

计及需求响应的虚拟电厂风险量化优化模型

张金良, 赵 乐*

华北电力大学 经济与管理学院, 北京 102206



摘 要 : 为促进分布式新能源在能源结构中的应用, 通过建立虚拟电厂使风力发电、光伏发电、燃气机组和储能系统聚合为一个实体参与电力市场调度, 提高了分布式能源的可调控性和整体经济效益。同时为提升新能源并网的利用率和系统的吸纳能力, 加入了需求响应机制。首先, 根据各机组出力和需求响应建立虚拟电厂常规协同优化模型。然后, 基于投资组合理论将系统运行收益期望最大化作为模型优化目标值, 建立以条件风险价值作为风险衡量量化参数的虚拟电厂协同运行模型。最后, 应用改进粒子群算法求解模型, 利用算例证明了该模型不仅可以衡量某风险容忍度下的规划建设虚拟电厂调度过程, 还能为解决多分布式能源机组出力选择问题提供定量化的分析参照。

关 键 词 : 分布式新能源; 虚拟电厂; 条件风险价值; 需求响应; 优化调度; 优化粒子群算法

中图分类号 : TM621 **文献标志码:** A **文章编号:** 2097-4981(2025)02-0286-11

DOI: 10.3724/j.issn.2097-4981.JECC-2024-0026

Quantitative Optimization Model of Virtual Power Plant Risks for Accounting and Demand Response

ZHANG Jinliang, ZHAO Le*

School of Economics and Management, North China Electric Power University, Beijing 102206, China

Abstract : In order to promote the application of distributed new energy in the energy structure, this paper establishes a virtual power plant so that wind power, photovoltaic power generation, gas units, and energy storage systems are aggregated into a single entity to participate in the power market scheduling, which improves the controllability of distributed energy and the overall economic efficiency, and at the same time, to enhance the utilization rate of new energy on-grid and the system's absorptive capacity to join the demand response mechanism. Firstly, the conventional co-optimization model of the virtual power plant is established based on the output of each unit and the demand response. Then, based on the portfolio theory, the expected maximization of the system operating revenue is taken as the optimization target value of the model, and the virtual power plant co-operation model with conditional value-at-risk as the quantitative parameter of the risk measurement is established. Finally, the improved particle swarm algorithm is applied to solve the model, and the example demonstrates that the model can not only measure the scheduling process of planning and constructing a virtual power plant under a certain risk tolerance but also provide a quantitative analytical reference for solving the problem of selecting the output of multi-distributed energy units.

Key Words : distributed new energy; virtual power plant; CVaR; demand response; optimal scheduling; particle swarm optimization algorithm

收稿日期: 2024-11-09; **接受日期:** 2025-02-06

基金项目: 国家自然科学基金项目 (72342007)

作者介绍: 张金良 (1981—), 男, 博士, 教授, 研究方向为电力体制改革、能源经济与气候变化。E-mail: zhangjinliang1213@163.com

通讯作者: 赵 乐 (1999—), 女, 硕士研究生, 研究方向为虚拟电厂优化调度。E-mail: zhaole11299@163.com

0 引言

在“双碳”目标背景下，发展集中式和分布式相结合的清洁能源和以风电和光伏等清洁能源为典型的新型分布式能源，使其参与电力市场交易的并网调度、构建新型电力系统是可持续发展的重要保障。分布式能源推动电网结构朝着多元化、小容量、离散化的方向发展^[1]。虚拟电厂（Virtual Power Plant, VPP）将各类分布式能源聚合形成整体参与电力系统的统一调配，实现了对分布式能源的灵活控制，解决了其无序性接入电力系统带来的问题^[2]。VPP在通过储能聚合、可控负荷、分布式电源实现需求响应的同时，还能参与电力市场、碳市场和辅助服务市场并且获得盈利。

当前，针对VPP调度模型的研究主要集中于优化调度算法、低碳经济调度、技术架构设计以及风险管理等方面。在优化调度算法与协同优化方面，文献[3]提出了在线分布优化算法，优化VPP的运行状态，解决了激励机制和自主响应等关键问题；文献[4]提出了两阶段分布式鲁棒优化方法，考虑了需求响应的不确定性，有效提高了VPP的响应精度。这些研究为VPP在复杂电力市场中的高效运行提供了重要的算法支持。在低碳经济调度方面，文献[5]基于碳捕集技术，构建了包含风电、光伏及负荷不确定性的低碳经济调度模型，通过模糊机会约束算法有效处理不确定性，提高了新能源渗透率和系统总收益；文献[6]基于碳捕集技术对热电机组和风电反调峰特性建立了考虑碳捕集及需求响应的优化模型，进一步提升了对风光等新能源的优化处理能力和运行总收益。此外，文献[7]提出了分区聚合、分层调度的市场化虚拟电厂调控架构设计，确保了在不掌握电网拓扑信息的情况下，VPP能够安全且经济地参与电网调度和市场交易。在风险管理方面，文献[8]提出了一种面向风险的随机优化模型，整合下行风险约束，实现了在市场不确定性下的分布式能源资源调度，兼顾了盈利最大化与网络安全性；文献[9]在日前阶段选择中以条件风险价值（Conditional Value at Risk, CVaR）作为不确定性风险参数，选择可调容量的机组参与系统的运行调度，有效规避了源荷不确定性带来的损失；文献[10]基于CVaR理论，量化

了VPP的运行风险，并采用改进的Shapley值方法进行内部收益分配，确保了分配结果的公平性与合理性；文献[11]计算了不同风险系数下虚拟电厂的运营策略和收益，进一步优化了风险与收益的平衡；文献[12]构建了考虑风险偏好的VPP调度优化模型，通过算例分析验证了不同风险偏好系数下调度策略对VPP收益的影响。文献[13]探讨了超大城市VPP的建设理念与创新实践，提出了分区聚合、分层调度的市场化调控架构，支持VPP在大规模城市环境中的常态化运营。

综合以上文献，尽管目前研究已在优化算法和技术架构等方面取得显著进展，但多数研究仍集中于单一维度的优化，缺乏对多种因素的综合考量，尤其是在高度不确定的分布式能源环境下，系统性的风险评估与管理框架尚未完善。本研究通过建立基于投资组合理论的风险量化优化模型，结合CVaR作为风险衡量参数，提出了一种综合考虑风力发电（Wind Power Plant, WPP）、光伏发电（Photovoltaic, PV）、燃气（Combustion Gas Turbine, CGT）机组、储能系统（Energy Storage System, ESS）及两种需求响应的VPP调度优化策略，提升了VPP在复杂电力市场中的适应性和竞争力。本文首先依据各机组的出力情况和需求响应，构建了虚拟电厂系统常规调度模型；然后，根据金融评估理论，将最大化虚拟电厂运行收益的期望值作为优化目标，建立了计及风险参数的协同优化模型；最后，采用粒子群算法求解模型，充分利用粒子之间的信息共享，提高了优化效率和算法的适应性。通过算例仿真，验证了该模型不仅能够特定风险容忍度下进行有效的虚拟电厂调度规划，还能多分布式能源机组的出力选择问题提供定量化的分析参考，从而支持投资运营决策，兼具经济性和稳定性。

1 虚拟电厂常规调度模型

1.1 虚拟电厂典型结构组成

虚拟电厂结构如图1所示，核心系统由WPP、PV和CGT机组组成，主要负责满足电力系统的负荷需求。此外，ESS在虚拟电厂中扮演着重要角色，为WPP和PV提供备用电力。而CGT机组则利用其快速




图1 虚拟电厂构成
Fig.1 Composition of the VPP

启停的优势，满足系统对备用电力剩余需求。价格需求响应所实施的峰谷分时电价策略能够让客户根据具体的电价结构削减或转移部分峰时段的需求以平抑负荷波动^[14]，而激励型需求响应虚拟电厂则通过改变用户的用电行为来提供虚拟发电输出。

（1）风电出力不确定性模型

WPP机组的输出功率受风速变化的影响，故WPP机组的输出功率为：

$$g_{W,t} = \begin{cases} 0, & 0 < v_t < v_{in}, v_t > v_{out} \\ (v_t - v_{in})(v_r - v_{in})g_r, & v_{in} \leq v_t \leq v_r \\ g_r, & v_r \leq v_t \leq v_{out} \end{cases} \quad (1)$$

式中： v_t 为时刻 t 的自然风速； v_{in} 和 v_{out} 分别为切入风速和切出风速，定义了风力发电的操作范围； v_r 为机组的额定风速，保证风力发电机在达到或超过此风速时能够安全运行，不会因为风速过高而造成设备损坏； g 为在额定风速下的输出功率。

（2）光伏发电不确定性模型

PV机组输出功率的不确定性源于光照强度的波动。首先，依赖于太阳能光伏板的面积，其直接影响系统的发电能力，同样影响光伏板在特定面积和光照条件下产生电力的能量转化率，从而影响电能的产生效率。PV机组输出功率为：

$$g_{P,t} = \eta S \theta_t \quad (2)$$

式中： θ_t 为 t 时刻自然光辐射强度； η 为太阳能电池将接收到的太阳光能转换成电能的比例； S 为光伏组件的总面积。

（3）燃气机组运行模型

CGT机组发电运行成本为：

$$\pi_{pg,t} = a + bg_C + cg_C^2 \quad (3)$$

式中： a 、 b 、 c 为CGT发电成本系数； G_C 为CGT在 t 时

刻的出力。CGT机组的启停成本：

$$\pi_{ss,t} = [u_{C,t}(1 - u_{C,t})]D_{C,t} \quad (4)$$

$$D_{C,t} = \begin{cases} N_{hot}, & T_{min} < T_{off,t} \leq T_{min} + T_{cold} \\ N_{cold}, & T_{off,t} > T_{min} + T_{cold} \end{cases} \quad (5)$$

式中： N_{hot} 和 N_{cold} 分别为CGT热/冷启动费用成本； T_{min} 为CGT机组最低暂停时间，确保了机组在停机后有足够的时间进行必要的维护和冷却； $T_{off,t}$ 为CGT机组在 t 时刻的累计暂停运行时间； T_{cold} 为CGT机组完全停止并冷却到室温后，重新启动并达到正常运行状态所需的时间。 $D_{C,t}$ 为CGT机组启动和停机费用； $u_{C,t}$ 为CGT状态控制指标，取（0,1）。

1.2 计及需求响应的优化调度模型

需求响应机制常在电力供应紧张或电力系统稳定运行受到威胁时启动，其通过电价激励或补贴等方式，引导用户主动减少或调整用电，以改变其用电模式，从而在短期内调整电力负荷曲线并促进电价稳定与电力市场的平稳运行。系统调度中心发起指令后，用户根据虚拟电厂的调度指示响应并调整用电行为，使整个系统更加高效运转，并充分挖掘各类分布式能源的潜力。

价格型需求响应（Price-Based Demand Response, PBDR）机制根据电力市场的具体需求，在高峰时段提高电价激励用户削减或转移负荷，在低谷时段降低电价以鼓励用户增加用电，从而平衡负荷曲线、降低用电成本，达到对电力负荷进行有效调节的目的^[14]。其电力需求量计算公式如下：

$$L_t = L_0 \times \left[1 + e^{\frac{(P_t - P_0)}{P_0}} + \sum_{s=1, s \neq t}^{24} e^{\frac{(P_s - P_0)}{P_0}} \right] \quad (6)$$

式中： P_t 和 P_0 分别为响应前/后参与电价； L_t 和 L_0 分别为参与调度前/后的基准负荷需求量； e 为在电价发生变化时，电力需求量相应的百分比变化；当 $s=t$ 时称为自适应弹性，衡量需求自身变化的响应度；当 $s \neq t$ 时，则称为交叉适应弹性，表示需求和价格相互影响。实施成本 T_{PBDR} 计算公式如下：

$$T_{PBDR} = P_0 L_0 - P_t L_t \quad (7)$$

当负荷聚合商下达指令时，柔性负荷将在负荷高峰期根据该指令主动调整和减少用电量。通过这

种方式可以获得激励补偿或优惠电价,从而降低负荷需求平抑波动并帮助维持电力系统的稳定运行^[15]。

激励性需求响应 (Incentive-Based Demand Response, IBDR) 实施成本 T_{IBDR} 计算公式如下:

$$T_{IBDR} = \sum_{i=1}^I \rho_{i,t} \Delta L_{i,t} + \sum_{i=1}^I \rho_{i,dn} \Delta L_{i,dn} + \sum_{i=1}^I \rho_{i,up} \Delta L_{i,up} \quad (8)$$

式中: $\Delta L_{i,t}$ 、 $\Delta L_{i,up}$ 和 $\Delta L_{i,dn}$ 为负荷上/下转移或削减的容量值; $\rho_{i,up}$ 和 $\rho_{i,dn}$ 为第 i 个负荷聚合商在时刻 t 上/下旋转的备用成本; $\rho_{i,t}$ 为第 i 个负荷聚合商在时刻 t 的备用容量,是为应对突发事件或需求高峰预留的额外电力供应能力。

当前需求侧负荷曲线往往在高峰和低谷区间存在用电量差异大的问题,且曲线斜率陡峭,呈现出一个或两个明显峰值。这不仅不利于发电机组的稳定运行,还可能导致系统载荷能力急剧上升,对电力系统的安全稳定运行造成挑战^[16]。相比之下,激励型需求响应机制通过提供经济奖励来引导用户在特定时段改变用电行为,从而达到削峰填谷的效果。该方式在实际应用中较为成熟;与此同时,价格型需求响应机制也具备及时反映供需关系、通过电价变化激励用户调节用电习惯的独特优势。

将以上两种需求响应策略结合使用,可在高峰期主要采用价格型需求响应机制,辅以激励型需求响应措施,从而更有效地控制峰值负荷并引导用户理性用电。通过削减高峰时段用电需求,一方面可以避免系统过载风险,另一方面也能优化电力资源配置,从而提升虚拟电厂整体运行的安全性与稳定性。

1.3 虚拟电厂常规配置问题目标函数

目标函数是运行收益最大化,其意味着通过优化虚拟电厂的运行策略,使其在市场中的经济回报达到最高:

$$\max F(g_{VPP,t}) = R(g_{VPP,t}) - C(g_{VPP,t}) \quad (9)$$

式中: $R(g_{VPP,t})$ 为虚拟电厂输出收益; $C(g_{VPP,t})$ 为虚拟电厂参与输出的运行成本; $g_{VPP,t}$ 为虚拟电厂在时刻 t 的输出功率。

$$R(g_{VPP,t}) = \sum_{t=1}^T \sum_{k=1}^K \left[\rho (P_{W,t} g_{W,t} + P_{P,t} g_{P,t} + P_{E,t} g_{E,t} + P_{C,t} g_{C,t}) \right] \quad (10)$$

式中: ρ 为典型场景概率; $g_{W,t}$ 、 $g_{P,t}$ 、 $g_{E,t}$ 和 $g_{C,t}$ 为各VPP机组在时刻 t 的参与电网的发电电量; $P_{W,t}$ 、 $P_{P,t}$ 、 $P_{E,t}$ 和 $P_{C,t}$ 为各VPP机组在时刻 t 的售电价格。

$$\sum_{t=1}^T \sum_{k=1}^K \left\{ \rho_k \left[\rho_{chr,t} g_{chr,t} + (\pi_{pg,t} + \pi_{ss,t}) + (\pi_t^{PBDR} + \pi_t^{IBDR}) + \rho_t g_t \right] \right\} \quad (11)$$

式中: $\pi_{pg,t}$ 和 $\pi_{ss,t}$ 为CGT在时刻 t 的发电运维成本和启停费用; $g_{chr,t}$ 为ESS在时刻 t 的充电功率; g_t 为系统电能购入量; $\rho_{chr,t}$ 为ESS在时刻 t 的充电成本; ρ_t 为系统电力采购价格。

2 VPP 风险量度优化模型

2.1 根据 CVaR 建立风险量化模型

风险量度 (Value at Risk, VaR) 涉及对某一具体发生事件的概率或损失程度的评估和量化。VaR主要用于量化金融资产或投资组合在一定置信水平下、一定时间期限内所面临的最大潜在损失。CVaR用于评估在超过VaR水平后的平均潜在损失。其作为VaR的补充,特别是在处理极端事件或尾部风险时,能够弥补传统均值-方差模型在控制风险时带来的限制与不足^[17]。在置信度下, VaR和CVaR具体计算公式如下:

$$V_{VaR} = \min \{ \alpha \in R : \varphi(x, \alpha) \geq \beta \} \quad (12)$$

$$V_{CVaR} = \frac{1}{1-\beta} \int_{f(x,y) \geq V_{VaR}(x)} f(x,y) \rho(y) dy \quad (13)$$

为便于求解CVaR,引入变换函数并且采取估计值简化计算:

$$\hat{F}_\beta(x, \alpha) = \alpha + \frac{1}{N(1-\beta)} \int [f(x,y) - \alpha]^+ \quad (14)$$

将CVaR理论应用于描述虚拟电厂调度运行风险描述。虚拟电厂运行净收益优化目标为:

$$\begin{aligned} \Delta R(G, g) &= R(G, g) - C(G, g) \\ &= P_{WPP,t} g_{WPP,t} + P_{PV,t} g_{PV,t} + P_{ESS,t} g_{ESS,t} + \\ &P_{CGT,t} g_{CGT,t} - \rho_{ESS,t}^{chr} g_{ESS,t}^{chr} + (\pi_{CGT,t}^{pg} + \pi_{CGT,t}^{ss}) + \\ &(\pi_t^{PBDR} + \pi_t^{IBDR}) + \rho_{UG,t} g_{UG,t} \end{aligned} \quad (15)$$

VPP运行损失函数 $f(G, g) = -\Delta R(G, g)$,将置信度设置为 β ,构建计及不确定性和需求响应的VPP风险量化目标函数。其中,以VPP内部常规协同的净收益

期望值作为参考临界值:

$$F_{\beta}(G, \alpha) = \alpha + \frac{1}{N(1-\beta)} \sum_{k=1}^N [f(G, g) - \alpha]_k^+ \quad (16)$$

N 为随机向量的样本值, 引入假设参数简化表达^[18], 得到考虑CVaR的VPP协同优化模型如下所示:

$$\min \hat{F}_{\beta}(G, \alpha) = \alpha + \frac{1}{N(1-\beta)} \sum_{k=1}^N z_k \quad (17)$$

2.2 约束条件

在上述目标风险量化目标函数优化的求解过程中, 为确保最终解能够满足实际问题的要求, 还需要满足以下约束条件:

(1) 负荷供需平衡约束

需求响应后负荷功率平衡:

$$\begin{aligned} &g_{W,t}(1-\varphi_W) + g_{P,t}(1-\varphi_P) + (g_{dis,t} - g_{chr,t}) + \\ &g_{C,t}(1-\varphi_C) + g_{GC,t} + \sum_{i=1}^I (\Delta L_{i,E} + \Delta L_{i,dn}) \\ &= L_t + \sum_{i=1}^I (\Delta L_{i,up}) \end{aligned} \quad (18)$$

(2) 系统选择备用约束

为应对风险因子对系统运行产生的不确定影响, 确保VPP在面对不确定性情况时仍能稳定运行, 需要预先配置一定的备用容量来保证系统的可靠性:

$$\begin{aligned} &g_{\max} - g_{VPP,t} + \Delta L_{PBDR,t} + \\ &\sum_{i=1}^I \Delta L_{i,E} \geq rL_t + r_{W,up}g_{W,t} + r_{P,up}g_{P,t} \end{aligned} \quad (19)$$

$$g_{VPP,t} - g_{\min} \geq r_{W,dn}\Delta g_{W,t} + r_{P,dn}\Delta g_{P,t} \quad (20)$$

式中: $g_{\max}$ 和 $g_{\min}$ 为虚拟电厂功率输出上/下限; $\Delta L_{PBDR,t}$ 为在时刻 t 的价格需求响应机制产生的负荷变化幅度; r 为机组系统备用系数, 是系统预留备用容量与峰值负荷的比值; $r_{W,up}$ 和 $r_{W,dn}$ 为WPP机组发电可调整发电能力比值, 表示机组在短时间内能够增加或减少的发电容量; $r_{P,up}$ 和 $r_{P,dn}$ 为光伏机组发电的增/减发电容量比值。

(3) CGT、ESS组件运行约束

CGT运行约束:

$$u_{C,t}g_C^{\min} \leq g_{C,t} \leq u_{C,t}g_C^{\max} \quad (21)$$

$$(T_{C,t-1}^{\text{on}} - M_C^{\text{on}})(u_{C,t-1} - u_{C,t}) \geq 0 \quad (22)$$

$$(T_{C,t-1}^{\text{off}} - M_C^{\text{off}})(u_{C,t} - u_{C,t-1}) \geq 0 \quad (23)$$

式中: $g_C^{\max}$ 和 $g_C^{\min}$ 为CGT的上/下限; $T_{C,t-1}^{\text{on}}$ 为CGT在 t 时刻连续的运行时间, $T_{C,t-1}^{\text{off}}$ 为CGT在 $t-1$ 时刻连续停机时间; M_C^{on} 和 M_C^{off} 为CGT的最小启动和关停时间。

ESS运行约束:

在整个虚拟电厂优化调度周期内, 充电功率和放电功率的关系满足以下约束条件:

$$\sum_{t=1}^T (Q_0 + g_{chr,t} - Q_t)(1 - \rho_E) = \sum_{t=1}^T g_{dis,t} \quad (24)$$

当ESS放电时:

$$Q_{t+1} = Q_t - g_{dis,t}(1 + \rho_{dis,t}) \quad (25)$$

当ESS充电时:

$$Q_{t+1} = Q_t + g_{chr,t}(1 + \rho_{chr,t}) \quad (26)$$

ESS不能同时放电和充电, 约束条件如下:

$$g_{ESS,t}^{\text{chr}} \cdot g_{ESS,t}^{\text{dis}} = 0 \quad (27)$$

式中: Q_0 为ESS的初始储存电量; Q_t 为ESS在 t 时刻的储电量; $\rho_{dis,t}$ 、 $\rho_{chr,t}$ 为ESS在 t 时刻的放电和充电的损耗功率。

(4) 需求响应约束

价格型需求响应的最大负荷变动约束:

$$|\Delta L_{PBDR,t}| \leq u_{PBDR,t} \Delta L_{PBDR,t}^{\max} \quad (28)$$

式中: $u_{PBDR,t}$ 为PBDR的状态变量, 取值为(0,1); $\Delta L_{PBDR,t}$ 为PBDR后在时刻 t 的用电需求变动量; $\Delta L_{PBDR,t}^{\max}$ 为总体变动量的上限。

负荷波动和总变动量约束:

$$\begin{aligned} &u_{PBDR,t} \Delta L_{PBDR} \leq \Delta L_{PBDR,t} - \\ &\Delta L_{PBDR,t-1} \leq u_{PBDR,t} \Delta \bar{L}_{PBDR} \end{aligned} \quad (29)$$

$$\sum_{t=1}^T \Delta L_{PBDR,t} \leq \Delta L_{PBDR}^{\max} \quad (30)$$

式中: ΔL_{PBDR} 和 $\Delta \bar{L}_{PBDR}$ 为通过PBDR来维持电网稳定性时, 负荷增减的功率变化速率; $\Delta L_{PBDR,t}$ 若为正, 表明终端用户减少部分负荷的使用量, 若为负, 表明终端用户进行将部分电力负荷转移。

激励型需求响应主要由负荷聚合商提供, 作为虚拟电厂的一部分需要满足最大负荷削减量约束:

$$D_i^{j,\min} \leq \Delta L_{i,t}^j \leq D_{i,t}^j, j=1 \quad (31)$$

式中： $D_i^{j,\min}$ 为第*i*个负荷聚合商在步骤*j*的可接受最小减少负荷使用量； $\Delta L_{i,t}^j$ 为步骤*j*在时刻*t*减少的用电量； $D_{i,t}^j$ 为在时刻*t*的可利用负荷减少量。

$$0 \leq \Delta L_{i,t}^j \leq D_{i,t}^j - D_{i,t}^{j-1}, j=2,3,\dots,J \quad (32)$$

$$\Delta L_{i,t}^E = \sum_{j=1}^J \Delta L_{i,t}^j \quad (33)$$

式中： $\Delta L_{i,t}^E$ 为第*i*个负荷聚合商在时刻*t*的总削减量。如果要降低增减比例，维持系统的平稳运行则需满足以下约束：

$$(X_{t-1}^{\text{on}} - T_U)(u_{\text{IBDR},t-1} - u_{\text{IBDR},t}) \geq 0 \quad (34)$$

$$(X_t^{\text{off}} - T_D)(u_{\text{IBDR},t} - u_{\text{IBDR},t-1}) \geq 0 \quad (35)$$

式中： $u_{\text{IBDR},t}$ 为IBDR的状态变量；为防止频繁启停造成损害， T_U 为机组每次启动后必须连续运行的最短时间， T_D 为机组保持停止状态的最短时间； X_{t-1}^{on} 为机组在*t*-1时刻的总运行时间， X_t^{off} 为机组在*t*时刻的总暂停时间。

3 基于改进粒子群优化的求解方法

粒子群算法具有较快的收敛速度，在面对高维度优化问题时，较大部分算法能够更快收敛于最优解^[19]。然而，为兼顾全局搜索与局部搜索能力，抑制早熟收敛并改善算法的寻优效率，通常在速度更新环节中加入惯性权重 ω ，形成基于惯性权重的粒子群（Inertia Weight-Particle Swarm Optimization, IW-PSO）算法。惯性权重的存在能够在全局搜索与局部搜索之间取得适当的平衡，在初始阶段具有较大值以增强种群多样性，后期逐渐减小以促进对最优解的精确搜索。针对虚拟电厂调度的CVaR风险模型，其对风险尾部有更严格的要求，需要在较高维度和不确定性条件下进行求解。IW-PSO算法在保证收敛速度的同时，可增强对风险尾部的敏感度以及对不确定环境下的鲁棒性，故本文采用IW-PSO算法优化VPP的CVaR风险模型。其主要步骤如下：

步骤1：确立典型场景集，根据实际场景对储能、光伏、负荷曲线参数进行初始化；确定系统各机组的负荷基本参数。

步骤2：初始化粒子群的各项参数，包括种群中各机组数量、整体的迭代次数、惯性权重 ω 、学习因子和粒子群寻优速度等。

步骤3：分别计算适应度，与 $p_{\text{best},ij}(t)$ 、 $g_{\text{best},ij}(t)$ 进行比较，若大于原始的适应度值，则更新粒子位置，确定整体场景下的极值；否则保持 $p_{\text{best},ij}(t)$ 、 $g_{\text{best},ij}(t)$ 不变。PSO算法的位置与速度更新公式为^[20]：

$$v_{ij}(t+1) = \omega v_{ij}(t) + c_1 r_1 [p_{\text{best},ij}(t) - x_{ij}(t)] + c_2 r_2 [g_{\text{best},ij}(t) - x_{ij}(t)] \quad (36)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (37)$$

式中： $v_{ij}(t)$ 、 $v_{ij}(t+1)$ 分别为在*t*和*t*+1时刻的速度； c_1 为个体学习因子； ω 为速度的惯性权重； c_2 为社会学习因子； $x_{ij}(t)$ 为*t*时刻粒子的位置； $p_{\text{best},ij}(t)$ 、 $g_{\text{best},ij}(t)$ 分别为第*d*次迭代*i*粒子经过的最优位置与第*d*次迭代所有粒子经过的最优位置；*j*为寻优空间的维度。

步骤4：更新适应度，计算全局最优值，指在当前整个群体中适应度值最优的个体对应的虚拟电厂调度最优期望值。

步骤5：判断当前结果是否满足整体约束或达到最大迭代次数。若满足则输出最优期望值，否则继续返回步骤3进行求解迭代。

综上，基于惯性权重的粒子群算法能够更好地控制粒子在全局搜索与局部搜索阶段的搜索能力，避免陷入局部最优并加快收敛速度。因此，使用IW-PSO算法求解虚拟电厂CVaR风险模型，既能在高维度和不确定环境下对风险分布的尾部进行有效控制，又能在有限迭代次数内以相对较快的速度收敛到较优解，为虚拟电厂调度决策提供更加稳健的优化结果。

4 算例分析

4.1 模型参数

假设VPP中包含WPP机组3台、PV机组2台、CGT机组2台、ESS设备3台，额定容量如表1所示。

对预测误差建立准确的概率模型有利于帮助系统更加有效地运行。利用韦布尔函数模拟实际风速^[21]，形状参数为2，尺度参数为 $\theta=2\pi/\sqrt{\pi}$ ，具体风速结果场景如图2所示。粒子群优化学习因子 c_1 和 c_2

表1 各机组额定容量

Table 1 Rated capacity of each unit

机组名称	额定容量/MW	机组名称	额定容量/MW
风电机组 W1	0.20	光伏机组 P4	0.16
风电机组 W2	0.60	燃气机组 C1	0.68
风电机组 W3	0.30	燃气机组 C2	0.34
光伏机组 P1	0.25	储能设备 E1	0.08
光伏机组 P2	0.12	储能设备 E2	0.14
光伏机组 P3	0.08	储能设备 E3	0.03




图2 CVaR 与下行风险动态表现

Fig.2 CVaR and downside risk dynamic performance

分别为1和2，速度的惯性权重 ω 为0.8^[22]。

光伏Beta分布函数形状参数^[23]分别为0.40和9.34；燃气机组启动时间和停机时间均为0.1h；成本为95元/MWh；需求响应提供负荷变动量不超过 ± 0.05 MW。储能机组充电和放电功率不超过0.04、0.05MW。电力成本模型被分为两个部分分别进行线性近似，坡度因子为100元/MW和350元/MW。价格型需求响应提供上/下旋备用成本分别为0.25元/kWh和0.55元/kWh。其提供电力输出不超过 ± 0.03 MW，参与调控的价格为0.50元/kWh。储能系统充放电价格遵照分时电价设置。峰谷设置和电价设置参考表2^[24]。

表2 峰谷分时电价

Table 2 Peak-to-valley time-sharing tariff

类型	时段	价格/(元/kWh)
高峰	8:00 ~ 12:00; 17:00 ~ 21:00	0.975
平	12:00 ~ 17:00; 21:00 ~ 24:00	0.510
低谷	1:00 ~ 8:00	0.195

4.2 CVaR与下行风险模型对比

在现代风险管理中，如何有效度量并分析系统的极端风险为关键问题。下行风险（Downside Risk）为一种用于衡量损失或风险的方法，主要关注损失超过某个固定阈值（如平均值或指定目标值）时的超额部分，常用于投资、金融、能源系统等领域，评估系统在不利情况下的潜在损失。利用CVaR和下行风险的在相同的VPP调度下的对比，从不同角度展示了CVaR在极端尾部风险评估中的优势。

图2为CVaR随置信水平变化的风险曲线和下行风险随阈值变化的风险曲线。可以看出：随置信水平的提高，CVaR曲线呈现较为平滑的增长趋势，表明其能稳定捕捉累积分布中更极端的尾部风险。下行风险曲线在不同水平间存在明显的波动，特别是存在分布跳跃区域，表现出风险对损失分布变化的不稳定性，表明下行风险是在固定阈值的基础上评估损失的超额部分，而对尾部分布的极端损失敏感性较低。在 $\alpha=0.95$ 时，CVaR为0.098，而下行风险阈值为0.014，表明CVaR的尾部敏感性强，能够捕捉到更极端的尾部损失。

图3为CVaR损失累积分布函数（Cumulative Distribution Function, CDF）以及对应的 $\alpha=0.95$ 分位点。CDF图清晰地展示了损失的分布特性，具体为损失随机变量小于等于某一特定值的概率，结合定义分析得出 CVaR的尾部分布覆盖范围更广，适用于高置信水平的极端风险分析。




图3 CVaR 损失累积分布函数

Fig.3 CVaR loss cumulative distribution function

为更全面地展示CVaR在风险管理中的普适性,模拟了10组典型场景,分别计算两种方法的风险表现,下行风险基于固定阈值为0.05, CVaR基于固定 α 值为0.95,结果如图4所示,每一个点代表一个模拟场景,对应一个特定的风速、光照、负荷扰动条件。通过散点图对比可以看出,大多数场景下CVaR值高于下行风险值。S2和S4存在显著的尾部损失,具体原因可能为这些场景下风光发电不足,负荷需求较高,导致损失集中在尾部。S3和S10风光发电较充足或负荷需求较低,则会导致损失较小。CVaR能更全面地反映极端尾部风险,特别是在S2和S4场景中,其捕捉到了最差条件下的平均损失,而下行风险可能低估了风险值。CVaR值随着下行风险的增大呈现总体增长趋势,但其值始终高于下行风险,尤其在尾部风险较高的场景中,如S2和S4。




图4 多场景 CVaR 与下行风险对比
Fig.4 Multi-scenario CVaR vs. downside risk

风险分布情况如图5所示, CVaR在所有场景中的中位值约为0.095MW。0.12MW的离散点表示一个场景下CVaR的极端值,说明该场景下系统遭遇了更严重的尾部损失。下行风险更加分散,范围比CVaR更宽,无离群点表明风险对极端尾部损失的敏感性较低。CVaR的分布整体比下行风险更为集中,表明其更加关注系统最坏情况下的风险。

4.3 典型场景算例结果及分析

常规VPP内部协同优化结果(未考虑不确定性因素)如图6所示。选取典型场景,优先以WPP和PV机组出力满足负荷。在负荷低谷时段(1:00~8:00), WPP机组整体出力仍维持一定的水平,与CGT机组一同满足基本负荷需求。随着白天时段到来, WPP机组受风速波动影响,其峰值出力时段与负荷高峰有时能够重合,但也存在时段差异,导致在局部时段可能出现系统损失或必须依赖储能和需求响应来调节。优化前的PV机组并未完全发挥出在高太阳辐照时段的潜力,某些时段即便太阳辐照较高,但由于没有严格考虑风光互补及WPP不确定性导致的风险,调度对光伏的利用率不算显著。可以看出, PBDR在峰谷定价策略下,其负荷曲线稍作平滑; IBDR在有激励时进行负荷转移,提升了系统调度的可控性,在高风险时刻,如WPP大幅下降时可及时削减负荷,降低系统损失。综上,优化前的整体调度更多依赖WPP与CGT机组的相对稳定供给, PV与ESS在部分时段未被充分利用。虽然风险较小,但若面临风电




图5 多场景下风险分布情况
Fig.5 Distribution of risk in multiple scenarios




图6 VPP内部协同优化结果
Fig.6 Synergistic optimization results within VPP

偏差大的极端情况，可能造成更高的系统损失。

基于虚拟电厂的风险量度模型，将置信度向量设为0.95，进行权重粒子群优化计算各机组出力。首先通过算法得到光伏电板的最优参数，进一步通过最优参数使光伏发电效率最大化，具体结果如表3所示。

表3 光伏电板的最优参数

Table 3 Optimal parameters for photovoltaic panels

	光伏板光电转换效率	光伏板面积/m ²
参数	0.225	1148.455

粒子群优化主要作用于光伏电板参数求解和虚拟电厂调度过程，旨在全局中寻找最优解法，算法参数如表4所示。

表4 粒子群优化算法参数

Table 4 Particle swarm optimization algorithm parameters

	迭代次数	种群规模	迭代时间/s
参数	100	50	52.7716

图7为IW-PSO算法与量子遗传算法（Quantum Genetic Algorithm, QGA）的收敛情况对比。可以看出，首先IW-PSO算法迅速达到较高的目标函数值，显示了较快的收敛速度；其次IW-PSO算法所达到的目标函数值明显高于QGA，表明IW-PSO算法更易接近全局最优解；最后IW-PSO算法的收敛曲线较为平滑，说明其在迭代过程中更易趋于稳定，不容易陷入局部最优。虚拟电厂的优化问题为多维度问题，使用粒子之间的信息共享，能够提高优化效率，增




图7 IW-PSO算法与QGA收敛情况对比
Fig.7 Comparison of convergence between IW-PSO algorithm and QGA

加求解稳定性，从而有效寻找全局最优解。

各机组具体优化结果如图8所示，主要分析WPP机组、CGT机组和ESS机组的具体出力情况。结合CVaR不确定性约束后，WPP峰值出力被主动限制，以避免在极端风况预测偏差时造成大的供需缺口。高峰时段也不再“盲目”将WPP推至最大，而是在评估风险后做出抑制。负荷低谷时段，WPP依旧保持一定出力，但在一些可能发生风速偏差的时间段能够选择ESS或CGT机组分担风险。WPP机组总出力为7.7630MWh，相较于常规优化结果增加了1.8047MWh。优化后PV机组出力在日照良好时段能够得到较好利用，由于考虑了风电波动风险，模型倾向于让相对更稳定的PV机组在白天时段产生更多收益。同时，整体光伏利用率有所提升，相对WPP出力减少能部分弥补供应不足。PV机组的总出力为7.1698MWh，




图8 风险量度模型优化结果
Fig.8 Risk measurement model optimization results

相较于常规优化结果增加了0.1502MWh。优化后ESS机组在更多时段表现为灵活调峰填谷：高峰时段明显放电，与CGT机组联合应对需求高峰；低谷时段或风电富余时段则进行充电，其被更充分地用来缓解风光出力的波动性及潜在缺口。CGT机组的运行成本为4872.21元，相较于常规优化结果5853.49元，减少了981.28元。

根据不同的机组参数得到的结果不同，各机组具体的优化结果可以为虚拟电厂的运行提供一定参考，ESS机组具体出力如图9所示。与优化前几乎闲置的状态相比，ESS机组被更高频度地调度，发挥出重要的风险对冲与灵活调峰功能。




图9 储能机组单机优化后输出

Fig.9 Output after optimisation of the ESS unit stand-alone

图10为优化前/后机组输出功率堆叠图，采用分层面积图形式，展示了各机组合并出力如何满足负荷需求。优化前在高峰时段WPP较为充分地并网，在可能出现风险的高峰时段仍然作为主力出力，而

CGT机组对负荷缺口进行补足；负荷低谷时段CGT机组占主要地位，ESS机组仅在少数时段发挥调峰作用。在优化后，WPP机组的峰值输出明显受到限制，而CGT机组在高峰时段有所提高，与PV机组共同满足负荷需求；PV机组在白天时段（8:00~17:00）的叠层面积有所增加，更大化程度地利用光照且风险更可控；ESS机组在某些时段更频繁地进行充/放电，削峰填谷。堆叠图直观展现出当CVaR侧重风险管理时，在WPP和PV不足或波动较大的时段，储能也起到调节作用。弃风弃光量为2.7065MWh，相较于常规优化有所增加，结合总成本分析表明，为追求规避风险，需要承担WPP机组和PV机组更高的发电运行成本，但是降低了总体的运行成本。

综上，常规调度虽在风电高峰时段能够获得清洁能源出力，但一旦发生预测偏差或风电骤降，就可能出现较大系统损失或迫使CGT机组紧急启动。优化后充分利用PV、ESS及需求响应，既减少极端情形下的供需缺口，也提高调度稳健性。激励性需求响应在各时段需求侧负荷均发生了一定程度的削减转移，或随峰谷电价进行小幅调整（价格型需求响应），为WPP和PV机组的波动预留了更多调度空间。激励型需求响应尤其在机组出力不足时段能够起到“备用负荷”功能。因此，从不同角度分析可以看出，CVaR模型在VPP调度中具备较强的风险管控能力，有助于在不确定性场景下实现成本与风险的平衡。在降低高峰风险与系统损失的同时，凸显了CVaR对虚拟电厂的风险管理价值（表5）。




图10 优化前后机组输出分层面积图

Fig.10 Stratified area plot of unit output before and after optimization

表5 优化模型运行数据
Table 5 Optimization model run data

	CVaR/MW	运行收益/元
常规优化	/	8296.07
风险量度优化	0.0781	8468.25

5 结论

为充分促进分布式新能源在能源结构中的应用，本文建立了虚拟电厂风险量度优化模型，提出了结合需求响应和计及不确定性的虚拟电厂调度运行模式，利用风险量化的方式对其进行优化，对比分析其他模型后可以得出其在尾部风险处理上的优势，最后采用粒子群优化求解模型得到最优参数和最佳调度解。算例结果表明该风险量度优化模型能够在适当规避风险的情况下实现虚拟电厂收益最大化。

CVaR理论结合置信度用于风险描述，可以有效衡量不确定因素在优化调度中的影响，从而根据风险情况得出最终优化结果。同时优化粒子群算法在模拟虚拟电厂的最优运行情况方面表现出色，显著提高了算例的全局寻优能力，能够在具体场景中找到各机组的最佳出力方案。这一方法适用于多个机组的场景计算，有助于促进新型电力系统中分布式能源的消纳，并实现各机组的协同运行。

综上所述，本文提出的虚拟电厂风险量度优化模型及其调度运行模式，不仅提升了分布式新能源在能源结构中的应用效率，同时为虚拟电厂在不确定环境下的优化调度提供了有力支持。该研究成果对于推进新型电力系统的建设和实现能源的可持续发展具有重要意义。

参考文献

[1] 陈会来, 张海波, 王兆霖. 不同类型虚拟电厂市场及调度特性参数聚合算法研究综述[J]. 中国电机工程学报, 2023, 43(1): 15–28.
[2] 刘吉臻, 李明扬, 房方, 等. 虚拟发电厂研究综述[J]. 中国电机工程学报, 2014, 34(29): 5103–5111.
[3] 范帅, 何光宇, 郑湘明, 等. 基于在线分布式优化的虚拟电厂自趋优运行方法研究[J]. 中国电机工程学报, 2023, 43(13): 4935–4950.
[4] Ju L W, Tan Z F, Yuan J Y, et al. A bi-level stochastic scheduling optimization model for a virtual power plant connected to a wind-photovoltaic-energy storage system considering the uncer-

ainty and demand response[J]. Applied Energy, 2016, 171: 184–199.
[5] 吕游, 毛乃新, 秦瑞钧, 等. 考虑风光及负荷不确定性的虚拟电厂低碳经济调度[J]. 太阳能学报, 2024, 45(11): 116–123.
[6] 袁桂丽, 钟飞, 张睿, 等. 考虑碳捕集及需求响应的虚拟电厂热电联合优化调度[J]. 电网技术, 2023, 47(11): 4458–4467.
[7] 张扬, 牛振勇, 陈皓勇, 等. 分区聚合、分层调度的市场化虚拟电厂调控架构设计[J/OL]. 南方电网技术, 1–10[2024-12-15]. <https://link.cnki.net/urlid/44.1643.TK.20241205.1003.004>.
[8] Deng J Y, Guo Q. Decentralized energy management system of distributed energy resources as virtual power plant: Economic risk analysis via downside risk constraints technique[J]. Computers & Industrial Engineering, 2023, 183: 109522.
[9] 刘国新, 吴杰康, 蔡志宏, 等. 基于条件风险价值风险控制的多电源虚拟电厂机组动态聚合优化模型[J]. 四川电力技术, 2022, 45(3): 8–15+22.
[10] 李新聪, 黄滢, 李振坤, 等. 基于条件风险价值的虚拟电厂优化运行与收益分配[J/OL]. 现代电力, 1–12[2024-12-15]. <https://doi.org/10.19725/j.cnki.1007-2322.2023.0263>.
[11] 王俊, 徐箭, 王晶晶, 等. 基于条件风险价值的虚拟电厂参与能量及备用市场的双层随机优化[J]. 电网技术, 2024, 48(6): 2502–2510.
[12] 王永利, 张思文, 赵伟博, 等. 电力市场背景下计及风险偏好的虚拟电厂调度优化策略[J]. 煤炭经济研究, 2024, 44(8): 44–50.
[13] 汤军, 高洪超, 余涛, 等. 电力市场环境超大城市虚拟电厂的建设理念与创新实践[J]. 电网技术, 2025, 49(1): 103–112.
[14] 崔杨, 曾鹏, 王铮, 等. 计及电价型需求侧响应含碳捕集设备的电-气-热综合能源系统低碳经济调度[J]. 电网技术, 2021, 45(2): 447–461.
[15] 李军祥, 陈鸣, 邵馨平. 基于信息间隙决策理论的虚拟电厂低碳需求响应调度模型[J]. 中国管理科学, 2023, 33(4): 345–356.
[16] Shabanzadeh M, Sheikh-El-Eslami M K, Haghifam M R. A medium-term coalition-forming model of heterogeneous DERs for a commercial virtual power plant[J]. Applied Energy, 2016, 169: 663–681.
[17] 刘蓉晖, 赵增凯, 孙改平, 等. 考虑不同风险偏好的虚拟电厂优化策略及利润分配[J]. 电力自动化设备, 2021, 41(4): 154–161.
[18] 王秋杰, 亓浩, 谭洪, 等. 考虑碳市场风险的热电联产虚拟电厂低碳调度[J]. 电力自动化设备, 2024, 44(10): 8–15.
[19] 胡祖源, 靳现林, 谭雅之, 等. 基于改进粒子群算法的分布式光伏及储能系统优化配置[J]. 综合智慧能源, 2023, 45(1): 49–57.
[20] 常先英, 李荣钧. 改进粒子群优化算法及其在CVaR模型中的应用[J]. 统计与决策, 2009, 25(8): 144–146.
[21] 杨三根, 陈峦, 曹璵月, 等. 基于风速Weibull分布的电力系统备用容量优化模型[J]. 可再生能源, 2013, 31(10): 49–52.
[22] 李昆, 刘航, 胡文东, 等. 基于粒子群算法的互联网AGC随机最优控制系统[J]. 电子设计工程, 2024, 32(6): 171–174+179.
[23] 杨宏, 闫玉杰, 王瑜. Beta分布在风电预测误差模型中的适用性[J]. 电测与仪表, 2020, 57(11): 37–41+48.
[24] 宋艺航, 谭忠富, 李欢欢, 等. 促进风电消纳的发电侧、储能及需求侧联合优化模型[J]. 电网技术, 2014, 38(3): 610–615.