



研究与开发

基于强化学习的边缘计算智能电网资源调度算法

余竞航, 赵一辰, 宋浒

(国网江苏省电力有限公司信息通信分公司, 江苏 南京 210024)

摘要: 智能电网是一种能够进行智能管理和优化的电力网络。网络虚拟化技术可以有效提高智能电网的资源利用率和可靠性, 从而满足不同用户的差异化需求。在资源有限的情况下, 传统的虚拟网络嵌入算法无法根据电力系统的资源使用情况和用户需求来动态调整虚拟资源的分配和映射。为解决这一问题, 将边缘计算和虚拟化技术相结合, 引入了一种基于强化学习的虚拟网络资源调度算法。仿真结果表明, 该虚拟网络资源调度算法在提高电网的可靠性和资源利用率方面优于其他 3 种调度算法。

关键词: 智能电网; 边缘计算; 虚拟网络嵌入; 资源调度

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024005

Edge computing smart grid resource scheduling algorithm based on reinforcement learning

YU Jinghang, ZHAO Yichen, SONG Hu

Information and Communication Company, State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210024, China

Abstract: A smart grid is a power network capable of intelligent management and optimization. Network virtualization technology can effectively improve the resource utilization and reliability of smart grids and meet the differentiated needs of different users. In the case of limited resources, traditional virtual network embedding algorithms cannot dynamically adjust the allocation and mapping of virtual resources according to the resource usage and user needs of the power system. To solve this problem, edge computing and virtualization technology was combined and a virtual network resource scheduling algorithm based on reinforcement learning was introduced. The simulation results show that the proposed virtual resource scheduling algorithm is better than the other three scheduling algorithms in improving power grid reliability and resource utilization.

Key words: smart grid, edge computing, virtual network embedding, resource scheduling

收稿日期: 2023-11-02; 修回日期: 2023-12-26

通信作者: 余竞航, yujinghang@163.com

基金项目: 国网江苏省电力有限公司科技项目 (No. SGJSXT00XTJS2200433)

Foundation Item: Science and Technology Project of State Grid Jiangsu Electric Power Co., Ltd. (No. SGJSXT00XTJS2200433)



0 引言

随着智能电网的快速发展,电力网络行业面临着资源高效调度的挑战^[1-2]。综合运用信息通信、传感、测量、自动化、智能控制等先进技术,为电力系统的安全稳定运行提供了有力保障^[3-5]。尽管如此,电力网络企业仍然面临着如何有效利用电力系统内各种资源的紧迫问题。近年来,边缘计算作为一种创新的计算范式出现,其在智能电网中的应用受到广泛的关注^[6]。边缘计算可以直接为用户提供计算资源和服务,降低网络时延和数据传输成本,为智能电网的发展带来新的机遇^[7]。此外,智能电网还引入虚拟化计算,实现了对网络资源的虚拟化管理,从而提高了电网的运行效率和可靠性^[8]。然而,智能电网对网络资源的分配还面临着众多挑战,首先智能电网中的通信网络需要支持大量的数据传输和实时通信。随着智能电网中设备和传感器数量的增加,以及数据量的增大,对网络带宽的需求也会增加。确保网络合理分配带宽资源以满足实时数据传输和通信的需求是一个挑战。同时,对这些大规模数据进行实时处理和分析以支持智能电网的运行和决策需要在有限的计算资源情况下提高计算资源的分配效率。因此,本文将资源需求转化为虚拟网络,考虑虚拟网络的带宽和计算资源,对物理网络资源进行分配。

强化学习(reinforcement learning, RL)是一种机器学习方法,用于解决智能体在环境中做出决策的问题。它可以通过了解电力系统的资源使用情况和用户需求,动态调整虚拟化资源的分配和映射,从而实现资源的最优利用,在解决电力系统资源调度问题上,该方法有很大的研究价值^[9-10]。

本文的主要贡献如下:

- 本文提出了一种基于强化学习的虚拟资源调度算法,该算法结合了边缘计算和虚拟化计算的优点;

- 该算法改善了电力网络中各种资源的调度,进一步优化了电力网络的运行;
- 本文的研究成果不仅解决了智能电网中的资源调度问题,而且为其他领域的资源调度提供了有价值的见解和启发。

1 相关工作

文献[11]描述了一种基于SDN架构的云网融合技术。但由于SDN的开放性,必须考虑SDN控制器建设、集群部署、安全等方面的困难。文献[12]提供了一种基于云计算的电网虚拟化调度系统。该系统不仅可以弥补传统电力调度系统的不足,而且降低了对硬件资源的要求,显著提高了电网调度的可靠性和准确性。文献[13]实现了电网系统和结构的优化和创新,有助于智能电网结构的重新优化和调整。文献[14]描述了一种新兴的移动云计算技术,并介绍了移动云计算技术在智能电网中的应用。文献[15]针对资源分配和任务卸载两个子问题提出了一种基于遗传算法的联合资源分配优化策略。

传统的虚拟网络嵌入(virtual network embedding, VNE)算法大多采用启发式或元启发式算法来解决VNE问题^[16]。文献[17]提出了一种能耗感知的节点链路整数线性规划模型,并设置两个目标函数来优化VNE问题。将算法与经典的加权最短距离路径算法进行对比,验证了算法的有效性。文献[18]使用V-hub线性规划方法来解决VNE问题,该方法使用P-hub中值方法将VNE视为混合整数规划问题。文献[19]使用粒子群算法来解决VNE问题。该算法将VNE中的各个模块重新定义为粒子群中的一个对象,通过设定目标函数来寻求最优解。上述方法采用启发式算法或者元启发式算法,虽然一定程度上解决了电网中资源分配的问题,但是还存在以下缺点:

- 采用启发式算法容易陷入局部最优解,在复杂的虚拟网络嵌入问题中,启发式算法

可能会受限子局部搜索空间, 无法找到最优的嵌入方案;

- 随着电网中接入设备的增加, 网络规模变得越来越复杂, 启发式算法在处理大规模问题时可能面临计算复杂度和时间效率的挑战;
- 以上研究采用启发式算法, 即假设所有虚拟网络请求是已知的, 这不符合现实网络环境;
- 忽略了智能电网中边缘计算技术的支持, 所有的数据被传输到云端, 这会增加数据处理时延和响应时间。

与上面提到的工作不同, 本文利用边缘计算和虚拟化技术, 以及强化学习来提高 VNE 算法性能, 保证了智能电网的效率和可靠性, 提高了电网资源的效率。

2 网络建模

2.1 网络建模描述

物理网络包含 3 种类型的设备。第一部分是终端设备, 位于模型的底部, 离用户最近, 主要负责数据的采集和处理。第二部分是边缘服务器, 位于模型的中间层, 用于处理终端设备上传的计算任务。第三部分是中心服务器, 位于模型的顶层。边缘服务器距离终端设备较近, 在传输过程中产生的传播时延相对较小, 但其数据处理能力低于中心服务器。中央服务器上设置资源限制, 只要有数据传输, 就可以进行处理, 具有较强的计算能力, 能够高效地处理上传的计算任务。但由于与终端设备的距离一般较远, 数据上传到中心服务器会产生较大的传输时延。本文使用无向图 G^S 来表示物理网络:

$$G^S = (N^S, L^S, A_N^S, A_L^S) \quad (1)$$

其中, N^S 和 L^S 分别表示物理节点和物理链路的集合, A_N^S 表示物理节点的属性, A_L^S 表示链路的属

性。本文以计算能力作为节点属性, 以带宽作为链路属性。同理, 本文也使用无向图 G^V 描述虚拟网络服务请求 (virtual network request, VNR):

$$G^V = (C_N^V, C_L^V, A_N^V, A_L^V) \quad (2)$$

其中, C_N^V 表示虚拟节点的约束, C_L^V 表示虚拟链路约束, A_N^V 表示虚拟节点的属性, A_L^V 表示虚拟链路的属性。物理节点需要有比虚拟节点更高的计算能力, 虚拟节点才会映射到物理节点。当虚拟网络请求到达物理节点时, 其目的是为物理网络中的请求分配不同类型的资源, 那么相应的解决方案也应该满足它们的需求。如果存在这样的解决方案, 则执行映射过程并接受请求。否则, 请求将被拒绝。

2.2 VNE 约束

使用二进制变量 $X_{n^s}^{n^v}$ 来表示虚拟节点 n^v 是否映射到物理节点 n^s 上, 如式 (3) 所示:

$$X_{n^s}^{n^v} = \begin{cases} 1, & n^v \uparrow n^s \\ 0, & \text{其他} \end{cases} \quad (3)$$

同时, 使用二进制变量 $Y_{l^s}^{l^v}$ 来表示虚拟链路 l^v 是否映射到物理链路 l^s 上, 如式 (4) 所示:

$$Y_{l^s}^{l^v} = \begin{cases} 1, & l^v \uparrow l^s \\ 0, & \text{其他} \end{cases} \quad (4)$$

每个物理节点可以由来自不同 VNR 的多个虚拟节点嵌入, 表示如下:

$$\begin{cases} \sum_{n^v \uparrow n^s} X_{n^s}^{n^v} \geq 1, & n^v \in G_i^V \quad i = 1, 2, \dots, |\text{VNR}| \\ \sum_{n^v \uparrow n^s} X_{n^s}^{n^v} = 1, & n^v \in G^V \end{cases} \quad (5)$$

每个虚拟链路都可以嵌入多个物理链路上, 表示如下:

$$\sum_{l^v \uparrow l^s} Y_{l^s}^{l^v} \geq 1 \quad (6)$$

如果虚拟节点 n_i^v 映射到在物理节点 n_j^s 上, 则 n_j^s 的计算资源容量应满足 n_i^v 的计算资源消耗, 使用 $\text{NCPU}(n_i^v)$ 表示虚拟节点需要的计算资源, $\text{CPU}(n_j^s)$ 表示物理节点剩余的计算资源, 计算式



如下:

$$\text{NCPU}(n_i^v) \leq \text{CPU}(n_j^s) \quad n_i^v \uparrow n_j^s \quad (7)$$

对于物理节点 n_j^s , 嵌入 n_j^s 中的所有虚拟节点的计算资源需求的总消耗不能超过 n_j^s 的总计算资源, 表示如下。

$$\sum_{i=1}^{|VNR|} \sum_{n_i^v \uparrow n_j^s} \text{NCPU}(n_i^v) \leq \text{CPU}(n_j^s) \quad (8)$$

此外, 链路嵌入必须符合带宽约束, 如果虚拟链路 l_k^v 嵌入物理链路 l_m^s 上, l_k^v 的带宽资源容量不应小于 l_m^s 的带宽资源需求, 使用 $\text{NBW}(l_k^v)$ 表示虚拟链路需要的带宽资源, $\text{BW}(l_m^s)$ 表示物理链路剩余资源, 计算式如 (9) 所示。

$$\text{NBW}(l_k^v) \leq \text{BW}(l_m^s) \quad l_k^v \uparrow l_m^s \quad (9)$$

对于物理链路 l_m^s , 嵌入在物理链路 l_m^s 中的所有虚拟链路的总带宽资源需求不能超过其总带宽资源, 表示如下。

$$\sum_{i=1}^{|VNR|} \sum_{l_i^v \uparrow l_m^s} \text{NBW}(l_i^v) \leq \text{BW}(l_m^s) \quad (10)$$

2.3 性能评估指标

对此, 本文采用一些指标来确定虚拟网络映射算法的性能。虚拟网络请求的长期平均收入定义如下。

$$\text{LR} = \lim_{T \rightarrow \infty} \frac{\sum_{\Delta t \in T} \left(\sum_{n_i^v}^{N^v} \text{NCPU}(n_i^v) + \sum_{l_j^v}^{L^v} \text{NBW}(l_j^v) \right)}{T} \quad (11)$$

其中, $\text{NCPU}(n_i^v)$ 和 $\text{NBW}(l_j^v)$ 分别表示虚拟节点 n_i^v 所需的计算资源和虚拟链路 l_j^v 所需的带宽资源。由此, 本文将长期平均收入成本比定义为:

$$\text{LR} / \text{C} = \lim_{T \rightarrow \infty} \frac{\sum_{\Delta t \in T} \left(\sum_{n_i^v}^{N^v} \text{NCPU}(n_i^v) + \sum_{l_j^v}^{L^v} \text{NBW}(l_j^v) \right)}{\sum_{\Delta t \in T} \sum_{n_i^v}^{N^v} \text{NCPU}(n_i^v) + \sum_{l_j^v}^{L^v} \text{NBW}(l_j^v) \times \text{hop}(l_j^v)} \quad (12)$$

其中, $\text{hop}(l_j^v)$ 表示虚拟链路 l_j^v 的跳数, 虚拟网络请求的接受率定义如下。

$$\text{ACC} = \lim_{T \rightarrow \infty} \frac{\sum_{t=0}^T G_{\text{acc}}^v}{\sum_{t=0}^T G_{\text{total}}^v} \quad (13)$$

其中, G_{acc}^v 表示接收成功的 VNR, G_{total}^v 表示接收到的 VNR 总数。

3 强化学习模型

本文使用 RL 来选择用于部署虚拟节点的物理节点。为了实现这一点, VNE 问题可以表示为马尔可夫决策过程 (Markov decision process, MDP)。

MDP 是强化学习的基本框架, 由状态、行动和奖励组成。

(1) 状态

MDP 的状态由物理网络的特征矩阵和 VNR 需求信息组成, 如式 (12) 所示, 通过提取物理网络的环境特征来构造物理节点 n_i^s 特征向量 $\mathbf{v}_i$ 。向量包含 4 个维度, 分别是节点的可用 CPU 资源量 $\text{CPU}(\cdot)$ 、节点相邻链路的可用带宽之和 $\text{SUM}_{\text{BW}}(\cdot)$ 、节点的程度 $D(\cdot)$ 和节点的接近中心性 $\text{CC}(\cdot)$ 。VNR 的信息包括虚拟节点的 CPU 资源需求和链路的带宽资源需求。

$$\mathbf{v}_i = [\text{CPU}(N_i^s) \quad \text{SUM}_{\text{BW}}(N_i^s) \quad D(N_i^s) \quad \text{CC}(N_i^s)] \quad (14)$$

(2) 动态

该操作表示 RL 代理制定的节点嵌入策略。根据传入的 VNR, 逐个考虑每个虚拟节点, 并将其放置在 RL 代理选择的概率最高的物理节点上。

(3) 奖励

VNR 成功嵌入后, 智能体可以接收奖励反馈, 并根据奖励值的大小调整其行为。奖励基于收入成本比率, 如式 (15) 所示:

$$\text{Reward} = \frac{\text{Re}_{G_k^V \rightarrow G^S}}{\text{Cost}_{G_k^V \rightarrow G^S}} \quad (15)$$

在式 (16) 中, 代理根据 $\mathbf{v}_i$ 计算每个节点的可用资源向量:

$$\text{ARV}_i = \text{ReLU}(w \times \mathbf{v}_i + b) \quad (16)$$

其中, $\mathbf{v}_i$ 是特征矩阵中的第 i 个向量, 即第 i 个物理节点的特征向量。随后, 使用 softmax 函数来计算选择物理节点的概率。计算式如下:

$$p_i^S = \frac{e^{\text{ARV}_i}}{\sum_{k=1}^{|N^S|} e^{\text{ARV}_k}} \quad (17)$$

完成所有虚拟节点的嵌入后, 利用广度优先搜索算法来完成链路嵌入。如果在节点和链路的嵌入过程中任何步骤失败, 则此 VNR 将被拒绝。否则, 此 VNR 的嵌入将成功, 如算法 1 所示。算法 1 的 5~6 行依次提取每个物理节点的特征向量来构造物理网络的特征矩阵, 作为策略网络的输入。策略网络通过卷积层、池化层、过滤层输出每个节点的映射概率。算法 1 的 8~9 行获得每个物理节点的映射概率, 根据映射概率选择映射节点, 并更新物理网络的计算资源。如果每个虚拟节点映射成功, 进行链路映射, 本文采用广度优先搜索算法遍历, 对应算法 1 的 11~12 行。当虚拟网络的所有节点和链路都映射成功时, 根据式 (13) 来计算奖励, 并获得梯度, 并根据获得的梯度更新策略网络参数, 对应算法 1 的 14~22 行。本文使用梯度下降法对策略网络参数进行更新, 计算式如下:

$$g = g' \cdot \alpha \cdot O \quad (18)$$

其中: α 为训练速率, 可以控制训练速度和训练梯度的大小; O 为优化结果, 即根据式 (15) 计算出来的奖励; g' 为堆叠梯度。对堆叠的梯度使用批处理来更新策略, 这样做的原因是, 一方面要加快整个训练过程, 另一方面又要获得一个更

稳定的梯度。

算法 1 EC-RLVNE 算法

输入: VNR 集合 VNR_{SET} , 迭代次数 epo ,

物理网络 G^S

输出: 节点映射结果, 策略网络参数;

```

(1) while iteration < epo do
(2)   cnt=0;
(3)   for  $G^V \in \text{VNR}_{\text{SET}}$  do
(4)     for  $n^V \in G^V$ 
(5)       for  $n_i^S \in G^S$ 
(6)          $M \leftarrow M + \mathbf{v}_i$ 
(7)       end for
(8)     getProbability( $M, n^V$ ); 获得映射概率值
(9)     Update  $G^S$ ;
(10)    end for
(11)    if is Mapped( $\forall n^V \in G^V$ ) then
(12)      BFS( $L_v, G^S$ ); 广度优先搜索算法进行链路映射
(13)    end if
(14)    if is Mapped( $\forall n^V \in G^V, \forall l^V \in G^V$ ) then
(15)      reward=GetReward( $G^V$ );
(16)      getGradient(reward);
(17)      cnt ++
(18)      if cnt == batch_size then
(19)        update parameter;
(20)        cnt=0;
(21)      end if
(22)    end if
(23)  end for
(24)  iteration ++
(25) end while

```

4 实验结果和分析

为了验证 EC-RLVNE 的有效性, 设计了 3 组对比实验来检验其性能。实验中使用的基线算法



是 DeepViNE^[20]、NRMVNE^[21]和 NODERANK^[22]。通过利用 GT-ITM 软件创建了一个具有 100 个节点和 500 个链路的网络拓扑。物理网络的 CPU 资源均匀分布在 40 到 110 之间,而带宽资源也均匀分布在 40 到 100 的之间。另外,生成了 2 000 个 VNR,将其分成两等份,用于算法的训练和评估。VNR 的 CPU 资源需求是均匀分布的,范围是 10 到 30 之间,带宽资源需求也是均匀分布的,范围是 10 到 70 之间。

实验选取了长期平均收入、长期平均收入成本比、虚拟网络请求接受率 3 个算法评价指标。实验结果如图 1 所示,其中图 1 (a) ~ (c) 显示了实验的比较结果。可以看出,刚开始时,4 种算法的长期平均收入都比较高,随着时间的推移,物理网络剩余的资源越来越少,映射成功的虚拟网络越来越少,所以长期平均收入和虚拟网络请求接受率都呈下降趋势。然而,随着收益的降低,成本也在降低,所以长期平均收入成本比相比波动较小。由图 1 可知,EC-RLVNE 各方面表现最好,其次是 DeepViNE; NRMVNE 和 NODERANK 在各方面都不如上述两种算法有效。NRMVNE 和 NODERANK 采用基于排序的启发式算法,优先使用资源丰富的节点和链路,导致资源碎片化。此外,它们主要依靠手动映射规则(如设置节点的排序方法)来实现 VNE 算法,这极大地限制了算法的灵活性。总体而言,与启发式算法相比,基于机器学习的算法表现更好,本文的算法使用强化学习来提高其灵活性,与环境不断交互来调整自己的映射策略使物理网络接受更多的虚拟网络,此外,通过提取关键特征属性,为强化学习代理建立接近现实的训练环境。因此,EC-RLVNE 可以获得更好的资源调度决策。最后,对实验数据进行分析,在长期平均收入方面,本文提出的算法比 DeepViNE、NRMVNE 和 NODERANK 算法平均高出 46.82%。在长期平均收入成本比方面,本文算法

比 DeepViNE、NRMVNE 和 NODERANK 分别高 4.12%、14.72%、17.79%。此外,在虚拟网络请求接受率方面,所提算法也表现出了比较好的性能,比 DeepViNE、NRMVNE 和 NODERANK 分别高 9.61%、10.716%、19.96%。






图 1 实验结果

5 结束语

边缘计算的引入使智能电网更方便地为用户提供服务,将数据处理和决策推向离数据源更近的边缘设备,减少了数据传输的时延,实现了更快速的响应和实时决策能力。此外智能电网中引入虚拟化技术,克服了网络僵化现象,同时实现了对网络资源的分配。然而,如何高效分配智能电网中的网络资源是现在面临的一个挑战。因此,本文提出了一种结合边缘计算和虚拟网络映射的方法来解决智能电网中的资源分配问题。具体来说,考虑了多目标资源分配的情况,提出了一种基于强化学习的资源分配算法。该算法利用强化学习代理提取网络特征来构建策略网络来训练模型、优化虚拟网络嵌入方案、实现网络资源的有效分配,从而提高智能电网的效率和性能。实验结果表明,所提算法在长期平均收入、长期平均收入成本比和虚拟网络请求接受率方面都优于其他 3 种对比算法,本文在智能电网中应用以及促进电网的可持续发展具有现实意义。

在未来的工作中,笔者团队将考虑智能电网中其他资源属性,如存储、能源和安全等。此外,将尝试调整神经网络模型或采用其他人工智能技术,对智能电网进行更全面、更有效的资源管理。同时,需要考虑智能电网是一个大规模的复杂网络,有必要设计一个更复杂、更深层次的神经网络模型来提高其处理复杂问题的能力。此外,考虑智能电网中网络的拓扑结构和资源条件不断变化,研究动态拓扑结构下的网络资源分配问题将更加现实。最后,笔者团队将探讨该算法的可扩展性及考虑分布式部署算法。

参考文献:

- [1] ZAFAR A, CHE Y B, AHMED M, et al. Enhancing power generation forecasting in smart grids using hybrid autoencoder long short-term memory machine learning model[J]. IEEE Access, 2023(11): 118521-118537.
- [2] BONDOK A H, MAHMOUD M, BADR M M, et al. Novel evasion attacks against adversarial training defense for smart grid federated learning[J]. IEEE Access, 2023(11): 112953-112972.
- [3] ALACA O, EKTİ A R, WILSON A, et al. Detection of grid-signal distortions using the spectral correlation function[J]. IEEE Transactions on Smart Grid, 2023, 14(6): 4980-4983.
- [4] SIKRI A, SELIM B, KADDOUM G, et al. RIS-aided wireless sensor network in the presence of impulsive noise and interferers for smart-grid communications[J]. IEEE Communications Letters, 2023, 27(9): 2501-2505.
- [5] FRANCES A, RAMIREZ D, UCEDA J. Blackbox small-signal modeling of grid-connected inverters in asymmetrical power grids[J]. IEEE Transactions on Power Electronics, 2023, 38(10): 13064-13073.
- [6] HOSSEINZADEHTAHER M, ZARE A, KHAN A, et al. AI-based technique to enhance transient response and resiliency of power electronic dominated grids via grid-following inverters[J]. IEEE Transactions on Industrial Electronics, 2023, 71(3): 2614-2625.
- [7] ZHANG H X, YANG Y J, SHANG B D, et al. Joint resource allocation and multi-part collaborative task offloading in MEC systems[J]. IEEE Transactions on Vehicular Technology, 2022, 71(8): 8877-8890.
- [8] ZHANG P Y, ZHANG Y, KUMAR N, et al. Dynamic SFC embedding algorithm assisted by federated learning in space-air-ground integrated network resource allocation scenario[J]. IEEE Internet of Things Journal, 2023, 10(11): 9308-9318.
- [9] WANG C, LIU L, JIANG C X, et al. Incorporating distributed DRL into storage resource optimization of space-air-ground integrated wireless communication network[J]. IEEE Journal of Selected Topics in Signal Processing, 2021, 16(3): 434-446.
- [10] 刘峻朋, 夏玮玮, 刘晗, 等. 面向电力业务质量保障的 NR-U 与 Wi-Fi 频谱共享[J]. 电信科学, 2023, 39(7): 11-22.
LIU J P, XIA W W, LIU H, et al. NR-U and Wi-Fi spectrum sharing for quality guaranteeing of power services [J]. Telecommunications Science, 2023, 39(07): 11-22.
- [11] 郭健. 基于 SDN 架构的云网融合技术研究与实践[J]. 电信工程技术与标准化, 2022, 35(3): 27-32.
GUO J. Research and practice of cloud network integration technology based on SDN architecture[J]. Telecom Engineering Technics Standardization, 2022, 35(3), 27-32.
- [12] 李洵, 廖臣, 杨箴, 等. 基于云计算的电网虚拟化调度系统研究[J]. 电子设计工程, 2019, 27(12): 138-141, 146.
LI X, LIAO C, YANG Z, et al. Research on power grid virtual-



- ization scheduling system based on cloud computing[J]. Electronic Design Engineering, 2019, 27(12): 138-141, 146.
- [13] 许广路. 物联网技术在智能电网中的应用[J]. 科技创新与应用, 2022, 12(5): 182-184.
- XU G L. Application of internet of things technology in smart grid[J]. Technology Innovation and Application, 2022, 12(5): 182-184.
- [14] 刘明月, 涂崎, 汪洋, 等. 移动云计算卸载技术研究现状及其在电网中的应用[J]. 电力信息与通信技术, 2021, 19(1): 49-56.
- LIU M Y, TU Q, WANG Y, et al. Research on mobile cloud computation offloading technology and its application in power grid[J]. Electric Power Information and Communication Technology, 2021, 19(1): 49-56.
- [15] DOU H E, XU Z C, JIANG X, et al. Mobile edge computing based task offloading and resource allocation in smart grid[C]//Proceedings of the 2021 13th International Conference on Wireless Communications and Signal Processing (WCSP). Piscataway: IEEE Press, 2021: 1-5.
- [16] CAO H T, HU H, QU Z C, et al. Heuristic solutions of virtual network embedding: a survey[J]. China Communications, 2018, 15(3): 186-219.
- [17] MELO M, SARGENTO S, KILLAT U, et al. Optimal virtual network embedding: energy aware formulation[J]. Computer Networks, 2015(91): 184-195.
- [18] SHANBHAG S, KANDOOOR A R, WANG C, et al. VHub: single-stage virtual network map through hub location[J]. Computer Networks, 2015(77): 169-180.
- [19] HAERI S, TRAJKOVIRÉ L. Virtual network embedding via Monte Carlo tree search[J]. IEEE Transactions on Cybernetics, 2017, 48(2): 510-521.
- [20] DOLATI M, HASSANPOUR S B, GHADERI M, et al. DeepViNE: Virtual network embedding with deep reinforcement learning[C]//Proceedings of the IEEE INFOCOM

2019-IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS). Piscataway: IEEE Press, 2019: 879-885.

- [21] ZHANG P Y, YAO H P, LIU Y J. Virtual network embedding based on computing, network, and storage resource constraints[J]. IEEE Internet of Things Journal, 2017, 5(5): 3298-3304.
- [22] YU M L, YI Y, REXFORD J, et al. Rethinking virtual network embedding: Substrate support for path splitting and migration[J]. ACM SIGCOMM Computer Communication Review, 2008, 38(2): 17-29.

[作者简介]



余竞航(1995-), 男, 国网江苏省电力有限公司信息通信分公司工程师, 主要研究方向为电力信息技术。



赵一辰(1996-), 男, 现就职于国网江苏省电力有限公司信息通信分公司, 主要研究方向为电力信息技术。



宋浒(1986-), 男, 博士, 国网江苏省电力有限公司信息通信分公司高级工程师, 主要研究方向为电力信息技术。