

DOI:10.3969/j.issn.1674-1951.2021.08.011

基于强化学习及纵横交叉粒子群算法的电网 最优潮流计算

Optimal power flow calculation of power grid based on reinforcement learning and crisscross
PSO algorithm particle swarm optimization

孟安波, 王鹏*, 丁伟锋, 陈顺, 梁濡铎, 张铮

MENG Anbo, WANG Peng*, DING Weifeng, CHEN Shun, LIANG Ruduo, ZHANG Zheng

(广东工业大学 自动化学院, 广州 510006)

(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

摘要:针对电力系统最优潮流计算问题,提出了一种新的基于 Q 学习和纵横交叉搜索的粒子群算法。改进的算法在粒子群的寻优模式中引入纵横交叉算子进行优化,加强了全局收敛能力。同时,该改进算法引入 Q 学习的探索模式,使其在已知的解空间内进行发掘,从而更好地平衡探索与利用之间的关系。为解决 Q 学习算法的维度灾难问题,使用了状态-组合动作链的方法。IEEE57和IEEE118节点系统的仿真结果表明,所提算法可以增强传统粒子群算法的全局收敛性,有效求解大规模的最优潮流问题。

关键词:最优潮流;改进粒子群; Q 学习;纵横交叉算法;群智能优化算法

中图分类号:TM 744 **文献标志码:**A **文章编号:**1674-1951(2021)08-0074-09

Abstract: To solve the optimal power flow in power systems, new particle swarm optimization (PSO) algorithm based on Q learning and crisscross search is proposed. The improved algorithm introduces crossover operator into PSO mode to enhance the global convergence ability. At the same time, introducing the exploration mode of Q learning into the improved algorithm makes the algorithm explore in the known solution space, so as to better balance the relationship between exploration and utilization. In order to solve the dimension disaster of Q learning algorithm, the method of state-action chain is used. Simulation results of IEEE57 and IEEE118 node systems show that the proposed algorithm can enhance the global convergence of the traditional PSO algorithm, and effectively solve large-scale optimal power flow problems.

Keywords: optimal power flow; improved particle swarm; Q learning; crisscross algorithm; swarm intelligence optimization algorithm

0 引言

最优潮流问题 (Optimal Power Flow, OPF) 已经被提出了很长时间,但是随着电力系统的发展,对最优潮流问题求解的要求越来越高。最优潮流问题具有连续变量和离散变量共存、约束较多且不适合线性化处理的特点。

目前,解决此类问题的主要方法有2类。一类是经典优化算法,另一类是智能优化算法。经典优化算法主要包括内点法^[1]、牛顿法^[2]和线性规划法^[3]等,这类方法对数学模型的依赖程度较高,不易于处理非线性和离散性优化问题。而智能优化算法

由于不需要对优化模型做线性处理,也不需要求导数,打破了传统数学优化方法的瓶颈,因此,逐渐成为研究的热点。文献[4]针对最优潮流问题离散变量和连续变量共存的特点,提出了模拟退火粒子群 (Simulated Annealing based Particle Swarm Optimization, SA-PSO) 和预测校正原对偶内点法 (Predictor-Corrector Primal-Dual Interior Point Method, PCPDIPM) 结合的改进最优潮流算法 (SA-PSO+PCPDIPM),该方法用模拟退火粒子群求解系统离散变量,用预测-校正原对偶内点法求解系统连续变量,发挥了SA-PSO算法求解离散变量方便和PCPDIPM算法优化速度快的优势。文献[5]将遗传算法 (Genetic Algorithm, GA) 应用于最优潮流问题的求解中,针对遗传算法容易出现早熟的缺点,将种群进行分化,编码、选择、交叉、变异等操作中

均进行改进,在IEEE14节点系统和IEEE118节点系统上的仿真结果,证明了改进遗传算法在寻优过程中能够避免陷入局部最优,提高求解精度。文献[6]将改进的引力搜索算法(Gravitational Search Algorithm, GSA)应用于电力系统最优潮流的计算,在IEEE30节点和IEEE57节点系统中,求解出与其他算法结果相比更小的发电成本。文献[7]提出了利用搜寻者优化算法(Seeker Optimization Algorithm, SOA)求解目标函数为有功网损最小的最优潮流问题。在IEEE30节点系统和IEEE57节点系统上的仿真结果,证明了SOA具有较好的寻优能力。文献[8]提出了一种改进的社会蜘蛛优化算法(Novel Improved Social Spider Optimization, NISSO),并对最小发电成本、最小有功功率损耗和最少污染排放量等多个目标函数进行求解,结果表明该方法能提高优化解的质量和加快传统社会蜘蛛优化的收敛速度。

粒子群算法^[9-15](Particle Swarm Optimization, PSO)是一种受鱼群、鸟群等自然集群行为启发的群智能优化算法。由于粒子群算法具有概念简单、易于实现和计算成本低等优点,近20年来受到了众多学者和研究人员的关注。同时,粒子群算法在电力系统中也广泛地应用在电力系统规划、机组优化组合等领域。然而,传统粒子群算法在处理多变量、高维度复杂问题时,具有容易陷入局部最优解,寻优精度不足的缺点。

因此本文引入纵横交叉^[16]搜索算子对粒子群算法进行改进,来提高粒子群算法的全局收敛能力。事实上,在寻优问题的研究中,如何在探索和利用之间取得良好的平衡决定了算法寻优能力的好坏。故引入Q学习算法^[17]在粒子群所探索的已知解空间中进行发掘,从而更好地平衡开发与利用之间的关系。基于以上2种改进,本文提出了一种新的启发式搜索算法——基于纵横交叉的Q学习粒子群优化算法(Crisscross Search based Q learning and Particle Swarm Optimizer, CS-QPSO),用于电力系统最优潮流问题。通过对IEEE57和IEEE118节点系统不同目标函数的潮流仿真计算,并与其他智能算法的优化结果进行分析对比,验证了CS-QPSO算法求解最优潮流问题上的良好性能。

1 最优潮流数学模型

电力系统最优潮流即通过调节电力系统中的控制变量,来改变电网潮流的分布,在满足电力系统整体稳定、经济运行要求的条件下,达到某一目标最优的状态。其数学模型可表示为

$$\begin{cases} \min f(u, x) \\ g(u, x) = 0, \\ h(u, x) \leq 0 \end{cases} \quad (1)$$

式中: u 和 x 分别代表控制变量和状态变量; $g(u, x)$ 和 $h(u, x)$ 分别代表等式约束和不等式约束。其中控制变量 u 包括除了平衡节点外的所有发电机的有功出力 P_G 、所有发电机的端电压 V_G 、变压器的变比 T 和无功补偿功率 Q_C 。状态变量包含平衡节点有功出力 P_{G1} 、负荷节点的电压幅值 V_L 、发电机的无功出力 Q_G 和所有节点的电压相角 δ 。则 u 和 x 分别表示为

$$u = [P_{G2} \cdots P_{GN_g}, V_{G1} \cdots V_{GN_g}, T_1 \cdots T_{N_t}, Q_{C1} \cdots Q_{N_c}] \quad (2)$$

$$x = [P_{G1}, V_{L1} \cdots V_{LN_a}, Q_{G1} \cdots Q_{GN_g}, \delta_1 \cdots \delta_N] \quad (3)$$

式中: N_g, N_t, N_c 分别代表系统发电机、变压器、无功补偿装置的总台数; N_a 和 N 分别表示负荷节点总数和系统节点总数。

1.1 目标函数

本文以系统中最小发电成本和有功网损最小为目标函数。最小发电成本数学模型为

$$\min P_{\text{cost}} = \min \sum_{i=1}^{N_g} (a_i + b_i P_{Gi} + c_i P_{Gi}^2) \quad (4)$$

式中: a_i, b_i 和 c_i 为第 i 台发电机的耗量系数。

有功网损最小数学模型为

$$\min P_{\text{loss}} = \sum_{i=1}^{N_g} P_{Gi} - \sum_{i=1}^N P_{Di} \quad (5)$$

式中: P_{Di} 为节点 i 的有功负荷。

1.2 约束条件

1.2.1 等式约束

有功功率平衡和无功功率平衡的约束组成了等式约束,数学表达式为

$$P_{Gi} - P_{Di} = \sum_{j=1}^N |V_i| |V_j| (G_{ij} \cos(\delta_i - \delta_j) + B_{ij} \sin(\delta_i - \delta_j)) \quad (6)$$

$$Q_{Gi} - Q_{Di} = \sum_{j=1}^N |V_i| |V_j| (G_{ij} \sin(\delta_i - \delta_j) - B_{ij} \cos(\delta_i - \delta_j)) \quad (7)$$

式中: Q_{Di} 分别为节点的无功负荷; G_{ij} 和 B_{ij} 分别为节点 i 和 j 之间所连支路的电导与电纳; $|V_i|$ 为节点 i 的电压幅值。

1.2.2 不等式约束

不等式约束包括发电机有功出力约束、变压器变比约束、无功补偿约束、节点电压幅值约束和传输功率约束等,数学表达式为

$$P_{Gi}^{\min} \leq P_{Gi} \leq P_{Gi}^{\max} \quad (8)$$

$$Q_{Gi}^{\min} \leq Q_{Gi} \leq Q_{Gi}^{\max} \quad (9)$$

$$T_i^{\min} \leq T_i \leq T_i^{\max}, \quad (10)$$

$$Q_{Ci}^{\min} \leq Q_{Ci} \leq Q_{Ci}^{\max}, \quad (11)$$

$$|V_i|^{\min} \leq |V_i| \leq |V_i|^{\max}, \quad (12)$$

$$S_{Li} \leq S_{Li}^{\max}. \quad (13)$$

式中： S_{Li} 为系统中第*i*条支路的传输功率。

2 算法描述

2.1 原始粒子群算法

粒子群算法是一种基于种群的优化算法,种群的每个个体即一个搜索粒子,所有的搜索粒子组成一个种群。粒子群算法维持 2 个种群:一个是粒子当前位置的种群;另一个是到目前为止,粒子所到达的最佳位置的种群。在粒子群算法中,种群最优和个体最优共同影响粒子的速度更新。而速度的更新又指导个体位置的更新。在 *D* 维空间中,设种群规模为 *N*,则粒子的更新公式为

$$v_i^d = w \times v_i^d + c_1 \times r_1 \times (pbest_i^d - x_i^d) + c_2 \times r_2 \times (gbest^d - x_i^d), \quad (14)$$

$$x_i^d = x_i^d + v_i^d, \quad (15)$$

式中:*w*为惯性权重; c_1, c_2 为粒子群学习因子,表示粒子偏向 *pbest* 和 *gbest* 的权重; r_1, r_2 是在 $[0, 1]$ 之间独立均匀分布的随机变量; x_i 表示第*i*个粒子的位置; v_i 表示第*i*个粒子的速度;*pbest_i*是粒子*i*到目前为止的最优位置;*gbest*是整个种群发现的当前最佳位置。

2.2 改进的粒子群算法

2.2.1 纵横交叉算法

纵横交叉算法(Crisscross Optimization, CSO)是一种启发式算法,它由独特的交叉操作和竞争机制组成。

横向交叉是指随机不重复从种群中挑选 2 个个体执行交叉操作,用于交换种群中不同个体之间的信息,能够提高算法的全局收敛能力。横向交叉后产生的解称为横向交叉中庸解,用 MS_{hc} 表示,表达式为

$$MS_{hc}(i_1, d) = r_1 \cdot X(i_1, d) + (1 - r_1) \cdot X(i_2, d) + c_3 \cdot (X(i_1, d) - X(i_2, d)), \quad (16)$$

$$MS_{hc}(i_2, d) = r_2 \cdot X(i_2, d) + (1 - r_2) \cdot X(i_1, d) + c_4 \cdot (X(i_2, d) - X(i_1, d)), \quad (17)$$

式中: r_1, r_2 为在 $[0, 1]$ 间均匀分布的 2 个随机数; c_3, c_4 为在 $[-1, 1]$ 间均匀分布的随机数; $MS_{hc}(i_1, d)$ 和 $MS_{hc}(i_2, d)$ 是 2 个横向交叉中庸解的第 *d* 维;*X* 为种群矩阵。

纵向交叉是指在一个个体内部进行交叉操作,用于交换个体内部不同维度的信息,能够在一定的

概率下,使个体摆脱维局部最优,从而保持种群多样性。纵向交叉后产生的解称为纵向交叉中庸解,用 MS_{vc} 表示,表达式为

$$MS_{vc}(i, d_1) = r \cdot X(i, d_1) + (1 - r) \cdot X(i, d_2), \quad (18)$$

式中:*r*是在 $[0, 1]$ 间均匀分布的随机数; $MS_{vc}(i, d_1)$ 是粒子 $X(i, :)$ 的第 d_1 和 d_2 维产生的纵向交叉中庸解的 d_1 维。

纵横交叉算法具有强大的搜索能力,这种搜索能力得益于横向和纵向的双交叉算子的交替运行。在每次交叉后,得到的中庸解都需要与其父代进行竞争,只有适应度高于其父代时,才可以进入下一次迭代。这样的双交叉及竞争机制,使得 CSO 具有较强的全局收敛能力。

2.2.2 Q 学习

经典 Q 学习是一种强化学习,在这种学习中,智能体通过在环境中的状态转换来执行一个动作,并通过执行该动作来达到目标状态从而获得奖励或惩罚。在不断的试错学习中,智能体通过环境提供的反馈调整控制策略,直到学习到的控制策略可以使智能体获得最大奖励。

目前, Q 学习算法主要通过 Q 表实现。Q 表中的元素 $Q(s, a)$ 表示在当前状态 *s* 下,采取动作所获得的奖励值的期望。因此,不可避免的, Q 表就需要涵盖所有的可选动作对,当求解问题的变量规模变大时, Q 表的动作对的个数将会呈指数增加,发生维数灾难。

因此,本文使用一种信息延伸的维度缩减方法,将高维的状态-动作空间 *Q* 分解成多个相互关联的低维度状态-动作组合链。

在 *n* 维解空间 $A(a_1, a_2, \dots, a_n)$ 中,每个变量 a_i 都有一个 Q_i 与之对应。变量 a_{i-1} 和变量 a_i 间通过 Q_i 联系起来,也就是说确定一个动作 a_{i-1} 后,以此动作 a_{i-1} 作为下个变量的当前状态,根据 Q_i 选择下个变量的动作。事实上, Q_i 空间中的元素,不仅反映了动作的策略,也反映了变量之间的联系。这样就在变量之间形成了链式关系,实现了对 Q 表的降维。 Q_i 的更新方式为

$$Q_{k+1}^i(s_k^j, a_k^j) = Q_k^i(s_k^j, a_k^j) + \alpha [R^j(s_k^j, s_{k+1}^j, a_k^j) + \gamma \max_{a' \in A_i} Q_k^i(s_{k+1}^j, a') - Q_k^i(s_k^j, a_k^j)], \quad (19)$$

式中:上标 *i* 表示第 *i* 个控制变量;上标 *j* 表示第 *j* 个粒子; $R^j(s_k^j, s_{k+1}^j, a_k^j)$ 表示第 *k* 步迭代时刻环境由状态 s_k 经动作 a_k 转移到状态 s_{k+1} 后的奖励函数值; α 是 Q 学习的学习因子; γ 是折扣因子。

此外, Q 学习采用 ϵ -贪婪规则的动作选择策略,具体为

$$a_{k+1}^j = \begin{cases} \arg \max_{a' \in A_i} Q^i(s_{k+1}^j, a'), q < \varepsilon \\ a_x, \text{其他} \end{cases}, \quad (20)$$

式中: ε 为贪婪因子; q 为 $[0, 1]$ 之间的随机数; a_x 为随机选择的1个动作。

2.2.3 改进策略

(1)直接用粒子所经过的最优解 $pbest$ 表示候选解,这使得改进的PSO算法始终保持1个 $pbest$ 种群。

(2)在种群更新的过程中,存在对开发与利用的取舍问题,若智能体只探索未知的位置,虽然增加了寻找新的解决方案的能力,但却降低了算法寻优的效率;若智能体只利用已知的位置解,则会使寻优过程陷入局部最优。

因此,算法的寻优能力取决于它在开发和利用之间找到平衡的能力。为此,本文将PSO算法的随机搜索模式和基于概率空间的动作选择策略相结合,使用一种新的速度更新方法。改进的PSO算法的速度更新公式为

$$v_i^d = \omega \times v_i^d + c_1 \times r_1 \times (Qbest^d - pbest_i^d) + c_2 \times r_2 \times (gbest^d - pbest_i^d), \quad (21)$$

式中: $Qbest$ 表示 Q 学习通过基于概率分布的动作选择策略在已知 $pbest$ 种群中选择出的1组解,代表了对已知解信息的利用;而 $gbest$ 是到目前为止,种群找到的最优解。因此通过PSO算法的速度更新公式,将已探索空间的解信息和当前代数找到的最优解信息结合起来,从而实现对开发和利用的平衡。

(3)引入横向交叉算子,与粒子群的搜索相级联,提高PSO的搜索能力。引入纵向交叉算子,避免PSO早熟,保持种群的多样性。通过纵横交叉算子的配合增强算法的全局搜索能力,一定程度上避免陷入局部最优。

3 CS-QPSO算法在最优潮流上的应用

3.1 离散变量处理

在最优潮流问题中,变压器变比 T 和无功补偿电容 C 是离散变量,所以优化得到的解必须满足实际的运行条件,故变压器变比和无功补偿容量保留小数点后2位。

3.2 惩罚函数

为了避免状态变量越限,需要采用惩罚函数,为

$$P = \lambda_p |P_{sl} - P_{sl}^{\lim}| + \lambda_v \sum_{i=1}^{N_d} |V_i - V_i^{\lim}| + \lambda_Q \sum_{i=1}^{N_g} |Q_i - Q_i^{\lim}|, \quad (22)$$

式中: $\lambda_p, \lambda_v, \lambda_Q$ 分别为平衡节点有功出力、负荷节

点电压幅值和发电机无功出力的惩罚系数; $P_{sl}^{\lim}, V_i^{\lim}, Q_i^{\lim}$ 分别为平衡节点有功出力、负荷节点电压、发电机无功出力的限值。

3.3 参数设置

所提算法中参数较多,包括种群数量 M ,纵向交叉概率 P_v ,惯性权重因子 ω ,粒子群学习因子 c_1, c_2 , Q 学习的学习因子 α ,折扣因子 γ 等。故对参数取值做如下说明。

(1)种群数量 M :种群数量影响算法的计算速度。种群规模太小,会造成解的多样性丧失;种群规模太大,会使算法计算缓慢。考虑到案例中控制变量较多,将控制变量个数设置为 N_u ,将种群数量 M 设置为30。因此,种群以矩阵的形式表示为

$$X = \begin{bmatrix} V_{G1} \cdots V_{GN_g}, P_{G2} \cdots P_{GN_g}, T_1 \cdots T_{N_t}, Q_{C1} \cdots Q_{N_c} \\ V_{G1} \cdots V_{GN_g}, P_{G2} \cdots P_{GN_g}, T_1 \cdots T_{N_t}, Q_{C1} \cdots Q_{N_c} \\ \vdots \\ V_{G1} \cdots V_{GN_g}, P_{G2} \cdots P_{GN_g}, T_1 \cdots T_{N_t}, Q_{C1} \cdots Q_{N_c} \end{bmatrix}_{M \times N_u} \quad (23)$$

(2)纵向交叉概率 P_v :纵向交叉有助于个体摆脱局部维最优,但是并不需要在每次迭代中都执行纵向交叉操作,因此当生成的0.0~1.0间的随机数小于交叉概率时,才会进行纵向交叉,根据多次实验经验,纵向交叉概率设置在0.4~0.8,本文中设置纵向交叉概率为0.7。

(3)惯性权重因子 ω :体现了迭代粒子前一代的速度在整个速度更新公式中所占的权重,惯性权重 ω 的大小,决定了上一代速度对当代速度的影响。 ω 越小,影响程度越小,粒子具有极好的局部搜索能力,但容易陷入局部最优; ω 越大,影响程度越大,粒子在全局范围的搜索能力更强,但算法不易收敛。为了兼顾局部搜索和全局搜索能力,采用惯性权重的二次函数计算方法,为

$$\omega(k) = \frac{\omega_{\text{initial}} - \omega_{\text{final}}}{k_{\text{max}}^2} (k - k_{\text{max}})^2 + \omega_{\text{final}}, \quad (24)$$

式中: ω_{initial} 和 ω_{final} 为预设初始和结束惯性系数,本文中取 $\omega_{\text{initial}}=0.9, \omega_{\text{final}}=0.2$ 。

(4)粒子群学习因子 c_1, c_2 :在改进算法中 c_1, c_2 表示粒子对 $gbest$ 和 $Qbest$ 的学习程度,当 c_1, c_2 均为0时,粒子既没有向已经探索的位置学习,也没有向最新开发的位置学习,难以找到全局最优解。所以 c_1, c_2 缺一不可。本文中 c_1, c_2 均取2.05。

(5) Q 学习的学习因子 α :决定了粒子从种群获取信息的速度, α 越大,算法收敛速度越快,本文中 α 取0.99。

(6)折扣因子 γ :反映了 Q 表更新时,对奖励的折扣程度,折扣因子越大,则对过去的奖励越重视,

本文中 γ 取0.9。

3.4 算法步骤及流程

综上所述,所提算法流程如图1所示,具体实现过程如下。

(1)初始化种群。设置种群大小为 M ,在相应维度的解空间中随机产生 M 个粒子,并初始化其速度和位置。

(2)初始化 Q 表,并设置对应的参数。

(3)评价种群。计算每个粒子的适应度值,并更新 Q 表,目标函数和惩罚函数已经在上文说明,完整的适应度计算公式为

$$F = F_{\text{obj}} + p, \quad (25)$$

式中: F_{obj} 为目标函数; p 为惩罚函数。

(4)对粒子群进行更新。根据 Q 表选出 Q_{best} ,通过式(22)、式(16)更新个体速度 v_i 和位置 x_i 。对于更新后的越限变量,则设为其所对应的上限或下限。若 x_i 即 p_{best_i} 适应度优于其上一代时,则对 x_i 进行更新替换;若存在 p_{best_i} 适应度优于 g_{best} 时,则对 g_{best} 进行更新。最终得到的种群 X 作为横向交叉的父代。

(5)对粒子群横向交叉。随机无重复的对粒子进行配对,根据式(17)、式(18)进行横向交叉,产生横向交叉中庸解 MS_{hc} 。

对于更新后的越限变量,则设为其所对应的上限或下限。若 x_i 即 p_{best_i} 适应度优于其上一代时,则对 x_i 进行更新替换;若存在 p_{best_i} 适应度优于 g_{best} 时,则对 g_{best} 进行更新。最终得到的种群 X 作为纵向交叉的父代。

(6)对粒子群纵向交叉。纵向交叉前后需要进行归一化和反归一化操作。纵向交叉需要在个体内部对不同维度按照式(19)进行交叉操作,并且纵向交叉具有一定的交叉概率,只有当生成的0~1间的随机数小于交叉概率时,才会进行纵向交叉。对纵向交叉后得到的纵向交叉中庸解进行反归一化,再与其父代进行与横向交叉一样的竞争操作。

(7)判定是否达到结束迭代条件。若迭代次数达到最大迭代次数时,停止迭代,输出最优解 g_{best} 。若迭代次数未达到最大迭代次数,则返回步骤(3),继续迭代,直到满足程序终止条件。

4 算例分析

本文选择 IEEE57 节点系统和 IEEE118 节点系统作为潮流计算仿真对象。算例使用 Python 3.7 软件在中央处理器(CPU)为 AMD Ryzen 3500U、主频为 2.1 GHz,内存为 8 GB,操作系统为 Windows 10 的

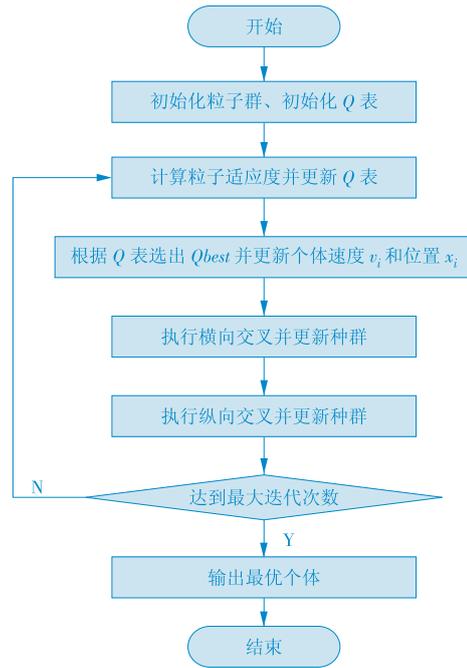


图1 改进的 PSO 算法的实现流程

Fig. 1 Implementation flow of the improved PSO algorithm

计算机上运行。

4.1 仿真案例 1

IEEE57 节点系统含有 7 台发电机、80 条支路、17 台变压器和 3 台无功补偿装置,相关参数见文献[17]。

本算例中,控制变量共有 33 个,以最小发电成本为目标函数,最小发电成本按照式(4)计算。将所提算法重复独立运行 10 次,最大迭代次数为 100。将 CS-QPSO 寻优的最小值与参考文献中同类方法比较,发电成本对比见表 1。

表中 HMICA-SQP 为改进的帝国主义竞争及顺序二次规划算法;DE 为差分进化算法;MSA 为蚁群算法;FAHSPSO-DE 为模糊自适应粒子群及差分进化算法。

试验结果表明,所提算法搜索能力更强,相对于其他算法能够找到更好的解。本案例中,CS-QPSO 取得最小发电成本 41 590.86 美元/h 时的控制变量设定见表 2。

案例 1 中 CS-QPSO 与 PSO 算法在 10 次运行中均取得优化结果最小值时的收敛曲线对比如图 2 所示,在相同的迭代次数下,CS-QPSO 的寻优能力更强。

4.2 仿真案例 2

IEEE118 节点系统含有 54 台发电机、186 条支路、9 台变压器和 14 台无功补偿电容器,相关参数见文献[18]。

本算例中,控制变量共有 130 个,相对于

表 1 案例 1 中改进的 PSO 与其他算法的发电成本对比^[17-22]

Tab. 1 Comparison between the power generation costs made by improved PSO algorithm and that by other algorithms in case 1^[17-22] 美元/h

优化算法	最小值	平均值	最大值
HMICA-SQP	41 881.66	—	—
GA	41 711.94	41 719.60	41 734.16
DE	41 709.88	41 715.29	41 720.36
GSA	41 695.87	—	—
MSA	41 673.72	—	—
NISSO	41 665.54	—	—
FAHPSO-DE	41 637.18	—	—
PSO	41 670.62	41 745.37	41 837.77
CS-QPSO	41 590.86	41 604.08	41 621.14

表 2 案例 1 中最优控制变量设定

Tab. 2 Optimal setting of control variables in case 1

控制变量	CS-QPSO	控制变量	CS-QPSO
P_{C2}/MW	89.25	$T_{24-25}/p.u.$	0.99
P_{C3}/MW	44.03	$T_{24-26}/p.u.$	1.01
P_{C6}/MW	69.16	$T_{7-29}/p.u.$	0.92
P_{C8}/MW	460.70	$T_{32-34}/p.u.$	0.95
P_{C9}/MW	100.00	$T_{11-41}/p.u.$	0.95
P_{C12}/MW	357.93	$T_{15-45}/p.u.$	0.91
$V_1/p.u.$	1.07	$T_{14-46}/p.u.$	0.90
$V_2/p.u.$	1.07	$T_{10-51}/p.u.$	0.92
$V_3/p.u.$	1.07	$T_{13-49}/p.u.$	0.90
$V_6/p.u.$	1.08	$T_{11-43}/p.u.$	0.90
$V_8/p.u.$	1.10	$T_{40-56}/p.u.$	1.10
$V_9/p.u.$	1.08	$T_{39-57}/p.u.$	1.01
$V_{12}/p.u.$	1.06	$T_{9-55}/p.u.$	0.94
$T_{4-18}/p.u.$	1.00	$Q_{C18}/Mvar$	6.44
$T_{4-18}/p.u.$	1.01	$Q_{C25}/Mvar$	11.99
$T_{21-20}/p.u.$	1.10	$Q_{C53}/Mvar$	11.06
$T_{24-25}/p.u.$	1.01		

IEEE57 系统,属于大规模系统。

以最小发电成本为目标函数,最小发电成本计算方法与案例 1 相同,将所提算法重复独立运行 10 次,最大迭代次数为 650。

将 CS-QPSO 寻优的最小值与参考文献中同类方法比较,发电成本对比见表 3。表中 SSO 为社交蜘蛛优化算法;GPU-PSO 为基于图像处理单元的并行粒子群算法;IABC 为改进的人工蜂群算法。试验结果表明,CS-QPSO 具有全局收敛能力,在处理多变量问题上,具有优越性。

本案例中,CS-QPSO 取得最小发电成本 129 568.55 美元/h 时的控制变量设定见表 4。

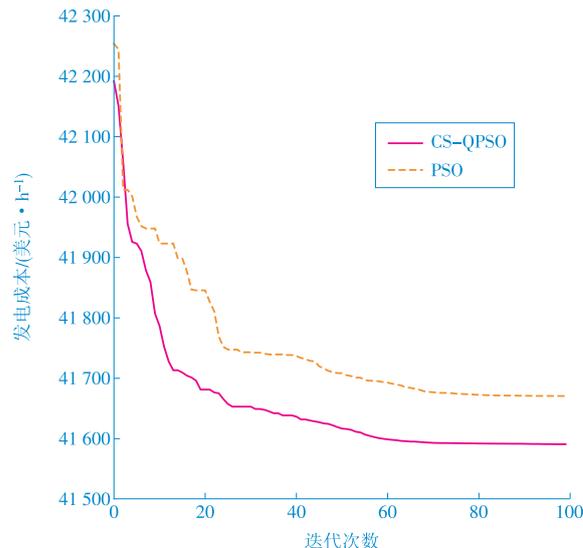


图 2 案例 1 中 CS-QPSO 与 PSO 收敛曲线对比

Fig. 2 Comparison of convergence curves between CS-QPSO and PSO in case 1

表 3 案例 2 中改进的 PSO 与其算法的发电成本对比^[18-22]

Tab. 3 Comparison between the power generation costs made by improved PSO algorithm and that by other algorithms in case 2^[18-22] 美元/h

优化算法	最小值	平均值	最大值
SSO	132 080.41	—	—
PSO	131 005.73	—	—
PSO	130 062.86	130 142.48	130 234.34
GPU-PSO	129 627.03	—	—
NISSO	129 879.45	—	—
IABC	129 862.00	129 895.00	129 941.00
MSA	129 640.72	—	—
PSO	130 344.33	131 417.60	133 016.09
CS-QPSO	129 568.55	129 627.23	129 698.87

表 4 案例 2 中最优控制变量设定

Tab. 4 Optimal setting of control variables in case 2

控制变量	CS-QPSO	控制变量	CS-QPSO	控制变量	CS-QPSO
P_{C2}/MW	0.00	P_{C46}/MW	38.33	$V_{C36}/p.u.$	1.04
P_{C3}/MW	2.84	P_{C47}/MW	0.47	$V_{C37}/p.u.$	1.05
P_{C4}/MW	0.00	P_{C48}/MW	7.10	$V_{C38}/p.u.$	1.05
P_{C5}/MW	406.68	P_{C49}/MW	29.08	$V_{C39}/p.u.$	1.04
P_{C6}/MW	86.46	P_{C50}/MW	8.03	$V_{C40}/p.u.$	1.05
P_{C7}/MW	19.90	P_{C51}/MW	35.18	$V_{C41}/p.u.$	1.03
P_{C8}/MW	16.22	P_{C52}/MW	35.22	$V_{C42}/p.u.$	1.03
P_{C9}/MW	18.72	P_{C53}/MW	0.00	$V_{C43}/p.u.$	1.04
P_{C10}/MW	0.00	P_{C54}/MW	0.00	$V_{C44}/p.u.$	1.04
P_{C11}/MW	196.11	$V_{C1}/p.u.$	1.03	$V_{C45}/p.u.$	1.04
P_{C12}/MW	282.58	$V_{C2}/p.u.$	1.05	$V_{C46}/p.u.$	1.02
P_{C13}/MW	13.20	$V_{C3}/p.u.$	1.04	$V_{C47}/p.u.$	1.02
P_{C14}/MW	7.23	$V_{C4}/p.u.$	1.10	$V_{C48}/p.u.$	1.01
P_{C15}/MW	13.92	$V_{C5}/p.u.$	1.10	$V_{C49}/p.u.$	1.00

续表

控制变量	CS-QPSO	控制变量	CS-QPSO	控制变量	CS-QPSO
P_{G16}/MW	3.88	$V_{G6}/p.u.$	1.04	$V_{G50}/p.u.$	1.01
P_{G17}/MW	11.87	$V_{G7}/p.u.$	1.03	$V_{G51}/p.u.$	1.02
P_{G18}/MW	49.38	$V_{G8}/p.u.$	1.04	$V_{G52}/p.u.$	1.00
P_{G19}/MW	42.55	$V_{G9}/p.u.$	1.03	$V_{G53}/p.u.$	1.04
P_{G20}/MW	19.24	$V_{G10}/p.u.$	1.05	$V_{G54}/p.u.$	1.10
P_{G21}/MW	193.26	$V_{G11}/p.u.$	1.08	$T_1/p.u.$	1.03
P_{G22}/MW	49.33	$V_{G12}/p.u.$	1.10	$T_2/p.u.$	1.10
P_{G23}/MW	29.48	$V_{G13}/p.u.$	1.05	$T_3/p.u.$	1.04
P_{G24}/MW	31.42	$V_{G14}/p.u.$	1.03	$T_4/p.u.$	1.04
P_{G25}/MW	149.66	$V_{G15}/p.u.$	1.04	$T_5/p.u.$	1.03
P_{G26}/MW	146.83	$V_{G16}/p.u.$	1.04	$T_6/p.u.$	1.03
P_{G27}/MW	0.00	$V_{G17}/p.u.$	1.04	$T_7/p.u.$	1.02
P_{G28}/MW	354.45	$V_{G18}/p.u.$	1.03	$T_8/p.u.$	0.97
P_{G29}/MW	349.49	$V_{G19}/p.u.$	1.04	$T_9/p.u.$	1.03
P_{G30}/MW	706.21	$V_{G20}/p.u.$	1.05	$Q_{C1}/MVar$	13.10
P_{G31}/MW	0.00	$V_{G21}/p.u.$	1.06	$Q_{C2}/MVar$	3.83
P_{G32}/MW	0.00	$V_{G22}/p.u.$	1.04	$Q_{C3}/MVar$	0.00
P_{G33}/MW	0.00	$V_{G23}/p.u.$	1.03	$Q_{C4}/MVar$	5.13
P_{G34}/MW	19.42	$V_{G24}/p.u.$	1.03	$Q_{C5}/MVar$	19.14
P_{G35}/MW	22.67	$V_{G25}/p.u.$	1.06	$Q_{C6}/MVar$	21.77
P_{G36}/MW	0.00	$V_{G26}/p.u.$	1.06	$Q_{C7}/MVar$	12.68
P_{G37}/MW	432.87	$V_{G27}/p.u.$	1.06	$Q_{C8}/MVar$	24.17
P_{G38}/MW	0.00	$V_{G28}/p.u.$	1.10	$Q_{C9}/MVar$	30.00
P_{G39}/MW	3.59	$V_{G29}/p.u.$	1.08	$Q_{C10}/MVar$	16.11
P_{G40}/MW	503.14	$V_{G30}/p.u.$	1.08	$Q_{C11}/MVar$	16.30
P_{G41}/MW	0.00	$V_{G31}/p.u.$	1.05	$C_{12}/MVar$	11.02
P_{G42}/MW	0.00	$V_{G32}/p.u.$	1.04	$C_{13}/MVar$	30.00
P_{G43}/MW	0.00	$V_{G33}/p.u.$	1.04	$C_{14}/MVar$	17.35
P_{G44}/MW	0.00	$V_{G34}/p.u.$	1.04		
P_{G45}/MW	230.86	$V_{G35}/p.u.$	1.03		

案例 2 中 CS-QPSO 与 PSO 算法在 10 次运算中均取得优化结果最小值时的收敛曲线对比如图 3 所示,在相同的迭代次数下,CS-QPSO 摆脱了局部最优解,全局收敛性更强。

4.3 仿真案例 3

本算例以最小有功网损为目标函数,在 IEEE57 节点系统上测试,试验方法与参数同仿真案例 1,最大迭代次数为 100。

将 CS-QPSO 寻优的最小值与相关参考文献中同类方法比较,有功网损对比见表 5,试验结果再次证明了所提混合算法的有效性。

案例 3 中 CS-QPSO 与 PSO 算法在 10 次运算中均取得优化结果最小值时的收敛曲线对比如图 4 所示,在相同的迭代次数下,CS-QPSO 寻优性能优于 PSO。

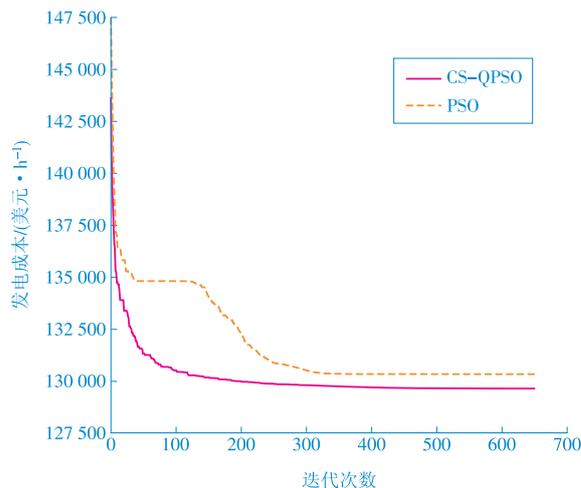


图 3 案例 2 中 CS-QPSO 与 PSO 收敛曲线对比

Fig. 3 Comparison of convergence curves between CS-QPSO and PSO in case 2

表 5 案例 3 中改进的 PSO 与其他算法的有功网损对比^[18-27]

优化算法	最小值	平均值	最大值
NISSO	9.98	—	—
FAHSPSO-DE	11.73	—	—
SSO	10.61	—	—
PSO	9.25	9.77	10.60
CS-QPSO	8.79	9.20	9.70

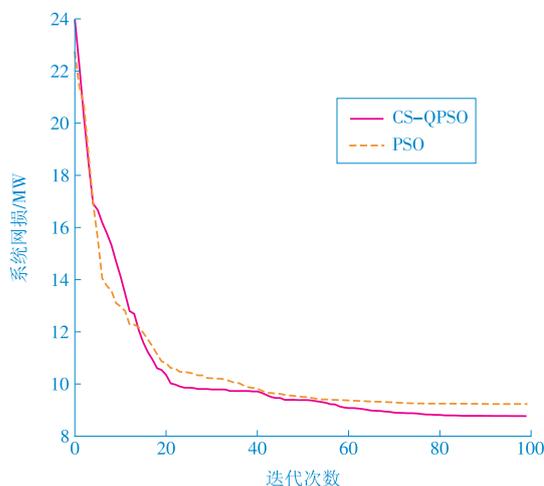


图 4 案例 3 中 CS-QPSO 与 PSO 收敛曲线对比

Fig. 4 Comparison of convergence curves between CS-QPSO and PSO in case 3

5 结论

本文基于粒子群算法全局收敛能力不足、搜索能力弱的特点,提出了一种改进的粒子群算法。将所提算法应用于最优潮流问题的求解,并在 IEEE57 节点系统和 IEEE118 节点系统中进行了仿真测试。试验结果表明,纵横交叉算子和 Q 学习的加入,能增

强传统粒子群算法的寻优能力,并有效提升算法的全局收敛能力。通过与其他算法的运行结果对比,该改进算法的求解精度与稳定性更优,能有效求解大规模的 OPF 问题,对实际电力系统优化运行提供了一定的参考。

参考文献:

- [1]李春晓,何仁君.基于内点法的最优潮流计算及算例分析[J].电气开关,2018,56(1):32-36.
LI Chunxiao, HE Renjun. The calculation of optimal power flow based on interior-point method[J]. Electric Switchgear, 2018, 56(1):32-36.
- [2]张江红,孟宪朋,刘怀东,等.最优潮流算法综述[J].华北电力技术,2010(7):23-26,45.
ZHANG Jianghong, MENG Xianpeng, LIU Huaidong, et al. A summary of algorithms for optimal power flow [J]. North China Electric Power, 2010(7):23-26,45.
- [3]李彩华,郭志忠.最优潮流的发展[J].继电器,2002(1):1-6,56.
LI Caihua, GUO Zhizhong. The development of optimal power flow[J]. Relay, 2002(1):1-6,56.
- [4]陈丽光,文波,聂一雄.基于退火粒子群和内点法的改进最优潮流算法[J].广东电力,2013,26(9):32-35,103.
CHEN Liguang, WEN Bo, NIE Yixiong. Improved optimal power flow algorithm based on annealing particle swarm and interior point method[J]. Guangdong Electric Power, 2013, 26(9):32-35,103.
- [5]刘敏.基于改进遗传算法的最优潮流问题的研究[D].长沙:中南大学,2010.
- [6]肖儿良,林蔚,毛海军,等.基于权值的引力搜索算法在电力系统最优潮流计算中的应用[J].电工电能新技术,2014,33(7):62-66.
XIAO Erliang, LIN Wei, MAO Haijun, et al. Calculation of optimal power flow problem using search algorithm based on weight of gravitation [J]. Advanced Technology of Electrical Engineering and Energy, 2014, 33(7):62-66.
- [7]陈维荣,张倩,王劲草,等.搜寻者优化算法在最优潮流中的应用[J].电力系统及其自动化学报,2009,21(1):64-67.
CHEN Weirong, ZHANG Qian, WANG Jincao, et al. Application of seeker optimization algorithm in optimal power flow[J]. Proceedings of the CSU-EPSA, 2009, 21(1):64-67.
- [8]NGUYEN T T. A high performance social spider optimization algorithm for optimal power flow solution with single objective optimization[J]. Energy, 2019, 171:218-240.
- [9]赵鑫,郑文禹,侯智华,等.基于粒子群优化算法的多能互补系统经济调度研究[J].华电技术,2021,43(4):14-20.
ZHAO Xin, ZHENG Wenyu, HOU Zhihua, et al. Research on economic dispatch of multi-energy complementary system based on Particle Swarm Optimization [J]. Huadian Technology, 2021, 43(4):14-20.
- [10]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.
LU Limin, CHU Guowei, ZHANG Tao, et al. Optimal configuration of energy storage in a microgrid based on improved multi-objective particle swarm optimization [J]. Power System Protection and Control, 2020, 48(15):116-124.
- [11]李彬,郝一浩,祁兵,等.边缘计算在需求响应中的应用现状及发展思路[J].华电技术,2021,43(3):1-8.
LI Bin, HAO Yihao, QI Bing, et al. Application and development of edge computing in demand response [J]. Huadian Technology, 2021, 43(3):1-8.
- [12]吴攀.光伏发电系统发电功率预测[J].发电技术,2020,41(3):231-236.
WU Pan. Power forecasting of photovoltaic power generation system [J]. Power Generation Technology, 2020, 41(3):231-236.
- [13]高明明,杨磊,于浩洋,等.量子计算在火电机组优化控制中的应用综述[J].华电技术,2020,42(8):90-96.
GAO Mingming, YANG Lei, YU Haoyang, et al. Review on the application of quantum computing in optimization control on thermal power units [J]. Huadian Technology, 2020, 42(8):90-96.
- [14]谈智玲,陈才明,徐胜朝,等.基于振动信号分析的滚动轴承寿命预测方法研究[J].华电技术,2021,43(5):36-44.
TAN Zhiling, CHEN Caiming, XU Shengchao, et al. Research on service life prediction on rolling bearings based on vibration signal analysis [J]. Huadian Technology, 2021, 43(5):36-44.
- [15]李鑫滨,朱庆军,马红霞,等.粒子群算法及其在电力系统无功优化中的应用综述[J].燕山大学学报,2008(3):245-250.
LI Xinbin, ZHU Qingjun, MA Hongxia, et al. Overview of particle swarm optimization algorithm on reactive optimization for power system [J]. Journal of Yanshan University, 2008(3):245-250.
- [16]MENG A B, CHEN Y C, YIN H, et al. Crisscross optimization algorithm and its application [J]. Knowledge-Based, 2014, 67:218-229.
- [17]胡细兵.基于强化学习算法的最优潮流研究[D].广州:华南理工大学,2011.
- [18]NARIMANI M R, AZIZIPANAH-ABARGHOEE R, ZOGHDAR-MOGHADAM-SHAHREKOHNE B, et al. A novel approach to multi-objective optimal power flow by a new hybrid optimization algorithm considering generator

- constraints and multi - fuel type [J]. Energy, 2013, 49: 119-136.
- [19] NADERI E, NARIMANI H, FATHI M, et al. Narimani a novel fuzzy adaptive configuration of particle swarm optimization to solve large - scale optimal reactive power dispatch [J]. Applied Soft Computing, 2017, 53: 441-456.
- [20] NADERI E, POURAKBARI-KASMAEI M, CERNA F V, et al. A novel hybrid self - adaptive heuristic algorithm to handle single - and multi - objective optimal power flow problems [J]. International Journal of Electrical Power & Energy Systems, 2021, 125. DOI: 10.1016/j.ijepes. 2020. 106492.
- [21] SHILAJA C, ARUNPRASATH T. Optimal power flow using moth swarm algorithm [J]. Future Generation Computer Systems, 2019, 98: 708-715.
- [22] DUMAN S, GÜVENÇ U, SÖNMEZ Y, et al. Optimal power flow using gravitational search algorithm [J]. Energy Conversion and Management, 2012, 59: 86-95.
- [23] GHASEMI M, GHAVIDEL S, GHANBARIAN M M, et al. Application of imperialist competitive algorithm with its modified techniques for multi-objective optimal power flow problem: A comparative study [J]. Information Sciences, 2014, 281: 225-247.
- [24] HMIDA J B, CHAMBERS T, LEE J. Solving constrained optimal power flow with renewables using hybrid modified imperialist competitive algorithm and sequential quadratic programming [J]. Electric Power Systems Research, 2019, 177. DOI: 10.1016/j.epsr.2019.105989.
- [25] SINGH R P, MUKHERJEE V, GHOSH S P. Particle swarm optimization with an aging leader and challengers algorithm for the solution of optimal power flow problem [J]. Applied Soft Computing, 2016, 40: 161-177.
- [26] ROBERGE V, TARBOUCHI M, OKOU F. Optimal power flow based on parallel metaheuristics for graphics processing units [J]. Electric Power Systems Research 2016, 140: 344-353.
- [27] BAI W, EKE I, LEE K Y. An improved artificial bee colony optimization algorithm based on orthogonal learning for optimal power flow problem [J]. Control Engineering Practice, 2017, 61: 163-172.

(本文责编:张帆)

作者简介:

孟安波(1971—),男,重庆人,教授,博士,从事电力系统自动化、系统分析与集成等方面的研究工作(E-mail: mengambo@vip.sina.com)。

王鹏*(1998—),男,宁夏吴忠人,在读硕士研究生,从事人工智能算法在电力系统中的应用方面的研究(E-mail: 1299093526@qq.com)。