DOI：10.13234/j.issn.2095-2805.2025.4.220 **中图分类号**：TM732 **文献标志码**：A

基于KKT条件的微网负荷波动抑制双层优化算法

刘 进[1]，郝文波[1]，李 童[2]，宋 智[1]，张笑宇[3]，
张纯江[3](中国电源学会高级会员)
(1.国网黑龙江省电力有限公司电力科学研究院，哈尔滨 150030；2.国网黑龙江省电力有限公司，哈尔滨 150090；3.燕山大学电气工程学院，秦皇岛 066004)

摘要：针对微电网中可再生能源发电出力的不确定性及负荷随机波动问题，提出1种基于微网负荷波动抑制策略的双层优化算法。对微网发电设备运行状态和功率分配方式进行建模，上层模型主要考虑微源输出功率约束及微网运行相关约束，以保证各发电设备调度优先级和降低微网运行成本为目标函数；下层模型以最小化微网等效负荷波动为目标函数，同时采用长短期记忆与注意力机制LSTM-Attention(long short-term memory-attention)神经网络的预测值，对微网发电设备输出功率进一步约束。优化模型根据KKT条件将双层模型转换为单层模型进行求解，降低模型的求解难度。设计2种负荷场景，采用双层优化算法分别对2种负荷场景进行仿真计算。仿真结果显示，所提双层优化算法能够动态调整微网各发电设备输出功率，提高可再生能源的消纳比例，并针对不同负荷场景改变微网的运行状态，降低负荷波动对微网运行造成的影响。

关键词：微电网；双层优化算法；长短期记忆与注意力机制；KKT条件；负荷波动

Two-layer Optimization Algorithm for Load Fluctuation Suppression in Microgrid Based on KKT Condition

LIU Jin[1], HAO Wenbo[1], LI Tong[2], SONG Zhi[1], ZHANG Xiaoyu[3], ZHANG Chunjiang[3], *Senior Member*, *CPSS*
(1. Electric Power Research Institute, State Grid Heilongjiang Electric Power Co., Ltd., Harbin 150030, China; 2. State Grid Heilongjiang Electric Power Co., Ltd., Harbin 150090, China; 3. School of Electrical Engineering, Yanshan University, Qinhuangdao 066004, China)

Abstract: A two-layer optimization algorithm based on a microgrid load fluctuation suppression strategy is proposed, aiming to address the uncertainties in renewable energy generation and random load fluctuations. Through the modeling of operating states of generation devices and power allocation modes, the upper-layer model mainly considers the micro-resource output power constraints and related constraints on microgrid operations, so as to ensure the scheduling priorities of generation devices while reducing the operating cost of microgrid. The lower-layer model minimizes the equivalent load fluctuations in microgrid while using the values predicted by LSTM-Attention neural network to further constrain the output power of generation devices. The two-layer model is transformed into a single-layer model by applying the KKT condition, thus reducing the complexity in solving the model. Two different load scenarios are designed, and the two-layer optimization algorithm is used to perform simulations under the two scenarios, respectively. Simulation results show that the proposed algorithm can dynamically adjust the output power of generation devices and improve the consumption proportion of renewable energy. In addition, it can change the microgrid's operating state according to different load scenarios and thus mitigate the impact of load fluctuations on microgrid operations.

Keywords: Microgrid; two-layer optimization algorithm;

收稿日期：2023-07-04；**修回日期**：2023-10-02，2023-10-23；**录用日期**：2023-10-27；**网络首发日期**：2024-01-19

基金项目：国网黑龙江省电力有限公司科技资助项目(522437230003)

This work is supported by Technology Project Funding from State Grid Heilongjiang Electric Power Co., Ltd. under the grant 522437230003

LSTM-Attention; KKT condition; load fluctuation

现代工业的快速发展引发了前所未有的能源需求，以化石燃料为基础的传统能源结构已无法满足未来技术发展对能源的要求。为了应对能源和环境污染所带来的挑战，寻找绿色、环保、低碳的生活方式已成为首要目标。因此，目前的重点是发展以可再生能源为主的新型能源系统，以解决当前的能源问题[1-2]。可再生能源的随机性和地域限制使其利用率较低，为了解决这一问题，国内外学者们提出了微电网的运行方式。微电网能够整合可再生能源并利用储能系统与之协调控制，有效提高可再生能源的利用率。

光伏发电存在随机性、间歇性和调度性差等缺点，连接大电网可能对电网质量产生负面影响，且给电力调度和调峰带来挑战。准确预测负载波动和可再生能源发电有助于提高微电网的稳定性并优化经济效益。文献[3]采用 *K*-means 聚类算法为目标光伏电站创建合成天气预报，通过天气数据来预测光伏输出功率；文献[4]提出了 1 种基于门控循环单元的循环神经网络 GRU-RNN(gated recurrent unit-recurrent neural network)，能够对单变量和多变量场景进行预测；文献[5]使用集成经验模型对历史负载数据进行分解，在此基础上结合 2 个神经网络的输出数据重构负载预测结果。

目前，诸多学者对微电网的优化控制方法进行了研究。文献[6]提出了 1 种解决长期电网规划和分布式能源调度优化问题的模型和算法；文献[7]采用长短期记忆 LSTM(long short-term memory)神经网络对可再生能源进行超短期预测，基于信息物理系统 CPS(cyber-physical systems)和社会物理信息系统 CPSS(cyber-physical-social systems)结构构建随机优化模型，对微电网运行进行优化；文献[8]提出了 1 种适用于可再生能源微电网的新型能量管理系统，采用滚动优化 RH(rolling horizon)策略对微网能量进行调度；文献[9]提出了存在节点注入不确定性时，安全约束机组组合问题的两阶段自适应鲁棒机组组合模型；文献[10]提出了 1 种用于孤岛微电网系统频率静态建模的鲁棒能量管理系统，采用信息间隙决策理论 IGDT(information gap decision theory)处理微电网中的不确定性问题。

对比上述方法，采用最优化算法可以得到一定优化效果[6-7]，但是针对不同的应用场景，需要对模型的目标函数及约束进行修改，从而满足实际场景的要求。采用鲁棒优化方式侧重于处理模型中的不确定性问题，通常采用两阶段鲁棒优化对模型求解[9-10]，由于两阶段鲁棒优化将模型分为 2 个阶段处理，第 2 阶段的最优化问题无法充分考虑第 1 阶段中的不确定性信息，可能导致第 2 阶段的最优化结果并非全局最优，局部优化可能面临不确定性的挑战，影响最终计算结果。采用双层优化方法具有较高的灵活性，能够根据具体问题设置不同的优化目标和约束，且双层优化算法能够同时考虑微电网的整体性和分布式能源的特点，在保证微网系统运行的基础上，使各节点的运行成本最小化，最终实现全局最优。

基于以上研究，本文提出 1 种考虑微网负荷波动的双层优化算法，基于 LSTM-Attention 神经网络的预测数据及实际运行数据对微源的运行状态和输出功率进行优化调度。通过对负荷波动抑制策略进行分析，设计协调微源运行的调度策略，根据微网运行及控制方式的要求搭建微网的双层优化模型，其中上层模型与下层模型之间相互传递变量，从而建立相关约束，根据 KKT 条件将双层模型转换为单层优化，简化优化问题的计算过程，最终计算结果可以实现微网的经济运行，并且可以有效降低微网负荷波动带来的影响。最后，通过仿真算例对双层优化算法进行仿真验证。

1　基于 LSTM-Attention 神经网络的预测算法

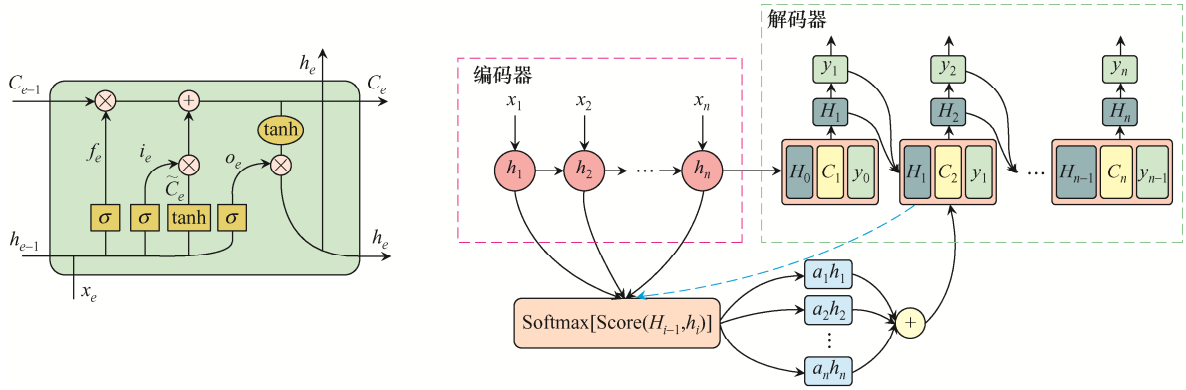
光伏发电量和负荷的动态特性随时间呈现出显著的连续变化趋势，依据统计方法获得的数据展现出独特的时间序列特征，可运用数学方法予以有效地预测。

LSTM 神经网络作为循环神经网络 RNN(recurrent neural network)的变体模型，继承了 RNN 模型的大部分特性，解决了 RNN 梯度反向传输过程中可能发生的梯度消失问题，被广泛应用于时间序列预测领域。近年来，Attention 机制在序列数据处理中发展迅速[11]，通过模拟人类大脑的注意力机制，能够获得目标的更多特征细节，并抑制其他无用信息。

LSTM 通过门机制修改细胞状态，LSTM 细胞结构如图 1(a)所示。当前细胞接收来自前一个细胞的细胞状态 C_{e-1} 和隐藏层 h_{e-1} 数据，通过处理 C_{e-1} 和 h_{e-1} 的信息更新细胞状态 C_e，然后计算出要保存在隐藏层 h_e 中的特征。输出 y_e 最终通过对 h_e 进行数值变换得到。LSTM 计算公式为

$$\begin{cases} f_e = \sigma(W_{\mathrm{f}} \cdot [h_{e-1}, x_e] + \boldsymbol{b}_{\mathrm{f}}) \\ i_e = \sigma(W_{\mathrm{i}} \cdot [h_{e-1}, x_e] + \boldsymbol{b}_{\mathrm{i}}) \\ \tilde{C}_e = \tanh(W_{\mathrm{C}} \cdot [h_{e-1}, x_e] + \boldsymbol{b}_{\mathrm{C}}) \\ C_e = f_e \cdot C_{e-1} + i_e \cdot \tilde{C}_e \\ o_e = \sigma(W_{\mathrm{o}} \cdot [h_{e-1}, x_e] + \boldsymbol{b}_{\mathrm{o}}) \\ h_e = o_e \cdot \tanh\ C_e \end{cases} \tag{1}$$

式中：f_e 为第 e 个神经元中遗忘门的输出值；σ 为激活函数；W_{f}、$\boldsymbol{b}_{\mathrm{f}}$ 分别为遗忘门权重、偏置矩阵；x_e 为第 e 个神经元的输入值；i_e 为第 e 个神经元中输入门的输出值；W_{i}、$\boldsymbol{b}_{\mathrm{i}}$ 分别为输入门权重、偏置矩阵；$\tilde{C}_e$ 为候选记忆值；W_{C}、$\boldsymbol{b}_{\mathrm{C}}$ 分别为候选记忆细胞权重、偏置矩阵；o_e 为第 e 个神经元中输出门的输出值；W_{o}、$\boldsymbol{b}_{\mathrm{o}}$ 分别为输出门权重、偏置矩阵；h_e 为第 e 个神经元隐藏层输出值。



(a) LSTM细胞结构　　(b) Attention结构

图 1　LSTM 细胞结构和 Attention 机制结构

Fig. 1 LSTM cell structure and Attention mechanism structure

注意力机制本质是 1 个包含编码器-解码器(Encoder-Decoder)结构的循环神经网络，注意力机制结构如图 1(b)所示。输入序列经过编码器网络得到特征表示，解码器根据当前输入和隐藏状态生成输出，通过计算相似度得到注意力权重，将注意力权重应用于特征表示，得到注意力值，注意力值作为解码器的输入，生成输出序列。注意力机制的计算公式为

$$\begin{cases} \alpha_i = \mathrm{Softmax}(Sim_i) = \dfrac{\exp(Sim_i)}{\sum_{j=1}^{L_x} \exp(Sim_j)} \\ Sim_i = \mathrm{Score}(H_{i-1}, h_i) = H_{i-1} W h_i \\ C_{\mathrm{A}i} = \sum_{i=1}^{L_x} \alpha_i h_i \\ H_i = f(H_{i-1}, y_{i-1}, C_{\mathrm{A}i}) \end{cases} \tag{2}$$

式中：α_i 为第 i 个数据分配的注意力权重；Sim_i 为第 i 个数据的相似度系数；L_x 为数据序列长度；H_i 为解码器第 i 个隐藏层输出值；h_i 为编码器第 i 个隐藏层输出值；W 为可学习参数；$C_{\mathrm{A}i}$ 为第 i 个数据序列关联系数。

LSTM 模型的局限性包括算法为输入序列生成固定长度的向量及无法识别信息的相关性。注意力机制与 LSTM 相结合增强了识别时间序列数据关键特征的能力，通过对提取的特征进行选择性加权，增强了其特征提取能力和整体预测性能[12-15]。本文采用的 LSTM-Attention 神经网络结构如图 2 所示。

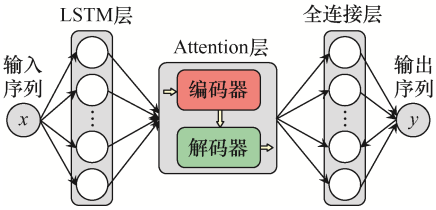


图 2　本文采用的 LSTM-Attention 神经网络结构

Fig. 2 Structure of LSTM-Attention neural network used in this paper

2　微网负荷波动抑制双层优化算法

本文提出 1 种适用于微电网的双层优化算法，结合预测数据与实际运行数据对微网内微源的运行状态和输出功率进行调节，优化微网内微源的功率分配。上层模型的目标函数包含 2 个部分：微源运行状态的组合优化及输出功率调度优化，以实现微网的经济运行；下层模型的目标函数为基于预测数据的微源输出功率优化，同时最小化微网等效负荷波动，从而降低负荷波动带来的影响。上层模型向下层模型传递二元变量，建立下层模型中微网备用容量的约束；下层模型基于预测数据对微源的输出功率范围进行计算，从而建立上层模型中微源的输出功率约束。通过上、下层模型的约束限制，得到更准确的功率输出约束区间，获得最优化的计算结果。

2.1　调度策略

为了实现功率合理分配，提高可再生能源的利用率，并使微网具备主动补偿谐波的能力，提出微网调度策略。

微网首先消耗光伏 PV(photovoltaic)发电设备发出的电能，从而提高光伏发电的消纳比例。储能 ES(energy storage)设备与其他微源配合，调节微网的能量平衡；在光伏发电设备供应不稳定或间断时，储能系统可以存储多余的能量并在需要时释放，以确保微电网的平稳运行。备用发电设备 GR(reserve generator)是由柴油发电机和燃料电池组合的发电系统，燃料电池通过逆变器与微网连接。逆变器采用双模式控制策略，能够工作在逆变模式和有源电力滤波 APF(active power filter)模式下。在逆变模式下，向微网输出能量；在 APF 模式下时，逆变器能够补偿安装节点的谐波电流，消除谐波电流对微网其他节点的影响。微网通过电力变压器与主网相连接，并与主网进行双向功率交换 EX(exchange power)，通过与主网功率交换提高微网运行的稳定性和经济性。

负荷波动抑制策略通过协同调控微网内微源的运行状态，从而减小微网等效负荷的波动。通过优化调度储能设备和备用发电设备的功率输出，削弱了微网负荷波动对微网的影响。同时，在负荷峰值时段通过调整可控负荷的功率，降低了该时段的供电压力。图 3 为可调负荷参与功率调整后的负荷曲线与实际负荷之间的对比，通过上述控制策略，降低了负荷峰时段对微网负荷波动带来的影响。

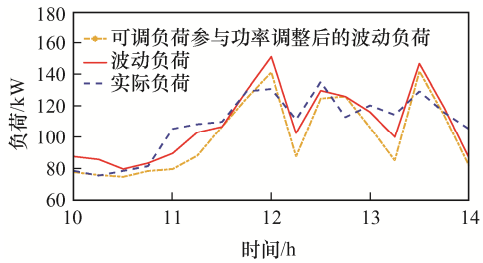


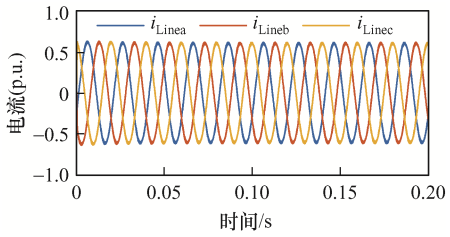
图 3　可调负荷参与功率调整相关曲线

Fig. 3 Related curves of adjustable load participating in power adjustment

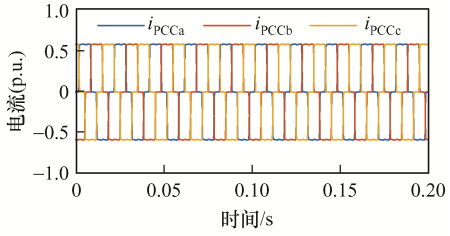
谐波抑制策略通过在各节点配置谐波滤波器对线路电流谐波进行补偿。此外，在微网支路与干路连接节点处还配置了备用发电设备。通过控制逆变器工作在 APF 模式下，对线路谐波电路进行补偿，从而削弱连接节点处谐波电流的影响。为有效降低支路谐波的影响并确保微网重要线路和微网公共连接点处的总谐波失真率 THD(total harmonic distortion)符合运行要求，被动式谐波滤波器与主动式谐波滤波器相互配合使用。

微网线路电流谐波补偿相关波形如图 4 所示，可见，通过在公共节点投入 APF 能够有效降低非线性负载对线路谐波造成的影响。在非线性负载并入电网后，对线路电流产生较大影响，线路电流 THD=28.42%；经过 APF 补偿后，线路电流 THD=4.91%。通过控制逆变器产生补偿电流能够有效降

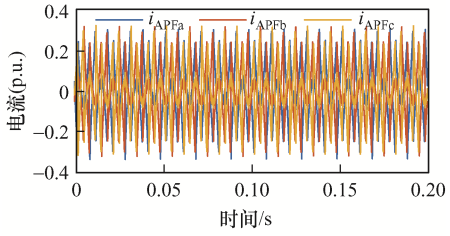
低非线性负载等谐波源对微网线路电流造成的影响。



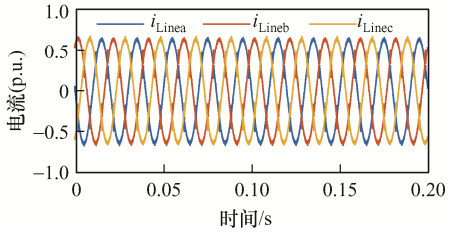
(a) 非线性负载投入前线路电流



(b) 非线性负载投入后线路电流



(c) APF补偿电流



(d) 经APF补偿后的线路电流

图 4 微网线路电流谐波补偿相关波形

Fig. 4 Related waveforms of compensating line current harmonics in microgrid

2.2 上层模型

上层模型以微网最优经济运行为目标函数，旨在降低微网的运行成本。上层模型考虑了微网功率平衡约束、微源输出功率约束、储能系统运行约束及微网谐波检测节点谐波约束。

2.2.1 目标函数

上层模型的目标函数参考调度策略设定不同微源的运行优先级，并且考虑微源的运行成本，以降低微网总运行成本为目标。上层优化算法的目标函数为

$$\begin{cases}\min\ F(X,P)=\alpha\cdot o(X)+\beta\cdot c(P)\\ o(X)=\sum O_{nx}X_n(t)=\sum O_{\mathrm{PV}x}X_{\mathrm{PV}}(t)+\\ \quad\sum O_{\mathrm{GR}x}X_{\mathrm{GR}}(t)+\sum O_{\mathrm{ES}x}X_{\mathrm{ES}}(t)+\\ \quad\sum O_{\mathrm{EX}x}X_{\mathrm{EX}}(t)\\ c(P)=\sum C_nP_n(t)=\sum C_{\mathrm{PV}}P_{\mathrm{PV}}(t)+\\ \quad\sum C_{\mathrm{GR}}P_{\mathrm{GR}}(t)+\sum C_{\mathrm{ES}}P_{\mathrm{ES}}(t)+\\ \quad\sum C_{\mathrm{EX}}P_{\mathrm{EX}}(t)\end{cases}\tag{3}$$

式中：α、β 为目标函数加权系数；$o(X)$为微电网中微源调度优先级的目标函数；$c(P)$为微网的运行成本函数；O_{nx} 为微源的调度优先级系数；$X_n(t)$为二进制向量，其数值用来表示各机组的运行状态；$O_{\mathrm{PV}x}$ 为光伏运行状态优先级系数；$X_{\mathrm{PV}}(t)$为 t 时刻光伏运行状态；$O_{\mathrm{GR}x}$ 为备用电源状态优先级系数；$X_{\mathrm{GR}}(t)$为 t 时刻备用电源运行状态；$O_{\mathrm{ES}x}$ 为储能运行状态优先级系数；$X_{\mathrm{ES}}(t)$为 t 时刻储能运行状态；$O_{\mathrm{EX}x}$ 为主网状态优先级系数；$X_{\mathrm{EX}}(t)$为 t 时刻主网运行状态；C_n 为微电网中微源的单位时间运行成本；$P_n(t)$为微网中微源的输出功率；C_{PV} 为光伏单位时间运行成本；$P_{\mathrm{PV}}(t)$为 t 时刻光伏输出有功功率；C_{GR} 为备用电源单位时间运行成本；$P_{\mathrm{GR}}(t)$为 t 时刻备用电源输出有功功率；C_{ES} 为储能单位时间运行成本；$P_{\mathrm{ES}}(t)$为 t 时刻储能输出有功功率；C_{EX} 为主网电价；$P_{\mathrm{EX}}(t)$为 t 时刻主网交换有功功率。

2.2.2 约束条件

微电网的功率平衡约束为

$$\begin{cases}\sum P_{\mathrm{PV}}(t)+\sum P_{\mathrm{GR}}(t)+\sum P_{\mathrm{ES}}(t)+P_{\mathrm{EX}}(t)=\\ \quad\sum P_{\mathrm{load}}^{\mathrm{real}}(t)+P_{\mathrm{CL}}(t)\\ \sum Q_{\mathrm{PV}}(t)+\sum Q_{\mathrm{GR}}(t)+Q_{\mathrm{EX}}(t)=\sum Q_{\mathrm{load}}^{\mathrm{real}}(t)\end{cases}\tag{4}$$

式中：$P_{\mathrm{load}}^{\mathrm{real}}(t)$、$Q_{\mathrm{load}}^{\mathrm{real}}(t)$ 分别为负荷的有功功率和无功功率；$P_{\mathrm{CL}}(t)$为可控负荷功率；$Q_{\mathrm{PV}}(t)$为 t 时刻光伏输出无功功率；$Q_{\mathrm{GR}}(t)$为 t 时刻备用电源输出无功功率；$Q_{\mathrm{EX}}(t)$为 t 时刻主网交换无功功率。

微电网中电源的输出功率约束为

$$\begin{cases}\underline{P}_n^{\min}X_n(t)\leqslant P_n(t)\leqslant\overline{P}_n^{\max}X_n(t)\\ \underline{P}_n^{\min}=\max\{\underline{P}_n^{\mathrm{B}},P_n^{\min}\}\\ \overline{P}_n^{\max}=\min\{\overline{P}_n^{\mathrm{B}},P_n^{\max}\}\\ \underline{Q}_m^{\min}X_m(t)\leqslant Q_m(t)\leqslant\overline{Q}_m^{\max}X_m(t)\\ \underline{Q}_m^{\min}=Q_m^{\min},\ \ \overline{Q}_m^{\max}=Q_m^{\max}\end{cases}\tag{5}$$

式中：$\overline{P}_n^{\max}$、$\underline{P}_n^{\min}$ 分别为各电源输出有功功率约束上、下限；$X_n(t)$为 t 时刻有功电源运行状态；$P_n(t)$为 t 时刻有功电源输出有功功率；$\underline{P}_n^{\mathrm{B}}$ 为下层优化模型电源输出有功功率最小值；$P_n^{\min}$ 为电源输出有功功率最小值；$\overline{P}_n^{\mathrm{B}}$ 为下层优化模型电源输出有功功率最大值；$P_n^{\max}$ 为电源输出有功功率最大值；$\overline{Q}_m^{\max}$、$\underline{Q}_m^{\min}$ 分别为各电源输出无功功率约束上、下限；$X_m(t)$为 t 时刻无功电源运行状态；$Q_m(t)$为 t 时刻无功电源输出无功功率；$Q_m^{\min}$ 为各电源输出无功功率最小值，$Q_m^{\max}$ 为各电源输出无功功率最大值。

储能系统由电池组构成，为了延长电池寿命，储能系统的荷电状态 SOC(state of charge)应满足约束

$$\begin{cases}\mathrm{SOC}_{\min}\leqslant \mathrm{SOC}(t)\leqslant \mathrm{SOC}_{\max}\\ \mathrm{SOC}(t)=(1-\sigma_{\mathrm{ES}})\mathrm{SOC}(t-1)-\dfrac{\eta_{\mathrm{ch}}P_{\mathrm{ES}}(t)\Delta t}{Cap_{\mathrm{ES}}} & \text{充电}\\ \mathrm{SOC}(t)=(1-\sigma_{\mathrm{ES}})\mathrm{SOC}(t-1)-\dfrac{P_{\mathrm{ES}}(t)\Delta t}{\eta_{\mathrm{dch}}Cap_{\mathrm{ES}}} & \text{放电}\end{cases} \tag{6}$$

式中：σ_{ES}为电池的自放电率；η_{ch}、η_{dch}分别为电池的充、放电效率；Δt为时间间隔；Cap_{ES} 为电池容量。

本文微电网中所有微源的输出功率变化率存在约束

$$-\Delta P_{\min}\leqslant P_n(t)-P_n(t-1)\leqslant \Delta P_{\max} \tag{7}$$

式中：$\Delta P_{\min}$ 为电源功率变化最小值；$\Delta P_{\max}$ 为电源功率变化最大值。

当备用发电设备的逆变器工作在 APF 模式时，需要满足约束

$$H_{\mathrm{PCC},i}+\varepsilon_{\mathrm{H},i}\leqslant (1-X_{\mathrm{GR},i})Cap_{\mathrm{APF},i}+Cap_{\mathrm{H},i} \tag{8}$$

式中：$H_{\mathrm{PCC},i}$为在节点 i 处检测到的谐波分量；$\varepsilon_{\mathrm{H},i}$为谐波的随机变量，表示各节点处谐波的不确定性；$X_{\mathrm{GR},i}$为第 i 个备用电源运行状态；$Cap_{\mathrm{APF},i}$为备用设备工作在 APF 模式下的补偿容量，$Cap_{\mathrm{H},i}$为节点 i 处无源器件的补偿容量。

2.3 下层模型

下层模型基于 LSTM-Attention 神经网络的预测结果，以微网运行经济性为目标函数，计算微源的发电上、下限，同时考虑降低微网等效负荷波动。此外，下层模型还考虑了微网备用容量安全约束、可控负荷约束和等效负荷波动约束。

2.3.1 目标函数

下层模型以预测数据为基础，对微源输出功率进行优化，并且考虑微网等效负荷波动最小化，建立目标函数，即

$$\begin{cases}\min\ f(P)=c(P^{\mathrm{B}})+P_{\mathrm{load}}^{\mathrm{eq,rate}}\\ c(P^{\mathrm{B}})=\sum C_nP_n^{\mathrm{B}}(t)=\sum C_{\mathrm{PV}}P_{\mathrm{PV}}^{\mathrm{B}}(t)+\\ \quad\sum C_{\mathrm{GR}}P_{\mathrm{GR}}^{\mathrm{B}}(t)+\sum C_{\mathrm{ES}}P_{\mathrm{ES}}^{\mathrm{B}}(t)+\\ \quad\sum C_{\mathrm{EX}}P_{\mathrm{EX}}^{\mathrm{B}}(t)\\ P_{\mathrm{load}}^{\mathrm{eq,rate}}=\sum[P_{\mathrm{load}}^{\mathrm{eq}}(t)-P_{\mathrm{load}}^{\mathrm{eq}}(t-1)]\end{cases} \tag{9}$$

式中：$c(P^{\mathrm{B}})$为微网的运行成本函数；$P_{\mathrm{load}}^{\mathrm{eq,rate}}$ 为微网等效负荷波动函数；$P_n^{\mathrm{B}}(t)$ 为基于预测数据的微网中微源的输出功率；$P_{\mathrm{PV}}^{\mathrm{B}}(t)$ 为 t 时刻下层模型光伏输出有功功率；$P_{\mathrm{GR}}^{\mathrm{B}}(t)$ 为 t 时刻下层模型备用电源输出有功功率；$P_{\mathrm{ES}}^{\mathrm{B}}(t)$ 为 t 时刻下层模型储能输出有功功率；$P_{\mathrm{EX}}^{\mathrm{B}}(t)$ 为 t 时刻下层模型主网交换有功功率；$P_{\mathrm{load}}^{\mathrm{eq}}(t)$ 为 t 时刻的微网等效负荷，$P_{\mathrm{load}}^{\mathrm{eq}}(t-1)$ 为 t−1 时刻的微网等效负荷。

2.3.2 约束条件

下层模型中采用光伏和负荷预测数据计算当前时刻微网内机组容量能否满足负荷供电需求。下层模型中总容量约束为

$$\begin{cases}\sum P_{\mathrm{PV}}^{\mathrm{fore}}(t)+\sum P_{\mathrm{GR}}^{\mathrm{B}}(t)+\sum P_{\mathrm{ES}}^{\mathrm{B}}(t)+\\ \quad P_{\mathrm{EX}}^{\mathrm{B}}(t)\geqslant\sum P_{\mathrm{load}}^{\mathrm{fore}}(t)+M\\ \sum Q_{\mathrm{PV}}^{\mathrm{B}}(t)+\sum Q_{\mathrm{GR}}^{\mathrm{B}}(t)+Q_{\mathrm{EX}}^{\mathrm{B}}(t)\geqslant\sum Q_{\mathrm{load}}^{\mathrm{fore}}(t)\end{cases} \tag{10}$$

式中：$P_{\mathrm{PV}}^{\mathrm{fore}}(t)$ 为光伏设备输出功率预测值；$P_{\mathrm{load}}^{\mathrm{fore}}(t)$ 和 $Q_{\mathrm{load}}^{\mathrm{fore}}(t)$ 为负荷有功功率和无功功率预测值；M 为足够大的随机变量，取值需满足微电网中微源的最优组合计算；$Q_{\mathrm{PV}}^{\mathrm{B}}(t)$ 为下层模型光伏设备输出无功功率；$Q_{\mathrm{GR}}^{\mathrm{B}}(t)$ 为下层模型备用电源输出无功功率；$Q_{\mathrm{EX}}^{\mathrm{B}}(t)$ 为下层模型主网交换无功功率。

下层模型中，各微源的输出功率约束为

$$\begin{cases} P_n^{\min} \leqslant \underline{P}_n^{\mathrm{B}}(t) \leqslant P_n^{\max} & M<0 \\ P_n^{\min} \leqslant \overline{P}_n^{\mathrm{B}}(t) \leqslant P_n^{\max} & M>0 \end{cases} \tag{11}$$

式中，$\overline{P}_n^{\mathrm{B}}(t)$、$\underline{P}_n^{\mathrm{B}}(t)$分别为下层模型中各微源输出功率约束上、下限。

对于备用发电设备，单位时间内输出的电能存在约束

$$E_{\mathrm{GR}}^{\min} \leqslant \sum P_{\mathrm{GR}}(t)\cdot\Delta t \leqslant E_{\mathrm{GR}}^{\max} \tag{12}$$

式中，$E_{\mathrm{GR}}^{\max}$、$E_{\mathrm{GR}}^{\min}$分别为单位时间内备用发电设备发出电能的上、下限。

微网中的备用容量存在约束

$$\sum \rho_{\mathrm{GR}} Cap_{\mathrm{GR}} X_{\mathrm{GR}}(t) + \sum \rho_{\mathrm{ES}} Cap_{\mathrm{ES}} \mathrm{SOC} \geqslant \varepsilon \sum P_{\mathrm{load}}^{\mathrm{fore}}(t) \tag{13}$$

式中：ρ_{GR}、ρ_{ES}分别为备用发电设备和储能系统的备用容量系数；Cap_{GR}、Cap_{ES}分别为备用发电设备和储能电池的容量；$X_{\mathrm{GR}}(t)$为备用发电设备的运行状态变量；ε为负荷功率系数。

微网中的可调负载存在约束

$$\begin{cases} P_{\mathrm{CL}}(t) = P_{\mathrm{CL}}^{\max} - \Delta P_{\mathrm{CL}}(t) \\ \Delta P_{\mathrm{CL}}^{\min} \leqslant \Delta P_{\mathrm{CL}}(t) \leqslant \Delta P_{\mathrm{CL}}^{\max} \end{cases} \tag{14}$$

式中：$P_{\mathrm{CL}}^{\max}$为可调负载额定功率；$\Delta P_{\mathrm{CL}}(t)$为可调负载当前时刻可调功率值；$\Delta P_{\mathrm{CL}}^{\max}$、$\Delta P_{\mathrm{CL}}^{\min}$分别为可调负荷功率上、下限。

微网中等效负荷存在约束

$$\begin{cases} P_{\mathrm{load}}^{\mathrm{eq}}(t) = \begin{cases} P_{\mathrm{load}}(t) + P_{\mathrm{CL}}(t) - P_{\mathrm{ES}}(t) \\ \quad \text{负荷谷时段} \\ P_{\mathrm{load}}(t) + P_{\mathrm{CL}}(t) - P_{\mathrm{ES}}(t) - P_{\mathrm{EX}}(t) \\ \quad \text{负荷峰时段} \end{cases} \\ \underline{P}_{\mathrm{load}}^{\mathrm{eq,min}} \leqslant \left| P_{\mathrm{load}}^{\mathrm{eq,rate}} \right| \leqslant \overline{P}_{\mathrm{load}}^{\mathrm{eq,max}} \end{cases} \tag{15}$$

式中：$P_{\mathrm{load}}^{\mathrm{eq}}(t)$为 t 时刻的等效负荷；$P_{\mathrm{load}}(t)$为 t 时刻的实际负荷；$P_{\mathrm{CL}}(t)$为负荷峰时段 t 时刻的可控负荷功率。

2.4 优化问题求解方法

为了解决双层最优化问题，常用方法是通过 KKT 条件将双层最优化问题转换为单层最优化问题[16]。对于包含不等式约束和方程约束的双层模型，存在

$$\begin{cases} \min F(x,p) & \text{(a)} \\ \text{s.t. } G_a(x,p) \leqslant 0 \quad a=1,2,\cdots,c \\ \quad H_b(x,p)=0 \quad b=1,2,\cdots,d \\ \min f(p) & \text{(b)} \\ \text{s.t. } g_i(p) \leqslant 0 \quad i=1,2,\cdots,m \\ \quad h_j(p)=0 \quad j=1,2,\cdots,n \\ x\in X,\ p\in P \end{cases} \tag{16}$$

式中：(a)表示上层模型，(b)表示下层模型；$F(x,p)$为上层模型目标函数，对应式(3)；$G_a(x,p)$和 $H_b(x,p)$分别为上层模型的不等式约束和等式约束，对应式(4)~(8)；$f(p)$为下层模型目标函数，对应式(9)；$g_i(p)$、$h_j(p)$分别为下层模型的不等式约束和等式约束，对应式(10)~(14)；p 为下层模型决策变量。

通过 KKT 条件对下层模型进行转换，即

$$\begin{cases} \dfrac{\mathrm{d}f(p)}{\mathrm{d}p} + \sum \lambda_i \dfrac{\mathrm{d}g_i(p)}{\mathrm{d}p} + \sum \mu_j \dfrac{\mathrm{d}h_j(p)}{\mathrm{d}p} = 0 \\ g_i(p) \leqslant 0,\ \lambda_i \geqslant 0,\ \lambda_i g_i(p) = 0 \\ h_j(p) = 0,\ \mu_j \neq 0 \\ p \in P \end{cases} \tag{17}$$

式中：λ_i为下层模型不等式约束的拉格朗日乘子；μ_j为下层等式约束的拉格朗日乘子。

将转换后的下层模型目标函数的约束与上层模型的约束结合，从而将双层模型转换为 1 个单层模型，即

$$\begin{cases} \min\ F(x,p) \\ \text{s.t. } G_a(x,p) \leqslant 0,\ H_b(x,p)=0 \\ \quad \dfrac{\mathrm{d}f}{\mathrm{d}p} + \sum \lambda_i \dfrac{\mathrm{d}g_i}{\mathrm{d}p} + \sum \mu_j \dfrac{\mathrm{d}h_j}{\mathrm{d}p} = 0 \\ \quad g_i(p) \leqslant 0,\ \lambda_i \geqslant 0,\ \lambda_i g_i(p) = 0 \\ \quad h_j(p) = 0,\ \mu_j \neq 0 \\ \quad x \in X,\ p \in P \end{cases} \tag{18}$$

求解单层模型的最优解，即求解式(17)，相当于求初始双层模型的最优解。本文所提双层优化算法的求解流程如图 5 所示。

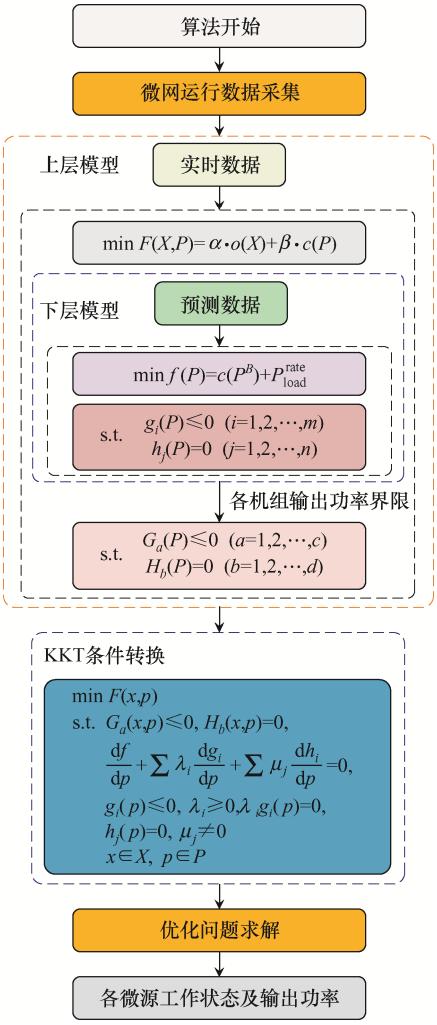


图 5　双层优化算法求解流程

Fig. 5 Flow chart of solution using two-layer optimization algorithm

3　仿真算例分析

3.1　神经网络预测结果分析

本文以 15 min 为周期对 31 d 的 PV 数据进行采样，共 2 976 组数据。训练集与测试集的比例为 8∶2，训练集划分 2 380 组数据，测试集划分 596 组数据。本文构建的神经网络与传统 LSTM 对光伏数据进行预测的结果对比如图 6 所示。

同时本文构建的神经网络也可用于对负荷进行预测。采用 RMSE 作为性能评价指标，分析 2 种模型对同一数据预测的准确性，见表 1。根据表1数据分析可知，本文采用的 LSTM-Attention 模型经过训练后对不同数据的预测性能优于传统 LSTM 模型，对本文中的应用场景，LSTM-Attention 能输出较为精确的结果。

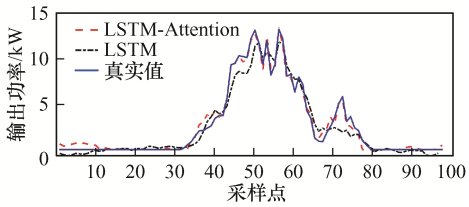


图 6　LSTM-Attention 和 LSTM 预测结果对比

Fig. 6 Comparison of prediction results between LSTM-Attention and LSTM models

表 1　神经网络模型对不同数据的预测性能对比

Tab. 1 Comparison of performance between different neural network models in predicting different data

输出数据类别	LSTM-Attention	LSTM
光伏/kW	2.228 2	2.883 2
负荷有功功率/kW	3.417 4	8.905 2
负荷无功功率/kvar	1.013 6	1.920 8

3.2　双层优化算法仿真分析

本文所提双层优化算法，上层算法为混合整数规划 MIP(mixed integer programming)，下层算法为线性规划 LP(linear programming)。在 MATLAB 中进行测试，使用的求解器为 Gurobi 10.0.1。本文采用 IEEE 33 节点网络拓扑进行微网仿真计算，微电网拓扑如图 7 所示。节点 1~18 线路为微网中的干路，节点 19~22、23~25、26~33 线路为微网中的支路。备用发电设备配置在节点 2、3、6，即谐波补偿设备配置在节点 2、3、6，节点 19、23、26 为谐波检测节点。

本文优化算法以 15 min 为计算周期，采用双层优化算法对微网进行 24 h 功率调度计算，微网中所有的储能设备初始 SOC 均设定为 50%。仿真中设置了 2 种不同的负荷场景，如图 8 所示，可见，2 种负荷场景具有不同特征的负荷曲线。其中，负荷场景 1 具有较大的峰谷差，最高负荷与最低负荷之差为 135 kW；场景 2 中负荷的峰谷差较小，最高负荷与最低负荷之差为 104 kW。

通过计算微网等效负荷波动偏移率来表示微

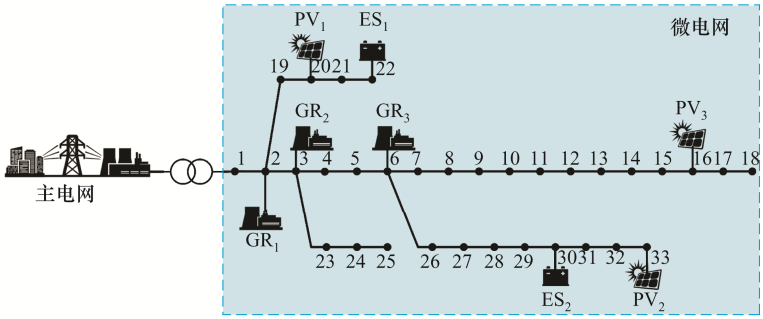


图 7 本文中的 33 节点微电网拓扑

Fig. 7 Topology of 33-node microgrid in this paper

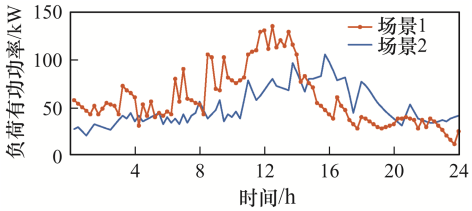


图 8 微网负荷场景

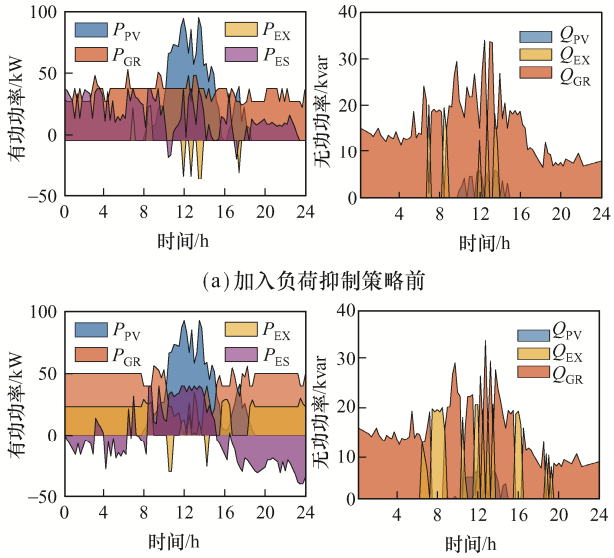
Fig. 8 Load scenarios of microgrid

网负荷的波动情况，从而分析双层优化算法对负荷波动的抑制效果。定义等效负荷波动偏移率计算公式为

$$R_{\text{load}}^{\text{fluc}}(t)=\frac{P_{\text{load}}^{\text{eq}}(t)}{\overline{P}_{\text{load}}} \tag{19}$$

式中：$R_{\text{load}}^{\text{fluc}}(t)$ 为 t 时刻的等效负荷波动偏移率；$\overline{P}_{\text{load}}$ 为负荷的平均值。

图 9 为双层优化算法计算结果，对应场景 1 中加入负荷波动抑制策略前后的优化调度结果。可见：加入负荷波动抑制策略前，微网主要依赖备用发电设备和储能系统供电，储能系统消耗较大，充电量较少，部分时段微网向主网输出电能，等效负荷波动率为 100%；加入负荷波动抑制策略后，不同类型的微源呈现出显著的时间特性，储能设备夜间充电，其他时段向微网放电。微网与主网之间的功率交换明显增加，不同类型微源的输出功率波动较平稳。由图 10(b)可见，在当前优化调度下，微网的等效负荷总体波动幅值较大，但等效负荷波动率降至 25%，通过微网的优化调度和负荷波动抑制策略共同作用，微网的等效负荷波动及各微源的输出功率波动明显降低。

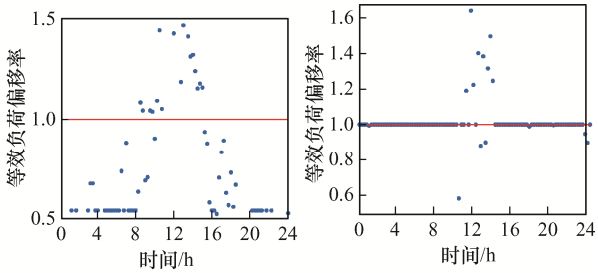


(a) 加入负荷抑制策略前

(b) 加入负荷抑制策略后

图 9 负荷场景 1 加入负荷波动抑制策略前后的双层优化算法计算结果

Fig. 9 Calculation results of two-layer optimization algorithm before and after implementation of load fluctuation suppression strategy under Scenario 1

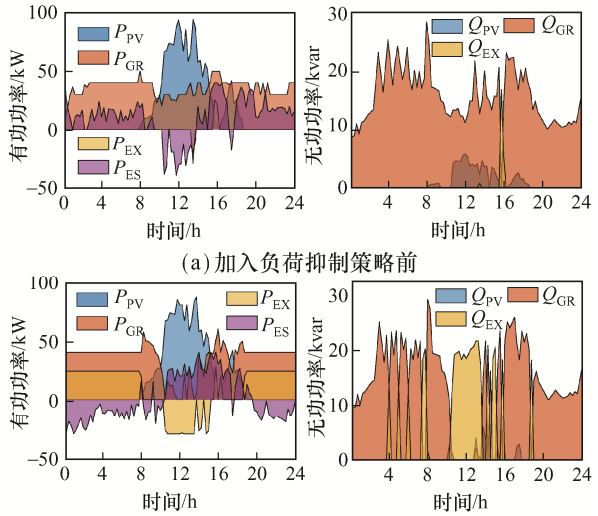


(a) 加入负荷抑制策略前　(b) 加入负荷抑制策略后

图 10 负荷场景 1 加入负荷波动抑制策略前后的等效负荷波动率分布

Fig. 10 Distribution of equivalent load fluctuation rate before and after implementation of load fluctuation suppression strategy under Scenario 1

图 11 为双层优化算法计算结果，分别对应场景 2 中加入负荷波动抑制策略前后的优化调度结果。由图 11(a)和图 12(a)可见，负荷场景 2 加入负荷波动抑制策略前，微网等效负荷波动范围较大，等效负荷波动率为100%；由图11(b)和图 12(b)可见，加入负荷波动抑制策略后，微网等效负荷波动范围较小，等效负荷波动率为 33%。

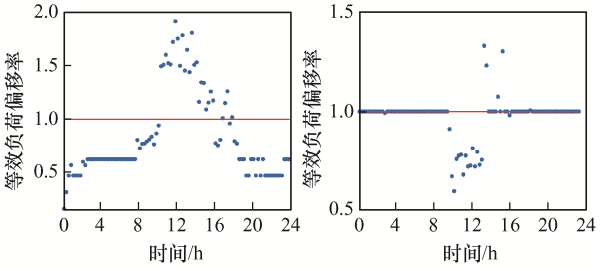


(a) 加入负荷抑制策略前

(b) 加入负荷抑制策略后

图 11　负荷场景 2 加入负荷波动抑制策略前后的双层优化算法计算结果

Fig. 11 Calculation results of two-layer optimization algorithm before and after implementation of load fluctuation suppression strategy under Scenario 2



(a) 加入负荷抑制策略前　　(b) 加入负荷抑制策略后

图 12　负荷场景 2 加入负荷波动抑制策略前后的等效负荷波动率分布

Fig. 12 Distribution of equivalent load fluctuation rate before and after implementation of load fluctuation suppression strategy under Scenario 2

对 2 种负荷场景下的优化调度结果进行分析，加入负荷波动抑制策略能够有效降低微网等效负荷波动，降低微源输出功率波动范围，如图 13 所示。采用负荷波动抑制策略后，储能系统的剩余 SOC 计算结果产生变化，负荷场景 1 的剩余 SOC 由 32.80%提升至 50.45%，场景 2 的剩余 SOC 由 37.85%提升至 48.25%。通过双层优化算法的优化调度，能够有效提高储能系统的剩余 SOC，有利于算法进行后续的优化调度安排。经双层优化算法调度，本文涉及的几种仿真场景中光伏平均消纳比例为 96.43%，表明该算法能够实现新能源的高比例消纳。

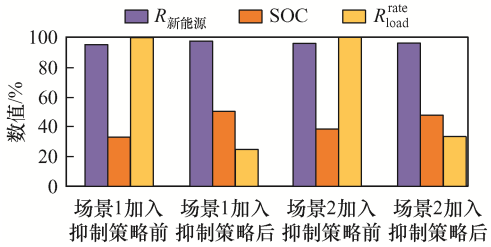


图 13　2 种负荷场景数据统计

Fig. 13 Data statistics under two load scenarios

双层优化算法在 2 种负荷场景下计算的总成本和每个周期的平均成本见表 2。仿真结果表明，2 种负荷场景在加入负荷波动抑制策略后，微网运行总成本均有一定程度降低。本文所提双层优化算法配合负荷波动抑制策略能够实现微网的经济运行。

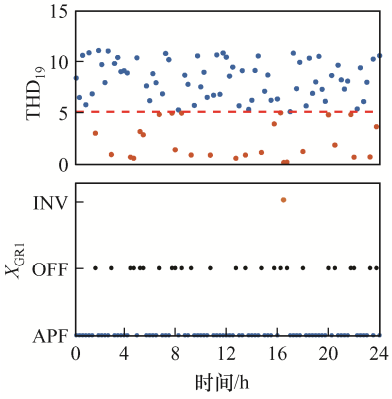
表 2　不同负荷场景下微网运行成本

Tab. 2 Operating costs of microgrid under different load scenarios

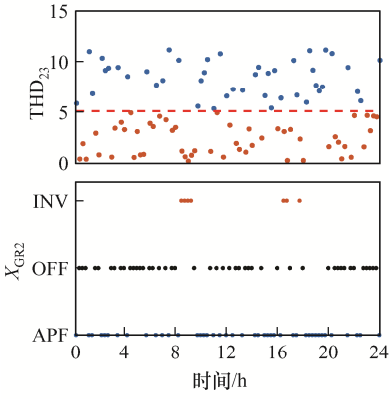
成本	场景 1		场景 2	
	加入抑制策略前	加入抑制策略后	加入抑制策略前	加入抑制策略后
总成本/元	9 917.6	9 836.6	9 057.8	8 782.8
平均成本/元	103.31	102.46	94.35	90.93

仿真设计在微网中随机时刻加入非线性负载，分析检测节点处电流的谐波含量，图 14 为谐波检测节点的 THD 值和备用发电设备逆变器的工作状态。重点分析谐波检测节点的电流谐波含量，根据谐波抑制策略，采用切换逆变器工作模式的方式，降低微网支路非线性负载对干路的影响。由图 14

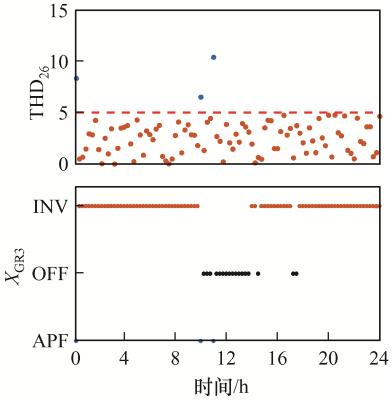
可见，当检测节点 THD 值超过运行要求时，逆变器切换为 APF 模式，从而对线路电流谐波进行补偿。图 15 为加入谐波抑制策略后微网主干线路的 THD 值分布。仿真结果表明，本文所提谐波抑制策略能够削弱支路谐波对干路的影响，降低电网公共连接点处的谐波含量，提高微网运行的稳定性和电能质量。



(a) 节点19处THD值和GR_1工作状态



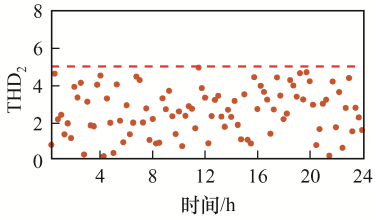
(b) 节点23处THD值和GR_2工作状态



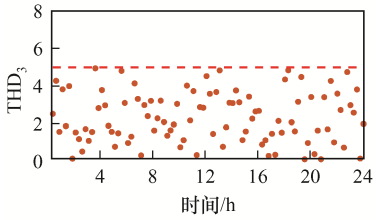
(c) 节点26处THD值和GR_3工作状态

图 14 支路谐波检测节点 THD 值和 GR 工作状态

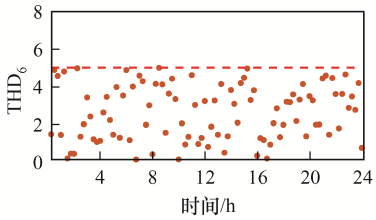
Fig. 14 THD values and GR operating states at harmonic detection nodes



(a) 节点2



(b) 节点3



(c) 节点6

图 15 加入谐波抑制策略后微网主干线路的 THD 值

Fig. 15 THD values of microgrid's main circuit after implementation of harmonic suppression strategy

4 结论

本文提出 1 种双层优化算法来应对微电网中可再生能源发电出力不确定性和微网负荷随机波动的问题。上层模型考虑微网功率平衡、微源输出功率、储能系统运行和节点谐波等约束条件，以实现微网的最优经济运行。下层模型基于 LSTM-Attention 神经网络的预测结果，综合考虑微网备用容量约束和降低等效负荷波动，保证微网的稳定性和经济性。双层优化算法通过 KKT 条件将双层问题转换为单层问题，简化优化问题的求解过程。

本文采用的 LSTM-Attention 神经网络与传统 LSTM 模型对同一组数据进行仿真分析，结果显示 LSTM-Attention 预测数据准确度更高。算例仿真中设置 2 种负荷场景，双层优化算法能够合理调整各设备的运行状态及输出功率，抑制负荷波

动对微网造成的不利影响，验证了谐波抑制策略的有效性。本文所提优化算法也存在一些局限，例如对预测数据的要求较高、计算时间相对较长、适用性需要根据不同微电网系统进行验证和调整等。未来需要结合实际情况进行深入研究，探索更有效、更快速的算法，以适应实际应用需求。

参考文献：

[1] 陈冲, 贾利民, 赵天宇, 等. 去碳化导向的轨道交通与新能源融合发展: 形态模式、解决方案和使/赋能技术[J]. 电工技术学报, 2023, 38(12): 3321-3337.
Chen Chong, Jia Limin, Zhao Tianyu, et al. Decarbonization-oriented rail transportation and renewable energy integration development: Configurations, solutions, and enabling/empowering technologies [J]. Transactions of China Electrotechnical Society, 2023, 38(12): 3321-3337. (in Chinese)

[2] 杨珺, 侯俊浩, 刘亚威, 等. 分布式协同控制方法及在电力系统中的应用综述[J]. 电工技术学报, 2021, 36(19): 4035-4049.
Yang Jun, Hou Junhao, Liu Yawei, et al. Distributed cooperative control method and application in power system [J]. Transaction of China Electrotechnical Society, 2021, 36(19): 4035-4049. (in Chinese)

[3] Hossain M S, Mahmood H. Short-term photovoltaic power forecasting using an LSTM neural network and synthetic weather forecast [J]. IEEE Access, 2020, 8: 172524-172533.

[4] Xia Min, Shao Haidong, Ma Xiandong, et al. A stacked GRU-RNN-based approach for predicting renewable energy and electricity load for smart grid operation [J]. IEEE Transactions on Industrial Informatics, 2021, 17(10): 7050-7059.

[5] Li Jian, Deng Daiyu, Zhao Junbo, et al. A novel hybrid short-term load forecasting method of smart grid using MLR and LSTM neural network [J]. IEEE Transactions on Industrial Informatics, 2021, 17(4): 2443-2452.

[6] Rotering N, Kellermann J, Moser A. Algorithm for simultaneous medium voltage grid planning and electric vehicle scheduling [J]. IEEE Transactions on Smart Grid, 2021, 12(4): 3305-3313.

[7] Chen Ziyu, Zhu Jizhong, Dong Hanjiang, et al. Optimal dispatch of WT/PV/ES combined generation system based on cyber-physical-social integration [J]. IEEE Transactions on Smart Grid, 2022, 13(1): 342-354.

[8] Palma-Behnke R, Benavides C, Lanas F, et al. A microgrid energy management system based on the rolling horizon strategy [J]. IEEE Transactions on Smart Grid, 2013, 4(2): 996-1006.

[9] Bertsimas D, Litvinov E, Sun X A, et al. Adaptive robust optimization for the security constrained unit commitment problem [J]. IEEE Transactions on Power Systems, 2013, 28(1): 52-63.

[10] Rezaei N, Ahmadi A, Khazali A H, et al. Energy and frequency hierarchical management system using information gap decision theory for islanded microgrids [J]. IEEE Transactions on Industrial Electronics, 2018, 65(10): 7921-7932.

[11] 张帅涛, 蒋品群, 宋树祥, 等. 基于注意力机制和CNN-LSTM融合模型的锂电池SOC预测[J]. 电源学报, 2024, 22(5): 269-277.
Zhang Shuaitao, Jiang Pinqun, Song Shuxiang, et al. SOC prediction for lithium battery based on fusion model of attention mechanism and CNN-LSTM [J]. Journal of Power Supply, 2024, 22(5): 269-277. (in Chinese).

[12] Yang Tongguang, Li Bin, Xun Qian. LSTM-attention-embedding model-based day-ahead prediction of photovoltaic power output using Bayesian optimization [J]. IEEE Access, 2019, 7: 171471-171484.

[13] 舒征宇, 翟二杰, 李镇翰, 等. 基于 Dropout 优化算法和LSTM的铅酸蓄电池容量预测[J]. 电源学报, 2023, 21(5): 173-181.
Shu Zhengyu, Zhai erjie, Li Zhenhan, et al. Prediction of lead-acid battery capacity based on dropout optimization algorithm and LSTM [J]. Journal of Power Supply, 2023, 21(5): 173-181. (in Chinese)

[14] 陈晨, 王小杨, 梁建盈, 等. 基于新型注意力机制的

LSTM 光伏发电预测方法[J]. 现代计算机, 2021, 27(11): 28-32, 38.

Chen Chen, Wang Xiaoyang, Liang Jianying, et al. LSTM photovoltaic power generation forecasting method based on attention mechanism [J]. Modern Computer, 2021, 27(11): 28-32, 38. (in Chinese)

[15] 马磊, 黄伟, 李克成, 等. 基于 Attention-LSTM 的光伏超短期功率预测模型[J]. 电测与仪表, 2021, 58(2): 146-152.

Ma Lei, Huang Wei, Li Kecheng, et al. Photovoltaic ultra-short-term power prediction model based on Attention-LSTM [J]. Electrical Measurement & Instrumentation, 2021, 58(2): 146-152. (in Chinese)

[16] 张迪, 苗世洪, 赵健, 等. 分布式发电市场化环境下扶贫光伏布点定容双层优化模型研究[J]. 电工技术学报, 2019, 34(10): 1999-2010.

Zhang Di, Miao Shihong, Zhao Jian, et al. A Bi-level locating and sizing optimal model for poverty alleviation PVS considering the marketization environment of distributed generation [J]. Transaction of China Electrotechnical Society, 2019, 34(10): 1999-2010. (in Chinese)



刘进

作者简介：

刘进(1982—)，女，硕士，高级工程师。研究方向：电力系统及其自动化，新能源电网稳定性。E-mail：15515120559@163.com。

郝文波(1976—)，男，博士，正高级工程师。研究方向：电力系统及其自动化。E-mail：176991383@qq.com。

李童(1984—)，男，硕士，高级工程师。研究方向：电能质量控制。E-mail：ljm121618233462319@126.com。

宋智(1995—)，男，硕士，助理工程师。研究方向：电能质量控制和新能源发电技术。E-mail：302623537@qq.com。

张笑宇(1999—)，男，通信作者，硕士研究生。研究方向：微电网优化控制。E-mail：abrahamz99@163.com。

张纯江(1961—)，男，中国电源学会高级会员，博士，教授。研究方向：可再生能源分布式发电及控制，储能变流器，微电网功率流控制。E-mail：zhangcj@ysu.edu.cn。

(责任编辑：耿越)

关于《电源学报》2024 年度优秀编委的表彰

为表彰《电源学报》第四届编委为学报发展做出的突出贡献，根据《2024 年度优秀编委推选方案》，由主编推选出优秀编委 3 名，具体名单如下。

耿　华　清华大学

金　阳　郑州大学

王懿杰　哈尔滨工业大学

特此表彰！

藉此，我们向所有编委表示最崇高的敬意！

《电源学报》编辑部

2025 年 6 月