

doi: 10.7690/bgzd.2025.09.011

基于多时间尺度分析的电网调控行为全生命周期管理技术

陈志伟¹, 李 谦¹, 蓝 天¹, 温立君¹, 王振宇², 袁树森²

(1. 广东电网有限责任公司电力调度控制中心, 广州 510220;

2. 南京南瑞信息通信科技有限公司, 南京 211100)

摘要: 为实现经济成本最小化的电网调控策略的精确控制, 提出一种基于多时间尺度分析的全生命周期管理技术。通过整合短期、中期和长期调控行为数据, 构建行为预测模型与优化框架。对构建的模型和调控策略进行仿真实验与算例分析, 并对其有效性进行验证。该预测模型对光伏和风电功率预测的平均准确率分别为 97.53% 和 96.27%; 系统日运行总成本为 1 386.32 元; 电网调控策略能适应负荷端的需求变化合理分配功率; 3 个调控阶段的预测相对误差逐级减小, 实时调控阶段最小相对误差为 0.26%。结果表明: 基于全生命周期管理的多时间尺度调控技术能够显著提升调控行为的规划性与精准性。该技术的应用不仅能提升电网调控能力, 而且可为军工领域的电力保障提供稳定支持, 确保关键设施的能源供应安全。

关键词: 多时间尺度; 电网调控; 全生命周期; 优化策略; 功率预测

中图分类号: TM73 **文献标志码:** A

Life Cycle Management Technology of Power Grid Regulation Behavior Based on Multi-time Scale Analysis

Chen Zhiwei¹, Li Qian¹, Lan Tian¹, Wen Lijun¹, Wang Zhenyu², Yuan Shusen²

(1. Power Dispatch Control Center of Guangdong Power Grid Co., Ltd., Guangzhou 510220, China;

2. Nanjing NARI Information and Communication Technology Co., Ltd., Nanjing 211100, China)

Abstract: In order to realize the precise control of power grid regulation strategy with minimum economic cost, a life cycle management technology based on multi-time scale analysis is proposed. By integrating short-term, medium-term and long-term regulatory behavior data, a behavioral prediction model and optimization framework are constructed. Simulation experiments and example analysis are carried out to verify the effectiveness of the proposed model and control strategy. The average accuracy of PV and wind power prediction is 97.53% and 96.27% respectively, the total daily operation cost of the system is 1 386.32 yuan, and the grid control strategy can adapt to the load demand changes and allocate power reasonably; The relative prediction errors of the three regulation stages decrease gradually, and the minimum relative error of the real-time regulation stage is 0.26%. The results show that the multi-time scale control technology based on life cycle management can significantly improve the planning and accuracy of the control behavior, and the application of this technology can not only improve the control ability of the power grid, but also provide stable support for the power security in the field of military industry to ensure the energy supply security of key facilities.

Keywords: multiple time scales; power grid regulation and control; full life cycle; optimization strategy; power forecasting

0 引言

随着全球经济的快速发展和能源需求的增长, 电力系统的稳定性和可靠性变得尤为重要, 特别是在海岛和高原等特殊军工领域环境中, 新能源电网需要在确保高效、安全运行的同时, 应对极端气候、孤网运行及应急需求等特殊挑战。电网调控技术的发展是确保电力系统高效、安全运行的关键因素^[1]。传统的电网调控方法主要基于稳态分析, 对电网进行静态监控与管理。由于可再生能源的大量接入、分布式电源的普及以及用户侧互动模式的变化, 电

力系统的动态特性日益复杂, 需要更加灵活与精确的调控策略来保障关键设施的能源供应, 单一时间尺度下的调控策略已难以满足当前的需求^[2]。多时间尺度分析作为一种新兴的技术手段, 通过综合考虑从不同时间尺度上的动态行为, 为电网调控提供更加全面和精准的支持^[3]。全生命周期管理是一种涵盖系统整个生命周期的综合性的管理策略, 目的是实现资源的最大化利用和运行成本最小化^[4]。该研究所提出的多时间尺度调控策略不仅可以显著提升电力系统的调度精度和稳定性, 而且可应用于军工领域, 保障军用设施在特殊环境下的电力供应和

收稿日期: 2024-09-20; 修回日期: 2024-10-28

基金项目: 中国南方电网有限责任公司信息化项目 (036000HK23120003)

第一作者: 陈志伟 (1986—), 男, 宁夏人, 硕士。

应急响应能力, 确保关键任务的顺利进行。为了提高对电网系统功率预测的准确度, 合理制定有效的调控方案, 研究通过建立多时间尺度调控策略优化框架对系统功率进行准确预测, 并结合全生命周期理论, 在进行准确的能源调控的同时实现电网系统的低成本运行。

研究的创新性在于根据各算法的特点将其构建为预测可再生能源功率的组合模型, 提高电网系统调度的准确性; 基于全生命周期理论构建系统经济最小化模型, 使得系统能以较低成本持续稳定运行; 通过日前、日内滚动优化、实时控制 3 阶段的调控策略实现电网系统的准确调控。

多时间尺度分析能捕捉同一变量在不同时间尺度上的特征, 以预测复杂系统的行为。Long 等^[5]为了量化新能源对电网的影响, 提出了多尺度评价体系, 包括输出、电量、调峰及灵活性需求指数。结果表明, 该系统能有效评估不同时间尺度下区域新能源影响, 并验证了其工程实用性。章雪萌等^[6]为了应对分布式能源的不确定性, 提出了虚拟电厂多阶段时间尺度经济调度方案。结果表明, 通过模糊优化和实时调度策略, 能降低运行成本并提高电网稳定性和经济性。赵心怡等^[7]为了减少高比例新能源接入电网带来的波动与接纳不足, 建立了多时间尺度协调调度模型。结果表明, 该模型有助于逐步修正发电计划, 增强系统接纳能力。

全生命周期内理论为优化系统的环境绩效提供了框架, 使得决策更加全面和长远。王振等^[8]针对建筑能耗增加的问题, 研究通过生命周期成本分析优化建筑围护结构, 以降低能源需求。结果显示, 岩棉保温墙比聚苯乙烯保温墙节能 17%。Wu 等^[9]为评估不同材料对抗海桥墩非均匀腐蚀的影响, 改进了基于生命周期成本的设计优化程序。结果表明, 选择的材料能确保桥梁长期性能同时具有较高的经济性。

综上所述, 当前对电网调控策略的研究中仍存在时间尺度整合度有限、缺乏动态反馈机制等问题。笔者通过建立多时间尺度的策略优化框架, 并结合全生命周期理论实现电网系统调控的准确性和经济性。

1 相关技术和方法

正运行成本是电网调控系统能否长期稳定工作的基础条件, 为了实现电网系统运行成本的最小化, 基于全生命周期理论对电网调控的综合经济成本进

行建模^[10]。以成本控制为目标构建的经济模型, 如式(1)所示:

$$\min F = \sum_{t=1}^{T_1} (F_{PV,t} + F_{WT,t} + F_{BES,t})。 \quad (1)$$

式中: F 为电网系统日均成本; $F_{WT,t}$ 、 $F_{PV,t}$ 和 $F_{BES,t}$ 分别光伏、风电和储能系统在 t 时刻的单周期成本; T_1 为全生命周期。由于初始投资成本、运行管理费用与可再生能源系统的发电功率成正比, 用日均成本代替初始投资成本, 对可再生能源系统单周期成本的计算如式(2)所示^[11]:

$$\left. \begin{aligned} F_{RE,t}^{\text{set}} &= \frac{C_{RE}^{\text{set}}}{8760} \times \frac{r(1+r)^{L_{RE}}}{(1+r)^{L_{RE}} - 1} \times \frac{P_{RE,t}^{\text{cl}}}{\eta_{RE}} \times \frac{\Delta t_1}{60} \\ F_{RE,t}^{\text{on}} &= C_{RE}^{\text{on}} \times \frac{P_{RE,t}^{\text{cl}}}{\eta_{RE}} \times \frac{\Delta t_1}{60} \end{aligned} \right\}。 \quad (2)$$

式中: $F_{RE,t}^{\text{set}}$ 、 $F_{RE,t}^{\text{on}}$ 分别为可再生能源系统在 t 时刻单周期的初始投资与运行管理成本; C_{RE}^{set} 、 C_{RE}^{on} 分别为其在全生命周期的单位容量初始投资与单位发电量的运行费用; L_{RE} 为设备最大使用年限; $P_{RE,t}^{\text{cl}}$ 为日前 L_{RE} 调控下系统的实时输出功率; Δt_1 为单周期的时间长度; η_{RE} 为系统输出功率; r 为年利率。储能系统的成本由电池荷电状态 (state of charge, SOC) 惩罚成本和初始投资费用组成, 储能系统单周期成本的计算如式(3)所示:

$$\left. \begin{aligned} F_{BES,t}^{\text{set}} &= \sum_{i=1}^2 \left(\frac{N_{BES,i} C_{BES,i}^{\text{set}}}{8760} \frac{r(1+r)^{L_{BES,i}}}{(1+r)^{L_{BES,i}} - 1} \left| P_{bat,t,i}^{\text{cl}} \right| \frac{\Delta t_1}{60} \right) \\ F_{BES,t}^{\text{soc}} &= \sum_{i=1}^2 N_{BES,i} \gamma_i \left[\left(\text{SOC}_{t,i} - \text{SOC}_{\text{pnsmin},i} \right)^2 + \left(\text{SOC}_{t,i} - \text{SOC}_{\text{pnsmax},i} \right)^2 \right] \end{aligned} \right\}。 \quad (3)$$

式中: $F_{BES,t}^{\text{set}}$ 、 $F_{BES,t}^{\text{soc}}$ 分别为储能系统在 t 时刻单周期的初始投资与 SOC 惩罚成本; $N_{BES,i}$ 为储能 VF 源和 PQ 源的数量; $C_{BES,i}^{\text{set}}$ 为全生命周期内第 i 类电池单位容量的初始投资费用; $L_{BES,i}$ 为第 i 类储能设备的最大使用年限; $P_{bat,t,i}^{\text{cl}}$ 、 γ_i 分别为日前调控中第 i 类电池的充放电功率和惩罚因子; $\text{SOC}_{t,i}$ 为第 i 类电池在 t 时刻的电量; $\text{SOC}_{\text{pnsmin},i}$ 、 $\text{SOC}_{\text{pnsmax},i}$ 分别为第 i 类电池电量的下限与上限。由于可再生能源的发电量受多种因素影响, 具有较强的随机性和间歇性, 这使得电网的负荷预测和调度变得更加困难。为了提高系统输出功率预测的准确度, 基于卷积神

神经网络(convolutional neural network, CNN)、双向门控循环单元(bidirectional gated recurrent unit,

BIGRU)和 Attention 机制, 构建短期光伏功率预测模型, 模型结构如图 1 所示。




图 1 光伏发电短期功率预测模型的构建

由图 1 可知: CNN 接收输入的历史光伏功率数据, 通过卷积层进行数据特征的提取和相关性的捕捉; 池化层对特征进行池化操作, 降低特征维度, 达到提高学习效率的目的; BIGRU 能够同时从前向和后向处理时间序列数据, 提高特征提取的准确性; Attention 机制计算注意力权重, 使模型能聚焦于特征信息; 全连接层将特征进行全局整合, 并映射到样本标记空间^[12]。预测流程如图 2 所示。




图 2 光伏发电功率短期预测模式流程

由图 2 可知: 模型将数据进行预处理后将其划分为不同的数据集, 设置初始参数以提高模型训练速度和预测精度; 将训练集用于模型训练, 计算模型输出结果的损失值; 通过 Adam 加快算法收敛; 训练完成后, 判断损失值是否达到目标要求, 若满足要求则输出预测结果, 否则继续进行迭代训练。由于原始数据中存在因外部因素影响而产生的异常数据, 通过简单统计量分析法对数据的偏差率进行比较, 偏差率的计算如式(4)所示^[13]:

$$\rho(i, t) = |x(i, t) - E(t)| / \sigma(t). \quad (4)$$

式中: $x(i, t)$ 为第 i 日 t 时刻的数据; $\rho(i, t)$ 为数据偏差率; $E(t)$ 、 $\sigma(t)$ 分别为样本均值和标准差。若某数据点偏差率大于设定阈值, 则利用线性插值法对该

数据点进行替换^[14]。为了提高风电功率的预测精度, 研究基于变分模态分解(variational mode decomposition, VMD)、CNN-GRU 构建短期风电功率预测模型, 预测流程如图 3 所示。




图 3 短期风电功率预测模型流程

由图 3 可知: 在该模型中, 利用麻雀搜索算法优化 VMD 参数, VMD 将原始数据序列分解为特征不同的多个子序列, 并采用 CNN-GRU 模型进行预测, CNN 擅长提取数据中的局部特征, 而 GRU 能够捕捉时间序列中的长期依赖关系。在预测流程中, 每 10 min 记录一次原始风电功率和相关气象信息, 并对异常和缺失的数据进行处理; 将风速和风向作为气象特征, 纳入预测模型的考虑范围并对其进行分析; 利用 VMD 将原始数据序列分解为多个子序列; 对各子序列建立基于 GRU-CNN 的预测模型, 同时利用气象信息训练模型; 将各子序列的预测结果进行叠加, 得到总的预测功率。

2 基于多时间尺度的电网调控策略

笔者根据上述预测方法和成本最低目标函数制定电网调控策略。由于电网中的可再生能源与负荷的预测准确率会随时间尺度的缩短而提高, 笔者通过不断缩短调控周期, 对预测误差进行逐级修正^[15]。构建的多时间尺度优化调度框架如图 4 所示。




图4 电网多时间尺度调度框架

由图4可知：模型对日前的各项功率进行短期




图5 日内滚动优化控制策略原理

由图5可知：模型根据 k 时刻的实时数据和超短期预测数据，对未来时段的系统变化进行预测，并根据目标函数求出各时段内最佳的调控方案序列；将 $k+1$ 时刻的方案发送到被控对象；实时调控阶段执行 $k+1$ 时刻的方案，更新 $k+1$ 时刻的状态，并不断循环执行上述步骤。预测模型中各变量的关系如式(5)所示：

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{A}\mathbf{x}(k) + \mathbf{B}\Delta\mathbf{u}(k) + \mathbf{D}\Delta\mathbf{v}(k) \\ \mathbf{y}(k) = \mathbf{C}\mathbf{x}(k) \end{cases} \quad (5)$$

式中： $\mathbf{A}$ 、 $\mathbf{B}$ 、 $\mathbf{C}$ 、 $\mathbf{D}$ 分别为各变量的系数矩阵； $\mathbf{x}(k)$ 、 $\mathbf{x}(k+1)$ 、 $\mathbf{y}(k)$ 分别为 k 、 $k+1$ 时刻的系统状态和输出变量； $\Delta\mathbf{u}(k)$ 、 $\Delta\mathbf{v}(k)$ 分别为 k 时刻的控制变量和扰动变量。预测模型对输出变量和状态变量的预测如式(6)所示：

$$\begin{cases} \mathbf{Y}(k) = [\mathbf{y}(k+1|k), \mathbf{y}(k+2|k), \dots, \mathbf{y}(k+m|k)] \\ \mathbf{X}(k) = [\mathbf{x}(k+1|k), \mathbf{x}(k+2|k), \dots, \mathbf{x}(k+m|k)] \end{cases} \quad (6)$$

式中 $\mathbf{X}(k)$ 、 $\mathbf{Y}(k)$ 分别为 $[k, k+m]$ 时域内的输出和状态变量。由于在滚动优化中按照日前优化方案进行电网调度时存在跟踪偏差，为了矫正偏差，储能系统会对充放电功率进行增减。跟踪偏差带的范围如式

预测，同时考虑电价及系统最低运行成本，对柔性负荷和联络线进行调控；制定次日柔性负荷用电和并网计划；在日内调控中，根据前一日的计划对电网进行控制。日内调控阶段由滚动优化调控与实时调控部分构成。为了进一步降低短期预测的误差，笔者将滚动优化中的调控周期设置为4 min，对1 h内的各项功率进行超短期预测，滚动优化储能系统状态与跟踪偏差，同时制定优化后的联络线方案^[16]。在实时调控中，通过实时调控策略对储能进行分配，调控周期设置为1 min，实时反馈调控策略执行后的电网信息，通过跟踪不同时间尺度下的电网方案实现调控的准确性和经济性。在滚动优化中，根据储能系统的负荷状态，对日前方案进行滚动调整。日内滚动优化控制策略原理如图5所示。

(7)所示：

$$\begin{cases} P_{G,up}(k) = (1+\alpha)P_{G,plan}(k) \\ P_{G,down}(k) = (1-\alpha)P_{G,plan}(k) \end{cases} \quad (7)$$

式中： $P_{G,up}(k)$ 、 $P_{G,down}(k)$ 分别为跟踪偏差带的上限和下限； α 为调整系数，用于改变跟踪偏差带的宽度。为了满足日前优化调度方案，并对储能SOC进行优化，笔者利用滚动优化模型在跟踪偏差带中确定最佳取值。考虑到联络线执行日前方案的平均偏差和储能系统的电量值的平均偏差，研究确立的目标函数如式(8)所示：

$$\min J = Q \cdot \sum_k^{k+m} [P_G(k) - P_{G,plan}(k)]^2 + R \cdot \sum_k^{k+m} [\text{SOC}_{DB}(k) - \text{SOC}_{ref}]^2 \quad (8)$$

式中： J 为平均偏差； Q 为跟踪偏差的权重系数； $P_G(k)$ 、 $P_{G,plan}(k)$ 分别为 k 时刻的联络线功率和日前计划功率； R 为储能电量值优化的权重系数； $\text{SOC}_{DB}(k)$ 、 SOC_{ref} 分别为 k 时刻储能系统的实际和参考电量值。滚动优化模型的约束条件如式(9)所示：

$$\left. \begin{aligned} P_G(k) &= P_{\text{LOAD}}(k) - P_{\text{RE}}(k) - P_{\text{DB}}(k) - P_{\text{EB}}(k) \\ P_{G, \text{down}}(k) &\leq P_G(k) \leq P_{G, \text{up}}(k) \\ P_{\text{DB}, \text{min}}(k) &\leq P_{\text{DB}}(k) \leq P_{\text{DB}, \text{max}}(k) \\ \text{SOC}_{\text{DB}, \text{min}}(k) &\leq \text{SOC}_{\text{DB}}(k) \leq \text{SOC}_{\text{DB}, \text{max}}(k) \end{aligned} \right\} \quad (9)$$

式中： $P_{\text{LOAD}}(k)$ 、 $P_{\text{RE}}(k)$ 、 $P_{\text{DB}}(k)$ 、 $P_{\text{EB}}(k)$ 分别为 k 时刻的负荷、可再生能源发电、储能系统和用户端的充放电功率； $P_{\text{DB}, \text{min}}(k)$ 、 $P_{\text{DB}, \text{max}}(k)$ 分别为 k 时刻储能系统功率的最小值和最大值； $\text{SOC}_{\text{DB}, \text{min}}(k)$ 、 $\text{SOC}_{\text{DB}, \text{max}}(k)$ 分别为 k 时刻的储能系统的最小和最大电量值。利用粒子群优化算法对目标函数进行求解，并通过该模型预测可得 $Y(k)$ 的最优值，将 $Y(k)$ 中首个时刻的联络线功率作为实时调控阶段的目标功率，在下个周期重复以上步骤，实现对储能的优化^[17]。储能系统根据反馈信息调整下一时刻系统的实际状态，模型的反馈校正如式(10)所示：

$$x(k+1|k) = x_{\text{real}}(k+1) \quad (10)$$

式中 $x_{\text{real}}(k+1)$ 为 $k+1$ 监测系统的实时反馈状态。反馈校正将预测的状态替换为实时状态，实现对实时调控阶段的精确控制。为了提高实时调控阶段对滚动优化阶段发出的调控计划的跟踪效果，将实时调控中的时间尺度周期设置为 1 min，对储能系统的功率进行分配，实时控制中的储能系统需输出的功率如式(11)所示：

$$P_{\text{DB}}^*(i) = P_{\text{LOAD}}^*(i) - P_{\text{RE}}^*(i) - P_{G, \text{ref}}(k) - P_{\text{EB}}(i) \quad (11)$$

式中： $P_{\text{DB}}^*(i)$ 、 $P_{\text{LOAD}}^*(i)$ 、 $P_{\text{RE}}^*(i)$ 分别为 i 时刻储能系统、可再生能源和负荷的实时功率； $P_{G, \text{ref}}(k)$ 为上一阶段提供的联络线参考功率； $P_{\text{EB}}(i)$ 为用户端的实时功率。日内优化调度工作的整体策略如图 6 所示。




图 6 日内优化调度策略

3 仿真实验

3.1 功率预测模型性能验证

为了验证研究提出的可再生能源输出功率预测

模型的有效性，将某光伏电站和风力电站 2023 年 1 月至 2023 年 10 月的历史数据作为训练集，将 2023 年 11 月和 12 月的数据分别作为验证集和测试集。将优化后的模型与其他模型进行仿真试验，并对模型的性能进行评估。实验采用的台式电脑的中央处理器为 Intel Core i5-10700K 设备 CPU Intel Core i5-10700K，显卡 NVIDIA GeForce RTX 3060 8 GB，存储装置 SSD 1TB NVMe，网络接口 Gigabit Ethernet，内存存储器 16 GB DDR4。软件环境为 Matlab R2023a 操作系统 Windows 10 Professional 64-bit，程序设计语言 Python 3.5，程序设计环境 Matlab R2023a，模拟和测试工具 Jupyter Notebook，深度学习框架 Keras2.3.1。

将各模型用于光伏发电功率的预测，预测结果如图 7 所示。




图 7 多云天气下光伏输出功率预测结果

由图 7 可知：雨天天气相比多云天气，光伏系统输出功率发生较大波动，本文中模型在 2 种复杂气候条件下的预测曲线能较好地拟合真实输出功率曲线。通过对比各模型的平均绝对误差和均方根误差，本文中模型的平均绝对误差比 CNN-BIGRU、GRU、LSTM、CNN 分别降低了 0.396 2、0.606 7、0.837 5 和 1.168 6，预测的平均准确率为 97.53%。将构建的风电预测模型和其他模型进行对比，预测结果如图 8 所示。

由图 8(a)可知：笔者提出的模型在不同风速条件下的预测结果与真实结果更为接近，曲线更为平

滑，波动更小。在图 8(b)中，本文中模型在 10:30 与 13:30 左右的波峰位置的预测曲线能较好地贴合真实曲线，而其余模型相较于真实值均有较大差距。本文中模型的平均绝对误差比 CNN-BIGRU、GRU、LSTM、CNN 分别降低了 0.415 1、0.627 8、0.857 7 和 1.251 4，预测的平均准确率为 96.27%。




图 8 风电出力预测结果

3.2 调控策略算例分析

为了验证研究建立的基于全生命周期理论的经济模型在调控策略中的有效性，利用 IEEE-30 节点系统进行算例仿真，并将一天内的各项成本以及惩罚费用进行统计，结果如图 9 所示。




图 9 各种经济成本累积情况

由图 9 可知：当日系统运行总成本为 1 386.32 元，

其中光伏系统累计发电量为 5 123.65 kW/h，运行成本为 413.42 元；风电系统累计发电量为 4 296.36 kW/h，运行成本为 448.76 元；储能 PQ 源和 VF 源的当日运行成本和 SOC 惩罚均低于 150 元，储能 VF 源在 SOC>0.5 的荷电状态下运行了当日时间的 52.11%，储能 PQ 源在 SOC>0.5 的荷电状态下运行了当日时间的 43.57%，惩罚费用分别为 16.37 元和 49.64 元。提出的电网调控策略的调度方案如图 10 所示。




图 10 多时间尺度优化调度框架下的调度策略

由图 10 可知：在 0:00~8:00 时段内，主要由风电系统输出功率，其次通过储能 PQ 源输出功率，以减少风电输出功率产生的突变，同时配合 VF 源稳定电压和频率；在 9:00~18:00 时段内，随着光伏系统开始出力，风电系统的功率输出逐渐减小为 0，两者之间及时进行功率互补，PQ 源和 VF 源利用过剩的光伏能源进行充电。随着光伏系统输出功率减少而负荷不断增加，储能系统输出功率满足负荷需求，此后风电系统重新开始供能为储能系统分担压力。为了比较不同时间尺度下功率预测的准确性，统计了不同时间跨度下各时段的平均计划功率与真实值之间的差距，结果如表 1 所示。

表 1 不同时间跨度下的预测误差表

时间跨度	实际功率/ kW	平均计划 功率/kW	绝对误差/ kW	相对误差/ %
日前调度(6:00~7:00)	323.65	307.20	16.45	5.08
滚动优化(6:00~7:00)	323.65	315.09	8.56	2.64
实时调度(6:00~7:00)	323.65	328.65	5.00	1.54
日前调度(11:00~12:00)	645.94	680.47	34.53	5.35
滚动优化(11:00~12:00)	645.94	662.60	16.66	2.58
实时调度(11:00~12:00)	645.94	641.95	3.99	0.62
日前调度(15:00~16:00)	417.07	439.34	22.27	5.34
滚动优化(15:00~16:00)	417.07	402.46	14.61	3.50
实时调度(15:00~16:00)	417.07	415.98	1.09	0.26
日前调度(20:00~21:00)	575.26	613.64	38.38	6.67
滚动优化(20:00~21:00)	575.26	592.32	17.06	2.97
实时调度(20:00~21:00)	575.26	569.11	6.15	1.07

由表 1 可知:在各时间段中,实时调度的计划功率与真实功率之间的偏差最小,绝对误差在 1.09~6.15 kW,相对误差在 0.26%~1.07%,明显低于日前调度和滚动优化调度。日前,调度在预测真实功率时存在一定的不确定性,但提供了初步的调度计划;滚动优化通过不断更新和调整计划,提高了调度的准确性;实时调度能够及时响应电力系统中的变化,进一步提高了预测准确性,确保电力供需的平衡。

4 结束语

笔者利用算法组合提高对可再生能源输出功率预测的准确度,从而合理安排可再生能源的接入位置和容量;结合全生命周期理论构建以成本控制为目标的经济模型,使得电网调控系统能以较低的成本运行;通过建立 3 阶段的多时间尺度调控框架,实现调控方案的准确跟踪。通过相关仿真实验与案例分析对构建的模型和调控策略进行验证。结果表明,笔者提出的可再生能源预测模型对光伏和风电的输出功率预测的平均准确率分别为 97.53%和 96.27%;系统日运行总成本为 1 386.32 元;电网调控策略能合理分配各能源的输出功率,并适应负荷端的需求变化;3 个调控阶段的预测相对误差逐级减小,实时调控阶段最小相对误差为 0.26%。研究构建的可再生能源输出功率预测模型具有较高的精度。该研究提出的基于全生命周期管理的多时间尺度调控技术,能够在确保低成本运行的情况下,实现较高的预测准确度和调控能力。在军用新能源,针对军用电网可能面临的极端气候、孤网运行及紧急响应,该研究可迅速适应电力需求变化,并提高可再生能源输出功率预测的准确度和优化调控策略,能够确保在复杂环境下的电网稳定性,保障军事任务的顺利进行。

参考文献:

- [1] 章锐,于继来.新型城市电网调控体系架构及关键技术[J].中国电机工程学报,2024,44(S1):97-113.
- [2] 王嘉诚,刘晓峰,梅文卿,等.全生命周期视角下区域级电动汽车碳排放评估[J].电力建设,2023,44(6):33-40.
- [3] 章雪萌,毛福斌,李玉良,等.多时间尺度下地区电网新能源出力特性及源荷相关性分析[J].电气应用,2023,42(2):28-32.
- [4] 徐婷婷,吴迪凡,王晨杰,等.基于全生命周期管理的离网型风光储交流微电网的双层优化调度策略[J].电力大数据,2024,27(2):87-96.
- [5] LONG W, ZHU B, LI H, et al. Grid Side Distributed Energy Storage Cloud Group End Region Hierarchical Time-Sharing Configuration Algorithm Based on Multi-Scale and Multi Feature Convolution Neural Network[J]. Energy Engineering, 2023, 120(5): 1253-1269.
- [6] 章雪萌,孟祥娟,毛福斌,等.考虑多时间尺度的新能源特性对地区电网的影响评估[J].南方能源建设,2023,10(5):166-173.
- [7] 赵心怡,谢俊,周翠玉,等.风-光-抽蓄零碳电力系统多时间尺度协调调度模型[J].电力工程技术,2023,42(3):121-129.
- [8] 王振,李祚华,许亚昆,等.基于全寿命效费比的地铁上盖隔震(振)结构优化设计方法[J].地震工程与工程振动,2024,44(4):1-14.
- [9] WU X, YUAN W, GUO A. Reliability-Based Life-Cycle Cost Seismic Design Optimization of Coastal Bridge Piers with Nonuniform Corrosion Using Different Materials[J]. Earthquake Engineering and Engineering Vibration, 2024, 23(1): 209-225.
- [10] 王永利,滕越,袁博,等.考虑风光不确定性的综合能源系统容量-成本两阶段规划优化研究[J].可再生能源,2024,42(4):513-521.
- [11] 李剑颖,任晓灵,王晓燕,等.餐厨废弃油脂制生物柴油全生命周期碳排放分析研究[J].环境卫生工程,2024,32(5):48-54.
- [12] 陈简,张惊雷.基于注意力机制的TCN-BiGRU模型短期风电功率预测[J].天津理工大学学报,2024,40(5):69-74.
- [13] 田佩宁,梁肖,官雨捷,等.中国电网全生命周期碳排放及发电结构转型路径规划研究[J].气候变化研究进展,2024,20(1):97-106.
- [14] 江雨燕,陶承凤,李平.融合线性插值和对抗性学习的深度子空间聚类[J].计算机技术与发展,2023,33(3):200-206,214.
- [15] 董存,王铮,白捷予,等.光伏发电功率超短期预测方法综述[J].高电压技术,2023,49(7):2938-2951.
- [16] 郭凯杰,耿光超,江全元,等.计及超短期预测误差的风储系统跟踪计划出力控制策略[J].太阳能学报,2023,44(2):326-333.
- [17] 方娜,陈浩,李新新,等.基于CNN-PSO-DBN的短期电力负荷预测[J].计算机仿真,2023,40(10):118-122.