

DOI: 10.12158/j.2096-3203.2025.01.020

# 考虑风光不确定性的虚拟电厂合作博弈调度及收益分配策略

宋铎洋, 薛田良, 李艺瀑, 涂金童, 毕宇豪, 王满康

(三峡大学电气与新能源学院, 湖北 宜昌 443000)

**摘要:**虚拟电厂(virtual power plant, VPP)通过先进的控制技术高效聚合容量小、数量多的分布式能源(distributed energy resource, DER)参与电力市场交易。随着DER数量的增加,其出力的波动性以及聚合后的收益问题需要解决。基于此,提出一种在日前电力市场下,多类型DER聚合于VPP的协同博弈调度模型。首先,提出多类型DER聚合于VPP的运营框架。其次,由于风光出力的不确定性严重影响系统的运行,建立基于变分模态分解(variational modal decomposition, VMD)和改进的双向多门控长短期记忆(bidirectional multi gated long short-term memory, Bi-MGLSTM)网络的组合预测模型。然后,同类型DER形成联盟,并以售电收益最大化为目标,构建VPP多联盟的合作博弈调度模型,为实现联盟及成员间收益分配的公平性,设计多因素改进shapley值法和基于奇偶循环核仁法的两阶段细化收益分配方案。最后,算例结果表明,所提方法能有效提高风光功率的预测精度,实现VPP内联盟间合作互补运行,保证了多个主体间收益分配的公平性与合理性。

**关键词:**虚拟电厂(VPP);分布式能源(DER);风光预测;合作博弈;shapley值;核仁法

**中图分类号:** TM74

**文献标志码:** A

**文章编号:** 2096-3203(2025)01-0193-14

## 0 引言

随着双碳目标的逐步落实,传统化石能源逐步退出电力市场,未来将由海量分布式能源(distributed energy resource, DER)参与电力市场交易<sup>[1-3]</sup>。然而DER存在容量小、数量大、出力不稳定等问题,无法独立进行电能交易,导致资源浪费<sup>[4]</sup>。虚拟电厂(virtual power plant, VPP)作为DER参与电力市场的统一代理商,通过合作互补的方式将DER灵活、高效聚合,保障整体收益最大化<sup>[5-7]</sup>。随着聚合的DER数量的增加,VPP内各成员的收入均影响其合作积极性,因此建立公平、合理的收益分配机制对于VPP的长期发展具有重要意义。

在绿色和低碳的新兴发电背景下,分布式风电和光伏是我国装机容量最大的清洁能源,但是其不确定性和出力波动性威胁着VPP的稳定运行<sup>[8]</sup>。针对这一问题,在传统的运筹学模型中有假设服从特定分布的随机优化<sup>[9]</sup>、概率场景模糊集的鲁棒优化<sup>[10]</sup>和最恶劣情况下寻优的分布鲁棒优化<sup>[11]</sup>等优化方法。但这些方法分别存在求解时间长、难以准确描述不确定变量的分布、结果较为保守和计算量较大等缺点,计算结果与实际出力偏差较大。随着人工智能的兴起,具有较强的自学习和非线性拟合能力的机器学习被广泛应用于风光出力的研究<sup>[12]</sup>。文献[13]采用改进的小波神经网络(wavelet neural network, WNN)预测方法完成风光荷的预测,构建了

多智能体技术的VPP动态博弈调度模型。文献[14]采用支持向量机(support vector machine, SVM)对VPP源荷出力、电力市场价格进行日前预测,并利用自回归移动平均(autoregressive moving average, ARMA)对预测误差进行典型场景生成,验证了所提方法的有效性。文献[15]对多重不确定性采用混合神经网络和浣熊优化算法(coati optimization algorithm, COA)生成场景,该方法在VPP优化运行中具有较好的响应性。上述文献多采用单一神经网络模型对历史数据进行预测,当预测步长增大时,会出现预测误差增大、过拟合、不同时间尺度预测精度降低等问题。

对于VPP内部主体间的复杂利益关系,现有研究多采用合作博弈。合作博弈是指多个参与者形成联盟并进行合作完成目标,从而使利益最大化,然后在内部进行利益分配,本质上是一个收益分配问题<sup>[16]</sup>。对于联盟的收益分配多数采用纳什谈判<sup>[17-19]</sup>、shapley值法<sup>[20]</sup>、核仁法<sup>[21]</sup>等。纳什谈判是将相关参与联盟作为谈判者,谈判解作为联盟利益分配的结果。文献[22]建立DER的运营商、云储能运营商以及产消者聚合商等多种运营主体的VPP纳什议价模型,将议价均衡问题转换为2个子问题,该方法能有效减少各运营主体的运行成本。shapley值法将参与者的边际贡献作为联盟收益分配的划分标准。文献[23-24]引入风险指标、满意度、碳减排贡献等综合因素,构建改进加权的shapley值VPP收益修正模型,得到的结果有利于维持VPP联盟的稳定性,但参与者数量增加时,

收稿日期:2024-06-22;修回日期:2024-09-17

基金项目:国家自然科学基金资助项目(62233006)

shapley值法会出现计算规模大、时间长的问题。核仁法的核心思想是使合作联盟成员对分配方案的总体最大满意度达到最小,在成本分摊、多目标决策等领域有广泛应用。文献[25]通过不同清洁能源聚合的VPP集群进行合作博弈,电量不同的VPP之间共享电力,采用核仁理论来分配联盟利益,结果表明整体利润得到提升。可见,合作博弈理论在VPP成本分摊和收益分配中得到了广泛应用,但随着VPP内部DER数量的增多,常规分配方法会出现计算量庞大、成本的平均分摊和收益不均衡等问题,难以保证分配策略的公平性与合理性。

综上所述,文中考虑风光出力不确定性的影响,提出多类型DER形成联盟聚合于VPP参与电力市场交易的运营模式。首先,采用变分模态分解(variational modal decomposition, VMD)将功率分解为具有不同中心频率的子模态,随后使用改进的双向多门控长短期记忆(bidirectional multi gated long short term memory, Bi-MGLSTM)网络进行迭代预测。其次,基于风光功率的预测结果,以售电收益最大化为目标构建VPP多联盟的合作博弈调度模型。同时,为保证VPP内聚合联盟的稳定性与收益的公平性,提出引入风险偏好、利润贡献、成本贡献因子的改进shapley值法以及基于奇偶循环核仁法的两阶段收益分配方案。最后,通过算例仿真验证了所提模型的高效性与合理性。

### 1 VPP多类型DER聚合的运营框架

随着我国电力市场建设和VPP技术的快速发展,将小型风电场、光伏电站、抽蓄电站等DER聚合于VPP,对于传统电能交易而言很难保证VPP主体收益的最大化。基于此,文中提出一种不考虑碳排放的VPP市场运营模式,其运营机制参考欧洲FENIX项目的商业框架<sup>[16]</sup>。在日前电力市场交易周期中,VPP调度中心在事前公布电力需求,VPP根据预测出力制定计划并上报购售电价给信息中心。多个风电场、光伏电站、抽蓄电站和需求响应用户形成多类型DER联盟聚合于VPP。风电、光伏的出力通过深度学习进行日前预测,多类型DER联盟依据出力计划进行合作博弈和多源发电,并通过VPP进行电力市场交易。最后,采用两阶段收益分配策略实现联盟经济效益最大化。这种运营机制可以拓展到海量DER的有效聚合,通过聚合VPP内多类型DER联盟既能实现各类DER的多能互补,又能满足电力市场可靠的电能需求。该模式下VPP运营框架如图1所示。

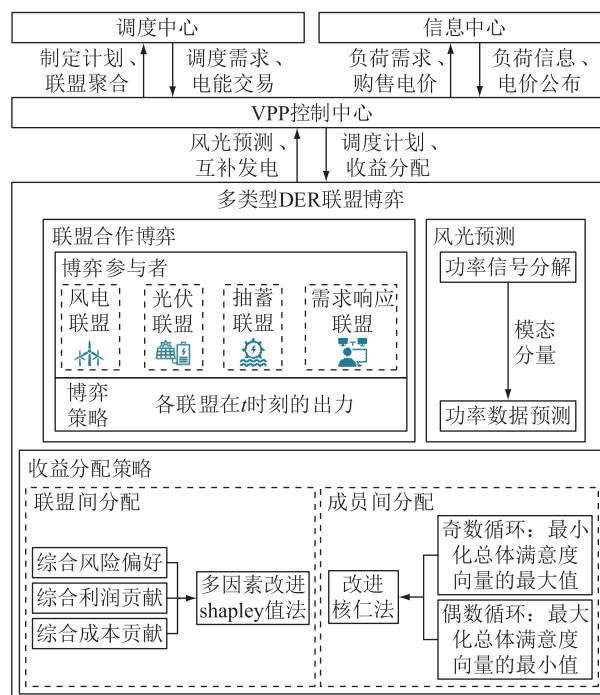


图1 VPP多类型DER聚合的运营框架

Fig.1 Operational framework for aggregation of multi-type DERs in VPP

## 2 基于VMD的Bi-MGLSTM风光出力预测

### 2.1 VMD算法

VMD是基于经验模态分解(empirical mode decomposition, EMD)提出的一种新的信号分解方法,能有效解决EMD中模态混叠和端点效应问题<sup>[26]</sup>。相比于傅里叶变换、拉氏变换等传统的信号处理方法,VMD具有更强的自适应性以及对于非线性、非平稳信号的处理能力<sup>[27]</sup>。利用该方法进行风光功率分解,既能充分提取原始数据的特征信息,又可以减小不同特征信息之间的相互影响,从而降低原始数据的复杂度并提升预测效果。VMD具体求解过程可参考文献[26-27]。

### 2.2 Bi-MGLSTM

风光功率预测模块采用Bi-MGLSTM,是在前后向的长短期记忆(long short term memory, LSTM)网络模型中多加1个遗忘门和1个输入门,添加的门的功能与原先的门的功能相同,但是多门控长短期记忆(multi gated long short term memory, MGLSTM)网络有着更强的信息筛选能力和更好的泛化能力<sup>[28]</sup>。此外,前后向层的输入有助于深入研究过去和未来信息之间的内在联系,从而提高特征数据的利用率。图2为Bi-MGLSTM网络结构。

图2中, $y_t$ 为 $t$ 时刻的输出; $\sigma, r$ 分别为Sigmoid和Relu激活函数; $\vec{h}_t, \overleftarrow{h}_t$ 分别为 $t$ 时刻前向、后向隐

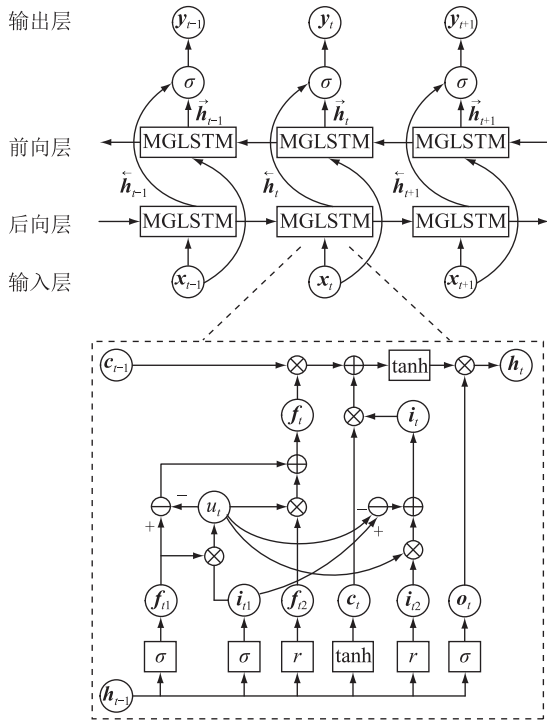


图2 Bi-MGLSTM 网络结构

Fig.2 Structure of Bi-MGLSTM network

藏层状态;  $f_{i1}$ 、 $f_{i2}$  分别为  $t$  时刻遗忘门 1 和遗忘门 2;  $i_{i1}$ 、 $i_{i2}$  分别为  $t$  时刻输入门 1 和输入门 2;  $o_t$  为  $t$  时刻输出门的单元状态;  $c_t$  为  $t$  时刻的细胞状态;  $u_t$  为  $f_{i1}$  与  $i_{i1}$  点乘的结果;  $x_t$ 、 $h_t$  分别为  $t$  时刻的输入和隐藏层的输出;  $f_i$ 、 $i_i$  分别为单个 MGLSTM 的总遗忘门和总输入门, 其计算见式(1)。

$$\begin{cases} f_{i1} = \sigma(\mathbf{W}_{f1}[\mathbf{h}_{t-1} \ \mathbf{x}_t] + \mathbf{b}_{f1}) \\ f_{i2} = r(\mathbf{W}_{f2}[\mathbf{h}_{t-1} \ \mathbf{x}_t] + \mathbf{b}_{f2}) \\ f_i = f_{i1} \cdot (f_{i2} \cdot i_{i1} + 1 - i_{i1}) \\ i_{i1} = \sigma(\mathbf{W}_{i1}[\mathbf{h}_{t-1} \ \mathbf{x}_t] + \mathbf{b}_{i1}) \\ i_{i2} = r(\mathbf{W}_{i2}[\mathbf{h}_{t-1} \ \mathbf{x}_t] + \mathbf{b}_{i2}) \\ i_i = i_{i1}(f_{i1} \cdot i_{i2} + 1 - f_{i1}) \end{cases} \quad (1)$$

式中:  $\mathbf{W}_{f1}$ 、 $\mathbf{W}_{f2}$  分别为遗忘门 1 和遗忘门 2 对应的权重矩阵;  $\mathbf{W}_{i1}$ 、 $\mathbf{W}_{i2}$  分别为输入门 1 和输入门 2 对应的权重矩阵;  $\mathbf{b}_{f1}$ 、 $\mathbf{b}_{f2}$  分别为遗忘门 1 和遗忘门 2 对应的训练偏置;  $\mathbf{b}_{i1}$ 、 $\mathbf{b}_{i2}$  分别为输入门 1 和输入门 2 对应的训练偏置。

最终的隐藏层输出  $h_t$  为:

$$\begin{cases} o_t = \sigma(\mathbf{W}_o[\mathbf{h}_{t-1} \ \mathbf{x}_t] + \mathbf{b}_o) \\ \mathbf{g}_t = \tanh(\mathbf{W}_g[\mathbf{h}_{t-1} \ \mathbf{x}_t] + \mathbf{b}_g) \\ c_t = f_i \mathbf{x}_{t-1} + i_i \mathbf{g}_t \\ \mathbf{h}_t = o_t \tanh(c_t) \end{cases} \quad (2)$$

式中:  $\mathbf{W}_o$ 、 $\mathbf{b}_o$  分别为输出门对应的权重和偏置;  $\mathbf{W}_g$ 、 $\mathbf{b}_g$  分别为单元细胞对应的权重和偏置;  $\mathbf{g}_t$  为  $t$  时刻的细胞临时状态。

遗忘门 2 和输入门 2 没有采用 Sigmoid 激活函数的原因: (1) Relu 函数比 Sigmoid 函数计算简单, 能大大提高计算效率。(2) Relu 函数在一定程度上可以缓解 Sigmoid 函数梯度消失问题。(3) Relu 函数的输入为负数时细胞信息输出为 0。

对于 Bi-MGLSTM 网络:

$$\begin{cases} \vec{\mathbf{h}}_t = f_1(\mathbf{x}_t, \vec{\mathbf{h}}_{t-1}) \\ \overleftarrow{\mathbf{h}}_t = f_2(\mathbf{x}_t, \overleftarrow{\mathbf{h}}_{t+1}) \\ \mathbf{y}_t = \sigma(\mathbf{W}_y [\vec{\mathbf{h}}_t \ \overleftarrow{\mathbf{h}}_t] + \mathbf{b}_y) \end{cases} \quad (3)$$

式(3)是通过前后向 MGLSTM 的隐藏层更新状态得到 Bi-MGLSTM 最终输出过程。其中,  $f_1$ 、 $f_2$  分别为 MGLSTM 网络前向和后向的计算函数;  $\mathbf{W}_y$ 、 $\mathbf{b}_y$  分别为输出层的权重和偏置。

### 2.3 基于 VMD 的 Bi-MGLSTM 功率预测模型

基于以上分析, 文中设计了基于 VMD 的 Bi-MGLSTM 功率组合预测模型, 其具体步骤如下:

(1) 数据的预处理, 获取风电/光伏的功率真实采集数据, 使用前后均值法补全缺失数据, 得到风光功率历史数据集。

(2) 基于 VMD-Bi-MGLSTM 功率组合预测模型, 采用 VMD 将风光发电功率数据分解为若干个子序列分量。将分解得到的子序列划分为测试集和训练集并输入 Bi-MGLSTM 模型中进行训练。为了使结果更加准确, 采用贝叶斯算法<sup>[29]</sup>对 Bi-MGLSTM 模型的超参数进行优化。然后, 将各分量的预测结果进行叠加重构, 得到初步功率预测结果。

(3) 误差修正模型, 为了减小预测误差, 将初步功率预测值与真实值进行求差, 得到预测值和真实值之间的误差时间序列。分析误差序列的特性, 并使用优化后的 Bi-MGLSTM 模型对误差序列进行训练与预测, 得到误差预测结果。

(4) 将功率预测值和误差预测值相加得到最终的预测结果, 并通过均方根误差  $e_{\text{RMSE}}$ 、平均绝对误差  $e_{\text{MAE}}$  评价预测模型性能。

$$\begin{cases} e_{\text{RMSE}} = \sqrt{\frac{1}{J} \sum_{j=1}^J (P_j - P'_j)^2} \\ e_{\text{MAE}} = \frac{1}{J} \sum_{j=1}^J |P_j - P'_j| \end{cases} \quad (4)$$

式中:  $J$  为功率数据集;  $P_j$ 、 $P'_j$  分别为第  $j$  个风电/光伏的实际功率值与预测功率值。

## 3 VPP 优化调度模型

### 3.1 系统优化目标

基于风光预测结果, 以 VPP 在 24 h (一个调度



周期)内的经济效益最高为目标,实现 VPP 运行内各主体售电收益最大化。VPP 收益包括风、光、抽蓄售电收益以及需求响应用户在削峰填谷时的净收益。具体计算如下:

$$\max F_{VPP} = \sum_{t=1}^T (F_{WPP,t} + F_{PV,t} + F_{PSS,t} + F_{DR,t}) \quad (5)$$

式中: $F_{VPP}$  为 VPP 收益; $T$  为调度周期; $F_{WPP,t}$  为  $t$  时刻风电场售电净收益; $F_{PV,t}$  为  $t$  时刻光伏电站的售电净收益; $F_{PSS,t}$  为  $t$  时刻抽蓄电站售电净收益; $F_{DR,t}$  为  $t$  时刻需求响应在削峰填谷时的净收益。

(1) 风电场主体收益模型。

$$F_{WPP,t} = \chi_t P_t^w - \chi_t \gamma_{ab}^w (P_t^{\text{pred},w} - P_t^{\text{gen},w}) - \gamma_{mc}^w P_{gro}^w \quad (6)$$

式中: $\chi_t$  为 VPP 提供的  $t$  时刻售电电价; $P_t^w$  为  $t$  时刻风电场向 VPP 内负荷输送的有功功率; $\gamma_{ab}^w$  为弃风惩罚系数; $P_t^{\text{pred},w}$ 、 $P_t^{\text{gen},w}$  分别为  $t$  时刻风电场的预测出力和实际出力; $\gamma_{mc}^w$  为风电机组运维成本系数; $P_{gro}^w$  为风电场的总容量。

(2) 光伏电站主体收益模型。

$$F_{PV,t} = \chi_t P_t^{\text{pv}} - \chi_t \gamma_{ab}^{\text{pv}} (P_t^{\text{pred},\text{pv}} - P_t^{\text{gen},\text{pv}}) - \gamma_{mc}^{\text{pv}} P_{gro}^{\text{pv}} \quad (7)$$

式中: $P_t^{\text{pv}}$  为  $t$  时刻光伏电站向 VPP 内负荷输送的有功功率; $\gamma_{ab}^{\text{pv}}$  为弃光惩罚系数; $P_t^{\text{pred},\text{pv}}$ 、 $P_t^{\text{gen},\text{pv}}$  分别为  $t$  时刻光伏电站的预测出力和实际出力; $\gamma_{mc}^{\text{pv}}$  为光伏机组运维成本系数; $P_{gro}^{\text{pv}}$  为光伏电站的总容量。

(3) 抽蓄电站主体收益模型。

$$F_{PSS,t} = \chi_t P_t^{\text{pss}} + \gamma_{pw}^{\text{pss}} P_t^w + \gamma_{pv}^{\text{pss}} P_t^{\text{pv}} - \gamma_{ab}^{\text{pss}} P_{pw,t}^{\text{pss}} - \gamma_{mc}^{\text{pss}} P_{gro}^{\text{pss}} \quad (8)$$

式中: $P_t^{\text{pss}}$ 、 $P_{pw,t}^{\text{pss}}$  分别为  $t$  时刻内抽蓄电站的发电功率和抽水功率; $\gamma_{pw}^{\text{pss}}$ 、 $\gamma_{pv}^{\text{pss}}$  分别为风电场、光伏电站支付给抽蓄电站的辅助服务综合成本系数; $\gamma_{ab}^{\text{pss}}$  为  $t$  时刻抽蓄电站的抽水电价; $\gamma_{mc}^{\text{pss}}$  为抽蓄电站的运维成本系数; $P_{gro}^{\text{pss}}$  为抽蓄电站的总容量。

(4) 需求响应主体收益模型。

$$F_{DR,t} = \chi_t \omega_{\alpha}^{\text{dr}} P_{u,t}^{\text{inc}} + \chi_t \omega_{\beta}^{\text{dr}} P_{u,t}^{\text{dec}} - \gamma_{mc}^{\text{dr}} (P_{u,t}^{\text{inc}} + P_{u,t}^{\text{dec}}) - \gamma_{st}^{\text{dr}} P_{u,t}^{\text{dr}} \quad (9)$$

式中: $\omega_{\alpha}^{\text{dr}}$ 、 $\omega_{\beta}^{\text{dr}}$  分别为需求响应中可转移负荷增加和削减电量时的价格激励系数; $P_{u,t}^{\text{inc}}$ 、 $P_{u,t}^{\text{dec}}$  分别为  $t$  时刻需求响应用户  $u$  增加和减少的负荷量; $\gamma_{mc}^{\text{dr}}$  为需求响应用户削减和增加负荷的转移成本系数; $\gamma_{st}^{\text{dr}}$  为备用负荷成本系数; $P_{u,t}^{\text{dr}}$  为  $t$  时刻需求响应用户  $u$  的总容量。

## 3.2 系统约束条件

### 3.2.1 功率平衡约束

$$\sum_{t=1}^T (P_t^w + P_t^{\text{pv}} + P_t^{\text{pss}}) = \sum_{t=1}^T (P_{u,t}^{\text{dec}} + P_{u,t}^{\text{inc}}) + \sum_{t=1}^T P_t^{\text{load}} \quad (10)$$

式中: $P_t^{\text{load}}$  为 VPP 在  $t$  时刻的负荷需求。

### 3.2.2 风电运行约束

$$P_t^w = P_t^{\text{gen},w} - P_t^{\text{pass},w} \quad (11)$$

$$0 \leq P_t^w \leq P_{t,\max}^{\text{pred},w} \quad (12)$$

$$0 \leq P_t^{\text{pass},w} \leq P_{t,\max}^{\text{pred},w} \quad (13)$$

式中: $P_t^{\text{pass},w}$  为  $t$  时刻风电场向抽蓄电站输送的发电功率; $P_{t,\max}^{\text{pred},w}$  为  $t$  时刻风电功率预测的最大值。

### 3.2.3 光伏出力约束

$$P_t^{\text{pv}} = P_t^{\text{gen},\text{pv}} - P_t^{\text{pass},\text{pv}} \quad (14)$$

$$0 \leq P_t^{\text{pv}} \leq P_{t,\max}^{\text{pred},\text{pv}} \quad (15)$$

$$0 \leq P_t^{\text{pass},\text{pv}} \leq P_{t,\max}^{\text{pred},\text{pv}} \quad (16)$$

式中: $P_t^{\text{pass},\text{pv}}$  为  $t$  时刻光伏电站向抽蓄电站输送的发电功率; $P_{t,\max}^{\text{pred},\text{pv}}$  为  $t$  时刻光伏功率预测的最大值。

### 3.2.4 抽水蓄能约束

$$P_{pw,t}^{\text{pss}} = P_t^{\text{pass},w} + P_t^{\text{pass},\text{pv}} + P_{pw,t}^{\text{pss,al}} \quad (17)$$

$$I_t^{\text{pss}} P_{\min}^{\text{pss}} \leq P_t^{\text{pss}} \leq I_t^{\text{pss}} P_{\max}^{\text{pss}} \quad (18)$$

$$I_t^{\text{p}} P_{\min}^{\text{pss}} \leq P_{pw,t}^{\text{pss}} \leq I_t^{\text{p}} P_{\max}^{\text{pss}} \quad (19)$$

$$I_t^{\text{p}} + I_t^{\text{g}} \leq 1 \quad (20)$$

$$E_{re,t} = E_{re,t-1} + \sum_{t=1}^T \left( \frac{P_t^{\text{pss}}}{\alpha^{\text{p}}} - \frac{P_{pw,t}^{\text{pss}}}{\alpha^{\text{g}}} \right) \quad (21)$$

$$E_{\min} \leq E_{re,t} \leq E_{\max} \quad (22)$$

式中: $P_{pw,t}^{\text{pss,al}}$  为  $t$  时刻抽蓄电站独立运行时的抽水功率; $P_{\max}^{\text{pss}}$ 、 $P_{\min}^{\text{pss}}$  分别为抽蓄电站发电功率上、下限; $P_{pw,\max}^{\text{pss}}$ 、 $P_{pw,\min}^{\text{pss}}$  分别为抽蓄电站抽水功率上、下限; $I_t^{\text{p}}$ 、 $I_t^{\text{g}}$  分别为抽水和发电时表征机组启停状态的 0-1 变量; $E_{re,t}$  为  $t$  时刻抽蓄电站水库库容; $\alpha^{\text{p}}$ 、 $\alpha^{\text{g}}$  分别为发电和抽水时的运行效率; $E_{\min}$ 、 $E_{\max}$  分别为最小库容容量和最大库容容量。

### 3.2.5 需求响应约束

$$0 \leq P_{u,t}^{\text{dec}} \leq a_{u,t}^{\text{dec}} P_{u,\max}^{\text{out}} \quad t \in (t_{u,\text{in}}^{\text{dec}}, t_{u,\text{out}}^{\text{dec}}) \quad (23)$$

$$0 \leq P_{u,t}^{\text{inc}} \leq a_{u,t}^{\text{inc}} P_{u,\max}^{\text{in}} \quad t \in (t_{u,\text{in}}^{\text{inc}}, t_{u,\text{out}}^{\text{inc}}) \quad (24)$$

$$\sum_{t=1}^T P_{u,t}^{\text{inc}} = \sum_{t=1}^T P_{u,t}^{\text{dec}} \quad (25)$$

$$\begin{cases} P_{u,t}^{\text{dec}} = 0 & t \notin (t_{u,\text{in}}^{\text{dec}}, t_{u,\text{out}}^{\text{dec}}) \\ P_{u,t}^{\text{inc}} = 0 & t \notin (t_{u,\text{in}}^{\text{inc}}, t_{u,\text{out}}^{\text{inc}}) \end{cases} \quad (26)$$

$$0 \leq a_{u,t}^{\text{dec}} + a_{u,t}^{\text{inc}} \leq 1 \quad (27)$$

式中: $P_{u,\max}^{\text{in}}$ 、 $P_{u,\max}^{\text{out}}$  分别为需求响应用户  $u$  的最大转入和转出功率; $a_{u,t}^{\text{dec}}$ 、 $a_{u,t}^{\text{inc}}$  分别为  $t$  时刻需求用户  $u$  负

荷减少和增加状态变量;  $t_{u,in}^{dec}$ 、 $t_{u,out}^{dec}$  分别为需求响应用户  $u$  的可转移负荷转出功率起始时间和结束时间;  $t_{u,in}^{inc}$ 、 $t_{u,out}^{inc}$  分别为需求响应用户  $u$  的可转移负荷转入功率起始时间和结束时间。

#### 4 多类型 DER 合作博弈和收益分配策略

在独立运行模式下, VPP 内部多个风电场和光伏电站按照风光资源进行电力满发, 发电量全部进行电能交易, 抽蓄电站通过抽发差价获取自身收益。需求响应用户考虑用电习惯和满意度进行负荷转移。在合作运行模式下, 同类型的风、光、抽蓄、需求响应形成合作联盟, 由 VPP 调度中心的负荷信息进行互补发电产生合作电量增益。因此, 通过 VPP 的聚合调度能实现联盟收益最大化并为电力市场提供高性价比的优质电能。

##### 4.1 合作博弈模型

(1) 博弈参与者。博弈模型是由 VPP 内部 DER 联盟成员, 即  $N_1$  个风电场、 $N_2$  个光伏电站、 $N_3$  个抽蓄电站、 $N_4$  个需求响应用户作为参与者进行四方博弈, 用  $\{N_1, N_2, N_3, N_4\}$  表示。

(2) 参与者策略。当 VPP 进行电力市场经济交易时, 各 DER 联盟在  $t$  时刻的出力  $P_t^w$ 、 $P_t^{pv}$ 、 $P_t^{pss}$  包括需求响应用户的可转移负荷量  $P_{u,t}^{inc}$ 、 $P_{u,t}^{dec}$  作为博弈策略。其策略空间表示为:

$$S_t = \{P_t^w, P_t^{pv}, P_t^{pss}, P_{u,t}^{inc}, P_{u,t}^{dec}\} \quad (28)$$

其中, VPP 的各 DER 联盟的策略空间应满足相应变量的约束条件式 (11) 一式 (27)。

(3) 特征函数。博弈的特征函数为文中各主体收益模型的目标函数  $F_{WPP,t}$ 、 $F_{PV,t}$ 、 $F_{PSS,t}$ 、 $F_{DR,t}$ 。

参与者是否达成合作联盟的条件为合作联盟是否满足超可加性条件, 即合作联盟产生的收益应大于联盟中各参与者在非合作模式下的收益之和。合作的可行性为:

$$V(1) + V(2) + \dots + V(l) = V(N_1) + V(N_2) + V(N_3) + V(N_4) \leq V(N) \quad (29)$$

式中:  $V(l)$  为 VPP 内部 DER 成员  $l$  不合作时的收益;  $V(N_x)$  为 DER 成员形成风、光、抽蓄、需求响应联盟时不合作的收益;  $V(N)$  为 VPP 内部各 DER 联盟形成合作联盟的总收益。

#### 4.2 VPP 内多联盟间改进 shapley 值法收益分配

##### 4.2.1 传统 shapley 值模型

shapley 值法是合作博弈中最经典的收益分配方法, 其目的是通过求取所有合作方式中成员的边际贡献期望值来确定其应分得的利润, shapley 值法具体计算可参考文献 [30]。

##### 4.2.2 基于多因素改进的 shapley 值法模型

在实际的 VPP 合作大联盟中, 仍须考虑各 DER 联盟的风险因素、综合利润、成本贡献的不同, 引入修正因子, 优化各 DER 联盟合作时的收益分配模型。

(1) 综合风险偏好程度。为提高 VPP 整体应对风险的能力, 减少风险损失, 实现收益共赢, 考虑风险偏好因素对收益分配结果进行补偿, 通过效用函数对可调节和不可调节的发电联盟进行风险量化<sup>[30]</sup>。3 种不同风险函数  $f_r$  的效用函数  $U(f_r)$  如图 3 所示。




图 3 风险效用函数

Fig.3 Risk utility functions

对于不可调控的风光联盟而言, 预测误差直接影响联盟的整体收益变化, 所以选取整体功率预测精准度作为风险函数, 定义为风险规避型效用。具体如下:

$$f_{r,1} = 1 - \frac{1}{tw_1} \sum_{w=1}^{w_1} \sum_{t=1}^T \frac{|P_{w,t}^* - P_{w,t}|}{P_{w,t}} \quad (30)$$

$$U(f_{r,1}) = \frac{e(1 - \exp(-f_{r,1}))}{e - 1} \quad (31)$$

式中:  $f_{r,1}$  为不可调控联盟的风险函数;  $P_{w,t}^*$ 、 $P_{w,t}$  分别为风光功率在  $t$  时刻的预测值和实际值;  $w_1$  为不可调控联盟的总数;  $U(f_{r,1})$  为风险规避型指数效用函数。

对于可调控的抽蓄联盟和需求响应联盟而言, 可以对不可控的风光出力误差进行调节并在调峰时获得更多收益。因此选择风险喜好型效用函数进行风险量化。具体如下:

$$f_{r,2} = \frac{1}{Z_{r_2}} - \frac{1}{tw_2} \sum_{w=1}^{w_2} \sum_{t=1}^T |P_{w,t}^* - P_{w,t}| \quad (32)$$

$$U(f_{r,2}) = \exp(f_{r,2}) \quad (33)$$

式中:  $f_{r,2}$  为可调控联盟的风险函数;  $Z_{r_2}$  为可调控联盟的最大可调节容量;  $w_2$  为可调控联盟的总数;  $U(f_{r,2})$  为风险偏好型指数效用函数。

综上, DER 联盟  $m$  的风险偏好因子  $p_m$  具体计算为:

$$p_m = \frac{U(f_{r,h})}{\sum_{h \in \{1,2\}} U(f_{r,h})} \quad (34)$$

(2) 综合利润贡献。在进行联盟收益分配时,不仅需要考虑 shapley 值法中的边际利润,还需要考虑各 DER 联盟对大联盟的利润贡献。基于此,定义综合利润贡献度为不同合作方式下 DER 联盟  $m$  加入前后的发电收益与大联盟整体的收益增量之比,即 DER 联盟  $m$  的利润贡献因子  $q_m$  具体计算为:

$$q_m = \frac{\sum_{m=1}^U \frac{|V(M) - V(M - \{m\}) - V(\{m\})|}{\sum_{m=1}^M |V(M) - V(M - \{m\}) - V(\{m\})|}}{\quad} \quad (35)$$

式中: $U$  为 DER 联盟总数; $V(M)$  为部分 DER 联盟参与合作时的收益; $V(M - \{m\})$  为 DER 联盟  $m$  未加入合作时联盟的收益; $V(\{m\})$  为 DER 联盟  $m$  独自运行时的收益。

(3) 综合成本贡献度。各 DER 联盟参与合作前后风光运维成本、抽蓄的辅助服务综合成本以及需求响应增削负荷运行成本也不同。故将综合成本贡献度纳入收益分配模型,定义综合成本贡献度为各联盟不同合作方式下成本变动与联盟总成本变动的比值,即 DER 联盟  $m$  的成本贡献度因子  $r_m$  具体计算为:

$$r_m = \frac{|C(M) - C(M - \{m\})|}{\sum_{m=1}^M |C(M) - C(M - \{m\})|} \quad (36)$$

$$C(N) = C_{\text{cost}}^{\text{WPP}} + C_{\text{cost}}^{\text{PV}} + C_{\text{cost}}^{\text{PSS}} + C_{\text{cost}}^{\text{DR}} \quad (37)$$

式中: $C(N)$  为 VPP 内部各 DER 联盟合作运行时的总成本; $C(M)$  为部分 DER 联盟参与合作时的成本; $C(M - \{m\})$  为 DER 联盟  $m$  未加入合作时联盟所需成本; $C_{\text{cost}}^{\text{WPP}}$ 、 $C_{\text{cost}}^{\text{PV}}$ 、 $C_{\text{cost}}^{\text{PSS}}$ 、 $C_{\text{cost}}^{\text{DR}}$  分别为风电场、光伏电站、抽蓄电站、需求响应用户各 DER 联盟包括运维成本、损耗成本和辅助服务费用的合作运行总成本之和。

综合考虑风险偏好、利润贡献和成本贡献后,采用熵权法<sup>[24]</sup>赋予每个修正因子的加权值,定义收益分配修正系数  $R_m$  如下:

$$R_m = [\nu_1 \ \nu_2 \ \nu_3] \left[ \begin{array}{ccc} \frac{p_m}{\sum_{m=1}^M p_m} & \frac{q_m}{\sum_{m=1}^M q_m} & \frac{r_m}{\sum_{m=1}^M r_m} \end{array} \right]^T \quad (38)$$

式中: $\nu_y$  为加权因子, $y=1,2,3$ ,且  $\nu_1 + \nu_2 + \nu_3 = 1$ 。改进后得到 DER 联盟新旧权重之差  $\Delta R_m$  为:

$$\Delta R_m = R_m - (1/U) \quad (39)$$

对于权重之差都满足  $\sum_{m=1}^M \Delta R_m = 0$ ,进一步求得

合作情况下各联盟的最终收益为:

$$Q^* = \sum_M \frac{(|M|-1)! (U-|M|)!}{|U|!} \times (V(M) - V(M - \{m\})) + V(M) \Delta R_m \quad (40)$$

式中: $Q^*$  为采用基于多因素改进的 shapley 值法得到的收益分配结果。

### 4.3 基于奇偶循环改进核仁法细化收益分配

#### 4.3.1 核仁法

核仁解的分配思想是尽可能寻找一个可以使所有子联盟成员满意度均衡的方式<sup>[31]</sup>,令  $e(S, x_i) = V(S) - x_i$ ,表示成员对子联盟  $S$  分配的满意程度。其中, $V(S)$  为成员  $i$  参与子联盟  $S$  时,内部所有成员的合作收益。此时的收益分配方式  $x_i$  即为合作博弈的核仁解,即对  $\min \max_{i \in S} e(S, x_i)$  求解。

当前求解核仁解较为常见的方法为循环线性规划(linear programming, LP),通过循环迭代优化最小化每个子联盟的满意度,具体可参考文献[32]。

#### 4.3.2 基于奇偶循环的改进核仁法

在计算单个子联盟最优核仁解时,将向量  $\theta(x) = [e(S_1, x_1) \ e(S_2, x_2) \ \dots \ e(S_i, x_i)]^T$  表示为子联盟总体满意度,核仁解为总体满意度最高的解,总体满意度的高低衡量标准为字典顺序<sup>[32]</sup>。提高总体满意度的方法有最大化总体满意度的最小值,但这种方法往往不能使其子联盟满意度达到最优状态,导致联盟总体满意度出现分布不均匀、稳定性波动较大等问题。因此,采用基于奇偶循环的改进核仁法细化 VPP 内部各子联盟成员收益。

具体步骤为:在奇数 LP 中以最小化总体满意度向量中的最大值为目标,在偶数 LP 中以最大化总体满意度向量中的最小值为目标,进行交替循环求解,直至求解得出唯一解。计算得到比核仁解总体满意度更高的联盟均衡解,即此时的收益分配方案为最优解,具体模型如下。

第  $n$  个以最小化为目标的奇数 LP 模型  $L_n^{\text{Odd}}$  为:

$$\left\{ \begin{array}{l} \min \varphi_n \\ \varphi_n = \max_{i \in S} e(S, x_i) \\ \text{s.t.} \sum_{i \in P} x_i \geq V(P) - \varphi_n \quad \forall P \subset S \\ \sum_{i \in P} x_i \leq V(P) - \tau_{n-1}^* \quad \forall P \subset S \\ \sum_{i \in P} x_i + \varphi_i^* = V(P) \\ \forall P \in H_i; i \in \{1, 2, \dots, n-1\} \\ \sum_{i \in P} x_i + \tau_{n-1}^* = V(P) \\ \forall P \in I_i; i \in \{1, 2, \dots, n-1\} \end{array} \right. \quad (41)$$



式中:  $\varphi_n^*$  为奇数 LP 模型的满意度最优解;  $\varphi_i^*$  为第  $n-1$  次线性循环的第  $i$  次小满意度;  $S$  为含有  $2^n$  个不同子联盟组合方式的有限集合,  $P$  为含有  $2^{n-1}$  个不同子联盟组合方式的有限集合, 且包含于集合  $S$ ;  $H_i$  为第  $i$  个 LP 模型  $L_i^{\text{Odd}}$  的解中, 其对应所有子联盟的满意度取到  $\varphi_i^*$  时的联盟集合;  $I_i$  为第  $i$  个 LP 模型  $L_i^{\text{Even}}$  的解中, 其对应所有子联盟的满意度取到  $\tau_i^*$  时的联盟集合。当  $L_n^{\text{Odd}}$  求解出唯一解时, 得到的求解结果即为联盟均衡解; 否则求解偶数 LP 模型中最小化总体满意度向量中的最大值  $\tau_n^*$ 。

第  $n$  个以最大化为目标的偶数 LP 模型  $L_n^{\text{Even}}$  为:

$$\left\{ \begin{array}{l} \max \tau_n \\ \tau_n = \min_{i \in S} e(S, x_i) \\ \text{s.t.} \sum_{i \in P} x_i \leq V(P) - \tau_n \\ \sum_{i \in P} x_i \geq V(P) - \varphi_n^* \\ \forall P \in H_i; i \in \{1, 2, \dots, n-1\} \\ \sum_{i \in P} x_i + \varphi_i^* = V(P) \\ \forall P \in H_i; i \in \{1, 2, \dots, n\} \\ \sum_{i \in P} x_i + \tau_{n-1}^* = V(P) \\ \forall P \in I_i; i \in \{1, 2, \dots, n-1\} \end{array} \right. \quad (42)$$

以上模型均满足  $\sum_{i \in S} x_i = V(S)$ , 表示参与合作的个体都是理性的。 $\sum_{i \in P} x_i \leq V(P) - \tau_{n-1}^*$  用于约束所有子联盟的满意度值均小于模型  $L_{n-1}^{\text{Odd}}$  求解出的  $\tau_{n-1}$  从而保证求  $\min$  函数时不会出现比第  $n-1$  次小的满意度  $\tau_{n-1}$  更小的满意度值。 $\sum_{i \in P} x_i \geq V(P) - \varphi_n^*$  用于约束所有子联盟的满意度值均大于模型  $L_{n-1}^{\text{Even}}$  求解出的  $\varphi_n$  从而保证求  $\max$  函数时不会出现比第  $n$  次大的满意度  $\varphi_n$  更大的满意度值。

## 5 算例分析

### 5.1 求解流程与算例数据

文中风光预测在 MATLAB 2018b 编译环境下进行仿真, 合作博弈调度模型及收益分配策略在 MATLAB 2018b 平台上调用 Yalmip 的 CLPEX 求解器进行求解。模型的具体求解流程如图 4 所示。

为了验证非对称结构下该模型的准确性和普适性, 将中国某地区的 DER 聚合为 VPP。设置风电场 1 的额定容量为 75 MW, 风电场 2 的额定容量为 80 MW, 光伏电站 1 和光伏电站 2 的额定容量均为

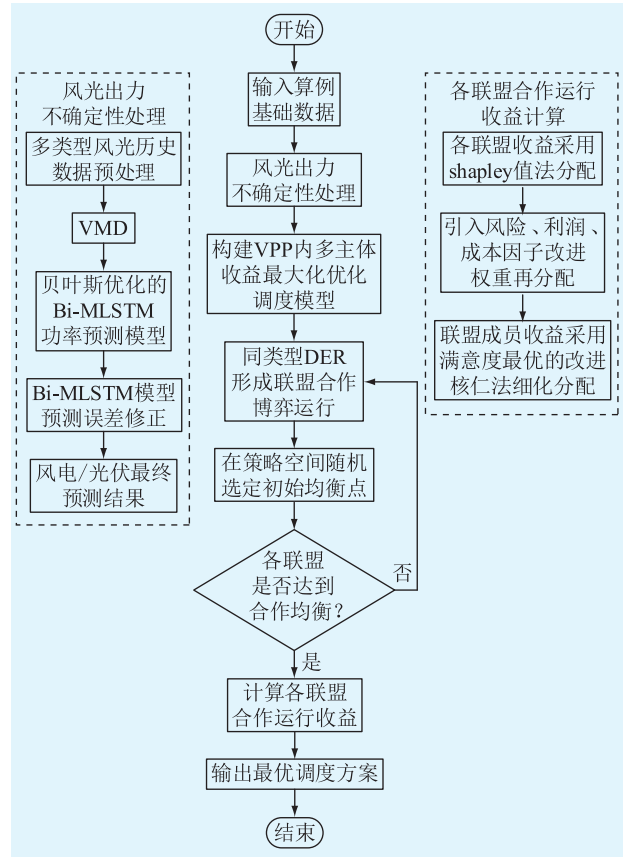


图 4 整体模型求解流程

Fig.4 Flow chart of overall model solving

65 MW, 光伏电站 3 的额定容量为 80 MW, 抽蓄电站 1 的额定容量为 80 MW, 抽蓄电站 2 的额定容量为 70 MW, 需求响应 1 的额定容量为 45 MW, 需求响应 2 的额定容量为 55 MW。假设 VPP 聚合以上主体参与日前电力市场 24 h 调度, 时间间隔为 1 h。分时电价如表 1 所示, 抽蓄电站的运行参数如表 2 所示, 其他主体成本相关系数如表 3 所示, 系统的用电负荷需求如图 5 所示。

表 1 某交易日的分时电价

类别	时段	电价/[元·(MW·h) <sup>-1</sup> ]
峰	08:00—11:00、 17:00—23:00	1 009.5
平	07:00—08:00、 13:00—17:00、 23:00—24:00	740.3
谷	00:00—07:00、 01:00—13:00	475.8

### 5.2 风光出力预测结果分析

文中使用的数据集为 2022 年 12 月中国某地区测得的 31 d 风电光伏发电数据。每 15 min 采集一次, 共 2 组数据集, 每组 2 976 个数据。选取前 26 d 的数据作为训练集, 最后 5 d 的数据作为测试集, 将

表 2 抽蓄电站运行参数

Table 2 Operating parameters of pumped storage station

参数	抽蓄电站 1	抽蓄电站 2
$P_{max}^{pss}/MW$	75	80
$P_{min}^{pss}/MW$	15	20
$P_{pw,max}^{pss}/MW$	65	60
$P_{pw,min}^{pss}/MW$	12	12
$\alpha^p/[MW \cdot (hm^3)^{-1}]$	240	240
$\alpha^g/[MW \cdot (hm^3)^{-1}]$	300	300
$E_{max}/hm^3$	10	12
$E_{min}/hm^3$	1.2	1.5

表 3 成本相关系数

Table 3 Coefficient of cost correlation

参数	数值
$\gamma_{ab}^{pv}$	0.16
$\gamma_{ab}^w$	0.15
$\omega_{\alpha}^{dr}$	0.15
$\omega_{\beta}^{dr}$	0.20
$\gamma_{mc}^w/[元 \cdot (MW \cdot h)^{-1}]$	120
$\gamma_{mc}^{pv}/[元 \cdot (MW \cdot h)^{-1}]$	150
$\gamma_w^{pss}/[元 \cdot (MW \cdot h)^{-1}]$	120
$\gamma_{pv}^{pss}/[元 \cdot (MW \cdot h)^{-1}]$	140
$\gamma_{ab}^{pss}/[元 \cdot (MW \cdot h)^{-1}]$	700




图 5 VPP 用电负荷需求


Fig.5 Electricity load demand of VPP

训练好的模型用于预测不同容量的风光发电功率。

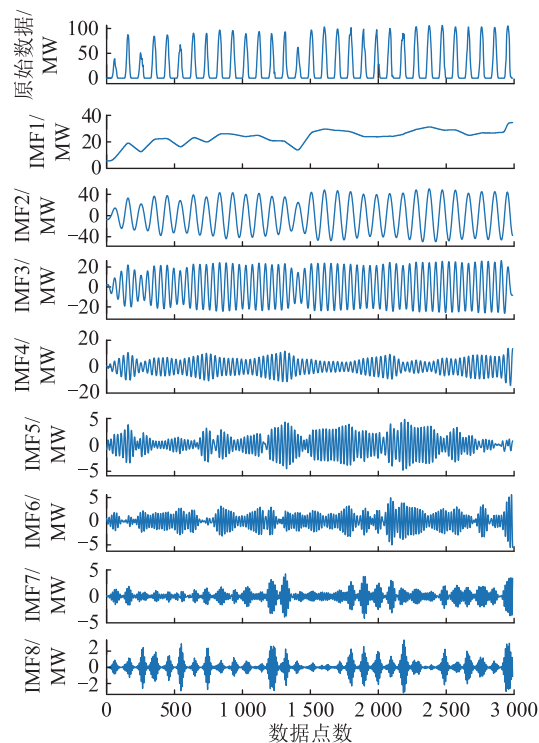
### 5.2.1 VMD 结果

利用 VMD 对光伏风电功率进行平稳化处理,得到若干个相关性更强的子序列。VMD 的模态数  $z$  值的选取会直接影响分解效果,当  $z$  值较小时,会处于欠分解状态,功率数据无法分解为本征模态函数 (intrinsic mode function, IMF) 分量。当  $z$  值较大时,会出现过分解状态,这是因为多个 IMF 分量具有相同的中心频率。经过多次仿真验证,设置模态数  $z$ 、惩罚参数  $\alpha$ 、中心频率  $w_0$  和收敛准则容忍度  $\tau$  分别为 8、2 000、1 和  $10^{-7}$ ,分解得到的子序列既不会出现模态混叠,又可以保证分解序列的保真度。图 6

为 VMD 结果,可用于预测模型。



(a) 风电功率分解结果



(b) 光伏功率分解结果

图 6 VMD 功率分解结果

Fig.6 VMD power decomposition results

### 5.2.2 风光功率预测结果分析

为了验证文中所提预测模型在风光功率预测方面的优越性,分别设置贝叶斯优化-双向长短期记忆 (Bayesian optimization-bidirectional long short-term memory, BO-BiLSTM) 网络、贝叶斯优化的双向多门



控长短期记忆 (Bayesian optimization-bidirectional multi gated long short term memory, BO-Bi-MGLSTM) 网络、VMD-BO-BiLSTM 网络、VMD-BO-Bi-MGLSTM 网络作为对比模型。实验结果如图 7 和表 4 所示。




图 7 模型预测结果对比

Fig.7 Comparison of model prediction results

表 4 不同预测模型评价结果

Table 4 Evaluation results of different prediction models

风电功率预测模型	$e_{RMSE}/MW$	$e_{MAE}/MW$
BO-BiLSTM	2.623 3	2.048 8
BO-Bi-MGLSTM	2.235 7	1.725 3
VMD-BO-BiLSTM	1.942 3	1.568 4
VMD-BO-Bi-MGLSTM	1.593 1	0.913 8
光伏功率预测模型	$e_{RMSE}/MW$	$e_{MAE}/MW$
BO-BiLSTM	2.235 2	1.827 8
BO-Bi-MGLSTM	1.958 9	1.534 6
VMD-BO-BiLSTM	1.653 3	1.257 1
VMD-BO-Bi-MGLSTM	1.195 4	0.853 7

由图 7 和表 4 可知,4 种模型在风电功率预测中波动性较大,在光伏功率预测中除了峰值结果相差较大,其他数据误差较小,这是因为光伏出力规律性更强,风电出力随机性更强。对比 BO-BiLSTM 模型和 BO-Bi-MGLSTM 模型,不管是风电功率预测还是光伏功率预测,预测精度都低于 VMD-BO-BiLSTM 模型和 VMD-BO-Bi-MGLSTM 模型。这说明对原始功率进行 VMD,去除模态分量中的多余噪

声,能在一定程度上降低功率的波动性,使得预测模型能更好地进行特征信息提取。其次,相较于 VMD-BO-BiLSTM 模型,VMD-BO-Bi-MGLSTM 在风电和光伏预测中的  $e_{RMSE}$  分别降低 0.349 2、0.457 9 MW,  $e_{MAE}$  分别降低 0.654 6、0.403 4 MW,这是因为 Bi-MGLSTM 模型中每个 LSTM 多加 1 个输入门和 1 个遗忘门,使得模型具有更强的信息处理能力,可以更加灵活地处理时间序列数据的保留与遗忘。

为验证文中模型在不同步长下的预测性能,对比各预测模型在预测步长为二步、四步时的风光功率预测评价结果,如表 5 所示。

表 5 不同预测模型的多步预测评价结果

Table 5 Multi-step prediction evaluation results of different prediction models

风电功率预测模型	步长	$e_{RMSE}/MW$	$e_{MAE}/MW$
BO-BiLSTM	二步	7.978 4	5.968 1
	四步	9.906 3	7.550 4
BO-Bi-MGLSTM	二步	5.837 7	4.667 0
	四步	6.589 8	5.389 2
VMD-BO-BiLSTM	二步	5.464 9	4.453 0
	四步	6.120 4	4.738 2
VMD-BO-Bi-MGLSTM	二步	2.790 6	2.135 1
	四步	4.149 6	3.695 3
光伏功率预测模型	步长	$e_{RMSE}/MW$	$e_{MAE}/MW$
BO-BiLSTM	二步	5.806 3	4.674 0
	四步	6.512 3	4.953 3
BO-Bi-MGLSTM	二步	4.632 1	3.711 3
	四步	4.995 9	3.790 1
VMD-BO-BiLSTM	二步	2.725 9	2.075 3
	四步	3.751 4	2.600 1
VMD-BO-Bi-MGLSTM	二步	1.380 2	0.897 2
	四步	1.948 5	1.464 2

由表 5 可得,随着预测步长的增加,所有模型的  $e_{RMSE}$  和  $e_{MAE}$  都逐渐增大,这是因为多步预测是在单步预测模型的基础上,将单步预测结果作为已知数据预测未来多步的功率值,从而导致误差不断累积,预测精度也随之下降。以随机性更强的风电功率预测为例,相比于 BO-BiLSTM 模型,BO-Bi-MGLSTM 模型在二步、四步预测的  $e_{RMSE}$  分别降低 2.140 7、3.373 2 MW,  $e_{MAE}$  分别降低 1.301 1、2.161 2 MW; 相比于 VMD-BO-BiLSTM 模型,VMD-BO-Bi-MGLSTM 模型在二步、四步预测的  $e_{RMSE}$  分别降低 2.674 3、1.970 8 MW,  $e_{MAE}$  分别降低 2.317 9、1.042 9 MW。实验结果表明,相比于其他模型,VMD-BO-Bi-MGLSTM 模型的多步预测结果的  $e_{RMSE}$  和  $e_{MAE}$  都是

最小的,具有更好的预测效果和稳定性能,可以满足调度模型所需的典型日风光功率预测。

基于上述预测模型,根据多个风电光伏所设容量,预测得到的风光出力数据如图 8 所示。




图 8 基于 VMD-BO-Bi-MGLSTM 的风光出力预测

Fig.8 VMD-BO-Bi-MGLSTM based wind power output prediction

### 5.3 VPP 合作博弈策略分析

在 VMD-BO-Bi-MGLSTM 风光功率预测模型下,设置 VPP 内风电、光伏、抽蓄、需求响应独立运行模式 1,同类型主体形成联盟进行合作互补发电运行模式 2。2 种运行模式下在一个调度周期的总发电收益结果对比如表 6 所示。

表 6 模式 1 和模式 2 的各联盟总收益对比  
Table 6 Comparison of total benefits across alliances for mode 1 and mode 2

联盟主体	发电收益/万元	
	模式 1	模式 2
风电联盟	10.095	12.029
光伏联盟	8.602	9.556
抽蓄联盟	9.863	10.734
需求响应联盟	9.454	10.408
总收益	38.014	42.727

可以看出,VPP 内部同类型主体形成联盟进行合作互补发电,联盟总收益及每个 DER 联盟的收益都得到了显著的提高。在模式 2 下,风电联盟与光伏联盟将大量的电能储存在抽蓄联盟中,实现发电量在峰谷时刻的填补,从而使得各自收益分别提高了 1.934 万元和 0.954 万元。抽蓄联盟和需求响应联盟在满足削峰填谷的电力需求的同时具备储能的效果,在负荷高峰时出力,低谷时进行储能和负荷的转移,从而各自收益提高了 0.871 万元和 0.954 万元。

模式 1 和模式 2 的出力结果如图 9、图 10 所示。在模式 1 下,各联盟都以自身利益最大进行电力满发。其中抽蓄联盟未与风电和光伏联盟进行合作互补,整体出力呈现大幅提升,进而导致系统产生

大量弃风弃光,这种运行模式不具备经济性和环境效益。在模式 2 下,风电联盟在系统用电高峰时期出力下降,出现“反调峰”现象,但是此时光伏联盟电力满发,将风光联盟多余的电量存储在抽蓄联盟进行抽水蓄能,进一步提升了可再生能源的利用率。需求响应联盟考虑到用户的用电习惯进行最大限度的负荷转移与削减,既能保证负荷用户的电力需求,又能提高自身收益。在平时段和谷时段,抽蓄联盟的抽水发电和需求响应的负荷转移,有效平抑了风光联盟出力的间歇性,实现了电能互补的优化运行。




图 9 模式 1 下各联盟出力结果

Fig.9 Output results of alliances under mode 1




图 10 模式 2 下各联盟出力结果

Fig.10 Output results of alliances under mode 2

### 5.4 VPP 收益分配模型分析

根据 2 种模式运行结果和各种组合下各联盟收益情况,考虑 3 种收益分配方式进行对比:按出力情况直接分配、传统 shapley 值分配、改进 shapley 值分配。3 种收益分配对比如图 11 所示。

详细分析 3 种分配结果的公平性和合理性,结果如下:

(1) 对于风电联盟和光伏联盟而言,3 种分配方式下,其出力的波动性与间歇性影响综合风险因子的权重逐渐增加,导致改进 shapley 值分配结果相




图 11 3种收益分配方法对比

Fig.11 Comparison of the three methods of income distribution

较于直接分配以及 shapley 值分配有所下降。但是作为参与日前电力交易的核心发电成员,风电联盟和光伏联盟对于整个大联盟的利润贡献以及成本支出相较于其他联盟更多,因此可以提高整体收益。最终风电联盟和光伏联盟的分配结果为 12.533 万元和 9.957 万元。

(2) 抽蓄联盟在改进 shapley 值下的分配结果为 11.439 万元,相较于 shapley 值分配多 1.037 万元,是因为在合作互补模式下,抽蓄联盟属于风险偏好型可调控成员,在应对风险过程中获得收益。与此同时,风电、光伏联盟的大量电力转移给抽蓄联盟进行抽水储能,在峰谷时段的利润增长幅度随之增大。需求响应联盟虽然风险波动较小,但是需求侧需要考虑用户用电满意度和用电行为的随机性,导致综合利润和成本支出都具有不确定性,所以需求响应联盟在改进 shapley 值下的分配结果相较于传统 shapley 值分配少了 1.487 万元,最终需求响应联盟的分配结果为 9.456 万元。

表 7 为改进核仁法下各联盟成员收益分配结果。由表 7 可知,改进核仁法得到的分配结果相较于核仁法的均衡程度更大。为了进一步证明改进核仁法收益分配方案的优势,对各联盟总体满意度的方差进行求解,结果如图 12 所示。方差越小,说明各子联盟的满意度分布更加稳定<sup>[32]</sup>。图 12 中,改进前后各联盟整体满意度的方差分别降低了 0.039、0.021、0.044 和 0.031,证明改进核仁解的均衡程度高于核仁解,即改进核仁解的公平性高于核仁解。基于奇偶循环改进核仁法为联盟成员的合作博弈提供了更优的收益分配方案,既保证了成员间的公平性和合理性,又增强了成员参与联盟的积

极性和稳定性。

表 7 基于改进核仁法细化分配结果

Table 7 Results of refined allocation based on improved kernel method

联盟成员	收益/万元	
	核仁法	改进核仁法
风电 1	6.087	6.155
风电 2	6.446	6.378
光伏 1	3.498	3.314
光伏 2	3.142	3.219
光伏 3	3.317	3.424
抽蓄电站 1	5.537	5.613
抽蓄电站 2	5.902	5.826
需求响应 1	4.567	4.625
需求响应 2	4.889	4.831




图 12 不同方法下各联盟整体满意度的方差

Fig.12 Variance of overall satisfaction across alliances under different methods

## 6 结论

文中在考虑风光出力不确定性的同时,提出了多类型 DER 聚合于 VPP 的运行模式。在该模式下,以购售电收益最大化为目标,建立多个风电场、光伏电站、抽蓄电站、需求响应用户形成联盟聚合于 VPP 的博弈优化调度模型。此外,设计了多因素改进 shapley 值法和基于子联盟满意度的核仁法的收益分配方案。通过算例仿真得到以下结论:

(1) 提出一种基于 VMD 和改进的 Bi-MGLSTM 的组合功率预测模型,通过不同方法预测结果对比,证明了该模型的准确性,可为调度模型提供精度更高的数据支持。

(2) 基于合作博弈理论实现了风电联盟、光伏联盟、抽蓄联盟和需求响应联盟的出力互补,有效平抑了风光出力的间歇性,减少弃风、弃光时的收益损失。相比于独立运行,合作互补模式大大提高了联盟的整体发电收益。

(3) 基于多因素改进 shapley 值法将联盟间的



收益进行综合性分配,保证了各联盟运行的公平性与互补性。基于奇偶循环的核仁法细化各联盟成员间的发电收益,使得各联盟成员的收入更加均衡,有助于增强成员参与联盟运行的积极性。

文中主要针对清洁能源,未考虑到燃气发电、生物质能发电、电动汽车储能等 DER。后续工作将着手更多能源的优化调度,并将碳排放以及多种负荷需求的收益分配方案作为下一步研究重点。

### 致谢

本文得到新型电力系统运行与控制国家重点实验室项目(SKLD23KMI8)资助,谨此致谢!

### 参考文献:

- [1] 杜效鹄,周兴波,周建平. 碳中和背景下我国电力碳排放水平分析[J]. 水力发电学报,2024,43(4):23-33.  
DU Xiaohu,ZHOU Xingbo,ZHOU Jianping. Analysis of electricity carbon emission levels in China in background of carbon neutrality[J]. Journal of Hydroelectric Engineering, 2024, 43(4):23-33.
- [2] SARMIENTO-VINTIMILLA J C, TORRES E, LARRUSKAIN D M, et al. Applications, operational architectures and development of virtual power plants as a strategy to facilitate the integration of distributed energy resources[J]. Energies, 2022, 15(3):775.
- [3] 詹智民,范玉宏,刘翊枫,等. 含可再生能源的虚拟电厂参与碳市场交易优化模型[J]. 可再生能源, 2023, 41(9):1263-1269.  
ZHAN Zhimin,FAN Yuhong,LIU Yifeng,et al. An optimization model of carbon market transactions of virtual power plants with renewable energy[J]. Renewable Energy Resources, 2023, 41(9):1263-1269.
- [4] 吴问足,赵玉柱,刘国伟,等. 考虑电网辅助服务的分布式能源聚合体优化方法[J]. 电力科学与技术学报,2023,38(4):205-213.  
WU Wenzu,ZHAO Yuzhu,LIU Guowei,et al. Research on the optimization method of distributed energy polymer considering grid ancillary services[J]. Journal of Electric Power Science and Technology, 2023, 38(4):205-213.
- [5] 田立亭,程林,郭剑波,等. 虚拟电厂对分布式能源的管理和互动机制研究综述[J]. 电网技术,2020,44(6):2097-2108.  
TIAN Liting,CHENG Lin,GUO Jianbo,et al. A review on the study of management and interaction mechanism for distributed energy in virtual power plants[J]. Power System Technology, 2020, 44(6):2097-2108.
- [6] 栗然,王炳乾,彭湘泽,等. 基于主从博弈的多虚拟电厂动态定价与优化调度[J]. 可再生能源,2024,42(7):986-994.  
LI Ran,WANG Bingqian,PENG Xiangze,et al. Dynamic pricing and optimal scheduling of multi-virtual power plants based on master-slave game[J]. Renewable Energy Resources, 2024, 42(7):986-994.
- [7] 彭超逸,徐苏越,顾慧杰,等. 基于主从博弈的虚拟电厂参与多元竞争市场投标策略研究[J]. 电力系统保护与控制, 2024, 52(7):125-137.  
PENG Chaoyi,XU Suyue,GU Huijie,et al. Bidding strategy for a virtual power plant participating in a multiple competitive market based on the Stackelberg game[J]. Power System Protection and Control, 2024, 52(7):125-137.
- [8] ZHANG Y Y,ZHAO H R,LI B K. Distributionally robust comprehensive declaration strategy of virtual power plant participating in the power market considering flexible ramping product and uncertainties[J]. Applied Energy, 2023, 343:121133.
- [9] 徐康轩,郭超,包铭磊,等. 市场环境下考虑多元不确定性的热电联合虚拟电厂竞标策略[J]. 电网技术,2022,46(9):3354-3365.  
XU Kangxuan,GUO Chao,BAO Minglei,et al. Bidding strategy for combined heat and power virtual power plant in electricity market considering multiple uncertainties[J]. Power System Technology, 2022, 46(9):3354-3365.
- [10] YAN Q Y,ZHANG M J,LIN H Y,et al. Two-stage adjustable robust optimal dispatching model for multi-energy virtual power plant considering multiple uncertainties and carbon trading[J]. Journal of Cleaner Production, 2022, 336:130400.
- [11] 刘鑫,李扬,史云鹏,等. 计及用户参与不确定性的虚拟电厂分布鲁棒优化模型[J]. 电力自动化设备,2022,42(7):84-93.  
LIU Xin,LI Yang,SHI Yunpeng,et al. Distributionally robust optimization model of virtual power plant considering user participation uncertainty[J]. Electric Power Automation Equipment, 2022, 42(7):84-93.
- [12] 黎静华,谢育天,曾鸿宇,等. 不确定优化调度研究综述及其在新型电力系统中的应用探讨[J]. 高电压技术,2022, 48(9):3447-3464.  
LI Jinghua,XIE Yutian,ZENG Hongyu,et al. Research review of uncertain optimal scheduling and its application in new-type power systems[J]. High Voltage Engineering, 2022, 48(9):3447-3464.
- [13] GAO Y J,ZHOU X J,REN J F,et al. Double layer dynamic game bidding mechanism based on multi-agent technology for virtual power plant and internal distributed energy resource[J]. Energies, 2018, 11(11):3072.
- [14] 杜宏宇,张宏宇,陈波,等. 计及多种需求响应资源的虚拟电厂运行机制及控制策略优化[J]. 电工电能新技术, 2023, 42(7):77-86.  
DU Hongyu,ZHANG Hongyu,CHEN Bo,et al. Operation mechanism and control strategy optimization of virtual power plant considering multiple DR resources[J]. Advanced Technology of Electrical Engineering and Energy, 2023, 42(7):77-86.
- [15] LAU J S,JIANG Y H,LI Z Y,et al. Stochastic trading of storage systems in short term electricity markets considering intraday demand response market[J]. Energy, 2023, 280:128103.
- [16] 陶伟健,艾芊,李晓露. 虚拟电厂协同调度及市场交易的研究现状及展望[J/OL]. 南方电网技术: 1-15[2024-05-07].

- http://kns.cnki.net/kcms/detail/44.1643.tk.20240318.1018.008.html.
- TAO Weijian, AI Qian, LI Xiaolu. Research status and prospects of collaborative scheduling and market trading of virtual power plants[J/OL]. Southern Power System Technology:1-15 [2024-05-07]. http://kns.cnki.net/kcms/detail/44.1643.tk.20240318.1018.008.html.
- [17] 张燕, 乔松博, 徐奇锋, 等. 基于纳什议价理论的分布式绿色电力交易优化分析[J]. 中国电力, 2022, 55(12): 168-178.
- ZHANG Yan, QIAO Songbo, XU Qifeng, et al. Analysis of distributed green power transaction optimization based on Nash bargaining theory[J]. Electric Power, 2022, 55(12): 168-178.
- [18] 聂永辉, 李宗锴. 基于纳什谈判和主从博弈的多园区综合能源系统优化调度[J]. 智慧电力, 2024, 52(5): 37-43, 104.
- NIE Yonghui, LI Zongkai. Optimal scheduling of multi-park integrated energy system based on Nash negotiation and master-slave game[J]. Smart Power, 2024, 52(5): 37-43, 104.
- [19] 陈志永, 胡平, 别朝红, 等. 基于合作博弈的虚拟电厂联盟策略与收益分配机制研究[J]. 智慧电力, 2024, 52(1): 39-46, 64.
- CHEN Zhiyong, HU Ping, BIE Zhao hong, et al. Alliance strategy and revenue allocation mechanism for clustered virtual power plants based on cooperative game[J]. Smart Power, 2024, 52(1): 39-46, 64.
- [20] WU W L, ZHU J Z, CHEN Y X, et al. Modified shapley value-based profit allocation method for wind power accommodation and deep peak regulation of thermal power[J]. IEEE Transactions on Industry Applications, 2023, 59(1): 276-288.
- [21] LI Y B, SUN Y T, ZHANG J J, et al. Optimal microgrid system operating strategy considering variable wind power outputs and the cooperative game among subsystem operators[J]. Energies, 2022, 15(18): 6601.
- [22] 王帅, 帅轩越, 王智冬, 等. 基于纳什议价方法的虚拟电厂分布式多运营主体电能交易机制[J]. 电力建设, 2022, 43(3): 141-148.
- WANG Shuai, SHUAI Xuanyue, WANG Zhidong, et al. Distributed electricity trading mechanism of multi-operator virtual power plant based on Nash bargaining method[J]. Electric Power Construction, 2022, 43(3): 141-148.
- [23] GAO Y, GAO L, ZHANG P, et al. Two-stage optimization scheduling of virtual power plants considering a user-virtual power plant-equipment alliance game[J]. Sustainability, 2023, 15(18): 13960.
- [24] 葛晓琳, 曹旭丹, 李伶俐, 等. 考虑风险与碳流动的多虚拟电厂优化运行方法[J]. 电力系统及其自动化学报, 2023, 35(8): 126-135.
- GE Xiaolin, CAO Xudan, LI Yiling, et al. Optimal operation method for multiple virtual power plants considering risk and carbon flow[J]. Proceedings of the CSU-EPSA, 2023, 35(8): 126-135.
- [25] HUANG F, LIN Q M, ZHAO Z K, et al. Cooperative game trading mode of virtual power plant group[J]. IOP Conference Series: Earth and Environmental Science, 2020, 467(1): 012206.
- [26] YU M, NIU D X, GAO T, et al. A novel framework for ultra-short-term interval wind power prediction based on RF-WOA-VMD and BiGRU optimized by the attention mechanism[J]. Energy, 2023, 269: 126738.
- [27] PANG B, WANG B C, HU Y Z, et al. Clustering group-sparse mode decomposition and its application in rolling bearing fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3523211.
- [28] 陈海鹏, 周越豪, 王趁录, 等. 基于改进的 CNN-LSTM 短期风功率预测的系统旋转备用经济性分析[J]. 高电压技术, 2022, 48(2): 439-448.
- CHEN Haipeng, ZHOU Yuehao, WANG Chenlu, et al. Economic analysis of system spinning reserve based on improved CNN-LSTM short term wind power prediction[J]. High Voltage Engineering, 2022, 48(2): 439-448.
- [29] HERRERA-CASANOVA R, CONDE A, SANTOS-PÉREZ C. Hour-ahead photovoltaic power prediction combining BiLSTM and Bayesian optimization algorithm, with bootstrap resampling for interval predictions[J]. Sensors, 2024, 24(3): 882.
- [30] 麻秀范, 余思雨, 朱思嘉, 等. 基于多因素改进 Shapley 的虚拟电厂利润分配[J]. 电工技术学报, 2020, 35(S2): 585-595.
- MA Xiufan, YU Siyu, ZHU Sijia, et al. Profit distribution of virtual power plant based on multi-factor improvement Shapley[J]. Transactions of China Electrotechnical Society, 2020, 35(S2): 585-595.
- [31] LAI S Y, QIU J, TAO Y C, et al. Option-based demand response management for electric vehicle aggregator[J]. IEEE Transactions on Transportation Electrification, 2024, 10(2): 4042-4054.
- [32] 饶卫振, 段忠菲, 朱庆华. 一种均衡协作配送子联盟满意度的成本分摊方法[J]. 系统工程学报, 2021, 36(4): 476-494.
- RAO Weizhen, DUAN Zhongfei, ZHU Qinghua. A cost allocation method for balancing the satisfaction of cooperative distribution sub-alliances[J]. Journal of Systems Engineering, 2021, 36(4): 476-494.

#### 作者简介:



宋铎洋

宋铎洋(1999),男,硕士在读,研究方向为虚拟电厂优化运行(E-mail:songduoyang@163.com);

薛田良(1977),男,博士,副教授,研究方向为含新能源的电力系统运行与控制;

李艺瀑(2000),男,硕士在读,研究方向为电力系统优化运行与调度。

## Cooperative game scheduling and revenue sharing strategy for virtual power plants considering scenery uncertainty

SONG Duoyang, XUE Tianliang, LI Yipu, TU Jintong, BI Yuhao, WANG Mankang

(College of Electricity and New Energy, Three Gorges University, Yichang 443000, China)

**Abstract:** Virtual power plants (VPP) efficiently aggregate small-capacity and large-volume distributed energy resources through advanced control technologies to participate in electricity market transactions. With the increase in the number of distributed energy sources, the volatility of their power output and the problem of their returns after aggregation still need to be solved. Based on this, a cooperative game scheduling model is proposed for multi-type distributed energy sources aggregated in a virtual power plant under the day-ahead power market. Firstly, the operation framework of multi-type distributed energy aggregation in virtual power plant is proposed. Then, a combined prediction model based on variational modal decomposition (VMD) and improved bidirectional multi gated long short-term memory (Bi-MGLSTM) network is established because the uncertainty of wind power output seriously affects the operation of the system. Secondly, the same type of distributed energy sources form alliances and aim to maximize the revenue from power sales, and construct a cooperative game scheduling model for multiple alliances of virtual power plants. In order to realize the fairness of revenue distribution among alliances and members, a multifactor improvement shapley value method and a two-stage refinement of the revenue distribution scheme based on the parity cycle kernel method are designed. Finally, the example results show that the proposed method effectively improves the prediction accuracy of wind power, realizes the cooperative and complementary operation among alliances within the virtual power plant, and ensures the fairness and reasonableness of the revenue distribution among multiple subjects.

**Keywords:** virtual power plant (VPP); distributed energy resource (DER); wind and solar forecasting; cooperative gaming; shapley values; kernel method

(编辑 方晶)

(上接第 142 页)

## Rapid estimation method of lithium battery state of health based on novel health feature

DONG Xiaohong<sup>1</sup>, DONG Jinbo<sup>2</sup>, WANG Mingshen<sup>3</sup>, ZENG Fei<sup>3</sup>, PAN Yi<sup>3</sup>

(1. School of Electrical Engineering, Hebei University of Technology, Tianjin 300130, China;

2. School of Artificial Intelligence, Hebei University of Technology, Tianjin 300130, China;

3. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China)

**Abstract:** The online estimation of the state of health (SOH) is an essential part of a lithium battery management system. Most data-driven lithium battery SOH estimation methods are computationally intensive and difficult to use in real-time in battery management system microcontrollers. Therefore, a rapid estimation method of lithium battery SOH based on novel health feature is proposed in this paper. The charging data of the battery is firstly analyzed in the method, and based on the existing health characteristics of time interval of an equal charging voltage difference (TIECVD) in the constant current charging process of the battery, constructs a new health feature, that is, the health feature of charging voltage at the same starting point and charging time interval. Then, a fast estimation method of lithium battery SOH based on the novel health feature and multiple linear regression (MLR) is proposed. Next, by analyzing the oxford battery aging dataset and the random usage dataset of lithium ion batteries used by NASA, the method traverses the constant current charging voltage range in steps of 0.01 V and determines the optimal starting voltage of the lithium battery by maximizing the Pearson correlation coefficient. Finally, considering different time intervals, the method uses the ordinary least squares (OLS) regression analysis method to determine the optimal time interval parameter of the lithium battery. The training set divided by two datasets is used to establish a multiple linear regression model, and the validation set divided by two datasets is used to verify the method. The experimental results show that the proposed method and novel health feature can greatly reduce the calculation volume, and can achieve fast estimation of lithium battery SOH while ensuring prediction accuracy.

**Keywords:** lithium battery; state of health (SOH) estimation; novel health feature; data-driven approach; multiple linear regression (MLR); charging voltage data fragment

(编辑 吴昊)