

DOI: 10.19783/j.cnki.pspc.200986

基于分布式神经动力学算法的微电网多目标优化方法

刘青¹, 赵洋¹, 李宁¹, 马博翔¹, 尚英强¹, 李文杰²

(1. 国网北京市电力公司电缆分公司, 北京 100022; 2. 中国电力科学研究院武汉分院, 湖北 武汉 430074)

摘要: 针对微电网多目标优化计算量较大问题, 提出了一种考虑需求响应的微电网分布式神经动力学优化算法。首先考虑平均效率函数、微电网的排放、需求响应引起的不满意度以及总利润函数等因素建立多目标优化模型。然后应用单目标积公式将多目标优化问题转换为单目标优化问题, 并证明了最优解是原始多目标问题的帕累托最优解。进一步使用对数障碍物惩罚因子处理不等式约束, 利用 Lasalle 不变性原理和 Lyapunov 函数证明所提出的算法可以收敛到最优解。最后, 通过仿真验证了所提方法可以在保证优化精度与收敛性条件下大大降低计算成本。

关键词: 神经动力学算法; 多目标优化; 最优解; 微电网; 需求响应

Multiple objective optimization of a microgrid based on a distributed neural dynamics algorithm

LIU Qing¹, ZHAO Yang¹, LI Ning¹, MA Boxiang¹, SHANG Yingqiang¹, LI Wenjie²

(1. Powercable Branch, State Grid Beijing Electric Power Company, Beijing 100022, China;
2. Wuhan Branch, China Electric Power Research Institute, Wuhan 430074, China)

Abstract: To solve the problem of large amounts of calculation in multi-objective optimization of a microgrid, a distributed neural dynamic optimization algorithm considering demand response is proposed. First, the multi-objective optimization model is established considering the average efficiency function, micro grid emissions, demand response-induced dissatisfaction and total profit function. Then, the multi-objective optimization problem is transformed into a single objective optimization problem using a single objective product formula, and it is proved that the optimal solution is the Pareto best of the original multi-objective problem. A logarithmic obstacle penalty factor is used to deal with inequality constraints, and the invariance principle of LaSalle and the Lyapunov function are used to prove that the proposed algorithm can converge to the optimal solution. Finally, the simulation results show that the proposed method can greatly reduce the calculation cost under while ensuring optimization accuracy and convergence.

This work is supported by the Science and Technology Project of the Headquarters of State Grid Corporation of China (No. GY71-18-040).

Key words: neural dynamic algorithm; multiple objective optimization; optimum solution; microgrid; demand response

0 引言

面对全球常规能源的逐渐枯竭和环境污染, 为了有效实现可持续发展, 风能和太阳能等可再生能源已广泛用于微电网^[1]。微电网作为负载大小可变的智能负载, 由于其便捷性与智能化得到了广泛的应用^[2-3]。在微电网优化中, 考虑需求响应能够避免电路拥塞, 提升能源利用率, 因此, 基于需求响应的微电网优化成为了研究热点^[4]。

针对需求响应, 提出了一系列可行的算法。例

如, 为了保护环境, 设计了需求响应模型, 提供了可能的基础架构以同时提高效率和能耗^[5-6]。在文献[7]中, 目标是在最小每日能量消耗水平、每单位时间的负载限制的最小和最大水平以及此类负载水平的上升限制的情况下, 最大限度地提高用户的利用率。但是上述模型都是需求响应的单目标模型, 对于微电网优化问题, 多目标模型会使得系统更加全面有效。

针对微电网的多目标优化问题, 已经有大量研究。在文献[8]中, 分布式梯度算法(Distributed Gradient Algorithm, DGA)被应用于处理分布式和优化(Distributed Sum Optimization, DSO)问题。此外,

在处理微电网的优化问题时，智能算法也很常见。粒子群优化(Particle Swarm Optimization, PSO)用于解决微电网中的混合整数非线性规划(Mixed Integer Nonlinear Programming, MINLP)问题^[9]。为了开发纠正策略并执行最少的成本分配，文献[10]提出了一种改进的蝙蝠优化算法对多目标进行优化。此外，神经网络已被广泛用于处理约束优化问题，例如线性规划、非线性规划等^[11-12]。但是上述算法均受限于数量较多的目标函数，即使通过各种方法对算法进行优化，依旧存在计算量较大的问题。

针对上述问题，提出了一种考虑需求响应的微电网分布式神经动力学多目标优化算法。应用单目标积公式将多目标优化问题转换为单目标优化问题，另外在分布式神经动力学算法中引入对数障碍物惩罚因子，有效处理不等式约束，最后仿真结果验证了所提出算法的有效性。

1 优化问题描述

考虑一个连接到主电网的微电网模型，包括图1所示的光伏发电机(PV)和用户负载。该问题由四个相互矛盾的目标函数组成：柴油发电机(DG)单元的平均效率函数、微电网的排放、对需求响应的不满意度以及总利润函数。目标函数表示为 $F_i(x)$ ，而 i 表示第 i 个目标。

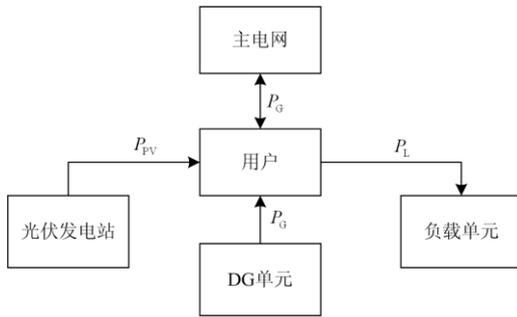


图1 Microgrid structure
Fig. 1 Microgrid structure

在该单元中，考虑了平均效率函数 $F_i(x)$ ，具体表达式如式(1)所示^[13]。

$$F_1(p_{DG}(t)) = \frac{1}{T} \sum_{t=1}^T \left(\frac{3600}{35000} \cdot p_{DG}(t) \right) \left(a \cdot p_{DG}(t)^2 + b \cdot p_{DG}(t) + c \right) \quad (1)$$

DG 单元的约束为

$$p_{DG}^{\min}(t) \leq p_{DG}(t) \leq p_{DG}^{\max}(t) \quad (2)$$

式中： $p_{DG}(t)$ 为 DG 单元的发电功率； a 、 b 和 c 为 DG 单元的二次成本函数的系数。该目标函数的图像由图2给出，该图表明它是域范围内的上凸函数。

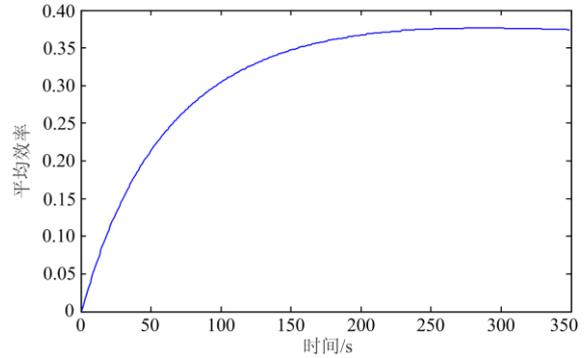


图2 平均效率曲线

Fig. 2 Average efficiency curve

在这个单元中，环境污染物是必须考虑的目标。值得一提的是，目标函数涉及三种最重要的污染物： $F_2(p_{DG}(t), p_G(t))$ 中的 CO_2 (二氧化碳)、 SO_2 (二氧化硫)和 NO_x (氮氧化物)^[14]。目标函数如式(3)所示。

$$F_2(p_{DG}(t), p_G(t)) = \sum_{i=1}^T \sum_{j=1}^N (E_{DGj} \cdot p_{DG}(t) + E_{Gj} \cdot p_G(t)) \quad (3)$$

约束应考虑

$$p_G^{\min}(t) \leq p_G(t) \leq p_G^{\max}(t) \quad (4)$$

式中： E_{DGj} 和 E_{Gj} 为每个发电机的污染物排放量；

p_G 为微电网和主电网之间交换的发电量。

对于需求响应，它是微电网中的重要部分，会对负荷单元造成极大的影响，因此，不满意度函数可以用于权衡需求响应对负荷单元的影响。当微电网所提供的电力达到额定电力时，用户的不满意度是最低的，而当所提供的电力低于或高于额定电力时，用户可能会因为不满足基本需求或浪费多余的电力而变得不满意。因此，该不满意度可以拟合为以下二次函数。

$$F_3(p_L(t)) = \frac{1}{T} \sum_{t=1}^T \varepsilon \cdot (p_L(t) - p_{SL}(t))^2 \quad (5)$$

约束是

$$p_L^{\min}(t) \leq p_L(t) \leq p_L^{\max}(t) \quad (6)$$

式中： ε 为弹性指数； $F_3(p_L)$ 为向下凸函数； p_{SL} 为最舒适的负载； p_L 为需求响应后的负载。

众所周知，需求响应通常被定义为小型消费者参与电力市场面临的市场现货价格并做出的回应^[15]。通常，需求响应的方法可以分为两种方案：基于激励的需求响应和基于时间的需求响应。在本节中，提出了一种基于弹性激励的需求模型如式(7)所示。

$$\Delta p_L(t) = p_{BL}(t) - p_L(t) \quad (7)$$

式中： $\Delta p_L(t)$ 为需求响应后的减负荷量； p_{BL} 为没有需求响应的负荷。

$$f_1(p_L(t)) = \sum_{t=1}^T \beta \cdot (\Delta p_{DR}(t) - \Delta p_L(t)) \quad (8)$$

β 的值是由市场运营商确定的, 这意味着为每个减荷单元 Δp_{DR} 支付给荷重单元的金额是需求响应合同中指定的减荷额。通常, 该系数被认为是需求响应之前电价的 0.1 至 10 倍, 当需求响应后的减负荷量未达到协议规定的减负荷量时, 负荷单元应当因违反规定而处以罚款, 相反, 负荷单元将被改写^[16]。

另外, 应考虑 DG 单元的二次成本函数。

$$f_2(p_{DG}(t)) = \sum_{t=1}^T (a \times p_{DG}(t)^2 + b \times p_{DG}(t) + c) \quad (9)$$

如上所述, a 、 b 和 c 表示 DG 单元的二次成本函数的系数。

为了平衡微电网中的电力供应并获得多余的利益, 微电网连接到电网^[17]。利润函数描述如式(10)所示。

$$f_3(p_G(t)) = \sum_{t=1}^T E_{price} \cdot p_G(t) \quad (10)$$

$E_{price} \cdot p_G(t)$ 可以为正或负。例如, $p_G(t) < 0$ 表示从微电网到电网的功率输出, 相反, $p_G(t) > 0$ 表示从电网到微电网的功率输入。总之, 总利润函数可以描述如式(11)所示。

$$F_4(p_L(t), p_{DG}(t), p_G(t)) = f_1(p_L(t)) + f_2(p_{DG}(t)) + f_3(p_G(t)) \quad (11)$$

目标 $F_4(p_L(t), p_{DG}(t), p_G(t))$ 是 DG 单元的成本、需求响应的改写/罚款和 PCC 链接单元罚款的总和。除了上面讨论的不同单元的单约束外, 还应考虑功率平衡约束:

$$p_{DG}(t) - p_L(t) + p_G(t) + p_{PV}(t) = 0 \quad (12)$$

因此, 多目标问题可以写为

$$\begin{cases} \min_{P_1, P_2, P_3, P_4} \{-F_1(P_1), F_2(P_2), F_3(P_3), F_4(P_4)\} \\ \text{s.t. 式(2), 式(4), 式(6), 式(12)} \end{cases} \quad (13)$$

式中: $P_i = [p_{DG}(1), \dots, p_{DG}(T), p_L(1), \dots, p_L(T), p_G(1), \dots, p_G(T)]^T$, 表示决策变量; $[\cdot]^T$ 表示转置向量。因为所有目标和约束集都是凸的, 所以整个问题也是凸的。因为在建模中要求 P_i 是一致的, 所以问题式(13)可以转换为

$$\begin{cases} \min_P \{-F_1(P), F_2(P), F_3(P), F_4(P)\} \\ \text{s.t. 式(2), 式(4), 式(6), 式(12)} \end{cases} \quad (14)$$

2 单目标积公式

由于多目标问题的数量增加, 因此多目标问题的计算难度不断提高^[18]。在本节中, 将引入单目标积公式, 从而将多目标问题转换为单目标问题, 找到多目标问题的解决方案^[19]。

定义 1^[20] 假设 \mathbf{a} 、 $\mathbf{b} \in \Omega$ 是两个决策向量。然后有以下定义:

1) $\mathbf{a} \preceq \mathbf{b}$ (\mathbf{a} 弱支配 \mathbf{b}), 当且仅当对于所有 $i \in \{1, 2, \dots, n\}$ 时, $y_i(\mathbf{a}) \leq y_i(\mathbf{b})$ 。

2) $\mathbf{a} \prec \mathbf{b}$ (\mathbf{a} 支配 \mathbf{b}), 当且仅当对于至少有一个 $j \in \{1, 2, \dots, n\}$ 时, $\mathbf{a} \preceq \mathbf{b}$ 且 $y_j(\mathbf{a}) < y_j(\mathbf{b})$ 。

3) $\mathbf{a} \sim \mathbf{b}$ (\mathbf{a} 与 \mathbf{b} 无关), 当且仅当 \mathbf{a} 和 \mathbf{b} 不在同一时间相互支配。

定义 2^[21] 当且仅当不存在 $p \in \mathbf{P}$ 使得 $p \prec p^*$ 时, 点 $p^* \in \mathbf{P}$ 被称为全局帕累托最优。如果 \tilde{p} 是全局帕累托最优的, 则将 $\mathbf{Y}(p^*)$ 称为全局有效。

定义 3^[22] 当且仅当存在一些 $\alpha > 0$ 和 $\beta > 0$ 且其集合 $\{p \in C_\alpha(\tilde{p}) \cap \mathbf{P} : p \prec \tilde{p} \text{ and } \mathbf{Y}(p) \in C_\beta(\mathbf{Y}(\tilde{p}))\}$ 为空时, 点 $\tilde{p} \in \mathbf{P}$ 称为局部帕累托最优, 其中 $C_\alpha(\tilde{p})$ 代表半径为 α 的 \tilde{p} 附近的开球, 且 $C_\beta(\mathbf{Y}(\tilde{p}))$ 代表半径为 β 的 $\mathbf{Y}(\tilde{p})$ 附近的开球, 如果 \tilde{p} 是局部帕累托最优, 那么 $\mathbf{Y}(\tilde{p})$ 称为局部有效。

假设 $r \in \mathbf{R}^n$ 是目标空间中的参考点, 则问题可以表述为

$$\begin{cases} \mathbf{G} = \min_{P_1, P_2, P_3, P_4 \in P_D} - \prod_{i=1}^n ((r_i - F_i(\mathbf{P}))_+)^2 \\ \text{s.t. 式(2), 式(4), 式(6), 式(12)} \end{cases} \quad (15)$$

当且仅当满足以下条件时, \mathbf{G} 称为 r 处的单目标公式:

1) 如果 F 是在某个 $\tilde{P} \in \Omega$ 附近的 Lipschitz, 则 \mathbf{G} 是在某个 $\tilde{P} \in \Omega$ 附近的 Lipschitz^[23]。

2) 如果 F 是在某个 $\tilde{P} \in \Omega$ 上接近 Lipschitz 且 $\tilde{P} \in \Omega$ 组成 $F(\tilde{P}) \in r$ 的情况, 并且 $d \in T_p(\tilde{P})$ 使得 $F_i^0(\tilde{P}; d) < 0$ 对于 $i=1, 2, \dots, n$, 则 $\mathbf{G} < 0$, 其中 $F_i^0(\tilde{P}; d)$ 是广义方向导数, $T_p(\tilde{P})$ 是切线锥^[24]。

公式(15)也可以写成

$$\begin{cases} \mathbf{G} = \min_{P_1, P_2, P_3, P_4 \in P_D} \sum_{i=1}^n -2 \times \log(r_i - F_i(\mathbf{P}))_+ \\ \text{s.t. 式(2), 式(4), 式(6), 式(12)} \end{cases} \quad (16)$$

显然, 问题式(16)更适合于分布式算法以寻找优化点。转换后问题的解决方案也是一个帕累托最优点。

命题 1^[25] 如果 F_U 是一个凸集, 显然, 式(15) 是一个凸全局优化问题。

命题 2^[26] 如果存在向量 $r \in \mathbf{R}^p$, 则除了式(15) 的值小于零外, p 是式(15)的最优解。那么 p 是多目标问题的帕累托最优。参考点 $r = (\max F_1, \max F_2, \max F_3, \max F_4)$ 。因此, 可以通过提出的算法获得帕累托最优点。

至此, 复杂的多目标问题可以转换为简单的单目标问题。

3 分布式神经动力学算法

3.1 算法流程

所提方法的流程图如图 3 所示。该方法可以解决随着目标函数数量的增加而成比例增长的计算量问题。而且, 与智能算法相比, 分布式神经动力学算法具有保护用户隐私和促进硬件实现等诸多优点。

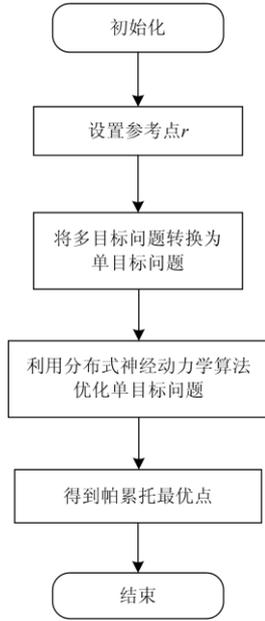


图 3 流程图

Fig. 3 Flow chart

问题式(16)可以简化如下:

$$\begin{cases} \min_{P_1, \dots, P_n} \left\{ \sum_{i=1}^n -2 \times \log(r_i - F_i(P_i))_+ \right\} \\ \text{s.t. } P_i \in \Omega_i \\ B_i P_i = d_i \\ (L \otimes I_m) P = \mathbf{0}_{nm} \end{cases} \quad (17)$$

其中 $P_i \in \mathbf{R}^m$ 并且 $P = [P_1^T, P_n^T]^T$ 代表决策向量, 而 $\log(r_i - F_i)_+$ 是第 i 个主体的凸目标函数。

$B = \text{diagonal}[B_1, \dots, B_n]$, 里面 $B_i = \mathbf{R}^{l \times m}$, 是指局部等式约束的系数矩阵。 $L = M - A$ 称为拉普拉斯矩阵, 表示每个主体的连接方式, 其中 $M = \sum_{j=1}^n a_{ij}$ 是对角矩阵, 而 $A = [a_{ij}] = \mathbf{R}^{n \times n}$ 是加权邻接矩阵, 另外, Ω_i 是相应决策向量的凸可行域。应考虑不同主体的重叠区域和决策向量的共同元素^[27-28]。利用对数障碍惩罚函数方法来处理盒约束, 从而可以将不等式约束隐藏在目标函数中。

$$\begin{cases} \min \sum_{i=1}^n (-2 \times \log(r_i - F_i(P_i))_+ - \varepsilon(\ln(P_i - P_i^{\min}) + \ln(P_i^{\max} - P_i))) \\ \text{s.t. } B_i P_i = d_i \\ (L \otimes I_m) P = \mathbf{0}_{nm} \end{cases} \quad (18)$$

可以将问题式(18)中的两个约束转换为全局相等约束。

$$\begin{cases} \min \sum_{i=1}^n (-2 \times \log(r_i - F_i(P_i))_+ - \varepsilon(\ln(P_i - P_i^{\min}) + \ln(P_i^{\max} - P_i))) \\ \text{s.t. } \sum_{i=1}^n W_i P_i - D = \mathbf{0} \end{cases} \quad (19)$$

式中: $D = [d_1, \dots, d_n, 0, \dots, 0_{nm}]^T$, $W = [W_1, \dots, W_n] = [B, L]^T$, $W_i \in \mathbf{R}^{(n+nm) \times m}$, 为了方便分布式处理, 问题式(19)的约束应以式(20)形式编写。

$$\begin{cases} \min \sum_{i=1}^n (-2 \times \log(r_i - F_i(P_i))_+ - \varepsilon(\ln(P_i - P_i^{\min}) + \ln(P_i^{\max} - P_i))) \\ \text{s.t. } \sum_{i=1}^n (W_i P_i - D_i) = \mathbf{0} \end{cases} \quad (20)$$

式中, $\sum_{i=1}^n D_i = D$ 。考虑到以上分析的问题式(20), 提出了一种分布式神经动力学算法。

$$\begin{cases} \dot{P}_i = -2 \times \frac{-\nabla F_i(P_i)}{r_i - F_i(P_i)} + W_i^T \lambda_i + \varepsilon \left(\frac{1}{P_i - P_i^{\min}} - \frac{1}{P_i^{\max} - P_i} \right) \\ \dot{\lambda}_i = D_i - W_i P_i - \sum_{j=1}^n (\lambda_i - \lambda_j) - \sum_{j=1}^n (z_i - z_j) \\ \dot{z}_i = \sum_{j=1}^n (\lambda_i - \lambda_j) \end{cases} \quad (21)$$

可以通过以下紧凑形式编写算法式(21)。

$$\begin{cases} \dot{P} = -2 \times \frac{-\nabla F(P)}{r - F(P)} + \bar{W}^T \lambda + \varepsilon Q \\ \dot{\lambda} = \bar{D} - \bar{W} P - \bar{L} \lambda - \bar{L} z \\ \dot{z} = \bar{L} \lambda \end{cases} \quad (22)$$

式中, $\bar{W} = \text{diagonal}\{W_1, W_2, \dots, W_n\}$, $\bar{L} = L_{nm} \otimes I_n$, $\bar{D} = \text{diagonal}[D_1, \dots, D_n]$, $\lambda = [\lambda_1^T, \lambda_2^T, \dots, \lambda_n^T]^T$, $Q =$

$$[\mathbf{Q}_1, \dots, \mathbf{Q}_n]^T = \left[\left(\frac{1}{\mathbf{P}_1^* - \mathbf{P}_1^{\min}} - \frac{1}{\mathbf{P}_1^{\max} - \mathbf{P}_1^*} \right), \dots, \left(\frac{1}{\mathbf{P}_n^* - \mathbf{P}_n^{\min}} - \frac{1}{\mathbf{P}_n^{\max} - \mathbf{P}_n^*} \right) \right]^T.$$

3.2 收敛性分析

定理^[29] 如果存在 $\{(\mathbf{P}^*, \lambda^*, \mathbf{Z}^*) \in \mathbf{R}^{3 \times n} \mid \mathbf{P}^* = 0, \lambda^* = 0, \mathbf{Z}^* = 0\}$, 算法式(22)的状态收敛到最优解。

证明 设问题式(19)的目标函数为 $\sum_{i=1}^n (\mathbf{Y}_i(\mathbf{P}_i) - \varepsilon \mathbf{Q}_i)$, 其中 $\mathbf{Y}_i(\mathbf{P}_i) = -2 \times \log(r_i - \mathbf{F}_i(\mathbf{P}))_+$ 和 $\mathbf{Q}_i = \left[\frac{1}{\mathbf{P}_i - \mathbf{P}_i^{\min}} - \frac{1}{\mathbf{P}_i^{\max} - \mathbf{P}_i} \right]$ 。问题式(19)的对偶拉格朗日函数为

$$\mathbf{h} = \inf_{\mathbf{P} \in \Omega} \left\{ \sum_{i=1}^n (\mathbf{Y}_i(\mathbf{P}_i) - \varepsilon \mathbf{Q}_i) - \mathbf{A} \left(\sum_{i=1}^n \mathbf{W}_i \mathbf{P}_i - \mathbf{D} \right) \right\} \quad (23)$$

其中 $\mathbf{A} \in \mathbf{R}^{1 \times (n+nm)}$ 是 $\sum_{i=1}^n \mathbf{W}_i \mathbf{P}_i - \mathbf{Q}$ 的乘数。同样, 问题式(20)的对偶拉格朗日函数为

$$\mathbf{h}_2 = \inf_{\mathbf{P}_i \in \Omega} \left\{ \sum_{i=1}^n (\mathbf{Y}_i(\mathbf{P}_i) - \varepsilon \mathbf{Q}_i) - \sum_{i=1}^n \lambda_i^T (\mathbf{W}_i \mathbf{P}_i - \mathbf{D}_i) \right\} \quad (24)$$

如果问题式(19)获得最优解, 则当 $\bar{\mathbf{L}}\lambda = \mathbf{0}$ 时, 对于 $\mathbf{h}_1 = \mathbf{h}_2$ 且 $\mathbf{A} \left(\sum_{i=1}^n \mathbf{W}_i \mathbf{P}_i - \mathbf{D} \right) = \sum_{i=1}^n \mathbf{A}(\mathbf{W}_i \mathbf{P}_i - \mathbf{D}_i) = \sum_{i=1}^n \lambda_i^T (\mathbf{W}_i \mathbf{P}_i - \mathbf{D}_i)$, 问题式(19)等价于问题式(20)。考虑以下子问题:

$$\begin{cases} \min \mathbf{h}_2 = \inf_{\mathbf{P}_i \in \Omega} \left\{ \sum_{i=1}^n (\mathbf{Y}_i(\mathbf{P}_i) - \varepsilon \mathbf{Q}_i) - \sum_{i=1}^n \lambda_i^T (\mathbf{W}_i \mathbf{P}_i - \mathbf{D}_i) \right\} \\ \text{s.t. } \bar{\mathbf{L}}\lambda = \mathbf{0} \end{cases} \quad (25)$$

该子问题的对偶函数为

$$\begin{cases} \mathbf{h}_3 = \inf_{\mathbf{Z}} \left\{ \inf_{\mathbf{P}_i \in \Omega} \left(\sum_{i=1}^n (\mathbf{Y}_i(\mathbf{P}_i) - \varepsilon \mathbf{Q}_i) - \sum_{i=1}^n \lambda_i^T (\mathbf{W}_i \mathbf{P}_i - \mathbf{D}_i) - \mathbf{Z}^T \bar{\mathbf{L}}\lambda - \frac{1}{2} \lambda^T \bar{\mathbf{L}}\lambda \right) \right\} \end{cases} \quad (26)$$

式中, \mathbf{Z} 是 $\mathbf{L}\lambda = \mathbf{0}$ 的乘数。 \mathbf{h}_3 的解也是问题式(19)的 Karush-Kuhn-Tucker 点(KKT 点)^[30]。此外, 基于以上描述和讨论, 问题式(19)等价于问题式(20), 而 $\bar{\mathbf{L}}\lambda = \mathbf{0}$ 。由于 $(\mathbf{P}^*, \lambda^*, \mathbf{Z}^*)$ 是系统式(22)的平衡点, 因此

$$\begin{cases} \bar{\mathbf{L}}\lambda^* = \mathbf{0} \\ -\bar{\mathbf{L}}\lambda^* - \bar{\mathbf{L}}\mathbf{Z}^* - (\bar{\mathbf{W}}\mathbf{P} - \bar{\mathbf{D}}) = \mathbf{0} \end{cases} \quad (27)$$

为了方便推导, 令 $\nabla \mathbf{G} = -\nabla \mathbf{Y}(\mathbf{P}) + \varepsilon \mathbf{Q}$, $\nabla \mathbf{G}^* = -\nabla \mathbf{Y}(\mathbf{P}) + \varepsilon^* \mathbf{Q}$, $\mathbf{C}^* = -\nabla \mathbf{Y}(\mathbf{P}) + \varepsilon \mathbf{Q}^* + \bar{\mathbf{W}}^T \lambda^*$,

Lyapunov 函数如下:

$$\mathbf{V} = \frac{1}{2} \|\mathbf{P} - \mathbf{P}^*\|_2^2 + \frac{1}{2} \|\lambda - \lambda^*\|_2^2 + \frac{1}{2} \|\mathbf{Z} - \mathbf{Z}^*\|_2^2 \quad (28)$$

那么 \mathbf{V} 的导数是:

$$\begin{aligned} \dot{\mathbf{V}} = & (\nabla \mathbf{G} + \bar{\mathbf{W}}^T \lambda, \mathbf{P} - \mathbf{P}^*) + (-\bar{\mathbf{L}}\lambda - \bar{\mathbf{L}}\mathbf{Z} - \\ & (\bar{\mathbf{W}}\mathbf{P} - \bar{\mathbf{D}}), \lambda - \lambda^*) + (\bar{\mathbf{L}}\lambda, \mathbf{Z} - \mathbf{Z}^*) = \\ & (\nabla \mathbf{G} + \bar{\mathbf{W}}^T \lambda + \mathbf{C} - \mathbf{C}^*, \mathbf{P} - \mathbf{P}^*) - \\ & (\bar{\mathbf{L}}(\lambda - \lambda^*), \lambda - \lambda^*) - (\bar{\mathbf{L}}\lambda^*, \lambda - \lambda^*) - \\ & (\bar{\mathbf{L}}(\mathbf{Z} - \mathbf{Z}^*), \lambda - \lambda^*) - (\bar{\mathbf{L}}\mathbf{Z}^*, \lambda - \lambda^*) - \\ & (\bar{\mathbf{W}}\mathbf{P} - \bar{\mathbf{D}}, \lambda - \lambda^*) + (\bar{\mathbf{L}}\lambda, \mathbf{Z} - \mathbf{Z}^*) = \\ & (\nabla \mathbf{G} - \nabla \mathbf{G}^*, \mathbf{P} - \mathbf{P}^*) + (\bar{\mathbf{W}}^T (\lambda - \lambda^*), \mathbf{P} - \mathbf{P}^*) + \\ & (\mathbf{C}^*, \mathbf{P} - \mathbf{P}^*) - (\bar{\mathbf{L}}(\lambda - \lambda^*), \lambda - \lambda^*) - \\ & (\bar{\mathbf{L}}(\mathbf{Z} - \mathbf{Z}^*), \lambda - \lambda^*) + (\bar{\mathbf{L}}(\lambda - \lambda^*), \mathbf{Z} - \mathbf{Z}^*) - \\ & (\bar{\mathbf{W}}\mathbf{P} - \bar{\mathbf{D}}, \lambda - \lambda^*) = (\nabla \mathbf{G} - \nabla \mathbf{G}^*, \mathbf{P} - \mathbf{P}^*) + \\ & (\mathbf{C}^*, \mathbf{P} - \mathbf{P}^*) - (\bar{\mathbf{L}}(\lambda - \lambda^*), \lambda - \lambda^*) \leq \\ & \mathbf{F}(\mathbf{P}^*) - \mathbf{F}(\mathbf{P}) - (\bar{\mathbf{L}}(\lambda - \lambda^*), \lambda - \lambda^*) \leq 0 \end{aligned} \quad (29)$$

问题式(19)点集满足系统式(22)中的 $\dot{\mathbf{V}} = 0$ 名称 $\mathbf{Z}_V = \{(\mathbf{P}, \lambda, \mathbf{Z}) \mid \dot{\mathbf{V}} = 0\}$ 。对于 $\mathbf{L}\lambda^* = 0$, λ^* 是属于 $\bar{\mathbf{L}}$ 的零空间, 则

$$\mathbf{K}_V = \left\{ (\mathbf{P}, \lambda, \mathbf{Z}) \mid \mathbf{P} = \mathbf{P}^*, \lambda = \lambda^* = \alpha \mathbf{I}_n, \alpha \in \mathbf{R}^{n+nm} \right\} \quad (30)$$

而 $\mathbf{Z} = \mathbf{Z}^*$, $\dot{\lambda} = -(\bar{\mathbf{W}}\mathbf{P} - \bar{\mathbf{D}}) - \bar{\mathbf{L}}\mathbf{Z}^*$ 而 $\lambda^* = \alpha \mathbf{I}_n$, $\alpha \in \mathbf{R}^{n+nm}$ 。

从 Lasalle 不变性定理和 Lyapunov 稳定性可以得出结论, 系统式(22)将在平衡点处保持稳定。

$$\left\{ (\mathbf{P}, \lambda, \mathbf{Z}) \mid \dot{\mathbf{P}} = 0, \dot{\lambda} = 0, \dot{\mathbf{Z}} = 0 \right\} \quad (31)$$

4 仿真分析

考虑了第 3.1 节中提到的 4 个目标函数, 以在线性等式和不等式约束内找到最优解。在微电网中, 与主电网交换的价格 $\mathbf{E}_{\text{price}}$ 是固定的。对于需求响应单元, 由于提出的策略是通过在实际电力消耗低于指定的电力消耗 $\mathbf{P}_{\text{BL}}(t)$ 时进行奖励或对违规行为进行惩罚的方法调整用电量 \mathbf{P}_L , 因此, $\mathbf{P}_{\text{BL}}(t)$ 也是已知数量的。此外, 二次成本函数的系数 a 、 b 和 c 以及二氧化碳、二氧化硫和氮氧化物的排放指数都可以从以前的文献中找到。为了便于参考, 在表 1 和表 2 中专门给出了实验中使用的数据。仿真中的参考点 $\mathbf{R} = (\max \mathbf{F}_1, \max \mathbf{F}_2, \max \mathbf{F}_3, \max \mathbf{F}_4)$ 在仿真中非常重要。

表 1 实验数据

Table 1 Experiment data

时间段	06:00-10:00	10:00-14:00	14:00-18:00
P_{PV}/MW	4	20	12
P_{SL}/MW	30	40	30
$E_{price}/(元/kWh)$	2	3	2

表 2 各微电网的参数

Table 2 Parameters of each microgrid

单元	a	b	c	CO ₂	SO ₂	NO _x	P_{min}	P_{max}
DG	0.000 177 3	0.170 9	14.67	489	0.103	0.064	0	350
P_L	0	0	0	0	0	0	0	100
P_G	0	0	0	724.105	0.127	0.004	-200	200

从图 4 中可知, 该优化算法使得三个参数均能够在有效时间内趋于稳定状态。显然, 优化变量最终收敛到满足局部不平等约束和全局平等约束的最优解。说明本文提出的方法保证了优化变量收敛性。

应用控制理论中的调节时间概念来评价各个时间段内的优化时间, 规定只要被控变量进入新的稳态值的-5%~5%, 而且不再越出时为止所经历的最短时间为调节时间^[31]。三个时间段的优化调节时间如图 4 所示, 在不同时间段内, 由于优化的条件因素均不相同, 所以调节时间与优化结果不同, 但是整体时间均比较稳定, 且均能较快地收敛, 说明该算法在不同条件下均能够保持较好的优化性能。另外通过与其他多目标优化算法的优化时间对比可知, 提出的算法能够大大降低调节时间。通过对算法收敛性的分析可知, 除了满足变量的一致性外, 算法还需要满足状态的一致性。为了便于观察, 在图 5 中分别列出了每个时间段的状态, 从图中可知所有

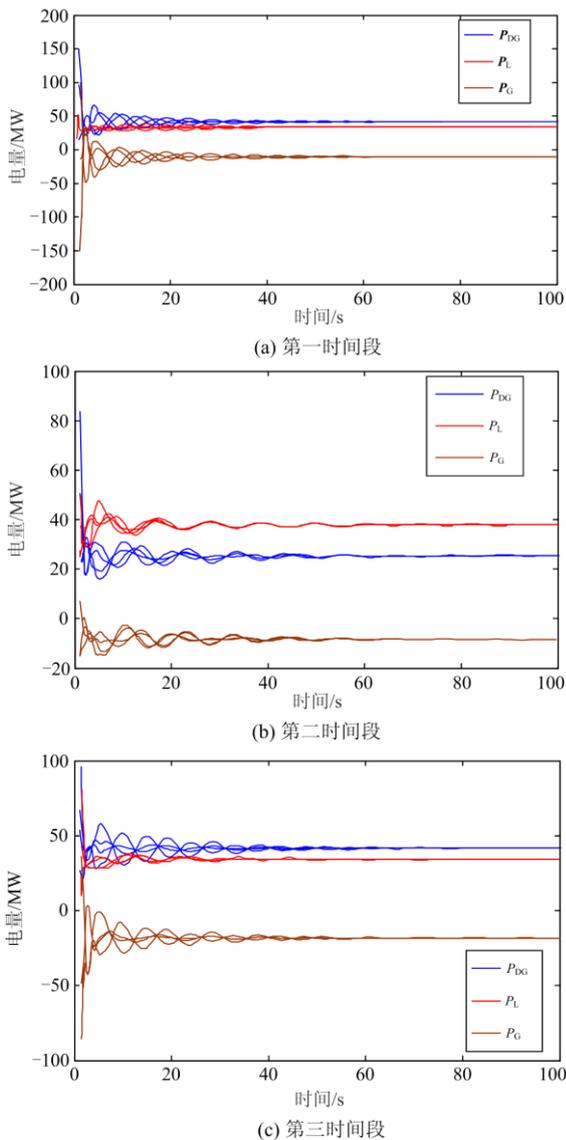
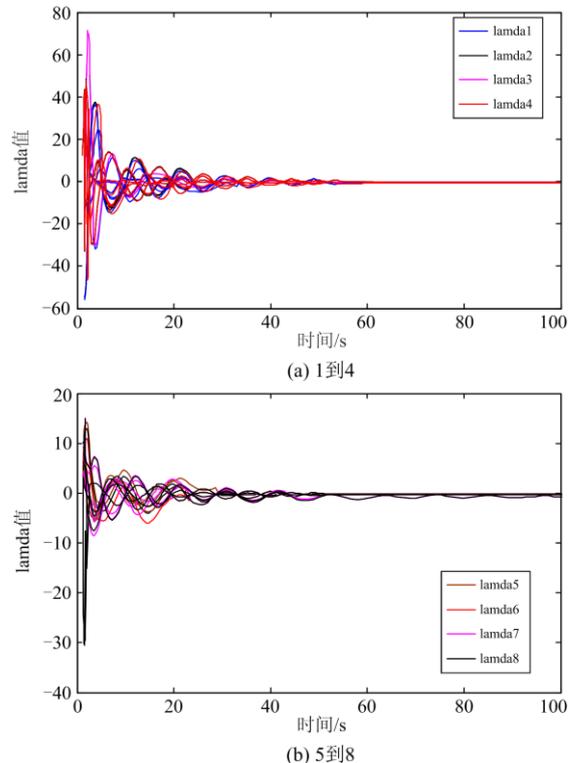
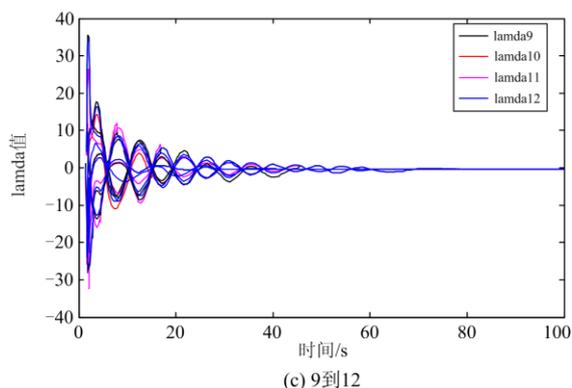


图 4 每个单元每个时间段的发电量和消耗电量图

Fig. 4 Power generation and consumption of each unit in each time period



(b) 5到8

图5 乘数 λ 的收敛曲线Fig. 5 Convergence curve of multiplier λ

的状态均能够满足有限时间收敛。进一步验证了该多目标优化算法的可行性。

表3显示了三个时间段条件下不同方法的调节

表3 优化性能对比

Table 3 Comparison of optimized performance

方法	DGA	PSO 算法	蝙蝠优化算法	非线性规划	所提方法	
P_{DG} 调节时间/s	第一段	88.8	90.6	108.2	106.3	31.5
	第二段	102.5	116.3	135.8	126.6	41.6
	第三段	98.5	95.6	122.5	109.6	42.6
	平均值	96.6	100.8	122.2	114.2	38.6
P_G 调节时间/s	第一段	99.6	96.5	144.6	129.6	34.8
	第二段	92.6	106.6	122.1	136.9	38.9
	第三段	97.4	113.3	131.6	125.8	41.2
	平均值	96.5	105.5	132.8	130.8	38.3
P_L 调节时间/s	第一段	49.6	67.8	81.5	90.6	35.6
	第二段	93.5	96.6	144.6	135.6	38.8
	第三段	98.5	69.6	75.9	88.6	26.6
	平均值	80.5	78.0	100.7	104.9	22.9
目标函数值	第一段	286.8	198.8	246.6	321.3	182.9
	第二段	373.9	183.3	255.3	311.6	223.5
	第三段	323.9	219.5	296.3	362.2	211.6
	平均值	328.2	200.5	266.1	331.7	205.9

表4 多目标优化性能对比

Table 4 Comparison of multi-optimized performance

目标	DGA	PSO 算法	蝙蝠优化算法	非线性规划	提出的方法
$-F_1$	128.5	105.6	118.2	109.6	92.6
F_2	88.6	98.6	78.6	99.2	77.5
F_3	66.6	58.8	92.2	54.5	55.5
F_4	182.3	195.5	208.6	176.5	112.5

另外, 相对于其他几种多目标优化方法, 所提方法的 DG 单元发电量 $P_{DG}(t)$ 、消耗电量 $P_L(t)$ 以及与主电网之间交换电量 $P_G(t)$ 的平均调节时间与其他

时间大小与式(16)目标函数中的 G 对比。图6和图7利用柱状图显示了各个方法的时间成本与目标函数优化值对比。进一步证明了本文提出的优化方法在优化效果上的优势。

可以看出, 本文提出的方法对目标函数的优化平均值明显优于 DGA 方法、蝙蝠优化算法以及非线性规划方法, 在优化精度上与比较成熟的 PSO 算法相当^[32], 说明本文提出的算法能够保证良好的优化精度, 验证了本文优化算法的可靠性。

除此之外, 已知多目标优化如式(14)所示, 即最终目标不仅是使得目标函数最小, 而且要使得 $\min_P\{-F_1(P), F_2(P), F_3(P), F_4(P)\}$, 因此, 表4显示了各个方法条件下的多目标优化结果, 从表中可以发现所提出的方法相对于其他方法来说 $-F_1, F_2, F_4$ 均最小, 且 F_3 也十分接近最小值, 综合考虑下, 本文提出的方法拥有更好的多目标优化效果。

几种算法中最短的调节时间相比仍旧降低了 60.1%、61.3%、70.6%, 说明了本文提出的算法能够大大减少计算复杂度, 使得该多目标优化问题

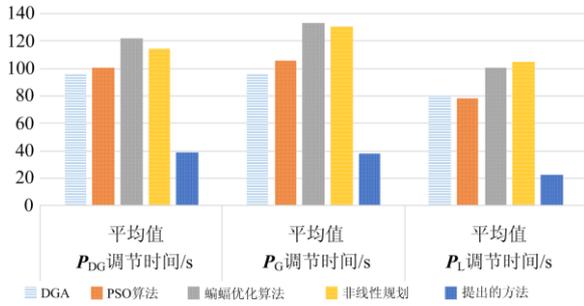


图 6 调节时间对比

Fig. 6 Comparison of adjustment time

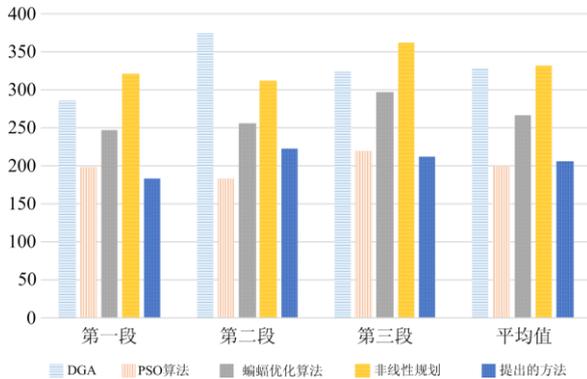


图 7 目标函数值对比

Fig. 7 Comparison of objective function values

减少约束, 大大提升收敛速度。虽然 PSO 算法相对于所提算法在优化精度上有着微小的优势, 但是其在调节时间上的巨大劣势使得该算法与所提算法相比没有竞争性。通过分析原因可知: 一方面, 由于其他优化算法本质上属于试凑对比循环, 因此容易陷入局部最优等问题, 导致了优化精度的降低与调节时间的增加; 另一方面, 多次的循环对比替换过程也会使得计算量有所增大。相比较而言, 所提方法则有效地解决了上述问题。

5 结论

本文提出了一种考虑需求响应的微电网分布式神经动力学优化算法。通过仿真结果分析可得如下结论:

(1) 提出的算法能够保证算法的收敛性与稳定性, 从而可以有效地得到多目标优化算法的最优解。

(2) 提出的分布式神经动力学算法可以有效地减少多目标优化的计算量, 大大降低调节时间, 从而避免了其他算法容易陷入局部最优的缺点。

(3) 提出的多目标优化算法在优化精度上与其他算法均相当, 进一步证明了本文多目标优化算法既能够保证优化精度, 还能大大提升收敛速度, 减少计算成本。

本文只考虑了一种分布式微电网结构, 下一步研究需要进一步考虑更具普遍性的微电网模型; 另外, 本文仅通过仿真验证了所提方法, 下一步需要通过多种仿真方法以及实验实现方法的验证才更具说服力。

参考文献

- [1] 陆立民, 褚国伟, 张涛, 等. 基于改进多目标粒子群算法的微电网储能优化配置[J]. 电力系统保护与控制, 2020, 48(15): 116-124.
- [2] LU Limin, CHU Guowei, ZHANG Tao, et al. Energy storage optimal allocation of microgrid based on improved multi-objective particle swarm optimization algorithm[J]. Power System Protection and Control, 2020, 48(15): 116-124.
- [3] 杨斌, 杨世海, 曹晓冬, 等. 基于 EMD-QRF 的用户负荷概率密度预测[J]. 电力系统保护与控制, 2019, 47(16): 1-7.
- [4] YANG Bin, YANG Shihai, CAO Xiaodong, et al. Probability density prediction of user load based on emd-qrff[J]. Power System Protection and Control, 2019, 47(16): 1-7.
- [5] 刘翊枫, 周国鹏, 刘昕, 等. 基于智能相似日识别及偏差校正的短期负荷预测方法[J]. 电力系统保护与控制, 2019, 47(12): 138-145.
- [6] LIU Yifeng, ZHOU Guopeng, LIU Xin, et al. Short term load forecasting method based on Intelligent similar day recognition and deviation correction[J]. Power System Protection and Control, 2019, 47(12): 138-145.
- [7] PELIKAN E, EBEN K, RESLER J, et al. Wind power forecasting by an empirical model using NWP outputs[C] // International Conference on Environment and Electrical Engineering, May 16-19, 2010 Prague, Czech Republic: 45-48.
- [8] 杨俊伟, 史旺旺. 交流电流直接控制的单相 PWM 整流器非线性控制策略[J]. 电工技术学报, 2018, 43(20): 114-118.
- [9] YANG Junwei, SHI Wangwang. Nonlinear control strategy for direct AC current control in single-phase PWM rectifier[J]. Transactions of China Electrotechnical Society, 2018, 43(20): 114-118.
- [10] CASSOLA F, BURLANDO M. Wind speed and wind energy forecast through Kalman filtering of numerical weather prediction model output[J]. Applied Energy, 2018, 99: 154-166.
- [11] 陈妮亚, 钱政, 孟晓风, 等. 基于空间相关法的风电场风速多步预测模型[J]. 电工技术学报, 2018, 28(5): 15-21.
- [12] CHEN Niya, QIAN Zheng, MENG Xiaofeng, et al.

- Multi-step ahead wind speed forecasting model based on spatial correlation and support vector machine[J]. Transactions of China Electrotechnical Society, 2018, 28(5): 15-21.
- [8] 王德明, 王莉, 张广明. 基于遗传 BP 神经网络的短期风速预测模型[J]. 浙江大学学报: 工学版, 2018, 46(5): 837-842.
WANG Deming, WANG Li, ZHANG Guangming. Short-term wind speed forecast model for wind farms based on genetic BP neural network[J]. Journal of Zhejiang University: Engineering Science, 2018, 46(5): 837-842.
- [9] 武小梅, 白银明, 文福拴. 基于 RBF 神经网络的风电功率短期预测[J]. 现代电力, 2019, 47(15): 80-83.
WU Xiaomei, BAI Yinming, WEN Fushuan. Short-term wind power forecast based on the radial basis function neural network[J]. Modern Electric Power, 2019, 47(15): 80-83.
- [10] BAHMAN F, AZZIP R. Optimal sizing of battery energy storage for micro-grid operation management using a new improved bat algorithm[J]. International Journal of Electric Power Energy Systems, 2018, 60(6): 42-54.
- [11] 何东, 刘瑞叶. 基于主成分分析的神经网络动态集成风功率超短期预测[J]. 电力建设, 2018, 41(4): 50-54.
HE Dong, LIU Ruiye. Ultra-short-term wind power prediction using ANN ensemble based on the principal components analysis[J]. Electric Power Construction, 2018, 41(4): 50-54.
- [12] 刘建华, 李锦程, 杨龙月, 等. 基于 EMD-SLSTM 的家庭短期负荷预测[J]. 电力系统保护与控制, 2019, 47(6): 40-47.
LIU Jianhua, LI Jincheng, YANG Longyue, et al. Short term household load forecasting based on EMD-SLSTM[J]. Power System Protection and Control, 2019, 47(6): 40-47.
- [13] 张玲玲, 杨明玉, 梁武. 基于相似日和 LS-SVM 的微网短期负荷预测[J]. 电力建设, 2018, 35(11): 32-37.
ZHANG Lingling, YANG Mingyu, LIANG Wu. Short term load forecasting of microgrid based on similar day and LS-SVM[J]. Electric Power Construction, 2018, 35(11): 32-37.
- [14] 荀港益. 基于聚类分析与随机森林的短期负荷滚动预测[J]. 智能城市, 2018, 4(9): 9-11.
XUN Gangyi. Short term load rolling prediction based on cluster analysis and random forest[J]. Smart City, 2018, 4(9): 9-11.
- [15] 张政国, 吴延增. 基于遗传算法优化 LS-SVM 的短期电力负荷预测研究[J]. 兰州交通大学学报, 2019, 31(6): 44-48.
ZHANG Zhengguo, WU Yanzen. Research on short-term power load forecasting based on genetic algorithm optimization LS-SVM[J]. Journal of Lanzhou Jiaotong University, 2019, 31(6): 44-48.
- [16] 周璇, 迟慧. 基于优化回声状态网络的短期电力负荷预测[J]. 工业控制计算机, 2018(10): 3-5.
ZHOU Xuan, CHI Hui. Short term power load forecasting based on optimized echo state network[J]. Industrial Control Computer, 2018(10): 3-5.
- [17] 翟帅华, 姜云腾, 李萍. 基于改进 PSO-BP 神经网络的短期电力负荷预测[J]. 工业控制计算机, 2018, 31(9): 145-147.
ZHAI Shuaihua, JIANG Yunteng, LI Ping. Short term power load forecasting based on improved PSO-BP neural network[J]. Industrial Control Computer, 2018, 31(9): 145-147.
- [18] 张素香, 赵丙镇, 王风雨, 等. 海量数据下的电力负荷短期预测[J]. 中国电机工程学报, 2015, 35(1): 37-42.
ZHANG Suxiang, ZHAO Bingzhen, WANG Fengyun, et al. Short term prediction of power load based on massive data[J]. Proceedings of the CSEE, 2015, 35(1): 37-42.
- [19] 马哲, 舒勤. 基于 ESPRIT 分解算法的短期电力负荷预测[J]. 仪器仪表学报, 2018, 43(7): 90-96.
MA Zhe, SHU Qin. Short term power load forecasting based on Esprit decomposition algorithm[J]. Journal of Instrumentation, 2018, 43(7): 90-96.
- [20] 张淑清, 任爽, 师荣艳, 等. 基于多变量气象因子的 LMBP 电力日负荷预测[J]. 仪器仪表学报, 2018, 36(7): 1646-1652.
ZHANG Shuqing, REN Shuang, SHI Rongyan, et al. LMBP daily load forecasting based on multivariate meteorological factors[J]. Journal of Instrumentation, 2018, 36(7): 1646-1652.
- [21] 李霄, 王昕, 郑益慧, 等. 基于改进最小二乘支持向量和预测误差校正的短期风电负荷预测[J]. 电力系统自动化, 2018, 43(11): 63-69.
LI Xiao, WANG Xin, ZHENG Yihui, et al. Short term wind power load forecasting based on improved least square support vector machine and prediction error correction[J]. Automation of Electric Power Systems, 2018, 43(11): 63-69.
- [22] 肖白, 聂鹏, 穆钢, 等. 基于多级聚类分析和支持向量的空间负荷预测方法[J]. 电力系统自动化, 2018, 39(12): 56-61.
XIAO Bai, NIE Peng, MU Gang, et al. Spatial load forecasting method based on multilevel clustering analysis and support vector machine[J]. Automation of Electric Power Systems, 2018, 39(12): 56-61.
- [23] 王贺, 胡志坚, 张翌晖, 等. 基于聚类经验模态分解和

- 最小二乘支持向量机的短期风速组合预测[J]. 电工技术学报, 2014, 29(4): 237-245.
- WANG He, HU Zhijian, ZHANG Yihui, et al. Short term wind speed combination prediction based on clustering empirical mode decomposition and least squares support vector machine[J]. Transactions of China Electrotechnical Society, 2014, 29(4): 237-245.
- [24] 田中大, 高宪文, 石彤. 用于混沌时间序列预测的组合核函数最小二乘支持向量机[J]. 物理学报, 2019, 63(16): 70-80.
- TIAN Zhongda, GAO Xianwen, SHI Tong. Combined kernel least squares support vector machine for chaotic time series prediction[J]. Acta physica Sinica, 2019, 63(16): 70-80.
- [25] 顾燕萍, 赵文杰, 吴占松. 最小二乘支持向量机鲁棒回归算法研究[J]. 清华大学学报: 自然科学版, 2018, 55(4): 396-402.
- GU Yanping, ZHAO Wenjie, WU Zhansong. Research on robust regression algorithm of LSSVM[J]. Journal of Tsinghua University: Natural Science Edition, 2018, 55(4): 396-402.
- [26] 张志, 杜延菱, 崔慧军, 等. 考虑关联因素的智能化中长期电力负荷预测方法[J]. 电力系统保护与控制, 2019, 47(2): 24-30.
- ZHANG Zhi, DU Yanling, CUI Huijun, et al. Intelligent medium and long term load forecasting method considering correlation factors[J]. Power System Protection and Control, 2019, 47(2): 24-30.
- [27] 席雅雯, 吴俊勇, 石琛, 等. 融合历史数据和实时影响因素的精细化负荷预测[J]. 电力系统保护与控制, 2019, 47(1): 80-87.
- XI Yawen, WU Junyong, SHI Chen, et al. Fine load forecasting integrating historical data and real-time influencing factors[J]. Power System Protection and Control, 2019, 47(1): 80-87.
- [28] 刘星, 崔双喜. 孤岛与重构相配合的配电网故障恢复策略[J]. 华电技术, 2020, 42(1): 29-34.
- LIU Xing, CUI Shuangxi. Fault recovery strategy for distribution network with isolated island and reconfiguration[J]. Huadian Technology, 2020, 42(1): 29-34.
- [29] 赵会茹, 赵一航, 郭森. 基于互补集合经验模态分解和长短期记忆神经网络的短期电力负荷预测[J]. 中国电力, 2020, 53(6): 48-55.
- ZHAO Huiru, ZHAO Yihang, GUO Sen. short term load forecasting based on complementary ensemble empirical mode decomposition and long-term memory neural network[J]. Electric Power, 2020, 53(6): 48-55.
- [30] 马愿, 张倩, 李国丽, 等. 基于频域分解的短期负荷预测研究分析[J]. 中国电力, 2020, 53(4): 114-121.
- MA Yuan, ZHANG Qian, LI Guoli, et al. Short term load forecasting analysis based on frequency domain decomposition[J]. Electric Power, 2020, 53(4): 114-121.
- [31] 赵冠南, 李正豪. 火电机组负荷分配中多源不确定性因素影响分析[J]. 热力发电, 2020, 49(12): 114-119.
- ZHAO Guannan, LI Zhenghao. Influence analysis of multi-source uncertain factors in load distribution of thermal power units[J]. Thermal Power Generation, 2020, 49(12): 114-119.
- [32] 骆小满, 皇甫成, 阮江军, 等. 基于神经网络的热电联产机组热负荷和电负荷预测[J]. 热力发电, 2019, 48(9): 46-50.
- LUO Xiaoman, HUANGFU Cheng, RUAN Jiangjun, et al. Heat and power load forecasting of cogeneration unit based on neural network[J]. Thermal Power Generation, 2019, 48(9): 46-50.

收稿日期: 2020-08-11; 修回日期: 2020-09-30

作者简介:

刘青(1984—), 男, 硕士, 高级工程师, 主要从事高压电缆运维检修工作; E-mail: hemingtang999@163.com

赵洋(1979—), 男, 博士研究生, 高级工程师, 主要从事高压电缆和隧道运检管理、消防管理工作;

李宁(1983—), 男, 硕士, 高级工程师, 主要从事高压电缆运维检修工作技术研究。

(编辑 张爱琴)