

# 控制与决策

Control and Decision

基于Conv-Seq2Seq模型的含弹性资源电力系统日前调度方法

谭琦, 孙晨皓, 唐昊, 王正风, 方道宏

引用本文:

谭琦, 孙晨皓, 唐昊, 等. 基于Conv-Seq2Seq模型的含弹性资源电力系统日前调度方法[J]. 控制与决策, 2025, 40(5): 1651-1659.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.0952>

---

您可能感兴趣的其他文章

Articles you may be interested in

[基于图卷积网络的行为识别方法综述](#)

A survey of action recognition methods based on graph convolutional network

控制与决策. 2021, 36(7): 1537-1546 <https://doi.org/10.13195/j.kzyjc.2020.0514>

[面向人机物三元数据的热轧调度问题研究](#)

Research on hot rolling scheduling problem oriented to human-cyber-physical data

控制与决策. 2021, 36(11): 2825-2832 <https://doi.org/10.13195/j.kzyjc.2020.0551>

[基于深度强化学习与迭代贪婪的流水车间调度优化](#)

Scheduling optimization for flow-shop based on deep reinforcement learning and iterative greedy method

控制与决策. 2021, 36(11): 2609-2617 <https://doi.org/10.13195/j.kzyjc.2020.0608>

[\$l\_p\$ -范数约束下MKL-OC-ELM的装备故障检测](#)

MKL and OC-ELM fault detection based on  $l_p$ -norm constraint

控制与决策. 2021, 36(10): 2379-2388 <https://doi.org/10.13195/j.kzyjc.2020.0443>

[改进集成深层自编码器在轴承故障诊断中的应用](#)

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

控制与决策. 2021, 36(1): 135-142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

# 基于 Conv-Seq2Seq 模型的含弹性资源电力系统 日前调度方法

谭琦<sup>1†</sup>, 孙晨皓<sup>1</sup>, 唐昊<sup>1</sup>, 王正风<sup>2</sup>, 方道宏<sup>1</sup>

(1. 合肥工业大学 电气与自动化工程学院, 合肥 230009; 2. 国网安徽省电力有限公司, 合肥 230061)

**摘要:** 针对新能源大规模并网带来的消纳问题, 提出一种考虑源荷双侧弹性资源的前日调度方法。首先, 对深度调峰机组、可平移负荷和可削减负荷的弹性调节能力进行分析, 建立含弹性资源的电力系统调度模型; 然后, 提出一种基于 Conv-Seq2Seq (convolutional sequence to sequence) 模型的前日调度方法, 使用多层卷积神经网络作为编码器对负荷预测数据等信息进行提取, 改进深度学习网络信息提取的能力和速度, 并使用门控循环单元作为解码器对编码器提取的信息进行解码, 以输出调度计划; 最后, 通过辅助决策修正来确保调度计划的安全性。基于改进的 IEEE39 节点算例验证所提出方法的有效性和正确性。

**关键词:** 新能源消纳; 深度调峰; 柔性负荷; 日前调度; 深度学习; Seq2Seq

中图分类号: TM721 文献标志码: A

DOI: 10.13195/j.kzyjc.2024.0952

引用格式: 谭琦, 孙晨皓, 唐昊, 等. 基于 Conv-Seq2Seq 模型的含弹性资源电力系统日前调度方法 [J]. 控制与决策, 2025, 40(5): 1651-1659.

## Day-ahead scheduling method of power system with flexible resources based on Conv-Seq2Seq model

TAN Qi<sup>1†</sup>, SUN Chen-hao<sup>1</sup>, TANG Hao<sup>1</sup>, WANG Zheng-feng<sup>2</sup>, FANG Dao-hong<sup>1</sup>

(1. School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China; 2. State Grid Anhui Electric Power Co., Ltd. Hefei 230061, China)

**Abstract:** To solve the challenges of accommodating large-scale renewable energy integration into the power grid, a day-ahead dispatching strategy utilizing flexible resources on both source-side and load-side is proposed. Firstly, the flexible regulation capabilities of deep peak regulation, shiftable loads and reducible loads are analyzed, and a power system dispatching model includes these flexible resources is established. Subsequently, a day-ahead scheduling method based on the convolutional sequence to sequence(Conv-Seq2Seq) model is proposed. Load forecasting data and other relevant information are extracted through the encoder using multi-layer convolutional neural networks, which enhances the capability and speed of information extraction in deep learning networks. The decoder employing a gated recurrent unit decodes the information extracted by the encoder and outputs the scheduling plan. Finally, auxiliary decision correction is applied to refine the outputted dispatching plan to ensure security. The effectiveness and correctness of the proposed method are verified using an improved IEEE 39-bus system.

**Keywords:** renewable energy accommodation; deep peak regulation; flexible load; day-ahead scheduling; deep learning; Seq2Seq

## 0 引言

在“碳达峰、碳中和”目标下, 建设以新能源为主体的新型电力系统是电网发展的必然趋势<sup>[1]</sup>. 截至 2024 年 6 月底, 我国风电装机容量约 4.67 亿千

瓦, 同比增长 20%, 对电力可靠性、电能质量均产生了重要影响. 同时, 新能源具有间歇性、波动性和不确定性等特征, 若仅依靠传统火电机组的调节能力往往难以满足. 充分利用电力系统中弹性资源的调

收稿日期: 2024-08-09; 录用日期: 2024-12-01.

基金项目: 国家自然科学基金项目 (62273130); 安徽省自然科学基金项目 (2108085UD01); 安徽省高校协同创新项目 (GXXT-2023-032).

责任编辑: 孙秋野.

<sup>†</sup>通信作者. E-mail: tanqi@hfut.edu.cn.

度潜力,可在一定程度上应对此种情况。

电力系统负荷侧弹性资源为柔性负荷,电源侧弹性资源为深度调峰机组。引入柔性负荷,能够平抑波动,降低峰谷差,加强电网的调节能力,且对于用户的正常用电影响较小,具有良好的经济效益和社会效益<sup>[2-3]</sup>;引入深度调峰机组,充分发挥火电机组深度调峰的主动性,可应对风电出力波动导致火电机组频繁启停的问题<sup>[4-5]</sup>。利用不断增多的源荷双侧弹性资源可应对新能源出力的不确定性,但是会提高系统复杂性,影响调度计划求解效率。

日前调度问题的传统求解思路是根据实际问题提炼出数学模型,然后进行求解,即“问题-模型-解”思路。部分学者使用数学规划方法,如拉格朗日松弛法<sup>[6]</sup>、随机规划<sup>[7]</sup>和鲁棒优化<sup>[8]</sup>等方法解决机组组合问题;另一部分学者使用启发式算法,通过直观或先验知识,给出可接受计算时间下机组组合问题的解,但是与最优解有不同程度的偏离<sup>[9]</sup>。传统数学规划方法虽然能够得到最优解,但是效率较低,随着弹性资源不断增多,系统规模不断增大,其计算效率已难以满足调度员的需求。基于此,部分学者使用强化学习方法<sup>[10-11]</sup>,通过智能体与环境交互探索得到调度计划,但是该类方法会受到高维状态带来的“维数灾难”影响,难以处理机组组合中的机组启停问题。而基于监督学习的深度学习可以解决这一问题<sup>[12-13]</sup>,即通过深度神经网络映射模型来表示负荷预测等信息与调度计划的关系,以简化求解过程,缓解机组和源荷双侧弹性资源不断增多给系统调度带来的困难。但是该方法高度依赖历史样本,错误的样本将带来灾难性的后果。结合数学规划方法和数据驱动方法的优点,利用数学规划方法所得到的最优调度方案离线训练深度神经网络,使用训练好的深度神经网络进行在线决策,可由负荷预测等信息直接映射得到包含机组启停方案的调度计划,有效提高求解效率。

电力系统的日前调度计划在决策依赖的信息和决策结果上均具有较强的时序性<sup>[14]</sup>。为了更好地处理时间序列,充分挖掘序列中的时序信息,文献<sup>[15]</sup>提出了一种基于编码器-解码器架构的 Seq2Seq 模型,其中编码器和解码器均由循环神经网络(RNN)、长短期记忆网络和门控循环单元(GRU)等 RNN 变种网络组成,该框架在自然语言处理中表现优异;文献<sup>[12]</sup>利用该架构提出了一种基于 E-Seq2Seq 的深度学习方法,用较低的决策时间获得高质量的日前调度计划,然而,该方法中编码器的 RNN 提取信息必须在不同时段逐步展开,无法充分发挥深度神

经网络提取信息的速度优势。卷积神经网络(CNN)可以同时提取不同时段的信息,使用 CNN 改进编码器,可进一步提高求解效率。

综上,为了充分利用新型电力系统中源荷双侧弹性资源调度潜力,提高新能源发电消纳率,本文基于 Seq2Seq 模型提出一种日前调度方法。首先,考虑电力系统的安全约束和源荷双侧弹性资源的调度弹性,建立日前调度模型;然后,构建包括负荷和新能源出力预测数据以及对应的最优调度计划在内的数据样本库;接着,利用 CNN 并行提取多时段信息能力,改进 Seq2Seq 模型的编码器结构,结合残差连接和辅助决策修正,在保证安全性和经济性的同时可以快速给出调度计划;最后,采用改进的 IEEE39 节点算例,验证所提出方法的有效性和正确性。

## 1 含源荷双侧弹性资源电力系统模型

### 1.1 电力系统调度模型

本文所研究的电力系统调度模型,电源侧包括  $N_f$  台火电机组和  $N_w$  台风电机组。其中:火电机组根据其调峰能力不同分为传统火电机组和深度调峰机组,深度调峰机组有  $N_d$  台。负荷侧包括刚性负荷和柔性负荷。这里:刚性负荷为必须满足的用电需求,不参与调度;柔性负荷包括可平移负荷和可削减负荷。

电力系统调度所需考虑的安全约束主要有功率平衡约束和线路传输容量约束,其中功率平衡约束为

$$\sum_{i=1}^{N_f} P_{i,t} + \sum_{k=1}^{N_w} P_{k,t}^w = P_t^{\text{load}} - P_t^{\text{cut}} + P_t^{\text{sh}} - P_t^{\text{sh}*}, \quad (1)$$

$$P_t^{\text{load}} = P_t^{\text{rigid}} + L_t^{\text{cut}} + P_t^{\text{sh}*}. \quad (2)$$

这里:  $P_{i,t}$  和  $P_{k,t}^w$  分别为  $t$  时段第  $i$  台火电机组和第  $k$  台风电机组的出力,  $P_t^{\text{load}}$  为  $t$  时段总负荷,  $P_t^{\text{cut}}$  为  $t$  时段可削减负荷的削减功率,  $P_t^{\text{sh}*}$  和  $P_t^{\text{sh}}$  分别为  $t$  时段调度前后可平移负荷功率,  $P_t^{\text{rigid}}$  为  $t$  时段刚性负荷功率,  $L_t^{\text{cut}}$  为  $t$  时段调度前可削减负荷功率,  $t$  时段系统线路传输容量约束为

$$\left| \sum_{i=1}^{N_f} T_{\text{br},i}^f P_{i,t} + \sum_{k=1}^{N_w} T_{\text{br},k}^w P_{k,t} - \sum_{l=1}^{N_b} T_{\text{br},l}^l P_{l,t} \right| \leq F_{\text{br}}^{\text{max}}. \quad (3)$$

其中:  $T_{\text{br},i}^f$ 、 $T_{\text{br},k}^w$  和  $T_{\text{br},l}^l$  为系统各节点对线路 br 的功率传输分配系数,上标 f、w 和 l 表示火电、风电和负荷所在节点,  $N_b$  为节点数,  $P_{l,t}^l$  为  $t$  时段节点  $l$  的负荷功率,  $F_{\text{br}}^{\text{max}}$  为线路 br 的潮流上限。

### 1.2 电源侧系统模型

本文考虑的电源侧模型包括传统火电机组和深

度调峰机组. 其中: 深度调峰机组属于电源侧弹性资源, 其调峰过程主要分为常规调峰阶段和深度调峰阶段, 当深度调峰机组运行在常规调峰阶段时, 其运行情况与传统火电机组相同.

### 1.2.1 约束条件

约束包括火电机组出力上下限约束、爬坡约束和启停时间约束. 火电机组出力上下限约束为

$$z_{i,t} P_i^{\min} \leq P_{i,t} \leq z_{i,t} P_i^{\max}. \quad (4)$$

其中:  $P_i^{\min}$ 、 $P_i^{\max}$  分别为第  $i$  台火电机组出力的下限和上限, 对于传统火电机组而言,  $P_i^{\min}$  为最小技术出力, 而对于深度调峰机组而言,  $P_i^{\min}$  为深度调峰阶段的最小出力;  $z_{i,t}$  表示火电机组是否启动,  $z_{i,t} = 0/1$  分别表示  $t$  时段机组  $i$  为停运/运行状态.

火电机组爬坡约束为

$$-r_i^{\text{down}} \Delta T \leq P_{i,t} - P_{i,t-1} \leq r_i^{\text{up}} \Delta T. \quad (5)$$

其中:  $r_i^{\text{down}}$ 、 $r_i^{\text{up}}$  分别为第  $i$  台火电机组的向下爬坡速率和向上爬坡速率,  $\Delta T$  为时间间隔.

火电机组启停时间约束为

$$t_i^{\text{on}} \geq T_i^{\text{on}}, t_i^{\text{off}} \geq T_i^{\text{off}}. \quad (6)$$

其中:  $t_i^{\text{on}}$ 、 $t_i^{\text{off}}$  分别为第  $i$  台火电机组的连续运行时段数和连续停运时段数,  $T_i^{\text{on}}$ 、 $T_i^{\text{off}}$  分别为第  $i$  台火电机组必须满足的最小运行和最小停运时段数.

### 1.2.2 运行成本

传统火电机组的运行成本包括煤耗成本  $C_{i,t}^{\text{fuel}}$  和启停成本  $C_{i,t}^{\text{onoff}}$ , 分别为

$$C_{i,t}^{\text{fuel}} = (a_i P_{i,t}^2 + b_i P_{i,t} + c_i) z_{i,t} \Delta T, \quad (7)$$

$$C_{i,t}^{\text{onoff}} = (1 - z_{i,t-1}) z_{i,t} C_i^{\text{on}} + (1 - z_{i,t}) z_{i,t-1} C_i^{\text{off}}. \quad (8)$$

其中:  $a_i$ 、 $b_i$  和  $c_i$  为第  $i$  台火电机组的煤耗系数,  $C_i^{\text{on}}$  和  $C_i^{\text{off}}$  分别为第  $i$  台火电机组的启动费用和停机费用.

当深度调峰机组工作在深度调峰状态时, 由于机组出力偏离设计值较多, 将产生损耗成本  $C_{i,t}^{\text{life}}$ <sup>[16]</sup>, 即

$$C_{i,t}^{\text{life}} = \frac{1}{2N_{i,t}(P_{i,t})} \omega C_i^{\text{limit}} \Delta T. \quad (9)$$

其中:  $N_{i,t}$  为机组  $i$  的转子致裂循环周次, 其值与  $P_{i,t}$  密切相关;  $\omega$  为火电机组运行损耗系数;  $C_i^{\text{limit}}$  为机组  $i$  的购机成本. 深度调峰状态下机组  $i$  总成本  $C_{i,t}^{\text{gen}}$  为

$$C_{i,t}^{\text{gen}} = C_{i,t}^{\text{fuel}} + C_{i,t}^{\text{onoff}} + C_{i,t}^{\text{life}}. \quad (10)$$

## 1.3 负荷侧弹性资源模型

本文考虑的负荷侧弹性资源包括可削减负荷和

可平移负荷. 可削减负荷是指可对功率进行部分削减的负荷. 削减量  $P_t^{\text{cut}}$  取值范围可表示为

$$0 \leq P_t^{\text{cut}} \leq \rho^{\text{cut}}(C_{\text{price}}^{\text{cut}}) \cdot L_t^{\text{cut}}. \quad (11)$$

其中:  $L_t^{\text{cut}}$  为可削减负荷的额定功率;  $C_{\text{price}}^{\text{cut}}$  为单位功率负荷削减的补偿价格;  $\rho^{\text{cut}}$  为可削减负荷弹性系数, 与补偿价格相关, 体现了可削减负荷的弹性, 可削减负荷弹性系数可表示为

$$\rho^{\text{cut}} = \begin{cases} 0, & 0 \leq C_{\text{price}}^{\text{cut}} < C_{\text{price}}^{\text{cut}-}; \\ \frac{2}{\pi} \arctan\left(\frac{C_{\text{price}}^{\text{cut}}}{\xi^{\text{cut}}}\right), & C_{\text{price}}^{\text{cut}-} \leq C_{\text{price}}^{\text{cut}} < C_{\text{price}}^{\text{cut}+}; \\ \rho_{\text{max}}^{\text{cut}}, & C_{\text{price}}^{\text{cut}+} \leq C_{\text{price}}^{\text{cut}}. \end{cases} \quad (12)$$

这里:  $C_{\text{price}}^{\text{cut}-}$  为用户有意愿参加调度的最低补偿价格;  $C_{\text{price}}^{\text{cut}+}$  为可削减量达到上限的补偿价格;  $\xi^{\text{cut}}$  为用户对于可削减负荷的补偿敏感度, 其值越小, 用户对其越敏感;  $\rho_{\text{max}}^{\text{cut}}$  为可削减负荷的最大弹性系数,  $0 < \rho_{\text{max}}^{\text{cut}} < 1$ .

可削减负荷对用户的补偿费用  $C^{\text{cut}}$  为

$$C^{\text{cut}} = \sum_{t=0}^T C_{\text{price}}^{\text{cut}} P_t^{\text{cut}} \Delta T. \quad (13)$$

可平移负荷是指工作时长固定, 工作时段可整体平移的负荷, 应选择合适的时间平移以达到削峰填谷的效果. 其可平移区间可表示为

$$[t_{\text{sh}-}(C_{\text{price}}^{\text{sh}}), t_{\text{sh}+}(C_{\text{price}}^{\text{sh}})] = [t_{\text{sh}}^* - \rho^{\text{sh}}(C_{\text{price}}^{\text{sh}}) \cdot \Delta \bar{t}^{\text{sh}}, t_{\text{sh}}^* + \rho^{\text{sh}}(C_{\text{price}}^{\text{sh}}) \cdot \Delta \bar{t}^{\text{sh}}]. \quad (14)$$

其中:  $C_{\text{price}}^{\text{sh}}$  为单位功率负荷平移的补偿价格;  $t_{\text{sh}}^*$  为可平移负荷原始运行起始时段;  $\Delta \bar{t}^{\text{sh}}$  为可平移区间的最大扩展时段数;  $\rho^{\text{sh}}$  为可平移负荷的弹性扩展系数, 与补偿价格相关, 体现了可平移负荷的弹性. 可平移负荷弹性扩展系数可表示为

$$\rho^{\text{sh}} = \begin{cases} 0, & 0 \leq C_{\text{price}}^{\text{sh}} < C_{\text{price}}^{\text{sh}-}; \\ 1 - \xi^{\text{sh}} / (C_{\text{price}}^{\text{sh}} + \xi^{\text{sh}}), & C_{\text{price}}^{\text{sh}-} \leq C_{\text{price}}^{\text{sh}} < C_{\text{price}}^{\text{sh}+}; \\ 1, & C_{\text{price}}^{\text{sh}+} \leq C_{\text{price}}^{\text{sh}}. \end{cases} \quad (15)$$

这里:  $C_{\text{price}}^{\text{sh}-}$  为用户有意愿参加调度的最低补偿价格,  $C_{\text{price}}^{\text{sh}+}$  为可接受平移时段的扩展时间达到上限的补偿价格,  $\xi^{\text{sh}}$  为可平移负荷的补偿敏感度.

可平移负荷需要满足的连续运行时间约束为

$$\sum_{t=t_{\text{sh}}}^{t_{\text{sh}}+T_{\text{sh}}-1} z_t^{\text{sh}} = T_{\text{sh}}. \quad (16)$$

其中:  $t_{\text{sh}}$  为负荷平移后的起始时段;  $T_{\text{sh}}$  为可平移负荷持续时段数;  $z_t^{\text{sh}}$  为  $t$  时段是否发生平移的 0-1 变量, 若  $z_t^{\text{sh}} = 1$ , 则该负荷平移到了  $t$  时段.

可平移负荷用户的补偿费用  $C^{sh}$  为

$$C^{sh} = C_{price}^{sh} \sum_{t=t_{sh}}^{t_{sh}+T_{sh}-1} P_t^{sh} \Delta T, \quad (17)$$

其中  $P_t^{sh}$  为可平移负荷的功率。

## 2 基于 Seq2Seq 的电力系统日前调度方法

计及弹性资源的前日调度方法整体结构如图 1 所示。首先,对数据样本库中样本的输入信息和对应的输出计划进行数据预处理,得到训练样本。然后,

将样本批量输入训练网络并进行参数更新;当网络训练到一定程度时,将泛化性最好的网络参数赋值给决策网络;将待决策样本输入决策网络,得到调度计划。最后,考虑到深度决策网络在拟合标签值时存在拟合误差,可能会导致所得调度计划不能满足系统安全约束的问题,需要对神经网络的输出方案进行辅助决策修正,固定所得调度计划中机组的启停方案,以系统运行成本最低为目标对机组出力进行修正,最终得到一个安全、经济的调度计划。

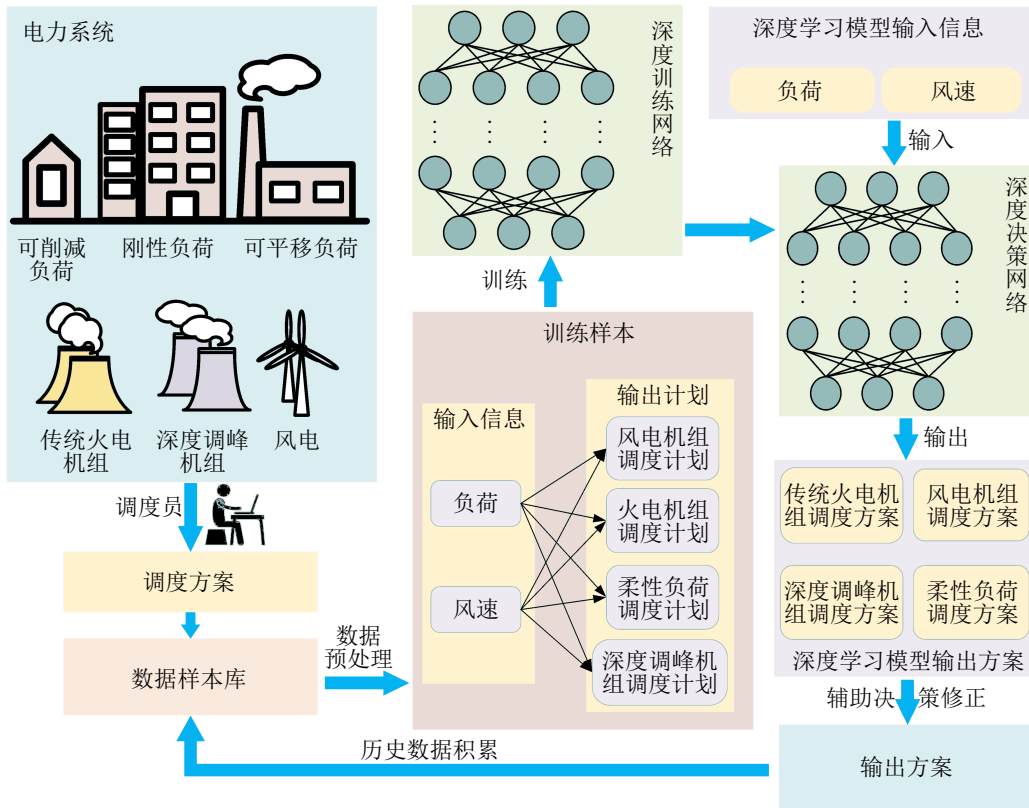


图1 基于 Conv-Seq2Seq 的日前调度方法

### 2.1 数据样本库数据预处理

数据样本库中存储的数据为历史负荷预测数据等输入信息和对应的最优调度计划。数据样本库中的输入序列  $\bar{X} = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_T)$ 。其中:  $t$ 时段输入  $\bar{x}_t = (P_t^{load}, P_t^{wind})^T$ ,  $T$ 为调度总时段数,  $P_t^{load}$  为负荷预测数据,  $P_t^{wind} = (P_{1,t}^{wind}, P_{2,t}^{wind}, \dots, P_{N_w,t}^{wind})^T$  为风电机组预测出力。对  $\bar{X}$  进行归一化处理,得到预处理后的输入序列  $X = (x_1, x_2, \dots, x_T)$ 。

本文中, Conv-Seq2Seq 模型使用监督学习的方式,采用均方误差为损失函数对决策网络进行训练,再利用训练好的决策网络对新数据进行预测,得到输出序列  $P^{out} = (P_1^{out}, P_2^{out}, \dots, P_T^{out})$ , 其中  $P_t^{out} = (P_t^{wind}, P_t^{rpr}, P_t^{dpr}, P_t^{lex})^T$  为  $t$ 时段风电机组、传统火电机组、深度调峰机组和柔性负荷的调度计划。

### 2.2 Conv-Seq2Seq 网络架构

#### 2.2.1 传统编码器-解码器架构

Seq2Seq 模型已成为基于递归神经网络的编码器-解码器架构的代名词<sup>[15]</sup>。其中:编码器用于分析输入的序列信息,解码器根据信息生成输出序列,其结构如图 2 所示。SOS 为序列开始的标志位。




图2 传统 Seq2Seq 模型示意图

编码器输入序列  $X$ , 利用第  $t$  步 GRU 的输入特征向量  $x_t$  和第  $t-1$  步的隐藏状态  $h_{t-1}^{en}$  计算第  $t$  步的隐藏状态  $h_t^{en}$ , 可表示为

$$z_t^{\text{en}} = \varphi(W_{\text{en}}^{(z)}x_t + U_{\text{en}}^{(z)}h_{t-1}^{\text{en}}), \quad (18)$$

$$r_t^{\text{en}} = \varphi(W_{\text{en}}^{(r)}x_t + U_{\text{en}}^{(r)}h_{t-1}^{\text{en}}), \quad (19)$$

$$\tilde{h}_t^{\text{en}} = \tanh(r_t^{\text{en}} \circ U_{\text{en}}h_{t-1}^{\text{en}} + W_{\text{en}}x_t), \quad (20)$$

$$h_t^{\text{en}} = (1 - z_t^{\text{en}}) \circ \tilde{h}_t^{\text{en}} + z_t^{\text{en}} \circ h_{t-1}^{\text{en}}. \quad (21)$$

其中:  $z_t^{\text{en}}$  和  $r_t^{\text{en}}$  分别为更新门和重置门,  $\tilde{h}_t^{\text{en}}$  为第  $t$  步输入  $x_t$  和第  $t-1$  步的隐藏状态  $h_{t-1}^{\text{en}}$  的汇总,  $\varphi$  为 Sigmoid 函数,  $W_{\text{en}}^{(z)}$ 、 $U_{\text{en}}^{(z)}$ 、 $W_{\text{en}}^{(r)}$ 、 $U_{\text{en}}^{(r)}$ 、 $U_{\text{en}}$ 、 $W_{\text{en}}$  为神经网络的参数,  $z_t^{\text{en}} \circ h_{t-1}^{\text{en}}$  表示  $z_t^{\text{en}}$  与  $h_{t-1}^{\text{en}}$  的复合关系. 解码器隐藏状态计算同理, 不再赘述.

将编码器最后一个隐藏状态  $h_T^{\text{en}}$  记为中间向量  $V$ . 解码器第  $t+1$  步的输出  $P_{t+1}^{\text{out}}$  可表示为

$$P_{t+1}^{\text{out}} = F_{\text{de}}(P_t^{\text{out}}, h_t^{\text{de}}). \quad (22)$$

其中:  $F_{\text{de}}$  表示解码器解码操作;  $h_t^{\text{de}}$  为第  $t$  步隐藏状态,  $h_0^{\text{de}} = V$ .

### 2.2.2 基于 Conv-Seq2Seq 的编码器-解码器架构

使用 CNN 作为编码器, 可同时提取输入序列在不同时段特征, 提高计算效率. 因此, 所提出方法使用多层 CNN 作为编码器, 低层次的卷积网络可提取邻近序列元素间的信息, 高层级的卷积网络可提取相邻较远序列元素的信息. 考虑到 CNN 结构不能有效挖掘时序信息, 引入位置编码体现输入序列元素间的时序性, 结合多层 CNN 捕捉其中复杂的时序依赖关系, 即对于输入序列  $X$  增加位置编码  $l_t$  来表示

元素在序列中的绝对位置, 得到综合输入  $E = (x_1 + l_1, x_2 + l_2, \dots, x_T + l_T)$ . 同时, 基于残差连接解决网络的退化问题, 提高网络的优化效率<sup>[17]</sup>.

多层卷积块具有相同的结构, 因此, 只对单层卷积块进行介绍. 单层卷积块主要包括卷积网络、门控线性单元激活函数和残差连接. 对于每个大小为  $k$  的卷积核, 其输入为嵌入在  $d$  维空间中的  $k$  个元素  $X^{\text{conv}} \in \mathbb{R}^{k \times d}$ , 可表示为

$$Y^{\text{conv}} = F_W^{\text{conv}}(X^{\text{conv}}) + b^{\text{conv}}. \quad (23)$$

其中: 卷积网络的参数  $W \in \mathbb{R}^{2d \times kd}$ ;  $b^{\text{conv}} \in \mathbb{R}^{2d}$ ;  $Y^{\text{conv}} = [A, B] \in \mathbb{R}^{2d}$ , 其输出的维度为输入的 2 倍.

使用门控线性单元作为激活函数, 引入残差连接得到一层卷积网络的输出, 其公式为

$$Y_{n,t}^{\text{conv}} = \Phi(F_{W_n}^{\text{conv}}(x_{n,t}^{\text{conv}}) + b_n^{\text{conv}}) + x_{n,t}^{\text{conv}}. \quad (24)$$

其中:  $\Phi$  为激活函数, 其输出的维度为  $Y^{\text{conv}}$  的一半;  $x_{n,t}^{\text{conv}}$  为第  $n$  层卷积网络第  $t$  次的输入.

基于 Conv-Seq2Seq 的编码器-解码器架构如图 3 所示. 编码器网络的输入为综合输入  $E$ . 经多层 CNN 的信息提取和全连接层的线性变换, 得到对应的中间向量  $V$ . 然后输入由 GRU 构成的解码器按照时间步得到每个时段的输出, 最终构成完整的输出序列以供调度计划参考. 该架构经过大量历史数据的训练后, 可构建出从新能源、负荷预测数据到调度计划的映射关系, 从而能够根据实际预测数据有效调控电力系统源荷双侧资源.

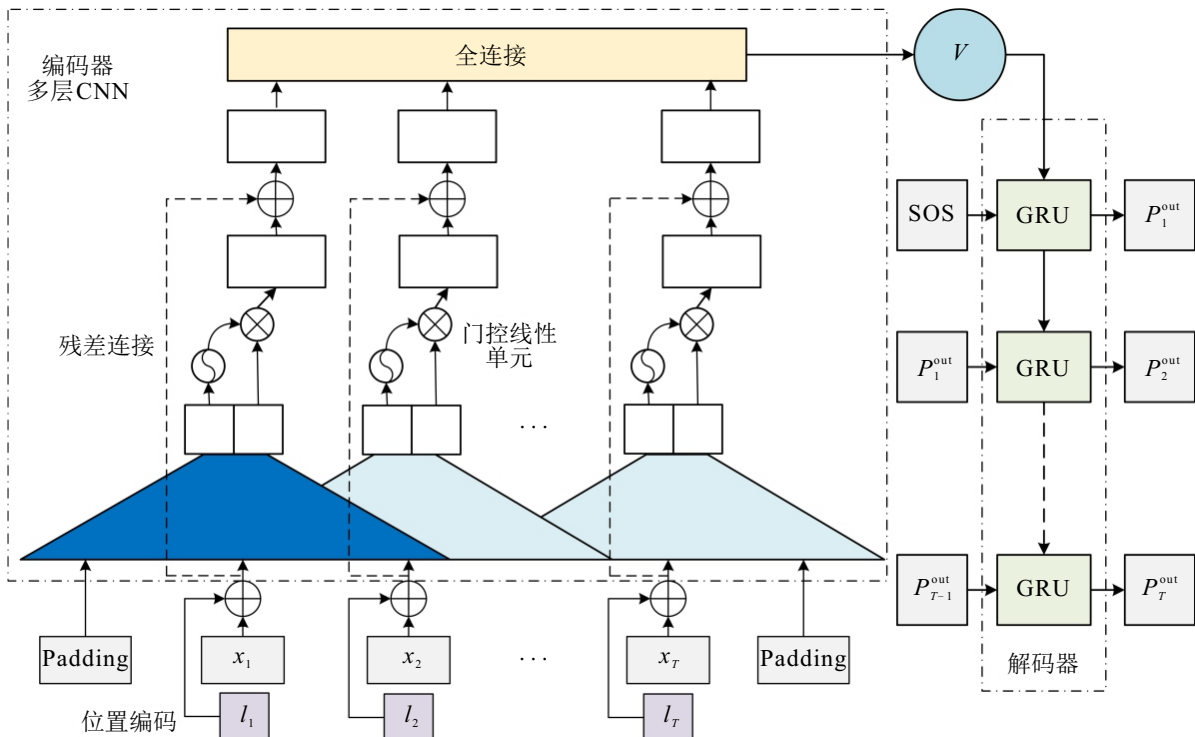


图3 Conv-Seq2Seq 网络结构

### 3 算例分析

为了验证所提出方法的有效性,采用改进的IEEE39节点系统为例进行分析计算.系统包含9台火电机组和1台风电机组(节点30处).其中:火电机组包含1台深度调峰机组(节点38处),火电机组装机总容量为6767MW,风电装机容量为1300MW,日最大负荷为6500MW.实验使用的计算资源的硬件条件为NVIDIA A10 GPU以及12核心的Intel(R)Xeon(R) Silver 4214R CPU.

本节设计3种方法进行对比实验,并对实验结果进行分析.

方法1:基于CNN网络的弹性模型决策方法,首先,采用3个大小不同的卷积核对输入序列进行特征提取,以提取不同相邻长度的序列元素信息;然后,使用最大化池化操作对提取的特征向量进行处理;最后,通过全连接层映射到对应的序列上,输出调度计划.该方法记为CNN方法.

方法2:基于GRU的编码器-解码器结构的弹性模型决策方法,采用传统的Seq2Seq模型,其编码器和解码器均为GRU网络.该方法记为GRU-S2S方法.

方法3:基于多层CNN的编码器-解码器结构的弹性模型决策方法,即编码器为CNN,解码器为GRU网络.该方法记为Conv-S2S方法.

#### 3.1 样本生成和参数设置

##### 3.1.1 决策模型映射样本的生成

负荷预测数据和风电功率预测数据来源于文献[12],共184组算例,每组算例涵盖一天24h的时间序列,相邻数据时间间隔为15min,即每组算例下单个样本序列共96个数据,共35328个样本数据.将所有算例随机划分为训练集、验证集和测试集.其中:验证集和测试集各包含35个算例,其余114个算例作为训练集.

对算例中的负荷和风电出力预测数据,利用优化器Gurobi求解,基于branch and cut算法得到各算例的最优调度计划,作为深度学习数据集中算例的标签值.图4为编号1训练样本负荷和风电出力预测数据所对应的机组组合方案,其中火电机组7和火电机组8在夜间负荷低谷时停机以提高风电的消纳.

对比分析有无弹性资源对电力系统运行的影响,结果如表1所示.

由表1可见,虽然考虑弹性资源会提升调度计划求解的复杂度,进而增加求解时间,但是弹性资源




图4 24 h 火电机组出力曲线

表1 有无弹性资源系统对比

	总成本/\$	弃风成本/\$	新能源消纳率/%	求解时间/s
无弹性	2705917.93	144514.56	96.35	751.68
有弹性	<b>2608155.50</b>	<b>28763.59</b>	<b>99.27</b>	1196.87

的使用可有效提高新能源消纳,降低系统运行总成本.

##### 3.1.2 参数设置

各方法网络结构组成如表2所示.批量训练数设定为64,学习率设定为0.0005,参数更新优化器为ADAM.使用Dropout方法防止网络过拟合.

表2 实验参数设置

方法	卷积核大小	卷积网络层数	编码器GRU网络层数	编码器GRU单元数量	解码器GRU单元数量
CNN	2、3、4	1	-	-	-
GRU-S2S	-	-	4	512	512
Conv-S2S	3	10	-	-	512

#### 3.2 本文方法仿真实验

首先,使用测试集从机组启停方案准确率方面分析深度决策网络的性能,如图5所示.由图5可见:Conv-S2S方法略优于GRU-S2S方法,CNN方法性能明显略差.

图6为对编号1测试样本中所有火电机组的调度结果.其他测试样本的调度结果近似,篇幅缘故未

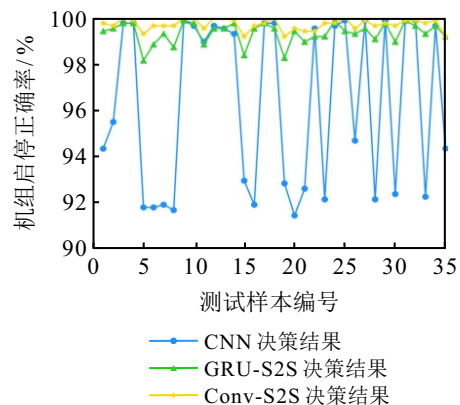


图5 机组启停方案预测准确率

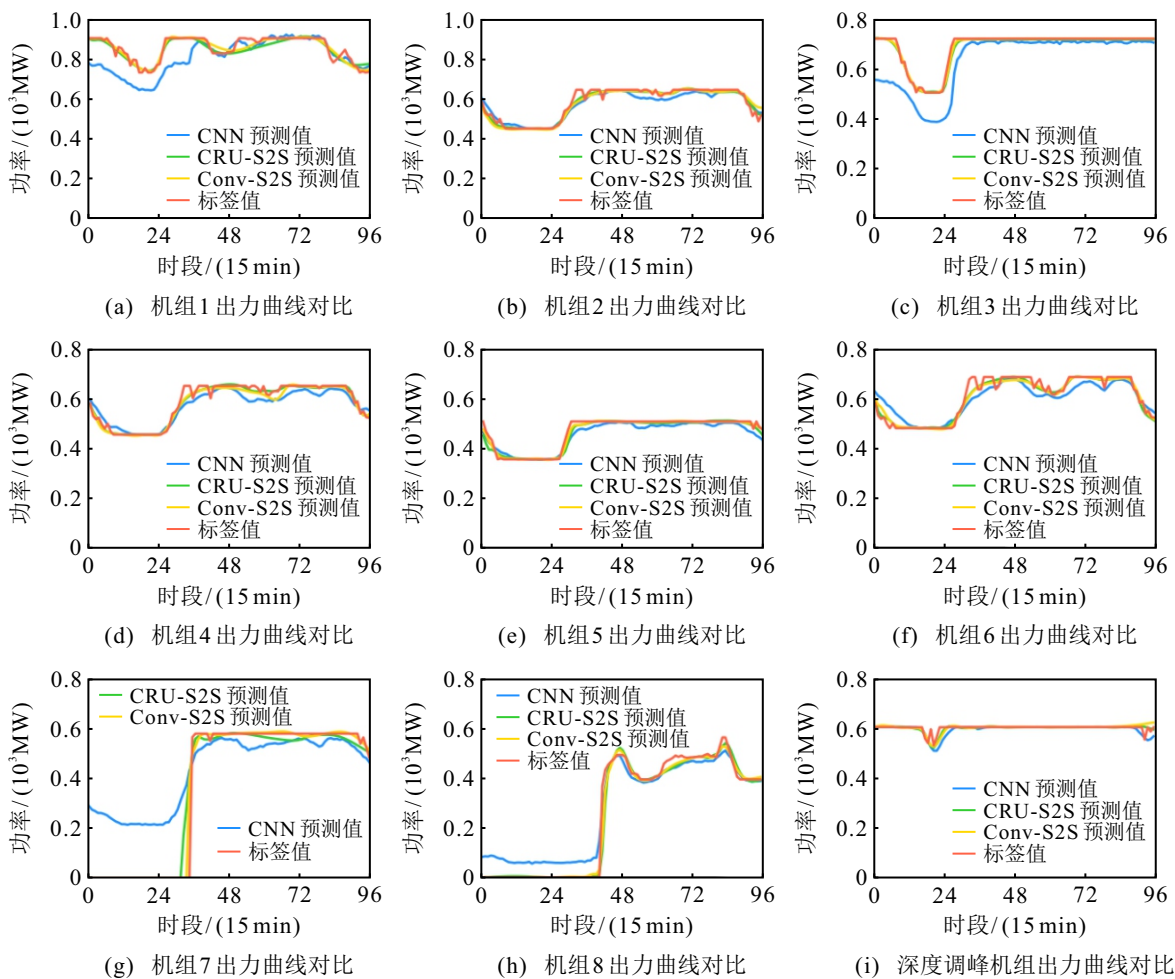


图6 火电机组计划曲线对比

进行展示. 由图6可见: CNN方法对于机组1、机组3、机组7和机组8以及深度调峰机组的深度调峰状态的曲线拟合具有较大的差异, 表明CNN网络具有一定提取信息的能力, 但是由于其结构简单、参数数量较少, 不能有效挖掘时序信息, 导致对于某些变化频繁的机组运行功率曲线难以拟合; 而其他两种深度学习方法对于不同情况下的机组运行功率曲线均具有较好的拟合效果, 特别是当机组7和机组8启停状态发生变化时, CNN方法在机组停止状态的拟合上存在较大的差异, 而GRU-S2S方法和Conv-S2S方法对其均能够进行较好的拟合, 较好的启停方案能够有效减少辅助决策修正的时间, 并保证方案的经济性.

图7和图8为编号1测试样本中的可削减负荷和可平移负荷的调度结果. 分析图7中可削减负荷的结果可以发现, 3种方法的拟合结果均存在一定的误差, 其中CNN方法在削减量低值处存在较为明显的误差, 出现此情况是因为可削减负荷在每个时段均可进行削减, 受到约束较少, 调整灵活, 导致可削减负荷削减量的曲线波动较为复杂. 分析图8的可平移负荷曲线可以发现, 3种方法均能够进行较好的

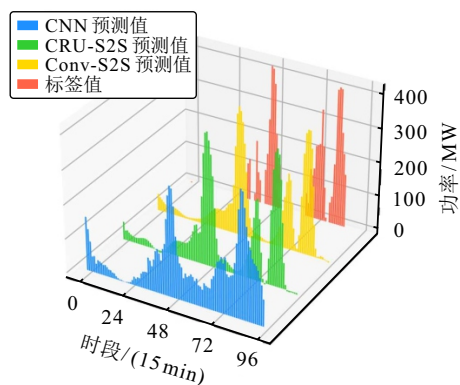


图7 可削减负荷削减量结果对比

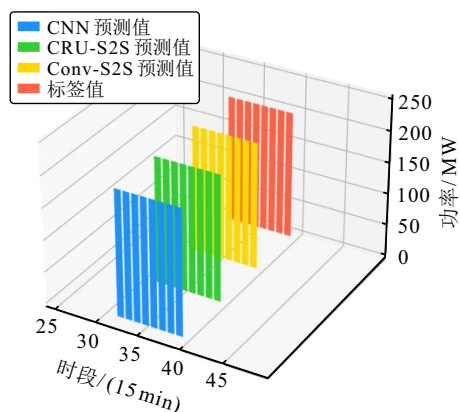


图8 可平移负荷结果对比

拟合,这是因为可平移负荷的曲线较为规则,学习难度较小。

### 3.2.1 两种 Seq2Seq 方法计算效率分析

在计算效率方面,两种方法的结构仅在编码器上存在差异,而解码器部分具有完全相同的结构和参数,故仿真分析时只考虑 100 次运行下编码器和前向传播的平均计算时间,结果如表 3 所示。由表 3 可见,Conv-S2S 方法的编码器虽然使用更多层的 CNN,但是可同时提取不同时段的信息,在训练和决策时均具有更高的效率。

表3 GRU-S2S 方法与 Conv-S2S 方法平均运行时间对比

方法	编码器平均运行时间/s	前向传播时间/s
GRU-S2S	0.0623	0.0834
Conv-S2S	<b>0.0485</b>	<b>0.0679</b>

综上所述,Conv-S2S 方法在测试集机组启停方案预测正确率和编码器的运行时间等方面,均优于 GRU-S2S 方法,验证了多层 CNN 结构可在保证性能的同时有效减少决策时间。

### 3.2.2 修正结果对比

考虑到深度学习方法在拟合标签值时存在一定的误差,为了保证调度计划满足系统安全约束,需要对网络输出的结果进行辅助决策修正。本节对 3 种深度学习方法采用辅助决策修正后的调度计划与 Gurobi 优化器直接求解的调度计划进行对比,展示算例为编号 1 测试样本。辅助决策修正的具体步骤为将深度学习模型输出结果中的机组启停方案保持不变,机组出力计划作为修正的初始值,以成本最低为目标函数,通过 Gurobi 优化器求解,最终输出满足安全约束的调度计划。而 Gurobi 直接求解方法利用 Gurobi 优化器求解原始调度问题,同时对机组启停和出力进行求解。另外,为了保证新能源消纳,4 种方法均将弃风成本设置足够大,只有无法得到可行解时,才考虑弃风。求解结果如表 4 所示。

表4 4 种方法求解结果对比

方法	弃风量	弃风成本外系统成本/\$	时间/s	新能源消纳率/%
CNN	1477.4	2753444.69	11.60	96.95
GRU-S2S	0	2672792.79	49.99	100
Conv-S2S	<b>0</b>	<b>2671819.20</b>	<b>35.95</b>	<b>100</b>
Gurobi直接求解	0	2671796.70	1196.87	100

分析表 4 结果,并结合图 6~图 8 可以发现:CNN 方法由于在机组运行功率曲线的拟合上存在较大的误差,只有通过弃风来得到可行解。虽然该方法具有最短的求解时间,但是产生了最高的系统运行成本,

所得日前调度计划质量较差。另外 3 种方法均无弃风量,其中 Conv-S2S 方法无论在系统运行成本还是求解时间上均优于 GRU-S2S 方法。通过对比两种 Seq2Seq 方法与 Gurobi 优化器直接求解的结果可以发现:虽然 Gurobi 直接求解的调度计划系统运行成本略优于 Conv-S2S 方法,但是会因为对机组启停方案进行寻优而消耗大量的时间;相比之下,Conv-S2S 方法虽然在辅助决策修正阶段消耗了一定的时间,但是整体效率仍然有显著提升。而日前计划在日内调度阶段还需要根据负荷与风电出力的预测误差进行调整,快速地求解可以有更多的时间来验证短期调度在预想故障集的可行性和修改风险调度点<sup>[13]</sup>。

## 4 结论

为了提高新型电力系统中新能源发电的消纳率,本文提出了一种计及源荷双侧弹性资源的前日调度方法,在传统 Seq2Seq 模型的基础上,引入了多层 CNN 作为编码器,并辅以位置编码和残差连接,给出一种基于 Conv-Seq2Seq 的电力系统日前调度方法。基于算例仿真得出如下结论。

1) 通过充分利用新型电力系统中源荷双侧弹性资源的调度潜力,基于 Conv-Seq2Seq 模型的前日调度方法可有效提高新能源发电消纳率。

2) 应用多层 CNN 作为 Seq2Seq 模型的编码器,使得编码器的信息提取可在不同时段同时展开,辅以位置编码体现序列元素的时序信息,加入了残差连接来保证 CNN 不发生网络退化,增强了信息提取能力。对比其他两种深度学习方法,所提出 Conv-Seq2Seq 方法在算例仿真中具有更快的训练和决策速度,所得调度方案具有更好的经济性。

3) 所提出 Conv-Seq2Seq 方法在不同典型算例下的计算效率能够满足日前调度的时效性要求,能够保证最终结果达到理想效果,适应性较强。

此外,目前的前日调度问题尚未考虑市场机制,后续的研究将围绕如何结合市场出清对各类机组和弹性资源进行调度展开。

## 参考文献 (References)

- [1] 曹知奥,汪晋宽,韩英华,等. 基于交叉-变异人工蜂群算法的微网优化调度[J]. 控制与决策, 2020, 35(9): 2059-2069.  
(Cao Z A, Wang J K, Han Y H, et al. Crossover-mutation based artificial bee colony algorithm for optimal scheduling of microgrid[J]. Control and Decision, 2020, 35(9): 2059-2069.)
- [2] 李鹏,李凤婷,宋新甫,等. 考虑柔性负荷的新能源接入系统旋转备用优化[J]. 电网技术, 2021, 45(4): 1288-1294.

- (Li P, Li F T, Song X F, et al. Considering the flexible load new energy access system optimization for spinning reserve[J]. *Power System Technology*, 2021, 45(4): 1288-1294.)
- [3] Mohandes B, Moursi M S E, Hatziaargyriou N D, et al. Incentive based demand response program for power system flexibility enhancement[J]. *IEEE Transactions on Smart Grid*, 2021, 12(3): 2212-2223.
- [4] Wang J J, Zhang S, Huo J K, et al. Dispatch optimization of thermal power unit flexibility transformation under the deep peak shaving demand based on invasive weed optimization[J]. *Journal of Cleaner Production*, 2021, 315: 128047.
- [5] Yang Y P, Qin C, Zeng Y, et al. Interval optimization-based unit commitment for deep peak regulation of thermal units[J]. *Energies*, 2019, 12(5): 922.
- [6] 何小宇, 张粒子, 谢国辉. 改进的拉格朗日松弛法求解机组组合问题[J]. *电力系统保护与控制*, 2010, 38(17): 16-21.  
(He X Y, Zhang L Z, Xie G H. Unit commitment using an improved Lagrangian relaxation method[J]. *Power System Protection and Control*, 2010, 38(17): 16-21.)
- [7] Putz D, Schwabeneder D, Auer H, et al. A comparison between mixed-integer linear programming and dynamic programming with state prediction as novelty for solving unit commitment[J]. *International Journal of Electrical Power & Energy Systems*, 2021, 125: 106426.
- [8] Zhao C Y, Guan Y P. Unified stochastic and robust unit commitment[J]. *IEEE Transactions on Power Systems*, 2013, 28(3): 3353-3361.
- [9] Tong W Y, Liu D, Hu Z B, et al. Hybridizing genetic algorithm with grey prediction evolution algorithm for solving unit commitment problem[J]. *Applied Intelligence*, 2023, 53(17): 19922-19939.
- [10] Tang H, Lv K, Bak-Jensen B, et al. Deep neural network-based hierarchical learning method for dispatch control of multi-regional power grid[J]. *Neural Computing and Applications*, 2022, 34(7): 5063-5079.
- [11] 季颖, 王建辉. 基于深度强化学习的微电网在线优化调度[J]. *控制与决策*, 2022, 37(7): 1675-1684.  
(Ji Y, Wang J H. Online optimal scheduling of a microgrid based on deep reinforcement learning[J]. *Control and Decision*, 2022, 37(7): 1675-1684.)
- [12] 杨楠, 贾俊杰, 邢超, 等. 基于 E-Seq2Seq 技术的数据驱动型机组组合智能决策方法[J]. *中国电机工程学报*, 2020, 40(23): 7587-7599.  
(Yang N, Jia J J, Xing C, et al. Data-driven intelligent decision-making method for unit commitment based on E-Seq2Seq technology[J]. *Proceedings of the CSEE*, 2020, 40(23): 7587-7599.)
- [13] Guan J Y, Tang H, Wang J Y, et al. A GAN-based fully model-free learning method for short-term scheduling of large power system[J]. *IEEE Transactions on Power Systems*, 2022, 37(4): 2655-2665.
- [14] 张智刚, 夏清. 智能电网调度发电计划体系架构及关键技术[J]. *电网技术*, 2009, 33(20): 1-8.  
(Zhang Z G, Xia Q. Architecture and key technologies for generation scheduling of smart grid[J]. *Power System Technology*, 2009, 33(20): 1-8.)
- [15] Gehring J, Auli M, Grangier D, et al. Convolutional sequence to sequence learning[J]. *Proceedings of the 34th International Conference on Machine Learning*, 2017, 70: 1243-1252.
- [16] 杨易达, 高红均, 刘挺坚, 等. 考虑 CCER 收益共享激励火电机组深度调峰的电力系统低碳调度[J]. *电力自动化设备*, 2024, 44(9): 121-128.  
(Yang Y D, Gao H J, Liu T J, et al. Low carbon dispatch of power system considering CCER revenue sharing incentive for deep peak-shaving of thermal power units[J]. *Electric Power Automation Equipment*, 2024, 44(9): 121-128.)
- [17] 王寅同, 郑豪, 常合友, 等. 基于残差注意网络的端到端手写文本识别方法[J]. *控制与决策*, 2023, 38(7): 1825-1834.  
(Wang Y T, Zheng H, Chang H Y, et al. An end-to-end handwritten text recognition method using residual attention networks[J]. *Control and Decision*, 2023, 38(7): 1825-1834.)

## 作者简介

谭琦 (1985-), 男, 讲师, 博士, 主要研究方向为深度学习、深度强化学习、电力系统优化调度, E-mail: [tanqi@hfut.edu.cn](mailto:tanqi@hfut.edu.cn);

孙晨皓 (1998-), 男, 硕士生, 主要研究方向为深度学习在电力系统优化调度中的应用, E-mail: [2020110442@mail.hfut.edu.cn](mailto:2020110442@mail.hfut.edu.cn);

唐昊 (1972-), 男, 教授, 博士, 博士生导师, 主要研究方向为离散事件动态系统、强化学习、深度强化学习, E-mail: [htang@hfut.edu.cn](mailto:htang@hfut.edu.cn);

王正风 (1976-), 男, 高级工程师, 博士, 主要研究方向为电力系统优化调度、电力市场, E-mail: [wang-zf0016@ah.sgcc.com.cn](mailto:wang-zf0016@ah.sgcc.com.cn);

方道宏 (1997-), 男, 博士生, 主要研究方向为电力系统需求侧管理, E-mail: [fangdaohong@mail.hfut.edu.cn](mailto:fangdaohong@mail.hfut.edu.cn).