

# 考虑风-光-荷时空相关性的分布式电源和 广义储能联合规划

高锋阳<sup>1</sup>,袁成<sup>1</sup>,李昭君<sup>1</sup>,齐晓东<sup>1</sup>,庄圣贤<sup>2</sup>

(1. 兰州交通大学 自动化与电气工程学院,甘肃 兰州 730070;2. 西南交通大学 电气工程学院,四川 成都 610031)

**摘要:**在分布式电源(DG)和广义储能(GES)联合规划中,针对运行与规划如何紧密耦合、在获取大量分散资源行为规律的基础上如何预测其在规划周期内的关联特性的难题,提出了多能互补发电系统中DG与GES的双层优化规划方法。上层以新能源历史出力为输入,建立了考虑综合成本、DG承载能力和系统综合运行风险的上层规划模型,决策得到DG和GES的安装方案;下层考虑运行成本以平衡各储能系统的充放电功率,决策得到GES的调度策略。提出了可描述多维风-光-荷时空相关性的MD-K2贝叶斯网络模型,用于实现多元数据驱动下DG和GES的协同优化。算例测试结果验证了所提模型和方法的合理性以及有效性。

**关键词:**时空相关性;广义储能;分布式电源;联合规划;MD-K2贝叶斯网络

**中图分类号:**TM 715

**文献标志码:**A

**DOI:**10.16081/j.epae.202106007

## 0 引言

随着产业成本降低、技术完善、风光等自然资源出力建模精度的提高以及能源政策的不断推进,作为用户侧电能转换和利用核心环节的配电网正经历着“主动”演变<sup>[1]</sup>。系统内分布式电源DG(Distributed Generation)的渗透率大幅增长<sup>[2]</sup>,在给源端注入新活力的同时,也给电力平衡调节和电网安全运行提出新的挑战。高渗透率DG就地消纳能力受负荷增速和外送电网建设速度约束限制<sup>[3]</sup>,导致出现源-网-荷发展不协调的问题,而一些具有高度灵活性的灵活性资源有足够的潜力来支撑配电网形态演变下的规划技术新需求。

现有的电网电源规划主要围绕DG进行,依据DG消纳能力<sup>[4]</sup>、电能质量安全<sup>[5]</sup>、不同投资主体的收益以及DG带来的潜在收益<sup>[6]</sup>等指标建立DG的选址定容规划模型。随着储能系统投资建设成本的降低,联合考虑DG和储能的电网规划成为研究热点。实际上,储能的形式可以拓展到一切可以实现电能时空转移的设备或调度措施,广义储能GES(Generalized Energy Storage)概念由此被提出<sup>[7]</sup>。将传统储能系统归类为固定储能技术,考虑到用户侧灵活性资源的调控潜力,将各类可控负荷归类为虚拟储能技术,包括可转移负荷、可中断负荷、电动汽车负荷等<sup>[8]</sup>,虚拟储能技术参与配电网的调控可以实现

DG的有效消纳和获得投资运营的最佳收益。针对含高渗透率DG的配电网配置GES的策略,文献[9]提出了内外层交替优化的思想,实现了虚拟储能和固定储能成本之间的转换。此外,随着电动汽车绿色属性在车-网(V2G)和网-车(G2V)技术中的逐步发展,合理引导用户侧需求响应可以有效抑制负荷波动<sup>[10]</sup>,因此各种灵活性资源在配电网或微电网的资源整合中成为重要要素<sup>[11]</sup>。

一方面,针对规划和运行如何紧密耦合的难题,文献[12]将GES的响应特性和数据模型的通用化思维相结合,提出了GES统一响应特性模型,刻画了运行问题、规划问题和市场机制之间的关联影响;文献[13]结合多时间尺度聚合思想,同时对市场环境下的主网友好性、投资及运行效益的经济成本进行协同优化,构建了微电网系统中DG和储能的优化模型。另一方面,针对在获取大量分散资源行为规律的基础上如何预测其在规划周期内关联特性的难题,文献[14]通过多场景技术的复杂演变,映射得到了风电出力、光伏出力和负荷需求三者间蕴涵的关联特性;文献[15]建立了描述风速、光照强度和负荷之间相关性的贝叶斯网络模型,并验证了该模型的有效性;文献[16]建立了符合风机实际运行状态的贝叶斯网络,采用多维数据并综合考虑多参数之间的相关性,实现了对机组高温降容状态的评估。但这类方法的应用存在以下主要制约因素:①选取变量的关联性强弱,但这正契合了相邻地区DG出力及负荷需求之间较强的关联性;②如何从数据中搜索到最优的贝叶斯网络结构,以K2算法为代表的评分-搜索方法能较好地度量不同变量间的拟合程度<sup>[17]</sup>。

收稿日期:2020-11-09;修回日期:2021-04-18

基金项目:甘肃省重点研发计划项目(18YF1FA058);兰州市人才创新项目(2017-RC-95)

Project supported by the Key R&D Program of Gansu Province (18YF1FA058) and Lanzhou Talent Innovation Program (2017-RC-95)

为了构建配电网中 DG 和 GES 的协调规划模型,本文首先从多维数据挖掘的角度出发,联合最大支撑树 MWST(Most Weight Supported Tree)和深度优先遍历 DFS(Depth First Search),提出了一种 MD-K2 贝叶斯网络模型,对相邻地区风速、光照强度及负荷需求的时空相关性进行关联性分析,然后充分考虑投资与运行成本、DG 承载能力和系统综合运行风险建立双层规划模型。深入地挖掘多维数据贯穿驱动、高渗透率下 DG 消纳能力提升、规划和运行动态平衡之间的联动关系,在系统安全运行边界内设计联合规划方案。以 IEEE 33 节点配电网为例进行分析,结果验证了所提方法的有效性。

## 1 DG 和 GES 规划的数学模型

### 1.1 固定储能

蓄电池储能设备可以在 DG 出力高峰时段和用电低谷时段储电,在 DG 出力不足时段和用电高峰时段放电。蓄电池储能设备模型可表示为:

$$\begin{cases} E_{ES,i}^{t+1} = (1-\beta)E_{ES,i}^t + x_{i,t}^u P_{ES,i}^u \eta_{ES}^u - x_{i,t}^d P_{ES,i}^d / \eta_{ES}^d \\ 0 \leq P_{ES,i}^u \leq P_{ES,i}^{u,\max}, 0 \leq P_{ES,i}^d \leq P_{ES,i}^{d,\max} \\ S_{ES}^{\min} \leq E_{ES,i}^t / E_{ES,i}^N \leq S_{ES}^{\max} \\ x_{i,t}^u + x_{i,t}^d \in \{0, 1\} \\ \sum_{t=1}^T (x_{i,t}^u P_{ES,i}^u \eta_{ES}^u - x_{i,t}^d P_{ES,i}^d / \eta_{ES}^d) = 0 \end{cases} \quad (1)$$

其中,  $E_{ES,i}^t$ 、 $E_{ES,i}^{t+1}$  分别为  $t$ 、 $t+1$  时刻节点  $i$  处蓄电池储能设备的剩余电量;  $\beta$  为蓄电池储能设备的自放电效率;  $P_{ES,i}^u$ 、 $P_{ES,i}^d$  分别为  $t$  时刻蓄电池储能设备的充、放电功率;  $\eta_{ES}^u$ 、 $\eta_{ES}^d$  分别为蓄电池储能设备的充、放电效率;  $P_{ES,i}^{u,\max}$ 、 $P_{ES,i}^{d,\max}$  分别为蓄电池储能设备的最大充、放电功率;  $S_{ES}^{\max}$ 、 $S_{ES}^{\min}$  分别为蓄电池储能设备荷电状态的上、下限;  $x_{i,t}^u$ 、 $x_{i,t}^d$  分别为  $t$  时刻节点  $i$  处蓄电池储能设备的充、放电决策变量,充电时有  $x_{i,t}^u = 1$ 、 $x_{i,t}^d = 0$ ,放电时有  $x_{i,t}^u = 0$ 、 $x_{i,t}^d = 1$ ;  $E_{ES,i}^N$  为节点  $i$  处蓄电池储能设备的额定容量;  $T$  为调度周期。

### 1.2 可转移负荷

一部分居民负荷和工业负荷具有时空上的二维可控性,可在一定时段内实现能源时移。可转移负荷模型可表示为:

$$\begin{cases} E_{TL,i}^{t+1} = E_{TL,i}^t + y_{i,t}^u E_{TL,i}^t - y_{i,t}^d E_{TL,i}^t \\ y_{i,t}^u \leq y_{u,i}^{\max}, y_{i,t}^d \leq y_{d,i}^{\max} \\ \sum_{t \in T_{TL,i}^u} y_{i,t}^u = \sum_{t \in T_{TL,i}^d} y_{i,t}^d = 0 \\ T_{TL,i}^u = [t_{TL,i}^{u,sta}, t_{TL,i}^{u,end}], T_{TL,i}^d = [t_{TL,i}^{d,sta}, t_{TL,i}^{d,end}] \\ \sum_{t=1}^T y_{i,t}^u E_{TL,i}^t = \sum_{t=1}^T y_{i,t}^d E_{TL,i}^t \end{cases} \quad (2)$$

其中,  $E_{TL,i}^t$ 、 $E_{TL,i}^{t+1}$  分别为  $t$ 、 $t+1$  时刻节点  $i$  处可转移负荷的功率;  $y_{i,t}^u$ 、 $y_{i,t}^d$  分别为  $t$  时刻节点  $i$  处可转移负荷

增加、缩减的比例,  $y_{u,i}^{\max}$ 、 $y_{d,i}^{\max}$  分别为其最大值;  $T_{TL,i}^u$ 、 $T_{TL,i}^d$  分别为节点  $i$  处可转移负荷增加、缩减负荷的时段;  $t_{TL,i}^{u,sta}$ 、 $t_{TL,i}^{u,end}$  分别为  $T_{TL,i}^u$  的始、末时刻;  $t_{TL,i}^{d,sta}$ 、 $t_{TL,i}^{d,end}$  分别为  $T_{TL,i}^d$  的始、末时刻。

### 1.3 可中断负荷

温控负荷作为主要的可中断负荷,根据用户舒适度削减负荷量,可视作 GES 的放电量,其模型可表示为:

$$\begin{cases} E_{IL,i}^{t+1} = (1-z_{i,t}^d)E_{IL,i}^t \\ z_{i,t}^d \leq z_{d,i}^{\max} \\ \sum_{t \in T_{IL,i}} z_{i,t}^d = 0 \\ T_{IL,i} = [t_{IL,i}^{sta}, t_{IL,i}^{end}] \end{cases} \quad (3)$$

其中,  $E_{IL,i}^t$ 、 $E_{IL,i}^{t+1}$  分别为  $t$ 、 $t+1$  时刻节点  $i$  处可中断负荷的功率;  $z_{i,t}^d$  为  $t$  时刻节点  $i$  处可中断负荷的中断比例,  $z_{d,i}^{\max}$  为其最大值;  $T_{IL,i}$  为节点  $i$  处可中断负荷的中断时段;  $t_{IL,i}^{sta}$ 、 $t_{IL,i}^{end}$  分别为  $T_{IL,i}$  的始、末时刻。

### 1.4 电动汽车负荷

V2G 技术使得电动汽车和电网的能量交互具有双向性,其独有的充放电随机特性与传统的可转移负荷不同,但在本质上可归属于可转移负荷。电动汽车负荷模型可表示为:

$$\begin{cases} P_{EV,i,t}^u \leq E_{EV,i}^u, P_{EV,i,t}^d \leq E_{EV,i}^d \\ k_{EV,i,t}^u + k_{EV,i,t}^d \in \{0, 1\} \\ 0 \leq P_{EV,i,t}^u \leq k_{EV,i,t}^u P_{EV,i}^N \eta_{EV}^u \\ 0 \leq P_{EV,i,t}^d \leq k_{EV,i,t}^d P_{EV,i}^N / \eta_{EV}^d \end{cases} \quad (4)$$

其中,  $P_{EV,i,t}^u$ 、 $P_{EV,i,t}^d$  分别为  $t$  时刻节点  $i$  处电动汽车向电网吸收、释放的电量;  $E_{EV,i}^u$ 、 $E_{EV,i}^d$  分别为节点  $i$  处电动汽车需求响应吸收、释放的电量上限;  $k_{EV,i,t}^u$ 、 $k_{EV,i,t}^d$  分别为  $t$  时刻节点  $i$  处电动汽车吸收、释放功率的决策变量,吸收功率时有  $k_{EV,i,t}^u = 1$ 、 $k_{EV,i,t}^d = 0$ ,释放功率时有  $k_{EV,i,t}^u = 0$ 、 $k_{EV,i,t}^d = 1$ ;  $\eta_{EV}^u$ 、 $\eta_{EV}^d$  分别为电动汽车的充、放电效率;  $P_{EV,i}^N$  为节点  $i$  处充电桩的额定功率。

采用参数方法建立风力发电、光伏发电的数学模型,相关研究内容已较多,本文不再赘述。本文构建的 DG 和 GES 联合系统示意图见图 1。

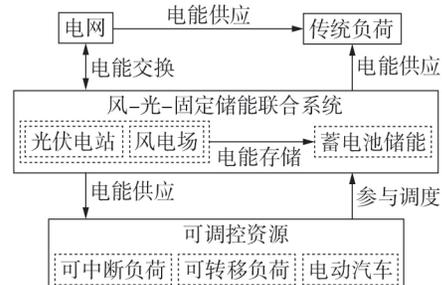


图1 DG和GES联合系统

Fig.1 Joint system of DG and GES

## 2 基于MD-K2贝叶斯网络模型的风-光-荷场景生成

### 2.1 贝叶斯网络基本理论

贝叶斯网络是用于对具有不同性质变量的复杂系统进行建模的概率图形模型,同时具备描述变量自身不确定性和不同变量之间相关性的能力。完整的贝叶斯网络包括以下两部分。

(1)具有 $n$ 个节点 $(X_1, X_2, \dots, X_n)$ 的网络结构,呈现为有向无环图DAG(Directed Acyclic Graph)。通过结构的有向边,DAG可以描述节点之间的相互依存关系。

(2)与所有节点相关的条件概率,可表示为 $p(X_i | \pi(X_i))$ 的集合,其中 $\pi(X_i)$ 为 $X_i$ 的直接双亲节点。应用链式规则可得变量的联合概率分布,如式(5)所示。

$$p(X_1, X_2, \dots, X_n) = \prod_{i=1}^n p(X_i | \pi(X_i)) \quad (5)$$

贝叶斯网络的研究点主要包括结构学习和参数学习2个部分。在DAG已被推算的情况下,根据大量数据获取相关参数更易处理,但输入数据的不同特性为DAG预测带来了挑战,因此准确构建表征输入特征相互关联的DAG是贝叶斯网络的研究核心。

### 2.2 基于MD-K2贝叶斯网络的DG样本生成

#### 2.2.1 MD-K2贝叶斯网络

K2算法是一种构建DAG结构的常见方法,为了解决K2算法依赖最大父节点数和节点序的先验要求,本文联合MWST和DFS进行节点序寻优,分析得到拓扑序列中两变量间的属性关系,进而提出一种MD-K2贝叶斯网络模型。

MWST通过互信息说明变量间的依赖性,互信息值的大小表示变量间相关性的强弱,根据节点 $X_i$ 的自身概率 $p(X_i)$ 、节点 $X_j$ 的自身概率 $p(X_j)$ 及其联合概率 $p(X_i, X_j)$ 可计算得到互信息值,如式(6)所示。

$$I(X_i; X_j) = \sum_{X_i, X_j} p(X_i, X_j) \log_2 \frac{p(X_i, X_j)}{p(X_i)p(X_j)} \quad (6)$$

互信息值 $I(X_i; X_j) > 0$ 表明节点 $X_i$ 与节点 $X_j$ 可能存在依赖关系,通过遍历所有互信息值使用无向边连接节点来表示变量间的紧密程度。文献[18]指出,相较于随机搜索节点序列,基于DFS得到的拓扑序列可有效减少搜索空间。在保证节点先后顺序正确性的条件下,结合K2算法可学习得到更优的网络结构。给定一个连通图,DFS的基本步骤如下:

(1)访问某个顶点 $v$ ,扫描 $v$ 的邻接点依次进行DFS,以提升搜索图的纵深层度为搜索策略;

(2)搜索开始回溯,查看上一路径是否有其他未被访问的邻接点,并重复上一过程;

(3)重复上述过程直到所有顶点均被访问。

可以看出,在路径搜索过程中,计算量将随图的复杂程度增加而增加。对于有 $n$ 个顶点的流通图而言,以顶点 $v$ 进栈后,建立链式栈的时间复杂度为 $O(n)$ ,然后对每个节点的邻接表进行扫描,时间复杂度为 $O(e)$ ( $e$ 为无向图中的边数),则总的时间复杂度为 $O(n+e)$ ,故在处理小型网络时无需缩小搜索空间就可取得较佳的结果。之后利用K2算法通过比较评分值的大小来确定贝叶斯网络的DAG。

最大似然估计(MLE)通常用于建立变量之间的条件概率表,从而确定各节点的参数。已知历史数据集 $Y$ 中包含 $n$ 个变量 $(Y_1, Y_2, \dots, Y_n)$ 。记 $\theta_{i,j,h} = p(Y_i = h | \pi(Y_i) = j)$ 为当父节点 $\pi(Y_i) = j$ 且子节点 $Y_i = h$ 时的状态参数,则 $\theta_{i,j,h}$ 的似然函数为:

$$L = \ln \prod_{i=1}^n p(Y_i | \theta) = \sum_{i=1}^n \ln p(Y_i | \theta) \quad (7)$$

定义特征函数如下:

$$R_{i,j,h,Y_i} = \begin{cases} 1 & Y_i = h \text{ 且 } \pi(Y_i) = j \\ 0 & \text{其他} \end{cases} \quad (8)$$

最终最大似然估计可更直观地表示为:

$$L = \frac{m_{i,j,h}}{\sum_h m_{i,j,h'}} \quad (9)$$

其中, $m_{i,j,h} = \sum_i R_{i,j,h,Y_i}$ 为 $Y$ 中满足条件 $Y_i = h$ 且 $\pi(Y_i) = j$ 的统计值。

#### 2.2.2 计及时空相关性的多场景生成

本文利用历史实测数据描述风-光-荷的随机性和时空相关性。假设已有 $N$ 组风速、光照强度和负荷数据,采用MD-K2贝叶斯网络生成具有时空相关性样本的步骤如下。

(1)由于设备功能故障、数据传输限制等原因,原始数据集中存在数据缺失现象是较为普遍的问题,在删除异常点的同时采用均值插补法进行补充,完成数据的预处理。

(2)利用核密度估计法分别估计风速、光照强度和负荷的边缘分布函数 $Z = [z_1, z_2, \dots, z_N]$ 。贝叶斯网络建模必须实现连续数据的离散化,本文采用经典的数据挖掘K-means聚类算法处理具有连续性特征的数据集以实现数据分割。

(3)根据样本数据建立MWST,通过互信息值确定变量间的依赖关系,从而计算得到最大父节点数。基于DFS得到节点拓扑序列,利用K2算法得到贝叶斯网络的DAG,再根据最大似然估计完成相关参数计算,建立完整的MD-K2贝叶斯网络模型。

(4)对MD-K2贝叶斯网络模型进行采样,再对步骤(2)进行回溯,通过边缘分布函数的逆变换 $Z^{-1}$ 生成考虑时空相关性的风-光-荷初始场景,并采用

层次聚类结合  $K$ -means 聚类算法缩减场景数。按照风、光出力的不确定模型得到风-光-荷功率规划场景。

### 3 多目标规划模型

#### 3.1 目标函数

上层模型主要考虑以下3个指标作为目标函数。

(1) 经济成本。

$$C_{TOT} = C_{INV} + C_{OPE} - C_{SAL} - C_{GES} \quad (10)$$

$$C_{INV} - C_{SAL} - C_{GES} = \frac{1}{365} \times \left[ \sum_{i \in L_{DG}} \frac{r(1+r)^{m_k}}{r(1+r)^{m_k} - 1} (1 - \xi_{DG,k}) a_k P_{DG,i,k} + \sum_{i \in L_{GES}} \frac{r(1+r)^{m_k}}{r(1+r)^{m_k} - 1} (1 - \xi_{GES,k}) b_k P_{GES,i,k} \right] \quad (11)$$

$$\left\{ \begin{array}{l} C_{OPE} = C_{OPE,DG} + C_{OPE,GES} + C_{OPE,GR} \\ C_{OPE,DG} = \sum_{t=1}^T \sum_i (c_{WTG} E_{WTG,i,t} + c_{PVG} E_{PVG,i,t}) \\ C_{OPE,GES} = \sum_{t=1}^T \left( \sum_i c_{ES} E_{ES,i}^t + \sum_i c_{TL} E_{TL,i}^t + \sum_i c_{IL} E_{IL,i}^t + \sum_i c_{V2G} P_{EV,i,t}^d \right) \\ C_{OPE,GR} = \sum_{t=1}^T c_{grid,t} P_{GR,t} \end{array} \right. \quad (12)$$

其中,  $C_{TOT}$  为规划方案的经济成本;  $C_{INV}$ 、 $C_{OPE}$  分别为规划方案的总投资成本、运行成本;  $C_{SAL}$ 、 $C_{GES}$  分别为 DG、GES 的剩余使用价值;  $r$  为贴现率;  $m_k$  为第  $k$  类设备的使用年限;  $\xi_{DG,k}$ 、 $\xi_{GES,k}$  分别为第  $k$  类 DG、GES 设备的剩余使用价值折算系数;  $a_k$ 、 $b_k$  分别为第  $k$  类 DG、GES 设备的单位容量投资价格;  $P_{DG,i,k}$ 、 $P_{GES,i,k}$  分别为节点  $i$  处第  $k$  类 DG、GES 设备的容量;  $L_{DG}$ 、 $L_{GES}$  分别为 DG、GES 设备的安装节点集合;  $C_{OPE,DG}$ 、 $C_{OPE,GES}$  分别为 DG、GES 的综合运行成本;  $C_{OPE,GR}$  为向上级电网购电的总成本;  $E_{WTG,i,t}$ 、 $E_{PVG,i,t}$  分别为  $t$  时刻节点  $i$  处风电机组、光伏机组的实际出力;  $P_{GR,t}$  为  $t$  时刻流入电网的功率;  $c_{WTG}$ 、 $c_{PVG}$ 、 $c_{ES}$  分别为风电机组、光伏机组、蓄电池储能的单位电量运维成本;  $c_{TL}$ 、 $c_{IL}$  分别为可转移负荷、可中断负荷单位功率激励价格;  $c_{V2G}$  为 V2G 响应的动态电价;  $c_{grid,t}$  为  $t$  时刻的分时电价。

(2) DG 承载能力指标。

DG 消纳机理示意图见附录 A 图 A1, DG 承载能力需反映电网备用能力、调峰能力因素的作用。

针对 DG 出力与电量占比之间的关系, 统计不同装机利用率区间的累积电量, 按照式(13)计算各区间 DG 出力累积电量贡献率  $E_g$ 。

$$E_g = \frac{\sum_{i=1}^M \min \{ P_i, g P_{SUM}/100 \}}{\sum_{i=1}^M P_i} \times 100\% \quad (13)$$

其中,  $P_i$  为  $i$  时刻的 DG 出力;  $P_{SUM}$  为 DG 的装机容量;  $g$  为区间编号,  $g \in \{1, 2, \dots, 100\}$ ;  $M$  为 DG 处理样本的序列长度。

根据  $E_g$  可以绘制 DG 电量利用率和装机利用率的统计学特征。甘肃省 2015 年 DG 的统计学特征见附录 A 图 A2。由图可见, 该特征曲线呈现渐近饱和的趋势。通常 DG 电量利用率达到 95% 时即达到技术领先水准, 装机利用率在 [40%, 70%] 范围内时即达到该水准。

装机利用率的大小反映了 DG 消纳能力与 DG 装机之间的关系, 考虑系统综合负荷、常规机组调峰能力、备用水平, 定义 DG 承载能力指标  $\mu$  为:

$$\left\{ \begin{array}{l} \mu = \frac{T_N P_{max}^{imp} [\varphi - (1+\beta)(1-\alpha)]}{\sum_{t=1}^T \sum_i P_{DG,i,t}} \\ \text{s.t. } \lambda(\mu) \geq 95\% \end{array} \right. \quad (14)$$

其中,  $P_{max}^{imp}$  为系统综合负荷最大值;  $T_N$  为日内 DG 的理论利用小时数;  $\alpha$ 、 $\beta$  分别为常规机组的调峰能力水平、上备用率;  $\varphi$  为系统负荷率;  $\lambda(\mu)$  为电量利用率。

(3) 系统综合运行风险。

由于 DG 规划是以风-光-荷预测数据为基础, 其所具有的较强不确定性特点加大了配电网状态变量的越限概率, 同时电动汽车接入配电网使得越限问题发生的可能性更大。考虑到系统节点和支路之间的相关性, 各状态变量之间往往存在同向的变化趋势, 因此综合考虑所有节点电压越限风险和所有支路潮流越限风险<sup>[19]</sup>。定义系统综合运行风险指标  $R_{SVR,t}$  为:

$$R_{SVR,t} = \alpha_1 R_{SVVR,t} + \alpha_2 R_{SPVR,t} \quad (15)$$

其中,  $R_{SVVR,t}$ 、 $R_{SPVR,t}$  分别为  $t$  时刻的电压越限风险指标、潮流越限风险指标;  $\alpha_1$  和  $\alpha_2$  为综合运行权重系数,  $\alpha_1 + \alpha_2 = 1$ 。  $R_{SVVR,t}$  和  $R_{SPVR,t}$  的计算方法类似, 以  $R_{SVVR,t}$  为例, 其计算式如式(16)所示,  $R_{SPVR,t}$  的计算过程不再赘述。

$$R_{SVVR,t} = \frac{\beta_1}{N_g} \sum_s \sum_i |S(U_{s,i,t})| + \beta_2 \max_{s,i} \left\{ |S(U_{s,i,t})| \right\} \quad (16)$$

$$S(U_{s,i,t}) = e^{\lambda \xi(U_{s,i,t})} - 1 \quad (17)$$

$$\xi(U_{s,i,t}) = \begin{cases} \left( \frac{U_{i,\min} - U_{s,i,t}}{U_{i,\max} - U_{i,\min}} \right)^2 & U_{s,i,t} < U_{i,\min} \\ 0 & U_{i,\min} \leq U_{s,i,t} \leq U_{i,\max} \\ \left( \frac{U_{s,i,t} - U_{i,\max}}{U_{i,\max} - U_{i,\min}} \right)^2 & U_{s,i,t} > U_{i,\max} \end{cases}$$

其中,式(16)等号右侧的第一项和第二项分别表征所有节点电压越限风险的平均值和最大值; $s$ 为场景编号; $\beta_1$ 、 $\beta_2$ 为电压越限风险的权重系数, $\beta_1 + \beta_2 = 1$ ,通过设定不同的权重系数取值可以改变节点电压越限风险平均值和最大值的影响,最大限度地消除指标遮蔽情况; $N_g$ 为系统节点总数; $U_{s,i,t}$ 为 $t$ 时刻场景 $s$ 下节点 $i$ 的电压值; $S(U_{s,i,t})$ 为 $t$ 时刻场景 $s$ 下节点 $i$ 的电压越限损失严重度,如式(17)所示; $\xi(U_{s,i,t})$ 为 $t$ 时刻场景 $s$ 下节点 $i$ 的电压损失量; $\lambda$ 为电压损失量惩罚系数,用于反映 $S(U_{s,i,t})$ 和 $\xi(U_{s,i,t})$ 的非线性关系程度; $U_{i,\max}$ 、 $U_{i,\min}$ 分别为节点 $i$ 处允许电压幅值的上、下限。

### 3.2 约束条件

(1)系统潮流约束。

$$P_{GR,t} + \sum_{i \in L_{DG}} E_{WTC,i,t} + \sum_{i \in L_{DG}} E_{PVG,i,t} + \sum_{i \in L_{GES}} P_{ES,i,t} + \sum_{i \in L_{GES}} P_{EV,i,t}^u = \sum_i P_{IM,i}^l + \sum_{i \in L_{GES}} E_{TL,i}^l + \sum_{i \in L_{GES}} E_{IL,i}^l + \sum_{i \in L_{GES}} P_{EV,i,t}^d \quad (18)$$

其中, $P_{ES,i,t}$ 、 $P_{IM,i}^l$ 分别为 $t$ 时刻节点 $i$ 处储能释放的功率、常规负荷功率。

(2)系统安全约束。

$$\begin{cases} U_{i,\min} \leq U_i \leq U_{i,\max} \\ |I_{ij}| \leq I_{\max} \\ |P_{ij}| \leq P_{\max} \end{cases} \quad (19)$$

其中, $U_i$ 为节点 $i$ 的电压; $I_{\max}$ 为支路电流 $I_{ij}$ 的最大允许值; $P_{\max}$ 为支路功率 $P_{ij}$ 的最大限值。

(3)可调可控资源的相关约束。

a. DG安装容量约束。

$$\begin{cases} P_{DG,i,k}^{\min} \leq P_{DG,i,k} \leq P_{DG,i,k}^{\max} \\ P_{DG,i}^{\min} \leq \sum_k P_{DG,i,k} \leq P_{DG,i}^{\max} \end{cases} \quad (20)$$

其中, $P_{DG,i,k}^{\max}$ 、 $P_{DG,i,k}^{\min}$ 分别为节点 $i$ 处允许第 $k$ 类DG设备安装容量的最大值、最小值; $P_{DG,i}^{\max}$ 、 $P_{DG,i}^{\min}$ 分别为节点 $i$ 处允许DG设备安装总容量的最大值、最小值。

b. GES相关约束。

GES资源的相关约束见式(1)~(4)。

### 3.3 双层规划模型

综上所述,可定义双层规划模型如下:

$$\begin{cases} \min F = f_1(x_1) + \max \{ \omega(x_1, u) \} \\ \text{s.t.} \begin{cases} G(x_1) \leq 0, H(x_1) = 0 \\ \omega(x_1, u) = \min \{ f_2(x_2, x_1, u) \} \\ \text{s.t.} \quad g(x_1) \leq 0, h(x_1) = 0 \end{cases} \end{cases} \quad (21)$$

其中, $f_1(x_1)$ 为考虑设备一次投资成本、DG承载能力和电能质量的上层目标函数; $x_1$ 为投资层的决策变量,包括DG和GES的位置、容量建设方案; $G(\cdot)$ 、 $H(\cdot)$ 为

投资层的约束条件; $f_2(x_2, x_1, u)$ 为模拟运行的下层目标函数; $x_2$ 为运行层的决策变量,包括DG实际出力、GES调度策略、购电量; $g(\cdot)$ 、 $h(\cdot)$ 为运行层的约束条件; $\max \{ \omega(x_1, u) \}$ 表示取 $f_2(x_2, x_1, u)$ 在计算存在不确定性误差 $u$ 的条件下的最大值。

上层优化决策得到风电机组、光伏机组和GES的安装方案,下层优化确定各类设备的实际出力、负荷分布和运行成本,并将配置结果返回上层进行下一次的迭代计算,双层规划求解架构如附录A图A3所示。GES的调度策略按照可转移负荷>可中断负荷>电动汽车的顺序进行。

## 4 模型求解算法

多目标粒子群优化(MOPSO)算法与多目标规划问题具有优良的匹配特征,MOPSO算法主要关注速度和位置更新2个方程。但MOPSO算法普遍存在易缺失种群多样性和陷入局部最优的陷阱,因此本文在引入非受控等级排序、动态拥挤度距离和精英集合更新规则的MOPSO算法的基础上<sup>[20]</sup>,对惯性权重 $\omega_i$ 的更新方式做如下改进:基于式(22)和式(23)非线性调节使 $\omega_i$ 根据全局最优位置和当前位置动态变化。具体求解流程见附录A图A4。

$$\omega_i = \omega_{\max} - (\omega_{\max} - \omega_{\min})(D_i^{(t)} - 1)^2 \quad (22)$$

$$D_i^{(t)} = \frac{1}{SN_d} \sum_{d=1}^{N_d} |x_{id}^{(t)} - g_{d\text{best}}^{(t)}| \quad (23)$$

其中, $D_i^{(t)}$ 为粒子 $i$ 在第 $t$ 次迭代时位置分量与全局最优位置之间的差值; $x_{id}^{(t)}$ 为粒子 $i$ 在第 $t$ 次迭代时的第 $d$ 维位置分量; $g_{d\text{best}}^{(t)}$ 为种群在第 $t$ 次迭代时第 $d$ 维全局最优位置; $S$ 为粒子上、下界之间的长度; $N_d$ 为空间维度数; $\omega_{\min}$ 、 $\omega_{\max}$ 分别为 $\omega_i$ 的初值、终值。

同时,根据模糊逻辑决策选择Pareto最优解,采用决策者的偏好来度量Pareto解的最优性。对多个目标函数集合定义隶属度 $\zeta_a$ 和线性隶属函数 $\tau_k(f_k^a)$ 如下:

$$\begin{cases} \zeta_a = \sum_k \omega_k \tau_k(f_k^a) \\ \tau_k(f_k^a) = \begin{cases} 1 & f_k^a < f_k^D \\ \frac{f_k^U - f_k^a}{f_k^U - f_k^D} & f_k^D \leq f_k^a \leq f_k^U \\ 0 & f_k^a > f_k^U \end{cases} \end{cases} \quad (24)$$

其中, $\omega_k$ 为目标函数 $k$ 的权重系数,满足 $\sum_k \omega_k = 1$ ; $f_k^a$ 为目标函数 $k$ 的第 $a$ 个Pareto解; $f_k^U$ 、 $f_k^D$ 分别为目标函数 $k$ 解的上、下限。

## 5 算例分析

### 5.1 算例参数设置

选取IEEE 33节点系统为例进行规划分析,电

网拓扑结构见附录A图A5, GES资源模型参数参考文献[12], MOPSO算法的参数设置见附录A表A1, 购电分时电价见附录A表A2。对于DG, 风电机组、光伏机组的单位容量安装成本分别为8000、10000元/kW, DG的寿命周期为10a, 风电机组、光伏机组的规划容量上、下限均分别为1000、500kW; 对于固定储能, 其充放电效率为90%, 允许的荷电状态范围为(25%, 100%), 容量上限为600kW·h, 单位投资成本为5000元/(kW·h), 使用寿命为10a; 对于虚拟储能, 可转移负荷容量、可中断负荷容量分别为所处节点负荷容量的90%~140%、90%~150%, 单位投资成本分别为800、1200元/kW, 电动汽车的充放电效率为90%, 最大转移功率为50%, 规定所有电动汽车的额定功率相同并且充放电功率恒定, 采用V2G技术使得电动汽车拥有固定储能的特性以实现与电网的能量交换。

### 5.2 MD-K2 贝叶斯网络的结构精确度验证

选择标准Asia网络为例进行结构学习, 该网络具有8个节点和8条边, 属于小型网络, 其先验网络和转移关系见附录A图A6。随机生成8个含有不同数据量的训练样本集, 为了降低数据随机性对实验的影响, 各训练样本集分别生成10组并且单独运行10次, 将100次运行计算后的平均值结果作为实验的最终结果。选取附录B中的4个DAG评价指标(增量边指标 $d_{IE}$ 、缺失边指标 $d_{ME}$ 、反向边指标 $d_{RE}$ 、结构汉明距离指标 $d_{SHD}$ )进行对比分析, 结果见图2。

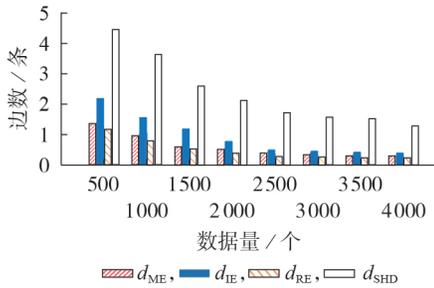


图2 DAG评价指标结果

Fig.2 DAG evaluation index results

由图可看出, 反向边的数量随着样本集数据量的增加而逐渐接近0, 这说明联合MWST和DFS得到的拓扑序列与标准结构的节点顺序相差不大, 因此代入K2算法后可降低反向边的数目; 缺失边指标 $d_{ME}$ 和增量边指标 $d_{IE}$ 结果均验证了该算法的准确度, 在给出节点序后保证了K2算法基本达到实际的Asia网络; 结构汉明距离指标 $d_{SHD}$ 用作度量预测结构与标准结构之间的整体匹配情况, 该指标结果随着样本集数据量的增加而降低, 当样本集数据量达到2500个后的变化趋势逐渐平缓, 说明样本集数据量达到一定的数值后, 使用该算法对小型网络构建贝叶斯网络结构模型已具有足够的合理程度。

定义基于贝叶斯信息度量BIC(Bayesian Information Criterion)的评分函数, 采用对数似然度判断结构与数据的拟合程度, 计算式见附录B式(B1)。表1给出了不同样本集数据量下的BIC评分结果, 表中 $B_b$ 、 $B_w$ 、 $B_a$ 分别为100次运行计算后的最优、最差、平均BIC评分,  $B_s$ 为标准结构的BIC评分。由表可知, 当样本集数据量规模达到2000个后, 本文算法搜索到的最优结构评分 $B_b$ 与标准结构评分 $B_s$ 几乎一致, 说明了该算法通过构建MWST来压缩搜索空间的有效性; 当样本集数据量少于2000个时,  $B_w$ 与 $B_s$ 之间的差值较大, 这主要是因为样本集数据量规模较小会降低MWST定向的精确性, 但联合DFS会逐渐弥补MWST定向时的缺陷。整体而言, 在小型网络中将联合MWST和DFS进行节点序寻优的结果作为先验知识代入K2算法, 所得DAG的准确度较好。

表1 不同样本集数据量下的BIC评分结果

Table 1 BIC score results with different data volumes sample set

样本集数据量/个	$B_b$	$B_w$	$B_a$	$B_s$
500	-1219.8	-1236.6	-1228.4	-1215.1
1000	-2349.3	-2354.9	-2351.2	-2347.5
1500	-3627.1	-3644.2	-3630.9	-3625.7
2000	-4649.7	-4661.4	-4652.5	-4648.4
2500	-5218.3	-5233.8	-5221.3	-5217.8
3000	-6815.1	-6819.2	-6817.7	-6814.6
3500	-7936.7	-7941.7	-7939.6	-7936.5
4000	-9425.4	-9429.3	-9427.7	-9425.3

### 5.3 风-光-荷联合场景的有效性验证

采集甘肃某地区8座观测站一年的风速、光照强度样本以及同步获取的负荷数据, 首先利用MD-K2贝叶斯网络模型随机生成500个场景, 使用概率潮流计算检验该联合场景是否能准确完整地代表历史风速、光照强度及负荷需求的非线性相关性。在节点5、9、15处接入3台风电机组, 在节点3、10、22处接入3台光伏机组。以8760组风-光-荷功率数据逐一进行确定性潮流计算的结果为基准, 得到全场景电压偏差最大值为 $3.428 \times 10^{-3}$  p.u., 最大相对偏差为0.369%, 偏差和为 $5.681 \times 10^{-3}$  p.u.。不同节点电压幅值的数字特征如图3所示(图中电压均值、标

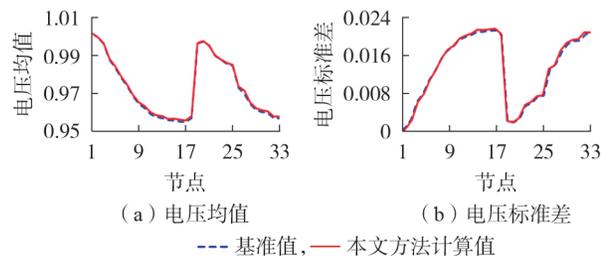


图3 节点电压幅值的数字特征

Fig.3 Digital characteristics of node voltage amplitude

准差均为标么值)。由图可知,通过MD-K2贝叶斯网络获得的风-光-荷联合场景与原样本的计算结果基本吻合,结果的计算精度验证了模型的有效性,说明MD-K2贝叶斯网络模型获得的样本仍与原始样本具有相同的基本概率特征,能够描述风-光-荷之间蕴涵的相关性。

#### 5.4 联合规划结果分析

在算例系统中,风电机组的候选节点为5、9、13、15,光伏机组的候选节点为10、11、18、24,GES资源的可选址节点为2—33,且计划安装3组风电机组、3组光伏机组和2组GES资源。采用MOPSO算法求解问题时,编码方式如下:

$$X = [X_{DG}, X_{GES}, Y_{DG}, Y_{GES}] \quad (25)$$

其中, $X_{DG}$ 、 $X_{GES}$ 分别为DG、GES的安装位置; $Y_{DG}$ 、 $Y_{GES}$ 分别为DG、GES的安装容量。对于虚拟储能,则是确定储能负荷实施需求响应的负荷点位置和负荷比例。

为了分析不同DG出力情况和多种储能资源重组协同作用下的联合优化结果,设置以下6种运行场景:①场景1,DG大出力(夏季),虚拟储能+固定储能协同规划;②场景2,DG大出力(夏季),固定储能协同规划;③场景3,DG小出力(冬季),虚拟储能+固定储能协同规划;④场景4,DG小出力(冬季),固定储能协同规划;⑤场景5,DG全年出力,虚拟储能+固定储能协同规划;⑥场景6,DG全年出力,固定储能协同规划。

不同场景下的最优Pareto前沿解集见附录A图A7。由图可看出:相比于DG小出力场景和全年出力场景,DG大出力场景下3个目标函数的Pareto前沿解分布明显更优,经济成本投入较低的同时,DG承载能力指标和系统综合运行安全性都得到了有效的保证;对比场景1和场景2可知,随着GES资源的增多,虚拟储能资源的加入增大了系统的运行风险,其主要受用户侧的行为影响,但由于资源重组空间增加,最终经济成本有所降低;对比场景1和场景3可知,DG小出力场景下GES削峰填谷的能力未得到有效利用,二者之间的资源协同和优势互补未被充分挖掘。不同场景下的最优规划方案见附录A表A3。由表可知,不同场景的结果并无直接关联,但随着GES资源增多,DG的规划容量明显增加,其可以较好地提高DG的承载能力,有效地抑制系统整体运行风险。

基于场景5的规划结果,将电动汽车负荷等效接入节点15,比较不同时段各类负荷的平均功率曲线,结果如图4所示。由图可知,按照既定的控制策略,可转移负荷由08:00—21:00时段转移至01:00—07:00和22:00—24:00时段,可中断负荷在08:00—11:00、17:00—20:00时段中断,各类储能

资源之间的协调互补得到了充分体现。电动汽车负荷和常规负荷的用电高峰期重叠时段较多,使得电网用电高峰集中在11:00、22:00时刻左右,此时电网状态变量的越限概率增加,运行风险增大。

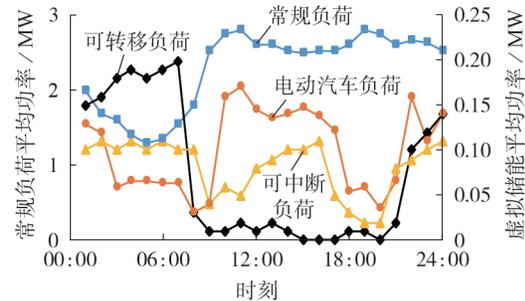


图4 各类负荷的平均功率

Fig.4 Average power of various loads

为了探究电动汽车额定充电功率对运行风险的影响,改变电动汽车负荷接入节点15的额定充电功率,得到不同时段各节点的系统综合运行风险最大值曲线如图5所示。由图可以看出,系统综合运行风险存在2个大峰值,分别在11:00、22:00时刻左右,此时随着电动汽车容量的增加,峰值呈增大趋势。这是因为该峰值时段属于一天中的峰荷时段,22:00时刻峰值更高的主要原因是夜间光伏出力为0,支路潮流重载情况下易导致支路潮流出现越限风险,从而引起较严重的系统综合运行风险。

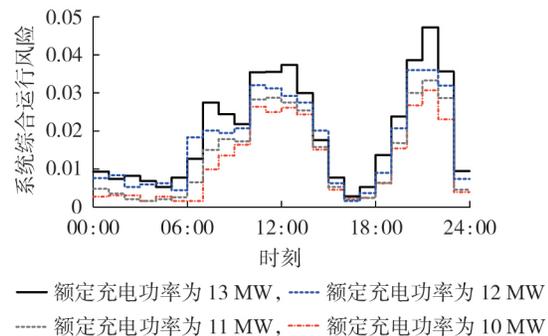


图5 不同电动汽车额定充电功率下的系统综合运行风险

Fig.5 Comprehensive operation risk of system with different rated charging power of EVs

## 6 结论

(1)针对DAG学习的实际问题,引入MWST和DFS达到K2算法构建贝叶斯网络结构的先验要求,并在小型网络中计算各类指标,实验结果证明了该方法在小型网络中的适用性,当样本集数据量达到2000个时,训练得到的DAG精度已足够高。

(2)所提MD-K2贝叶斯网络模型能够处理DG之间、DG与负荷之间的时空相关性特征,能更好体现相邻地区DG出力及负荷需求之间较强的关联性,潮流计算结果满足工程精度要求。

(3)建立了综合考虑经济成本、DG承载能力和系统综合运行风险的双层规划模型。随着GES资源增多,DG规划容量明显增加,其可以较好地提高DG的承载能力,系统综合运行风险也得到了有效抑制。

(4)在电动汽车和负荷用电高峰重叠的情况下,系统运行风险在11:00、22:00的越限概率最大,由于夜间光伏功率为0,22:00时刻更易导致支路潮流出现越限风险。

需要说明的是,本文对于虚拟储能资源类型的考虑还不够全面,其调控灵活性的研究还需要进一步探索。

附录见本刊网络版(<http://www.epae.cn>)。

### 参考文献:

- [1] 王成山,王瑞,于浩,等. 配电网形态演变下的协调规划问题与挑战[J]. 中国电机工程学报,2020,40(8):2385-2396.  
WANG Chengshan,WANG Rui,YU Hao,et al. Challenges on coordinated planning of smart distribution networks driven by source-network-load evolution[J]. Proceedings of the CSEE,2020,40(8):2385-2396.
- [2] 万千,夏成军,管霖,等. 含高渗透率分布式电源的独立微网的稳定性研究综述[J]. 电网技术,2019,43(2):598-612.  
WAN Qian,XIA Chengjun,GUAN Lin,et al. Review on stability of isolated microgrid with highly penetrated distributed generations[J]. Power System Technology,2019,43(2):598-612.
- [3] 张振宇,王文倬,张钢,等. 基于非时序模型的新能源消纳能力评估方法[J]. 电力系统自动化,2019,43(20):24-30.  
ZHANG Zhenyu,WANG Wenzhuo,ZHANG Gang,et al. Assessment method of accommodation capacity of renewable energy based on non-time-series model[J]. Automation of Electric Power Systems,2019,43(20):24-30.
- [4] 孙旻,余愿,曾伟,等. 考虑主动管理的配电网分布式光伏并行优化配置[J]. 电力自动化设备,2019,39(3):169-174,181.  
SUN Min,YU Yuan,ZENG Wei,et al. Parallel optimal allocation of distributed PV in distribution network considering active management[J]. Electric Power Automation Equipment,2019,39(3):169-174,181.
- [5] 刘佳,徐谦,程浩忠,等. 考虑N-1安全的分布式电源多目标协调优化配置[J]. 电力自动化设备,2017,37(7):84-92.  
LIU Jia,XU Qian,CHENG Haozhong,et al. Multi-objective coordinated DG planning with N-1 security[J]. Electric Power Automation Equipment,2017,37(7):84-92.
- [6] 刘向实,王凌纤,吴炎彬,等. 计及配电网运行风险的分布式电源选址定容规划[J]. 电工技术学报,2019,34(增刊1):264-271.  
LIU Xiangshi,WANG Lingxian,WU Yanbin,et al. Locating and sizing planning of distributed generation power supply considering the operational risk cost of distribution network[J]. Transactions of China Electrotechnical Society,2019,34(Supplement 1):264-271.
- [7] 李宏仲,房宇娇,肖宝辉. 考虑广义储能的区域综合能源系统优化运行研究[J]. 电网技术,2019,43(9):3130-3138.  
LI Hongzhong,FANG Yujiao,XIAO Baohui. Research on optimized operation of regional integrated energy system considering generalized energy storage[J]. Power System Technology,2019,43(9):3130-3138.
- [8] WANG D X,MENG K,GAO X D,et al. Coordinated dispatch of virtual energy storage systems in LV grids for voltage regulation[J]. IEEE Transactions on Industrial Informatics,2018,14(6):2452-2462.
- [9] 茆美琴,刘云晖,张榴晨,等. 含高渗透率可再生能源的配电网广义储能优化配置[J]. 电力系统自动化,2019,43(8):77-85.  
MAO Meiqin,LIU Yunhui,ZHANG Liuchen,et al. Optimal configuration of generalized energy storage in distribution network with high with high-penetration renewable energy[J]. Automation of Electric Power Systems,2019,43(8):77-85.
- [10] 刘晋源,吕林,高红均,等. 计及分布式电源和电动汽车特性的主动配电网规划[J]. 电力系统自动化,2020,44(12):41-49.  
LIU Jinyuan,LÜ Lin,GAO Hongjun,et al. Planning of active distribution network considering characteristics of distributed generator and electric vehicle[J]. Automation of Electric Power Systems,2020,44(12):41-49.
- [11] 李宏仲,吕梦琳,胡列翔,等. 考虑广义储能的微电网联合规划[J]. 电力自动化设备,2020,40(7):149-160.  
LI Hongzhong,LÜ Menglin,HU Liexiang,et al. Joint planning of microgrid considering generalized energy storage[J]. Electric Power Automation Equipment,2020,40(7):149-160.
- [12] 程林,齐宁,田立亭. 考虑运行控制策略的广义储能资源与分布式电源联合规划[J]. 电力系统自动化,2019,43(10):27-35,43.  
CHENG Lin,QI Ning,TIAN Liting. Joint planning of generalized energy storage resource and distributed generator considering operation control strategy[J]. Automation of Electric Power Systems,2019,43(10):27-35,43.
- [13] 马国龙,蔡泽祥,刘平. 考虑电价激励需求响应下多主体微电网电源容量优化[J]. 电力自动化设备,2019,39(5):96-102,108.  
MA Guolong,CAI Zexiang,LIU Ping. Power capacity optimization of microgrid with multiple subjects considering price incentive demand response[J]. Electric Power Automation Equipment,2019,39(5):96-102,108.
- [14] 孙惠娟,刘君,彭春华. 基于分类概率综合多场景分析的分布式电源多目标规划[J]. 电力自动化设备,2018,38(12):39-45.  
SUN Huijuan,LIU Jun,PENG Chunhua. Multi-objective DG planning based on classified probability integration multisenario analysis[J]. Electric Power Automation Equipment,2018,38(12):39-45.
- [15] 王洪涛,李晓刚,邹斌. 基于贝叶斯网络刻画风-光-荷相关性的配电网概率潮流计算[J]. 中国电机工程学报,2019,39(16):4753-4763,4977.  
WANG Hongtao,LI Xiaogang,ZOU Bin. Probabilistic load flow calculation of distribution system based on Bayesian network to depict wind-photovoltaic-load correlation[J]. Proceedings of the CSEE,2019,39(16):4753-4763,4977.
- [16] 杨锡运,米尔扎提·买合木提,刘思渠,等. 基于Vine-Copula贝叶斯网络模型的风机高温降容状态评估方法[J]. 中国电机工程学报,2020,40(11):3583-3592.  
YANG Xiyun,MAIHEMUTI Mierzhati,LIU Siqu,et al. State assessment method of capacity reduction at high temperature for wind turbine based on Vine-Copula Bayesian network model[J]. Proceedings of the CSEE,2020,40(11):3583-3592.
- [17] BEHJATI S,BEIGY H. Improved K2 algorithm for Bayesian network structure learning[J]. Engineering Applications of Artificial Intelligence,2020,91:103617.
- [18] WANG F,ZHUANG Y,GU H,et al. OctreeNet:a novel sparse 3-D convolutional neural network for real-time 3-D outdoor scene analysis[J]. IEEE Transactions on Automation Science and Engineering,2020,17(2):735-747.
- [19] 李振坤,路群,符杨,等. 有源配电网动态重构的状态分裂多目标动态规划算法[J]. 中国电机工程学报,2019,39(17):5025-5036,5284.  
LI Zhenkun,LU Qun,FU Yang,et al. State split multi-objective dynamic programming algorithm for dynamic reconfigura-

tion of active distribution network[J]. Proceedings of the CSEE, 2019, 39(17):5025-5036, 5284.

- [20] DING S X, CHEN C, XIN B, et al. A bi-objective load balancing model in a distributed simulation system using NSGA-II and MOPSO approaches[J]. Applied Soft Computing, 2018, 63: 249-267.

#### 作者简介:

高峰阳(1970—),男,甘肃兰州人,教授级高级工程师,博



高峰阳

士,主要研究方向为电力系统安全可靠运行以及配电网运行规划(E-mail: 329365048@qq.com);

袁成(1997—),男,四川广安人,硕士研究生,通信作者,主要研究方向为配电网规划与运行(E-mail: cheng\_y1108@163.com)。

(编辑 陆丹)

## Joint planning of distributed generation and generalized energy storage considering spatial-temporal correlation of wind-photovoltaic-load

GAO Fengyang<sup>1</sup>, YUAN Cheng<sup>1</sup>, LI Zhaojun<sup>1</sup>, QI Xiaodong<sup>1</sup>, ZHUANG Shengxian<sup>2</sup>

(1. School of Automation & Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

**Abstract:** In the joint planning of DG (Distributed Generation) and GES (Generalized Energy Storage), a two-level optimal planning method of DG and GES in multi-energy complementary power generation system is proposed to solve the problems of how to couple operation and planning closely and how to predict the correlation characteristics of a large number of decentralized resources in the planning cycle on the basis of obtaining their behavior rules. Taking the historical output of new energy as input, the upper level planning model considering the comprehensive cost, DG carrying capacity and system comprehensive operation risk is established, and the installation scheme of DG and GES is obtained. The lower level considers the operation cost to balance the charging and discharging power of each energy storage system, and obtains the scheduling strategy of GES. The MD-K2 Bayesian network model, which can describe the spatial-temporal correlation of multi-dimensional wind-photovoltaic-load, is proposed to realize the collaborative optimization of DG and GES driven by multi-variate data. The rationality and effectiveness of the proposed model and method are verified by the test results of a numerical example.

**Key words:** spatial-temporal correlation; generalized energy storage; distributed generation; joint planning; MD-K2 Bayesian network

(上接第 132 页 continued from page 132)

## Short-term coal storage forecasting of thermal power plant for power grid dispatching based on CNN-LSTM neural network

PENG Daogang<sup>1,2</sup>, ZHU Qi<sup>1,2</sup>, CHE Quan<sup>3</sup>, ZHAO Huirong<sup>1,2</sup>

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

2. Shanghai Engineering Research Center of Intelligent Management and Control for Power Generation Process, Shanghai 200090, China; 3. State Grid Chongqing Electric Power Company, Chongqing 400014, China)

**Abstract:** The univariate single-step forecasting of coal storage for power plant with traditional regression fitting cannot meet the need of optimal dispatching for power grid, for this problem, CNN (Convolutional Neural Networks) and LSTM (Long Short-Term Memory) neural network are combined, and a CNN-LSTM neural network forecasting model is proposed, which uses CNN's good extraction capability and LSTM's special memory forecasting function to realize accuracy forecasting of future coal storage for power plant. In order to make the forecasting results more consistent with the actual coal storage, further optimization is carried out based on the existing forecasting results. Case verification results show that, compared with the traditional ARIMA (AutoRegressive Integrated Moving Average) model and single LSTM neural network model, the proposed model obtains better effect, and the forecasting accuracy after optimization is further improved.

**Key words:** short-term forecasting; coal storage of power plant; deep learning; model optimization; power grid dispatching

# 附录 A

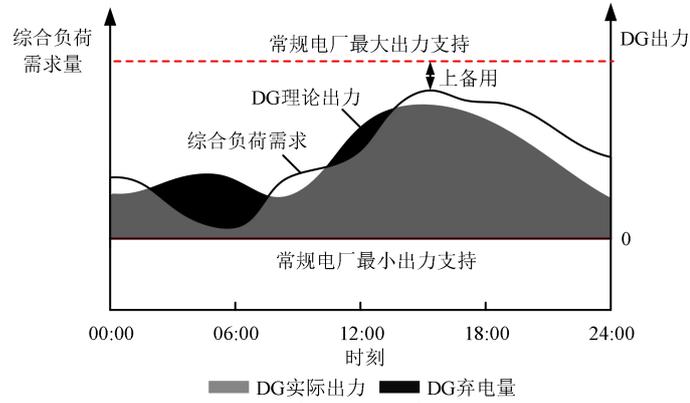


图 A1 DG 消纳机理示意图

Fig.A1 Schematic diagram of DG absorption mechanism

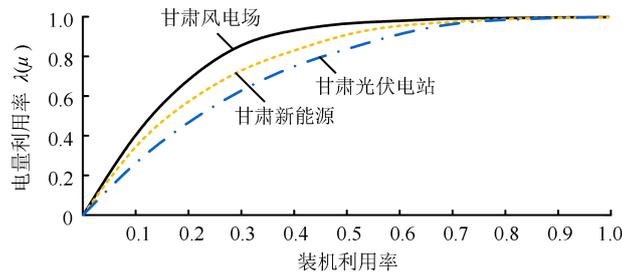


图 A2 DG 电量利用率的统计学特征

Fig.A2 Statistical characteristics of DG power utilization rate

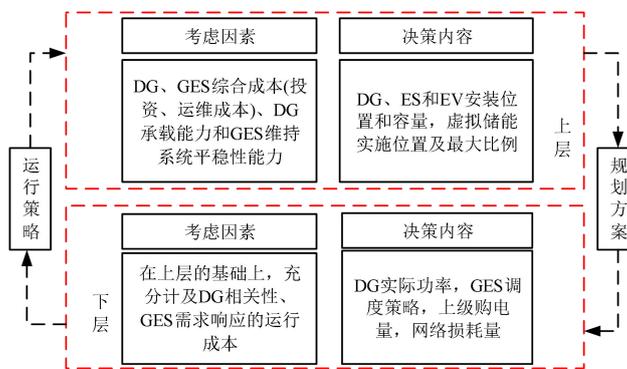


图 A3 双层规划求解架构

Fig.A3 Two-level programming solution architecture

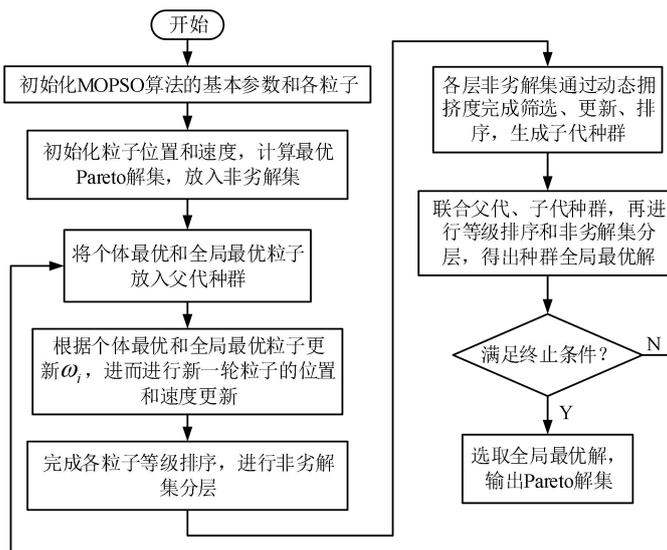


图 A4 MOPSO 算法迭代流程  
Fig.A4 Iterative process of MOPSO algorithm

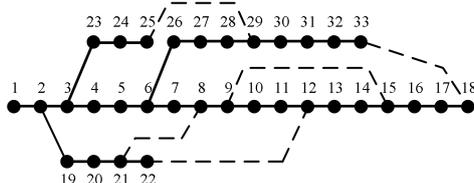


图 A5 IEEE 33 节点配电系统  
Fig.A5 IEEE 33-bus distribution system

表 A1 MOPSO 算法的相关参数  
Table A1 Related parameters of MOPSO algorithm

种群规模	迭代次数	Pareto 解集规模	权重更新区间	学习因子	
				$C_1$	$C_2$
100	200	50	[0.4,0.9]	2.5 递减至 0.5	0.5 递增至 2.5

表 A2 电网分时电价  
Table A2 Time-of-use electricity price of power grid

时段	电价 / [元·(kW·h) <sup>-1</sup> ]
10:00—15:00, 18:00—21:00	0.85
07:00—10:00, 15:00—18:00, 21:00—23:00	0.51
00:00—07:00, 23:00—24:00	0.16

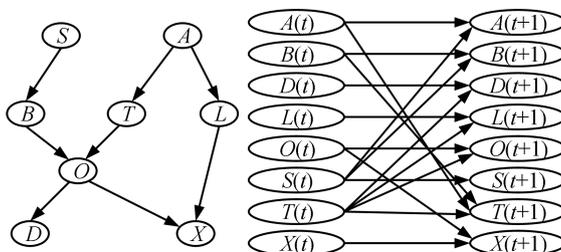


图 A6 标准 Asia 网络及其转移关系  
Fig.A6 Standard ASIA network and its transfer relation

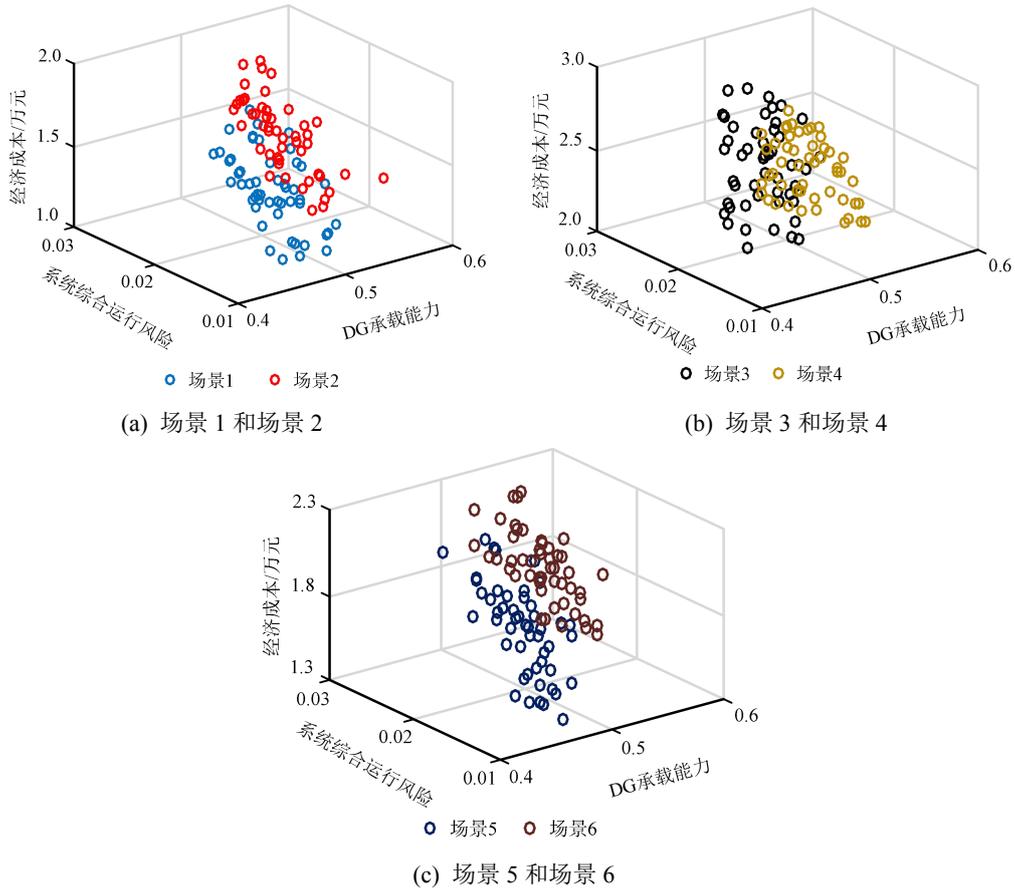


图 A7 不同场景的最优 Pareto 前沿解集  
Fig.A7 Pareto frontier solution set of different scenarios

表 A3 不同场景的最优规划方案  
Table A3 Optimal planning schemes of different scenarios

场景	风电机组功率/kW	光伏机组功率/kW	可转移负荷/实施比例	可中断负荷/实施比例	储能/kW
1	937(9), 928(13), 843(15)	432(10), 275(18), 316(24)	0.34(14), 0.22(25)	0.42(7), 0.48(18)	492(15), 527(21)
2	824(5), 859(13), 793(15)	310(10), 321(11), 369(18)	—	—	521(16), 543(17)
3	814(9), 796(13), 742(15)	246(10), 267(11), 235(24)	0.38(16), 0.33(27)	0.43(6), 0.41(16)	467(15), 453(22)
4	824(5), 818(9), 756(15)	234(10), 251(18), 179(24)	—	—	476(14), 489(17)
5	860(5), 891(13), 758(15)	327(10), 292(11), 276(24)	0.36(15), 0.37(24)	0.35(9), 0.39(17)	430(16), 512(23)
6	905(9), 883(13), 795(15)	383(10), 346(11), 217(24)	—	—	567(11), 493(18)

注：括号中数字表示节点位置。

## 附录 B

(1) DAG 评价指标。

增量边 IE (Increasable Edge) 指标  $d_{IE}$ ：预测结构与标准结构无关的边。

缺失边 ME (Missing Edge) 指标  $d_{ME}$ ：预测结构缺失标准结构的边。

反向边 RE (Reversed Edge) 指标  $d_{RE}$ ：预测结构中边的方向与标准结构中相反。

结构汉明距离 SHD (Structural Hamming Distance) 指标  $d_{SHD}$ ：度量预测结构与标准结构之间的匹配程度。

(2) BIC 评分函数：给定样本数  $M$ ，用对数似然度判断结构与数据的拟合程度。计算式如下：

$$BIC(G_T|Y) = \sum_i \sum_j \sum_k m_{i,j,k,l} \lg \frac{m_{i,j,k,l}}{\sum_k m_{i,j,k,l}} - \frac{1}{2} \sum_i q_i (r_i - 1) \lg M \quad (B1)$$