新型能源替代石化能源, 提高负载使用弹性和需求侧管理水平等措施<sup>[2-3]</sup>, 正日益受到各国的关注与重视. 近年来, 我国在以风

能为代表的可再生能源接入方面取得了举世瞩目的成就. 然而, 由于风能受到多种自然因素的影响而具有强烈的随机性、间歇性和不确定性, 长期的风电输出预测精度较低, 大规模风电接入对电力系统的运行将产生重大影响<sup>[4-8]</sup>. 传统的以长期预测数据为基础的日前计划调度方法难以满足大规模风电接入的

收稿日期: 2018-10-19; 修回日期: 2018-12-10.

基金项目: 国家自然科学基金项目(61773390, 71571187); 湖南省自然科学基金杰出青年基金项目(2017JJ1001); 湖南省湖湘青年英才计划项目(2018RS3081); 国防科技大学科研计划-重点项目(ZK18-02-09).

责任编辑: 孙秋野.

<sup>†</sup>通讯作者. E-mail: zhangyan10a@nudt.edu.cn.

要求<sup>[9]</sup>, 为保证含大规模风电的电力系统安全稳定运行, 大幅增加了系统的备用容量, 甚至产生严重的“弃风”现象<sup>[10]</sup>. 因此, 有必要建立灵活经济的大规模风电调度策略模型.

文献[10-12]将含大规模风电的调度策略考虑为旋转容量增加后的确定性调度问题, 研究如何优化系统的旋转备用容量. 但这类方法很难对风电不确定引起问题的严重性和可能性进行有效协调, 使得优化结果较难反映系统的实际运行风险. 文献[13-17]采用基于随机优化的动态经济调度方法考虑含大规模风电接入的优化调度问题, 通过构建场景树描述风电输出的不确定性. 但这类方法仍然是以日前调度为基础的开环调度模式, 在风电渗透率较高的情况下, 难以有效降低风电随机性、间歇性的影响. 文献[18-19]提出了基于鲁棒优化的含风电场动态经济调度模型, 但其开环调度的特点决定了鲁棒调度的结果相对更加保守, 使得其调度经济性有一定下降. 文献[9]提出了基于滚动优化的大规模风电接入调度策略, 采用拉格朗日对偶松弛法求解这一调度策略, 但其预测时域与控制时域没有随着时间推移而逐步向前, 在某种程度上降低了系统运行的效率, 且其没有考虑离散化输出等约束. 文献[20]在文献[9]的基础上进一步考虑传统机组中存在离散化输出等情况. 文献[21]提出了基于模型预测控制的大规模风电接入电网的有功分层调度方法. 其分层调度架构与模型预测控制(MPC)方法的闭环模式相结合, 较大程度上降低了风电输出不确定性的影响. 但该文献采用的模型预测控制模式是基于点估计的预测期望值进行优化调度的, 当风电随机性较强时, 此方法存在一定的不足. 文献[22]提出了基于随机模型预测控制(SMPC)的能源局域网优化调度模型, 考虑了风电、光伏等输出的不确定性, 但没有考虑机组离散化出力约束.

本文在充分考虑部分发电机组存在离散化出力特性的基础上, 针对含大规模随机风力发电接入、负载需求波动的电力系统, 提出一种基于随机模型预测控制的动态经济调度方法. 模型预测控制方法的闭环、反馈等特性能从运行机制上降低风电输出不确定对电力系统运行调度的影响, 同时, 该模型可将电力系统的控制问题直接转换为优化问题, 从而直接考虑发电机组离散化约束问题, 减少系统控制中复杂耦合性对物理建模的影响. 进一步, 针对基本模型预测控制方法仅采用点估计预测模型作为优化调度输入的不足, 融合基于场景的随机优化方法, 采用多个典型场景表达系统的不确定性, 更加贴近大规模风电接入电力系统运行的实际情况. 最后, 通过算例验证本

文所提出的优化调度方法的可行性和有效性.

## 1 随机场景下风电调度模型

本节将首先对含风电的电力系统进行描述, 并给出随机场景下的风电调度模型.

### 1.1 含风电的电力系统描述

本文研究的含大规模风电接入的电力系统如图1所示, 包括风电场、自动发电控制(AGC)机组和传统计划(TSCH)机组. 这些设备都受发电能量管理系统(EMS)的调度与控制. 其中, TSCH机组由于部署了很多年, 大多仍然采用人工开环调节的方式, 没有实现AGC, 因此, TSCH机组的出力无法像AGC一样频繁调节, 且其出力也需要EMS离散化以后下发给调度人员执行.

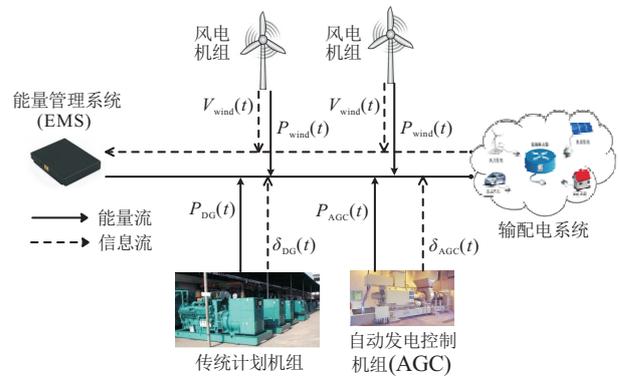


图1 含风电的电力系统示意

### 1.2 随机场景下的风电调度模型

在含风电的电力系统随机场景动态经济调度中, 各发电机组不仅需要满足所有场景下的出力限制约束和爬坡率约束, 还要满足离散化的发电调约束、最小运行/停机时间约束、机组调节次数约束等. 其目标函数是最小化各种场景下的系统运行成本, 这是一个混合整数二次规划模型(MIQP), 即

$$\begin{aligned} \min \quad & \sum_{t=1}^T \sum_{s=1}^S \pi^s \left( \sum_{i=1}^N [C(P_{i,DG}^s(t)) + \right. \\ & C_{i,DG}^{up} \max(\delta_{i,DG}^s(t), \delta_{i,DG}^s(t-1), 0) + \\ & C_{i,DG}^{down} \max(\delta_{i,DG}^s(t), \delta_{i,DG}^s(t-1), 0)] + \\ & \sum_{j=1}^M [(P_{j,AGC}^s(t)) + \\ & C_{j,AGC}^{up} \max(\delta_{j,AGC}^s(t), \delta_{j,AGC}^s(t-1), 0) + \\ & C_{j,AGC}^{down} \max(\delta_{j,AGC}^s(t), \delta_{j,AGC}^s(t-1), 0)] + \\ & \left. c_{wind}^{curt} C(P_{curt,wind}^s(t)) \right). \end{aligned} \quad (1)$$

其中:  $T$  为风电调度模型的预测与控制时域;  $t$  为时间指数, 表示以当前时间为起点的时间段(如 5 min、15 min、1 h 等), 并假设功率或状态等参数在这一时

间段内保持不变;  $P_{i,DG}^s(t)$ 、 $\delta_{i,DG}^s(t)$  分别表示 TSCH 机组  $i$  在场景  $s$  下时段  $t$  的有功出力 and 运行状态 ( $\delta_{i,DG}^s(t) = 1$  表示本时段处于运行状态,  $\delta_{i,DG}^s(t) = 0$  表示本时段处于停止状态);  $P_{j,AGC}^s(t)$ 、 $\delta_{j,AGC}^s(t)$  分别表示 AGC 机组  $j$  在场景  $s$  下时段  $t$  的有功出力 and 运行状态 ( $\delta_{j,AGC}^s(t) = 1$  表示本时段处于运行状态,  $\delta_{j,AGC}^s(t) = 0$  表示本时段处于停止状态);  $N$ 、 $M$  分别表示系统中 TSCH 机组与 AGC 机组的数量;  $C_{i,DG}^{up}$ 、 $C_{i,DG}^{down}$  分别表示 TSCH 机组  $i$  的启动与停机成本系数;  $C_{j,AGC}^{up}$ 、 $C_{j,AGC}^{down}$  分别表示 AGC 机组  $j$  的启动与停机成本系数;  $c_{wind}^{curt}$  为弃风惩罚系数;  $\pi^s$  为风电在场景  $s$  下的概率;  $S$  为总的典型场景数;  $\delta_{j,AGC}^s(0)$ 、 $\delta_{i,DG}^s(0)$  分别表示 AGC 机组  $j$  和 TSCH 机组  $i$  的初始运行状态。

$C(P_{i,DG}^s(t))$ 、 $P_{j,AGC}^s(t)$  分别表示 TSCH 机组  $i$  和 AGC 机组  $j$  在场景  $s$  下时段  $t$  的燃料成本。通常表示为二次形式, 即

$$C(P_{i,DG}^s(t)) = a_{i,DG}(P_{i,DG}^s(t))^2 \Delta t + b_{i,DG}P_{i,DG}^s(t)\Delta t + c_{i,DG}\delta_{i,DG}^s(t)\Delta t, \quad (2)$$

$$C(P_{j,AGC}^s(t)) = a_{j,AGC}(P_{j,AGC}^s(t))^2 \Delta t + b_{j,AGC}P_{j,AGC}^s(t)\Delta t + c_{j,AGC}\delta_{j,AGC}^s(t)\Delta t. \quad (3)$$

其中:  $a_{i,DG}$ 、 $b_{i,DG}$  和  $c_{i,DG}$  分别表示 TSCH 机组  $i$  的燃料成本系数,  $a_{j,AGC}$ 、 $b_{j,AGC}$  和  $c_{j,AGC}$  分别表示 AGC 机组  $j$  的燃料成本系数。

$C(P_{curt,wind}^s(t))$  表示风电机组在时段  $t$  的弃风惩罚成本, 有

$$C(P_{curt,wind}^s(t)) = a_{wind}(P_{curt,wind}^s(t))^2 \Delta t + b_{wind}(\delta_{curt,wind}^s(t))\Delta t. \quad (4)$$

其中:  $a_{wind}$  和  $b_{wind}$  为风电机组弃风惩罚成本系数,  $P_{curt,wind}^s(t)$  为风电机组  $t$  时段的弃风量,  $\delta_{curt,wind}^s(t)$  为风电机组在时段  $t$  的弃风行为状态。为保证系统的稳定运行, 要求发电侧与需求侧时刻满足供需平衡, 即

$$\sum_{i=1}^N P_{i,DG}^s(t) + \sum_{j=1}^M P_{j,AGC}^s(t) + P_{wind}^s(t) = \text{Load}(t) + L_{flex}(t). \quad (5)$$

其中:  $\text{Load}(t)$  为需求侧在时段  $t$  的负荷需求, 由于未进行智能化改装, 一般认为是关键性负载, 不考虑其可调度性, 且这部分负载预测相对于风力预测精度高很多;  $L_{flex}(t)$  为系统中的可调度负荷, 其运行功率在

一定范围内可调, 但一定时间 (一般设定为 1 天) 内总的负荷需求必须得到满足。另外

$$L_{flex}^{\min} \delta_{flex}^s(t) \leq L_{flex}^s(t) \leq L_{flex}^{\max} \delta_{flex}^s(t), \quad (6)$$

$$\sum_{t=1}^T L_{flex}^s(t) \Delta t = L_{total}. \quad (7)$$

其中:  $L_{flex}^{\min}$ 、 $L_{flex}^{\max}$  分别为可调度负荷的最小、最大可运行功率,  $\delta_{flex}^s(t)$  为可调度负荷在时段  $t$  的运行状态 ( $\delta_{flex}^s(t) = 1$  表示本时段处于运行状态,  $\delta_{flex}^s(t) = 0$  表示本时段处于停止状态),  $L_{total}$  为可调度负荷在一段时间内的总的能量需求。

由于 TSCH 机组的调度由人工操作执行, 其输出不仅需要满足下面的功率限制约束 (8)、爬坡率约束 (9), 还需要满足最小运行/停机时间约束 (10) 和 (11) 以及运行调节次数约束 (14)。并且其输出功率是离散化的表示形式 (即  $P_{i,DG}^s(t)$  每次调整量都为某一数值的整数倍, 例如 50 kW)。

$$P_{i,DG}^{\min} \delta_{i,DG}^s(t) \leq P_{i,DG}^s(t) \leq P_{i,DG}^{\max} \delta_{i,DG}^s(t); \quad (8)$$

$$-R_{i,DG} \leq P_{i,DG}^s(t) - P_{i,DG}^s(t-1) \leq R_{i,DG}; \quad (9)$$

$$\delta_{i,DG}^s(t) - \delta_{i,DG}^s(t-1) \leq \delta_{i,DG}^s(\tau_1), \quad \tau_1 = t, \dots, \min(k + T_{i,DG}^{up} - 1, T); \quad (10)$$

$$\delta_{i,DG}^s(t) - \delta_{i,DG}^s(t-1) \leq \delta_{i,DG}^s(\tau_2), \quad \tau_2 = t, \dots, \min(k + T_{i,DG}^{down} - 1, T); \quad (11)$$

$$\delta_{i,DG}^s(t) - \delta_{i,DG}^s(t-1) \leq \delta_{i,DGst}^s(t); \quad (12)$$

$$\delta_{i,DG}^s(t-1) - \delta_{i,DG}^s(t) \leq \delta_{i,DGsd}^s(t); \quad (13)$$

$$\sum_{t=1}^T \delta_{i,DGst}^s(t) + \Gamma \sum_{t=1}^T \delta_{i,DGsd}^s(t) \leq N_{switch}. \quad (14)$$

其中:  $P_{i,DG}^{\min}$ 、 $P_{i,DG}^{\max}$  分别表示 TSCH 机组  $i$  的最小和最大功率输出;  $R_{i,DG}$  为 TSCH 机组  $i$  的额定爬坡功率;  $\tau_1$ 、 $\tau_2$  均为引入的辅助参数, 分别表示 TSCH 机组  $i$  的最小运行与停机时间约束。

式 (12) 和 (13) 分别为引入辅助变量  $\delta_{i,DGst}^s(t)$ 、 $\delta_{i,DGsd}^s(t)$  的表达式。其中: 式 (12) 表示发电机组由停机转为运行的启动状态变化,  $\delta_{i,DGst}^s(t) = 1$  表示此刻发电机组启动; 式 (13) 表示发电机组由运行转为停止的停机状态变化,  $\delta_{i,DGsd}^s(t) = 1$  表示此刻发电机组停机。  $\delta_{i,DGst}^s(t)$ 、 $\delta_{i,DGsd}^s(t)$  均用于式 (14) 中发电机组  $i$  在  $T$  时间 (通常为 1 天) 内的最大运行调节次数,  $\sum_{t=1}^T \delta_{i,DGst}^s(t)$  表示发电机组  $i$  在  $T$  时间内启动的次数,  $\sum_{t=1}^T \delta_{i,DGsd}^s(t)$  表示发电机组  $i$  在  $T$  时间内停机的次数。

需要指出的是  $P_{i,AGC}^s(t)$  是离散化的变量, 即整型变量. 离散数据的间隔大小由 TSCH 机组  $i$  的容量和操作人员熟练程度决定. 对于 AGC 机组而言, 因其具有自动发电控制功能, 其运行调节不需要人工干预, 运行输出更加灵活, 故其约束条件没有 TSCH 机组那么复杂, 仅需要满足如下功率限制约束(15)、爬坡率约束(16)即可:

$$P_{j,AGC}^{\min} \delta_{j,AGC}^s(t) \leq P_{j,AGC}^s(t) \leq P_{j,AGC}^{\max} \delta_{j,AGC}^s(t), \quad (15)$$

$$-R_{j,AGC} \leq P_{j,AGC}^s(t) - P_{j,AGC}^s(t-1) \leq R_{j,AGC}. \quad (16)$$

其中:  $P_{j,AGC}^{\min}$ 、 $P_{j,AGC}^{\max}$  分别表示 AGC 机组  $j$  的最小和最大功率输出,  $R_{j,AGC}$  为 AGC 机组  $j$  的额定爬坡功率.

在基于场景的随机优化模型中, 风能输出功率不仅需要满足系统容量约束, 其弃风量也应当在一定的范围之内, 即

$$0 \leq P_{wind}^s(t) \leq \delta_{curt,wind}^s(t) P_{wind}^{\max}, \quad (17)$$

$$0 \leq P_{curt,wind}^s(t) \leq P_{wind}^s(t). \quad (18)$$

其中:  $P_{wind}^{\max}$  为风电机组的额定容量,  $P_{wind}^s(t)$  为风电在场景  $s$  下时段  $t$  的预测出力. 为进一步保证系统安全、稳定的运行, 提高应对风电输出不确定性的能力, 需要满足系统的旋转备用约束

$$\sum_{i=1}^N \min\{R_{i,DG}, (\delta_{i,DG}^s(t) P_{i,DG}^s(t) - P_{i,DG}^s(t))\} + \sum_{j=1}^M \min\{R_{j,AGC}(\delta_{j,AGC}^s(t) P_{j,AGC}^s(t) - P_{j,AGC}^s(t))\} \geq R(t), \quad (19)$$

其中  $R(t)$  为时段  $t$  的旋转备用要求. 式(19)表明系统的旋转备用容量满足旋转备用的要求.

## 2 基于SMPC的风电调度方法

基于日前规划调度方法在未接入大规模可再生能源的电力系统中运行效果较好, 但大规模风电输出的强随机性、间歇性会导致日前规划调度方法的性能出现较大退化. 基于 MPC 的优化调度方法也未能提供一种有效的方法来处理预测不确定性的影响<sup>[23]</sup>. 基于 SMPC 的调度方法作为 MPC 方法在处理随机性方面的改进, 能够利用统计信息模拟系统的不确定, 从而进一步降低随机性的影响.

### 2.1 风电出力不确定建模及场景筛选

随着我国风电接入规模越来越大, 对风电输出预测的研究也越来越多, 预测精度也在逐步提升. 但受

天气、地形地貌、季节等因素的影响, 风电的预测出力结果与实际情况还存在着较大的差距, 并且这一差距随着时间的推移变得越来越大<sup>[24]</sup>. 预测误差为

$$\epsilon_{wind}(t) = P_{wind}^{s,pre}(t) - P_{wind}^{act}(t), \quad (20)$$

其中  $P_{wind}^{act}(t)$  为风电时段  $t$  的实际功率.

为提高调度策略应对风电输出不确定性的能力, 利用式(20)所示的预测误差模型, 采用 Monte Carlo 方法生成  $N_{wind}$  组风电预测输出的随机场景, 每种场景都包含未来  $T$  时段内的风电输出预测值, 构成初始场景集. 这一场景集为  $R^{N_{wind} \times T}$  的矩阵, 每组场景的概率均为  $1/N_{wind}$ . 由于采用 Monte Carlo 方法生成的初始场景集合较大, 为提高调度模型的计算效率, 同时降低各场景之间的相似性, 有必要进行场景缩减. 本文在传统同步回代场景缩减法<sup>[13]</sup>的基础上, 提出基于两阶段缩减的改进场景缩减方法. 其具体步骤如下.

**Step 1:** 运用 Monte Carlo 方法生成包含  $N_{wind}$  个初始风电输出场景的集合.

**Step 2:** 依据初始场景集的规模大小, 将风电场景集分为  $N_{piece}$  个子集. 需要注意的是,  $N_{piece}$  数值一般较小, 进而保证每个场景子集中有足够的场景数, 使得每一个场景子集所选出的典型场景都与最终选出的典型场景具有较强的相关性.

**Step 3:** 第 1 阶段场景缩减, 多个场景自己并行缩减. 利用传统的同步回代场景缩减法<sup>[13]</sup>对每个场景子集进行缩减筛选, 使每个子集保留  $N_{tem}$  个场景, 并将所有子集保留的场景组成新的场景集合, 包含  $N_{tem} \times N_{piece}$  个场景.

**Step 4:** 第 2 阶段场景缩减, 各子集筛选场景组合缩减. 再次运用同步回代场景缩减法对新组建的场景集合进行场景缩减, 最终筛选出  $S$  个典型的风电输出场景.

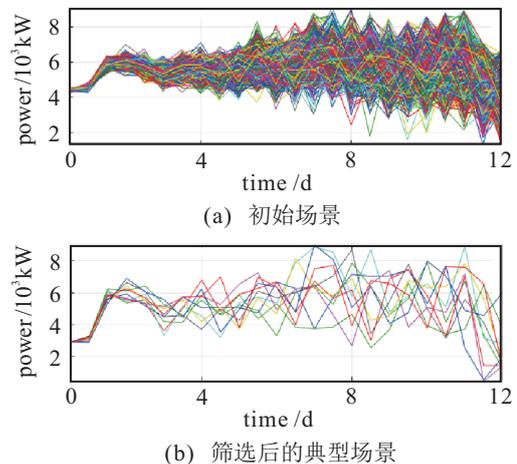


图2 风电初始场景与筛选后的典型场景

按照本文提出的基于两阶段缩减的改进场景缩减法从3000个初始场景中筛选出10个典型场景耗时仅为12s,而采用同一台电脑用传统场景缩减法耗时则需要约3min.

## 2.2 基于SMPC的风电调度模型

基于场景SMPC的风电调度模型是一种基于最大可能性的方法,在每一时段根据最新的能源局域网信息与更新的预测数据生成待优化的场景树.场景树上的每一个节点都代表一个能源局域网的状态,为了保证所有场景下求得的下一时段的调度TSCH一致以指导实际的运行,要求每种场景的根节点一致<sup>[22]</sup>.基于场景SMPC的含风电的电力系统优化调度模型如图3所示,分为:预先调度阶段和实时优化分配与功率补偿阶段.

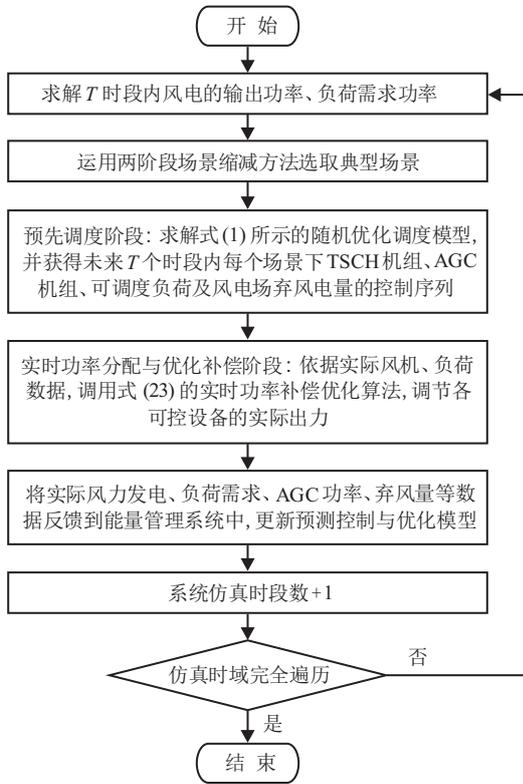


图3 基于SMPC的含风电电力系统优化调度

具体步骤如下:

Step1: 在 $k$ 时段后期,获取含风电的电力系统在未来 $T$ 个时段典型场景集合 $P_{\text{wind}}^{s,\text{pre}}$ ,为 $R^{S \times T}$ 矩阵;

Step2: 求解式(1)所示的含风电的电力系统优化调度模型,并获得未来 $T$ 个时段内每个场景下TSCH机组、AGC机组、可调度负荷及风电场弃风电量的控制序列 $[u^s(k+1|k), \dots, u^s(k+t|k), u^s(k+T|k)]$ .其中 $u^s(k+t|k)$ 的表达式为

$$u^s(k+t|k) = [P_{1,\text{DG}}^s(k+t|k), \dots, P_{i,\text{DG}}^s(k+t|k),$$

$$\begin{aligned} & \dots, P_{N,\text{DG}}^s(k+t|k), \\ & P_{1,\text{AGC}}^s(k+t|k), \dots, P_{j,\text{AGC}}^s(k+t|k), \\ & \dots, P_{M,\text{AGC}}^s(k+t|k), \\ & \delta_{\text{curt},\text{wind}}^s(k+t|k), L_{\text{flex}}^s(k+t|k)]. \end{aligned} \quad (21)$$

为保证各场景下,各机组在 $k+1$ 时段开始时控制指令的一致性,预先调度阶段需要对目标函数(1)再增加一个场景约束,即下一时段的决策与具体场景无关.有

$$\begin{aligned} P_{i,\text{DG}}^s(1) &= P_{i,\text{DG}}^{s+1}(1), \\ P_{j,\text{AGC}}^s(1) &= P_{j,\text{AGC}}^{s+1}(1), \\ P_{\text{curt},\text{wind}}^{s+1}(1) &= P_{\text{curt},\text{wind}}^s(1), \end{aligned} \quad (22)$$

其中 $s \in [1, S-1]$ .式(22)表明,所有场景下的控制序列在以当前时刻为起点的下一时刻都相同.

Step3:  $k+1$ 时段开始时,获得实际的风电输出数据,并以此为基础执行实时优化分配与功率补偿算法,计算AGC机组的实时运行功率 $P'_{\text{curt},\text{wind}}(k+1)$ 、风电场的实际弃风量 $P'_{j,\text{AGC}}(k+1)$ ,即

$$\begin{aligned} \min & c_{\text{wind}}^{\text{creal}} C(P'_{\text{curt},\text{wind}}(k+1)) + \\ & \sum_{j=1}^M C'(P'_{j,\text{AGC}}(k+1)). \end{aligned} \quad (23)$$

其中: $c_{\text{wind}}^{\text{creal}}$ 为实时功率分配阶段弃风操作的惩罚成本系数, $C'(P'_{j,\text{AGC}}(k+1))$ 为实时功率分配阶段AGC机组实际运行成本.

Step4: 将最新的风电输出数据、系统数据反馈到相应的模型中,以调整相关的参数.并继续从Step1开始重新执行,直到仿真结束.

## 3 算例分析

### 3.1 算例描述

本算例采用图1所示的含风力发电的电力系统结构.总的仿真时长为2周,控制(预测)时域为1天,每个时段间隔长度为0.5h,即 $T=48$ .在该系统中包含4台TSCH机组、2台AGC机组,设备参数如表1所示.其中SCH机组的调度间隔为50kW,即输出功率是50kW的倍数.风电输出数据以及负荷数据源于比利时电力传输系统数据库,关键负荷额定容量为8MW,风电机组额定容量为5MW.可调度负荷最大功率为1.6MW,最小运行功率为400kW,1天内总的能量需求为24MWh.具体的负荷、风电数据如图4所示.

由图4可见,风电输出功率在某些时段大于关键负荷需求,因此若不采用可调度负荷,则在某些时段将会产生弃风行为.

表1 TSCH机组及AGC机组参数

名称	最大最小功率/kW	运行成本系数 (\$/(kW) <sup>2</sup> , \$/kW, \$)	最小运行停机时间/h	爬坡功率
TSCH1	3500/150	$8.5 \times 10^{-4}, 0.66, 25$	3/3	3000
TSCH2	3000/200	$9.6 \times 10^{-4}, 0.58, 28$	4/4	2500
TSCH3	4000/200	$7.5 \times 10^{-4}, 0.64, 30$	3/3	3500
TSCH4	2500/100	$1.4 \times 10^{-3}, 0.49, 25$	3/3	2000
AGC1	500/5	$5.2 \times 10^{-3}, 1.06, 16$	—	400
AGC2	600/5	$6.8 \times 10^{-3}, 0.94, 14$	—	500

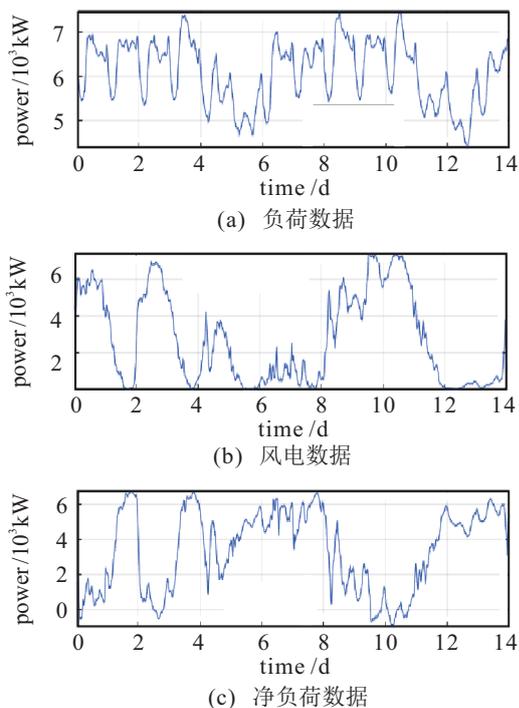


图4 风电、负荷及净负荷历史数据

3.2 仿真算例及结果分析

实验采用的设备配置为: Intel(R) Core(TM) i5-6400 CPU@2.7 GHz, 8 G ROM 台式机电脑. 为了提高运算效率, 运行 ILOG CPLEX v.12 优化软件与 YALMIP 工具箱, 通过 Matlab 2013a 平台实现.

为验证本文所提出的基于 SMPC 的风电调度方法的可行性与有效性, 首先将其与基于随机优化的改进日前规划 (SDAP) 的调度方法进行性能对比分析, 然后分析 TSCH 机组启停次数以及可调度负荷对系统运行性能的影响.

3.2.1 与基于 SDAP 方法的性能对比分析

SDAP 方法<sup>[13-14]</sup> 针对基于传统日前规划的开环调度方法在处理预测不确定性时性能退化较快的情况, 引入随机优化的思想, 改进了传统日前规划调度方法. 具体而言, SDAP 方法通过多场景的方式替代传统日前规划中的点预测期望值, 从而提高了调度的鲁棒性. SDAP 方法也分为两个阶段, 即: 预先调度阶段和实时优化分配与功率补偿阶段. 其预先调度

阶段的目标函数与 SMPC 方法的目标函数一致, 即为式 (1); 但场景约束与式 (22) 有所区别, 如式 (23) 所示. 且 SDAP 方法只在每天开始时刻执行一次式 (1), 然后确定 TSCH 机组的运行状态. 而 TSCH 机组的具体输出功率、AGC 机组的运行功率、风电场的弃风行为等都在实时优化分配与功率补偿阶段优化确定. 有

$$\delta_{i,DG}^s(t) = \delta_{i,DG}^{s+1}(t),$$

$$\delta_{curt,wind}^s(t) = \delta_{curt,wind}^{s+1}(t). \quad (24)$$

其中:  $s \in [1, S - 1], t \in [1, T]$ . 式 (24) 表明, 所有场景、所有时段下的 TSCH 机组的运行/停止状态和弃风行为状态都需要保持一致.

由于本文的重点是研究能量管理模型及其调度方法, 本算例采用文献 [9, 21-23] 所提出的风电功率预测误差服从正太分布的假设及模型参数, 并采用 2.1 节所介绍的风电出力不确定建模及场景筛选方法生成典型的风电功率预测场景. TSCH 机组、AGC 机组、可调度负荷以及风电场弃风情况如图 5~图 8 所示. 由于 TSCH 机组调解过程中需要调度人员手工操作, 且其运行功率呈现离散化特征, 无论是在 SMPC 策略还是 SDAP 策略下, TSCH 机组的实际运行功率都是在预先调度阶段确定的, 如图 5 所示. SMPC 策略下各 TSCH 机组总的输出电能分别为 330.8 MWh、302.7 MWh、380.37 MWh 和 227 MWh; SDAP 策略下各 TSCH 机组总的输出电能分别为 330.48 MWh、296.85 MWh、378.2 MWh 和 219.35 MWh. 尽管 SMPC 和 SDAP 策略下各 TSCH 机组输出总的能量相差不是很明显, 但各时刻的输出功率还是存在一定的差异, 这一差异会因为 SMPC 策略和 SDAP 策略运行机制的不同而逐步放大到 AGC 机组、可调度负荷和弃风功率中.

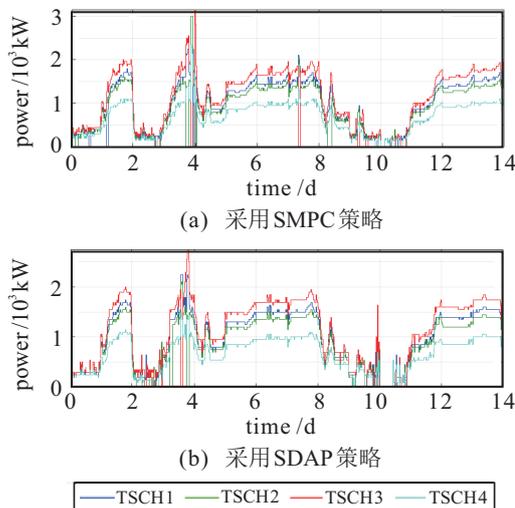


图5 TSCH 机组分别在 SMPC、SDAP 策略下的运行情况

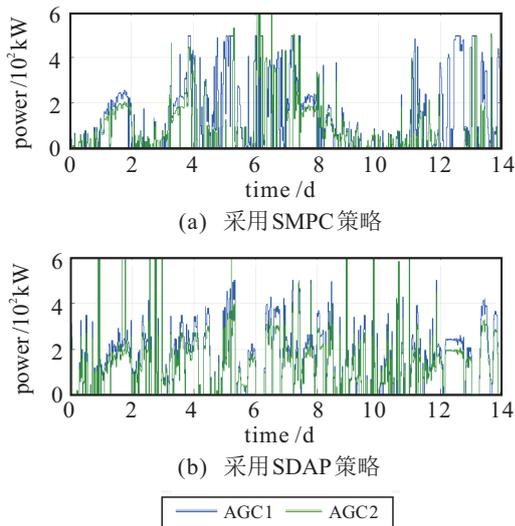


图6 AGC机组分别在SMPC、SDAP策略下的运行情况

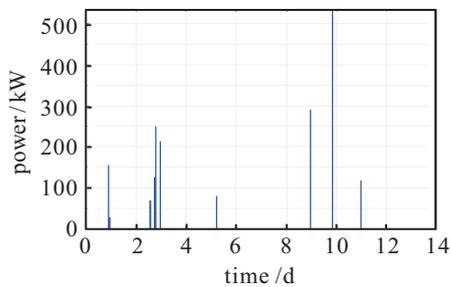


图7 SDAP策略下需要启动备用机组的情况

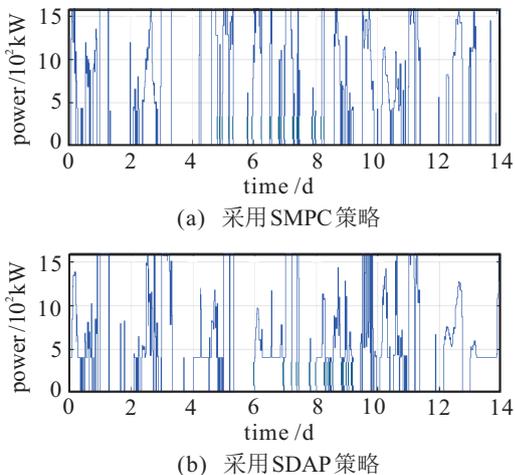


图8 可调度负荷在SMPC与SDAP策略下的运行功率

SMPC策略下各AGC机组总的输出电能分别为4.63 kWh、2.63 kWh; SDAP策略下各AGC机组总的输出电能分别为5.28 kWh、4.46 kWh. AGC机组在SDAP策略下比在SMPC策略下输出更多电能有以下2个原因: 1) 相对于SMPC策略, 弥补了SDAP策略下TSCM机组发电输出的不足; 2) 弥补了由于开环策略导致的较大预测误差产生的发电系统输出功率不足. 机组AGC2在SDAP策略下较之于SMPC策略可输出更多的电能, 其原因主要是SDAP策略在实时优化分配与功率补偿阶段采用了当前时段最优经济分

配策略. 此外, 表1显示, 机组AGC2在某些功率输出情况下比机组AGC1更加经济.

需要进一步说明的是由于SDAP策略的开环特性, 存在极少数时段(整个仿真时域内一共5h)会由于预测误差太大, 而导致尽管AGC机组以最大功率输出但仍难以满足系统需求的情况, 如图7所示. 这就需要启动备用快速响应机组以弥补所出现的功率不足. 由于SMPC本身所具有的闭环反馈与滚动优化机制, 以及针对预测不确定性实时生成新的典型场景机制, 使得SMPC策略下不需要启动快速响应的备用机组.

如图8所示, SMPC与SDAP策略下系统可调度负荷的运行轨迹存在较大差异. SMPC策略下可调度负荷每天都会有以最大功率运行的时候, 而SDAP策略下则有部分天数没有最大功率运行的情况; 并且相对于SMPC策略, SDAP策略下的可调度负荷需要花费更长的时间完成任务, SMPC策略下可调度负载一共运行144.5 h, 而SDAP策略下可调度负载一共运行206 h.

SMPC策略与SDAP策略的性能差异通过弃风行为最能体现. 在没有储能的情况下, 弃风量的多少直接与系统的运行策略、系统运用可调度负荷的能力密切相关. 相对于SDAP策略, SMPC策略下的弃风量明显减少, 弃风行为的次数也明显降低. 整个仿真时域内, SMPC策略下的弃风总量为644.76 kWh, 而SDAP策略下的弃风总量为28.7 MWh.

如图9所示, 尽管SMPC采用了闭环反馈机制, 且在预先调度阶段采用了多场景的方式表示预测误差, 但还是存在一定的弃风行为, 其原因如下: 1) 预测误差无法完全消除, SMPC策略在实时优化分配与功率补偿阶段的运行机制难以完全抵消存在的预测误差; 2) 弃风惩罚成本函数(4)决定了当弃风量较小时, 采取弃风行为会比调整AGC出力计划和可调度负荷计划更加经济. 之所以SMPC策略下的弃风行为与SDAP策略下的弃风行为会产生如此巨大的差异是与这两种策略在处理预测不确定性方面的机制相关的: SMPC策略采用的闭环反馈机制, 能够根据最新的预测结果调整预测模型以及系统未来一段时间的输出, 使整个仿真时域内的控制决策中的预测误差值始终保持在较小范围内(极少数情况会出现较大的预测误差值); 而SDAP采用的是开环机制, 一天内只能预测和调度优化一次, 随着时间的推移, SDAP策略下的预测误差越来越大, 但SDAP策略又无法根据最新的电能输出数据调整预测模型与系统未来一段时

间的输出,只能通过AGC机组、可调度负载和弃风行为进行实时的功率补偿。

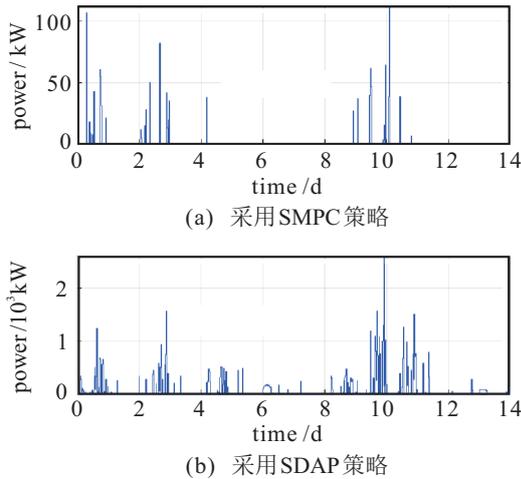


图9 SMPC与SDAP策略下的风电弃风情况

如表2所示,SDAP策略下的系统运行成本比SMPC策略下的系统运行成本高25.72%。但SMPC策略下的TSCH机组和AGC机组总运行成本均比SDAP策略下的高,其中SMPC策略下的TSCH机组和AGC机组总运行成本分别为 $2.21 \times 10^6$  \$和 $3.98 \times 10^5$  \$,而它们在SDAP策略下的运行成本分别为 $2.16 \times 10^6$  \$和 $2.59 \times 10^5$  \$。由于SDAP策略的开环特性,使得系统的优化控制决策无法更加全面地顾及预测不确定性的影响,导致SDAP策略下的系统弃风成本和备用机组启动成本迅速增加。SMPC策略下的系统弃风成本和备用机组启动成本分别为 $2.30 \times 10^3$  \$和0,而它们在SDAP策略下分别为 $8.63 \times 10^5$  \$和 $3.95 \times 10^3$  \$。

表2 SMPC与SDAP策略下系统运行成本

策略	SMPC	SDAP
成本/\$	$2.6112 \times 10^6$	$3.2829 \times 10^6$

### 3.2.2 控制时域内TSCH机组启停次数影响分析

由于TSCH机组出力的变化需要调度人员手工操作,这就要求TSCH机组在运行过程中尽量避免频繁的启动和停机操作,这也是为何会有式(14)约束的原因。但若减少TSCH机组的启停次数又会较大影响系统的运行成本,则需要重新考虑这一问题,并选择合适的启停次数约束。本节主要分析SMPC策略下,启停次数约束对TSCH机组和系统运行的影响。

如图10所示,总体上有无TSCH启停次数约束情况下各TSCH机组的运行情况没有太大变化,主要是某些时段个别机组的处理有所不同。从各机组总的启停次数上分析,考虑各TSCH机组启停次数约束时,各TSCH机组的启停次数分别为14、15、14和10;不考

虑各TSCH机组启停次数约束时,启停次数分别为8、14、20和12。系统中所有TSCH机组在仿真时域内总的启停次数相差不大,但机组TSCH1和TSCH3的启停次数在考虑启停次数约束和不考虑启停次数约束情况下,启停次数有较大变化,这也与它们的参数有关(结合表1分析)。如表3所示,考虑或不考虑TSCH机组的启停次数对系统运行总成本影响不大;由图10的分析可知,对系统中TSCH机组总的启停次数影响也不大;从对系统运行求解时间上分析,每个时段求解中,考虑TSCH机组启停次数约束的系统运行求解时间比不考虑TSCH机组启停次数约束的求解时间增加不到1s。综上分析,考虑或者不考虑TSCH机组的启停次数对系统影响不大,但从各TSCH机组启停次数均匀分配的角度看,一般需要额外考虑各TSCH机组的启停次数。

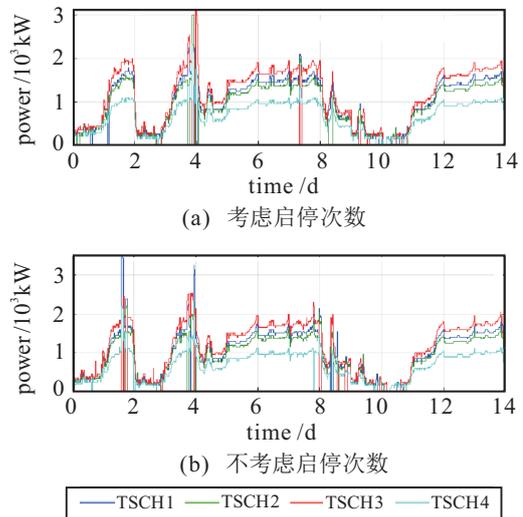


图10 考虑或不考虑TSCH启停次数约束的TSCH机组运行情况

表3 考虑或不考虑TSCH启停次数约束的系统运行成本

策略	考虑启停次数	不考虑启停次数
成本/\$	$2.6112 \times 10^6$	$2.6364 \times 10^6$

### 3.2.3 有无可调度负荷影响分析

作为重要的可调度单元,可调度负荷的引入能够有效减少系统的弃风行为,增加系统的可调度能力。由图11可知,有无可调度负荷情况下系统可控发电单元总的发电趋势无明显变化,但无可调度负荷情况下可控负荷在某些时段均处于低位运行,总的输出功率较低。由图12分析可知,有可调度负荷情况下系统总的弃风量为644.76kWh,而无可调度负荷情况下系统总的弃风量为1404.4kWh,增长约一倍多。通过进一步分析可知,可调度负荷的可用功率并没有完全用于消除弃风这一功能上,见表4。

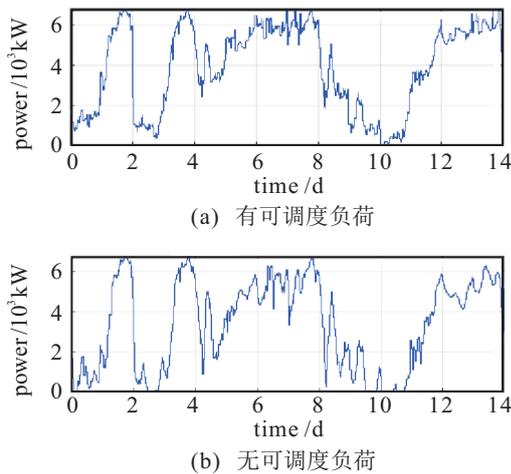


图 11 有无可调度负荷情况下系统可控发电输出

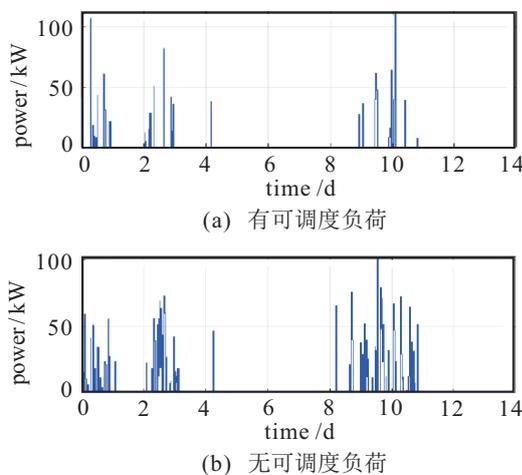


图 12 有无可调度负荷下的弃风情况

表 4 有无可调度负荷的系统运行成本

策略	有可调度负荷	无可调度负荷
成本/\$	$2.6112 \times 10^6$	$2.2745 \times 10^6$

无可调度负荷情况下,系统弃风惩罚成本为  $4.80 \times 10^3$  \$,有可调度负荷情况下系统弃风惩罚成本为  $2.30 \times 10^3$  \$,由此可见,可调度负荷在一定程度上降低了系统的弃风惩罚.然而,有可调度负荷的情况下,系统总的成本高于无弃风情况下系统总的运行成本.因此,若可调度负荷都是有用负荷,则本文方法可增加系统的弹性;若有部分负荷仅用于减少弃风量,则应将这部分负荷的运行模型重新调整,不参与系统的优化调度,以集中在风电输出过高时段使用.

### 4 结论

风电的运用和接入电网能够有效缓解石化能源紧张以及石化能源使用所引起的环境污染问题,但风力发电输出的强随机性和间歇性会给电力系统的运行调度带来一定的困难,尤其是对需要进行离散化发电调节的不含AGC功能的传统发电机组.本文提出了基于SMPC的含大规模风电接入电力系统优化

调度方法,该系统中包含需要进行离散化控制调度的TSCH机组、可连续自动控制调度的AGC机组以及部分可调度负荷,并允许风电场在特殊情况下的弃风行为.建立了含大规模风电接入电力系统优化调度的MIQP模型,提出了两阶段场景缩减方法以快速筛选典型的风电输出场景.仿真结果表明:基于SMPC的系统调度方法较传统的基于SDAP的调度方法能够取得更好的优化效果和更强的鲁棒性;进一步的敏感性分析表明,本算例中TSCH机组的运行启停次数约束对系统运行影响不大,而可调度负荷在系统中的作用需要根据负荷类型进行进一步的区分.

当然,算法的整体效率与典型场景数量、优化时间粒度以及电网组成规模密切相关,还需要深入研究更加快速高效的求解方法,以及探索分布式鲁棒控制方法.

### 参考文献(References)

- [1] 孙宏斌,郭庆来,潘昭光.能源互联网:理念、架构与前沿展望[J].电力系统自动化,2015,39(19):1-8.  
(Sun H B, Guo Q L, Pan Z G. Energy internet: Concept, architecture and frontier outlook[J]. Automation of Electric Power Systems, 2015, 39(19): 1-8.)
- [2] 徐青山,丁一帆,郑爱霞.计及需求响应的电网安全优化调度模型[J].控制与决策,2018,33(3):549-556.  
(Xu Q S, Ding Y F, Zheng A X. Safe and optimized scheduling of power system considering demand response[J]. Control and Decision, 2018, 33(3): 549-556.)
- [3] 江琦,路改香,唐昊,等.智能电网弹性响应时间业务需求的接入控制[J].控制与决策,2014,29(7):1311-1315.  
(Jiang Q, Lu G X, Tang H, et al. Access control of demand requests with response time flexibility in smart grids[J]. Control and Decision, 2014, 29(7): 1311-1315.)
- [4] Zhang Y, Wang R, Zhang T, et al. Stochastic model predictive control based economic dispatch for hybrid energy system including wind and energy storage devices[C]. IEEE Symposium Series on Computational Intelligence. Cape Town: IEEE, 2015: 1267-1271.
- [5] Zhang Y, Meng F L, Wang R, et al. A stochastic MPC based approach to integrated energy management in microgrids[J]. Sustainable Cities and Society, 2018, 41: 349-362.
- [6] Soares J, Fotouhi Ghazvini M A, Borges N, et al. A stochastic model for energy resources management considering demand response in smart grids[J]. Electric Power Systems Research, 2017, 143: 599-610.
- [7] Uckun C, Botterud A, Birge J R. An improved stochastic unit commitment formulation to accommodate wind uncertainty[J]. IEEE Trans on Power Systems, 2016, 31(4): 2507-2517.

- [8] Wang Q, Guan Y, Wang J. A chance-constrained two-stage stochastic program for unit commitment with uncertain wind power output[J]. IEEE Trans on Power Systems, 2012, 27(1): 206-215.
- [9] 沈伟, 吴文传, 张伯明, 等. 消纳大规模风电的在线滚动调度策略与模型[J]. 电力系统自动化, 2011, 35(22): 136-140.  
(Shen W, Wu W C, Zhang B M, et al. An on-line rolling generation dispatch method and model for accommodating large-scale wind power[J]. Automation of Electric Power Systems, 2011, 35(22): 136-140.)
- [10] Lu P M, Wen B Y, Jiang Y W. Study on optimization of spinning reserve in wind power integrated power system based on multiple timescale and unit commitment coordination[J]. Power System Protection and Control, 2015, 43(5): 94-100.
- [11] Zhao J Q, Tang J, Luo W H, et al. Day-ahead generation scheduling and spinning reserve decision-making model for power grid containing wind power[J]. Electric Power Automation Equipment, 2014, 34(5): 21-26.
- [12] Ai X M, Tayierjiang B, Yang L B, et al. Optimizing the spinning reserve in wind power system using scenario method[J]. Power System Technology, 2018, 42(3): 835-841.
- [13] Lei Y, Yang M, Han X S. A two-stage stochastic optimization of unit commitment considering wind power based on scenario analysis[J]. Power System Protection and Control, 2012(23): 58-67.
- [14] Sirus Mohammadi, Soodabeh Soleymani, Babak Mozafari. Scenario-based stochastic operation management of microgrid including wind, photovoltaic, micro-turbine, fuel cell and energy storage devices[J]. Electrical Power and Energy Systems, 2014, 54: 525-535.
- [15] Meibom P, Barth R, Hasche B, et al. Stochastic optimization model to study the operational impacts of high wind penetrations in Ireland[J]. IEEE Trans on Power Systems, 2011, 26(3): 1367-1379.
- [16] Wang H B, Qi Y Z, Wang C M, et al. Two-stage stochastic optimal scheduling model considering flexible load[J]. Power System Technology, 2018, 42(11): 3670-3676.
- [17] Schulze, T, Grothey A, McKinnon K. A stabilised scenario decomposition algorithm applied to stochastic unit commitment problems[J]. European J of Operational Research, 2017, 261(1): 247-259.
- [18] 李志刚, 吴文传, 张伯明. 消纳大规模风电的鲁棒区间经济调度:(一)调度模式与数学模型[J]. 电力系统自动化, 2014, 38(20): 33-39.  
(Li Z G, Wu W C, Zhang B M. A robust interval economic dispatch method accommodating large-scale wind power generation, Part one: Dispatch scheme and mathematical model[J]. Automation of Electric Power Systems, 2014, 38(20): 33-39.)
- [19] 陈建华, 吴文传, 张伯明, 等. 安全性与经济性协调的鲁棒区间风电调度方法[J]. 中国电机工程学报, 2014, 34(7): 1033-1040.  
(Chen J H, Wu W C, Zhang B M, et al. A robust interval wind power dispatch method considering the tradeoff between security and economy[J]. Proc of the CSEE, 2014, 34(7): 1033-1040.)
- [20] 李志刚, 吴文传, 张伯明, 等. 计及风电考虑离散化发电约束的在线滚动调度方法[J]. 电力系统自动化, 2014, 38(10): 36-42.  
(Li Z G, Wu W C, Zhang B M, et al. A look-ahead generation dispatch method considering discrete generation regulation constraints with large-scale wind power integration[J]. Automation of Electric Power Systems, 2014, 38(10): 36-42.)
- [21] 张伯明, 陈建华, 吴文传. 大规模风电接入电网的有功分层模型预测控制方法[J]. 电力系统自动化, 2014, 38(9): 6-14.  
(Zhang B M, Chen J H, Hu W C. A hierarchical model predictive control method of active power for accommodating large-scale wind power integration[J]. Automation of Electric Power Systems, 2014, 38(9): 6-14.)
- [22] 张彦, 张涛, 刘亚杰, 等. 基于随机模型预测控制的能源局域网优化调度研究[J]. 中国电机工程学报, 2016, 36(13): 3451-3462.  
(Zhang Y, Zhang T, Liu Y J, et al. Stochastic model predictive control for energy management optimization of an energy local network [J]. Proc of the CSEE, 2016, 36(13): 3451-3462.)
- [23] Ripaccioli G, Bernardini D, Di Cairano S, et al. A stochastic model predictive control approach for series hybrid electric vehicle power management[C]. Proc of the 2010 American Control Conf. Baltimore: IEEE, 2010: 5844-5849.
- [24] Alessandra Parisio, Evangelos Rikos, Luigi Glielmo. A model predictive control approach to microgrid operation optimization[J]. IEEE Trans on Control Systems Technology, 2014, 22(5): 1813-1827.

## 作者简介

王锐(1986—), 男, 副研究员, 博士, 从事智能优化调度理论方法及其应用等研究, E-mail: ruiwangnudt@gmail.com;

张彦(1988—), 男, 讲师, 博士, 从事模型预测控制、智能能量管理、混合储能系统充放电控制的研究, E-mail: zhangyan10a@nudt.edu.cn;

王冬(1989—), 男, 讲师, 博士, 从事装备系统综合保障、系统评估与优化的研究, E-mail: wangdong10a@gmail.com;

张涛(1976—), 男, 教授, 博士生导师, 从事复杂系统建模与优化、电池管理技术、能源互联网技术等研究, E-mail: zhangtao@nudt.edu.cn;

刘亚杰(1975—), 男, 副教授, 博士, 从事动态不确定性环境下大规模抢险救灾应急资源保障网络优化、电力系统随机系统与分析、鲁棒优化等研究, E-mail: liuyajie@nudt.edu.cn.

(责任编辑: 李君玲)