Research on Multi-Peak MPPT Control Simulation of Photovoltaic Based on EQWOA Algorithm

HU Haoxuan, ZHANG Chunyan*
(College of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201600, China)

Abstract: When the PV array is under local shade (PSC), the $P-U$ output curve of the PV array shows multi-peak output characteristics. The traditional MPPT algorithm is easy to fall into local optimum, which affects the power generation efficiency of the PV system. In response to the above problems, elite reverse learning strategy and quadratic interpolation whale optimization algorithm (EQWOA) is proposed. The initial population diversity of the algorithm is optimized through an elite reverse learning strategy at an early stage to improve the global search ability of the algorithm, and a quadratic interpolation method is introduced to generate new whale individuals to solve the problem of slow convergence of the algorithm and strengthen the local search ability. The simulation results show that the EQWOA algorithm has good tracking performance under different shading conditions and effectively improves optimization efficiency and tracking accuracy which can effectively avoid the problem of local extreme value.

Key words: photovoltaic power generation; maximum power point tracking; whale optimization algorithm; elite reverse learning; quadratic interpolation
EEACC: 7220; 8150; 8250 **doi**: 10.3969/j.issn.1005-9490.2026.04.029

基于 EQWOA 算法的光伏多峰 MPPT 仿真研究

胡皓轩, 张春燕*
(上海工程技术大学机械与汽车工程学院, 上海 201600)

摘 要: 光伏阵列在局部遮荫(PSC)时, 输出曲线呈多峰性的输出特性。针对传统的 MPPT 算法容易陷入局部最优, 影响光伏系统的发电效率的问题, 提出一种基于精英反向学习与二次插值改进的鲸鱼优化算法(EQWOA), 该算法在早期通过精英反向学习策略优化其初始种群, 提升算法全局搜索能力, 并引入二次插值的方法生成新的鲸鱼个体, 解决算法收敛速度慢的问题并加强局部搜索能力。仿真结果表明: EQWOA 算法在不同遮光条件下具有良好的追踪性能, 寻优效率和追踪精度均得到了有效提升, 能有效避免陷入局部极值的问题。

关键词: 光伏发电; 最大功率点跟踪; 鲸鱼优化算法; 精英反向学习; 二次插值
中图分类号: TP391.9; TM617 **文献标识码**: A **文章编号**: 1005-9490(2026)04-0900-09

在新能源经济发展的背景下, 随着“碳达峰、碳中和”两大战略决策的提出, 太阳能光伏发电研究备受关注[1]。在光伏系统的实际工作中, 外界环境不发生改变时, 存在唯一的最大功率点(Maximum Power Point, MPP)[2]。光伏系统一般通过最大功率点跟踪(Maximum Power Point Tracking, MPPT)[2]保证发电效率。不同于均压的光照条件下的光伏阵列输出曲线呈单峰性的特点[3], 在实际应用中光伏阵列往往会受到天气、环境等影响产生局部遮荫现象, 在局部遮荫条件下, 光伏阵列各个组件受到的光照强度不同, 其输出曲线呈多峰特征, 存在若干个局部最大功率点。

传统 MPPT 法包括扰动观察法[4](Perturb and Observe, P&O)、电导增量法[5](Incremental Conductance, INC)等等, 在固定光照强度和恒定温度的条件下, 传统 MPPT 法具有较好的追踪性能。但在应对复杂的遮荫情况时, 光伏系统存在多个局部最大功率点, 传统的 MPPT 算法容易陷入局部最优值, 影响光伏系统的发电效率。局部遮荫条件下的光伏阵列强调算法的全局搜索能力, 针对光伏阵列输出曲线呈多峰性的情况常用新型的启发式算法, 其中包括粒子群优化算法[6](Particle Swarm Optimization, PSO), 鲸鱼优化算法[7](Whale Optimization Algorithm, WOA)等等。新型的启发式算法能提升

收稿日期: 2024-03-30 **修改日期**: 2024-06-10

全局搜索能力,但也存在问题,例如粒子群算法的粒子只向最优解移动,容易在算法的初期陷入局部最优,鲸鱼优化算法也存在收敛速度慢、收敛精度低等缺陷。许多学者在启发式算法的基础上提出改进优化,并将其应用于复杂遮荫条件下的光伏阵列,实现快速、稳定与高精度的最大功率点跟踪。徐珊珊等[8]提出带全局判据的改进量子粒子群优化算法,对粒子位置进行周期性变异及随进化速度和粒子聚集度变化的搜索范围变异,提高了算法的全局搜索能力,但其在收敛过程中存在振荡现象。李志军等[9]提出一种改进粒子群算法,结合徐珊珊等提出的改进量子粒子群优化算法和 INC 算法,应用于多峰 MPP,对最大功率点进行局部跟踪,可避免动态过程中功率的振荡,有效追踪到最大功率点,但收敛过程中存在振荡现象,易影响系统的稳定性。针对在局部遮荫下的光伏阵列存在的最大功率追踪问题,传统 MPPT 算法容易陷入局部最优值,影响系统发电功率,结合新型启发式算法的 MPPT 在多峰追踪时,影响寻优速度,存在系统不稳定等问题。

因此本文提出一种精英反向学习与二次插值改进的鲸鱼优化算法。在算法早期通过精英反向学习策略优化其初始种群,提升算法全局搜索能力;引入二次插值的方法生成新的鲸鱼个体,解决算法收敛速度慢的问题并加强局部搜索能力。最后通过求解多个测试函数优化问题验证其有效性,应用于局部遮荫下的光伏阵列的多峰跟踪问题并通过仿真验证。

1　光伏阵列多峰输出特性

在实际的工作环境中,局部阴影遮蔽下的光伏阵列无法正常工作。阴影遮蔽部分会成为电路负载导致光伏阵列出现发热现象形成热斑效应,严重影响输出功率,甚至造成组件损坏。针对上述问题,太阳电池模块通常在光伏组件的并联支路间串联防逆二极管防止各并联回路间电流倒流对光伏组件造成伤害。

以图 1 所示的 3×1 串并联光伏阵列为对象开展局部遮荫条件下的仿真分析。在仿真模型中,各个光伏组件参数均相同,标准太阳辐照度为 1 000 W/m^2,标准工作环境温度为 25 ℃。图 2 为对应表 1 的 3×1 光伏阵列在无遮荫的标准测试条件(Standard Test Conditions,STC)下和局部遮荫情况(Partial Shading Condition,PSC)下的 $P-U$ 曲线图。

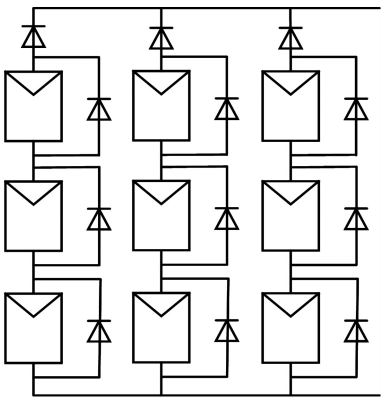

图 1　3×1 串并联光伏阵列

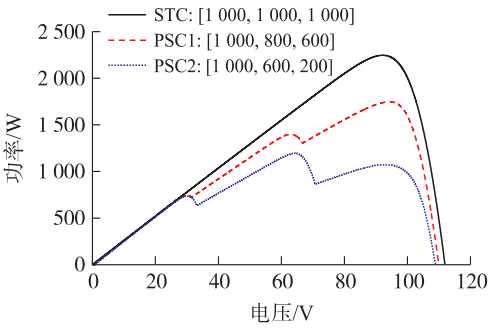

图 2　光伏阵列输出 *P–U* 曲线

表 1　不同光照模式下的光照幅度

局部阴影情况	G1	G2	G3
STC	1 000	1 000	1 000
PSC1	1 000	800	600
PSC2	1 000	600	200

在局部遮荫的条件下,光伏阵列的曲线呈多峰特征,光伏阵列的开路电压随光照强度的变化而变化,不同情况下的局部遮荫其多峰情况也不同。若采用传统的最大功率点跟踪算法难以实现复杂阴影下的光伏阵列的最大功率的工作输出,极有可能跟踪到的光伏系统的最大功率为局部最优值,进而影响到光伏系统的发电效率。为追踪到光伏阵列的最大功率点,需要算法具有跳出局部极值的能力。

2　精英反向学习与二次插值改进的鲸鱼优化算法在 MPPT 中的应用

2.1　鲸鱼优化算法的描述

鲸鱼优化算法是一种模拟座头鲸捕猎行为的优化算法。WOA 算法主要分为三个阶段:随机搜索、包围猎物和气泡网捕食。

①随机搜索。在初始的随机搜索猎物阶段,座头鲸根据它们的位置与其他鲸鱼的位置进行随机搜索。WOA 算法模拟这种行为,采用随机搜索的方式,扩大寻找最优解空间的搜索范围以提高算法在

前期的全局寻优能力。其数学模型如下：

$$D=|C\cdot x_r(t)-x(t)| \tag{1}$$

$$x(t+1)=x_r(t)-A\cdot D \tag{2}$$

式中：$x(t)$ 为当前搜索个体的位置向量；$x_r(t)$ 为当前选择的随机个体的位置向量；D 为当前搜索个体和选择的随机个体的距离；t 为当前迭代轮次；A、C 为系数向量，表达式如下：

$$A=2a_1\times r-a_1 \tag{3}$$

$$C=2\times r \tag{4}$$

式中：参数 a_1 随着迭代次数增加，其值从 2 线性减到 0；r 为取值[0,1]的随机向量。

②包围猎物。在包围猎物的阶段，基于当前解为最优解的假定基础上，其余搜索个体向当前最优个体的位置靠近，主动完成位置更新，其公式为：

$$D=|C\cdot x^*(t)-x(t)| \tag{5}$$

$$x(t+1)=x^*(t)-A\cdot D \tag{6}$$

式中：$x^*(t)$ 为当前迭代轮次最优个体的最优解。

③气泡网捕食。此阶段，座头鲸通过包围捕食或气泡网攻击两种方式接近猎物。当采用气泡网攻击时，鲸鱼沿着螺旋路径运动。WOA 算法用对数螺旋方程模拟这一过程，表示为：

$$D^*=|x^*(t)-x(t)| \tag{7}$$

$$x(t+1)=D^*\cdot e^{bl}\cdot\cos(2\pi l)+x^*(t) \tag{8}$$

式中：b 为对数螺线的常量系数；l 是值域为[-1,1]的均匀分布随机数。

WOA 算法利用系数向量的绝对值|A|大小来选择随机搜索或包围猎物进行位置更新：当|A|>1 时，WOA 算法强调全局搜索能力，通过等式(2)进行随机搜索更新位置。当|A|<1 时，WOA 算法通过等式(6)或式(8)向较优的搜索个体靠近，更新当前搜索个体的位置。并根据值域为[0,1]均匀分布的概率因子，WOA 算法在包围猎物或气泡网捕食间切换。其具体更新位置的方式为：

$$x(t+1)=\begin{cases}x_r(t)-A\cdot D & p<0.5,|A|\geqslant 1\\ x^*(t)-A\cdot D & p<0.5,|A|<1\\ D^*\cdot e^{bl}\cdot\cos(2\pi l)+x^*(t) & p\geqslant 0.5\end{cases} \tag{9}$$

2.2 精英反向学习与二次插值改进的鲸鱼优化算法

2.2.1 精英反向学习策略

相关研究表明：初始种群作为全局搜索算法的第一步，分布越均匀，越能提高找到最优解的概率，提升算法收敛速度[10]。但是 WOA 算法的初始种群采用纯随机的方式选取，初始种群随机性的特点导致种群分布不均匀，种群多样性差。EQWOA 算法引入反向学习策略(Opposition-Based Learning, OBL)优化初始种群，通过计算当前解的反向解，并评估当前解与反向解的优劣，保留最优解至下一代，增强种群的多样性，进而提高算法的学习率。

定义 1 反向解[11]。假设在 D 维搜索空间内的一点 $X=(x_1,x_2,\cdots,x_D)$ $(x_j\in[a_j,b_j])$ 是当前种群的一个可行解，其反向解为 $\bar{X}=(\bar{x}_1,\bar{x}_2,\cdots,\bar{x}_D)$，其中 $\bar{x}_j=k(a_j+b_j)-x_j$，k 为[0,1]上均匀分布的随机数。

反向学习虽然可以扩大算法的搜索空间，但其生成的反向解有一定概率比当前解在当前搜索空间内寻优效果更差，因此 EQWOA 算法的设计在反向学习的基础上引入精英反向学习(Elite Opposition-Based Learning，EOBL)。算法通过评估当前搜索空间的当前解与反向解的优劣，以适应度值作为评估标准，选取适应度值大于其反向解的原解作为精英个体群；在精英个体群组成的搜索空间中，计算作为精英个体的当前解的反向解，并保留最优解至下一代。

定义 2 精英反向解[11]。假设当前种群中的一般个体的极值点作为种群中的精英个体，$X_{i,j}^E=(X_{i,1}^E,X_{i,2}^E,\cdots,X_{i,D}^E)$ $(i=1,2,\cdots,N;j=1,2,\cdots,D)$，这些精英个体反向解 $\bar{X}_{i,j}^E=(\bar{X}_{i,1}^E,\bar{X}_{i,2}^E,\cdots,\bar{X}_{i,D}^E)$，定义为：

$$\bar{X}_{i,j}^E=K\times(a_j+b_j)-X_{i,j}^E \tag{10}$$

在式中，K 是在[0,1]上均匀分布的随机数，$\bar{X}_{i,j}^E\in[a_j,b_j]$，$a_j=\min(X_{i,j})$，$b_j=\max(X_{i,j})$，$a_j$ 和 b_j 分别为动态边界的上下界，利用动态边界替代固定边界保证精英反向解定位在较准确的搜索空间，以克服固定边界难以保存搜索经验的缺点，减短收敛时间，提高收敛效率。当存在反向解跳出动态边界成为非可行解时，利用随机生成的方法重置：

$$\bar{X}_{i,j}^E=\mathrm{rand}(a_j,b_j) \tag{11}$$

2.2.2 二次插值方法

精英反向学习策略虽然能增强算法全局搜索能力，但随着迭代轮次的增加，搜索群体的减少，搜索方向存在不确定性，易导致收敛速度的降低以及局部搜索能力的不足。为避免上述问题，本文在结合精英反向学习策略的基础上引入二次插值(Quadratic Interpolation，QI)[12]，二次插值属于一种利用曲线拟合的局部搜索算法，可以获得曲线极值点近似函数最优解，提升算法的收敛速度，加强局部搜索能力。

假设 D 维空间里，存在两个随机节点 $X=(x_1,x_2,\cdots,x_d)$，$Y=(y_1,y_2,\cdots,y_d)$ 和最优位置 $Z=(z_1,z_2,\cdots,z_d)$。其对应的适应度值分别为 $f(x)$，$f(y)$，

$f(z)$,利用二次插值方法生成的新个体 $\bar{X}=(\bar{x}_1,\bar{x}_2,\cdots,\bar{x}_D)$,如式(12)所示:

$$\bar{x}_k=\frac{(z_k^2-y_k^2)\times f(x)+(x_k^2-z_k^2)\times f(y)+(y_k^2-x_k^2)\times f(z)}{2[(z_k-y_k)\times f(x)+(x_k-z_k)\times f(y)+(y_k-x_k)\times f(z)]} \tag{12}$$

式中:$k=1,2,3,\cdots,D$。

随着二次插值的个体更新,种群会更新成新种群。为了提升种群的多样性,保证二次插值后的种群不会陷入局部最优:在每次迭代新的种群过程中,会将鲸鱼重新按照适应度由高到低排序。并将对应的个体 $a_i,a_{i+1}(i=1,2,\cdots,n-2)$ 再通过二次插值的方法生成新的个体 $\bar{a}_i$。并通过式(13)将其与目前全局最佳个体重新进行适应度评估,避免算法陷入局部最优,扩大搜索范围,提升种群多样性。

$$a_i=\begin{cases}a_i & f(a_i)>f(\bar{a}_i)\\ \bar{a}_i & f(a_i)\leqslant f(\bar{a}_i)\end{cases} \tag{13}$$

2.3　用于 MPPT 控制的改进鲸鱼算法步骤

本文提出精英反射学习(Elite Reverse Learning Strategy and Quadratic Interpolation Whale Optimization Algorithm,EQWOA)算法并用于 MPPT 控制中,将鲸鱼的位置作为光伏电池某一点的输出电压并将光伏发电系统的输出功率作为目标函数。其具体的执行步骤如下:

①初始化种群的相关参数,种群规模 N,最大迭代次数 T 和空间维度 D。并利用反向学习策略生成鲸鱼种群的反向种群 $OP=\{\cdots\}$。

②采集初始种群每个鲸鱼的个体位置和其对应反向个体位置的电压、电流,计算出初始种群个体和其反向种群个体的输出功率,确定其适应度大小。适应度值大于其反向种群个体的原个体作为精英个体群。

③根据 $a_j=\min(X_{i,j})$,$b_j=\max(X_{i,j})$ 确定步骤②中精英个体的电压搜索边界。

④精英个体群则根据式(10)生成精英反向种群 $EOP=\{\cdots\}$,并与初始精英种群的适应度进行排序,择优选取新一代初始种群,并将适应度最高的个体设为最优位置;

⑤更新参数 A、C、p。算法根据参数所处的不同域值按式(9)选取随机搜索、包围猎物或气泡网捕食的方式更新个体的位置。

⑥按式(12)结合二次插值的方法更新鲸鱼种群位置,并通过式(13)进行适应度评估,取输出功率大的鲸鱼个体保留。并判断是否到达最大迭代次数或满足终止条件,如果是,则跳出循环,输出最优占空比,系统跟踪到全局最大功率点,否则返回步骤②。

2.4　算法的启动条件

光伏阵列在实际工作中易受到环境的影响。其中包括了环境温度的变化、光照强度的变化或受到遮荫变化的影响,其最大功率点的位置也会有较大的波动。为适应环境的变化,此时系统应重新寻找最大功率点的位置,启动条件:

$$\Delta p=\left|\frac{P_t-P_{t-1}}{P_t}\right|\geqslant 0.1 \tag{14}$$

式中:P_t 为当前周期的输出功率;P_{t-1} 为上一周期的输出功率。设定好以一定周期对系统输出功率进行采样,当 $\Delta p\geqslant 10\%$ 时算法重新启动,重新寻找最大功率点的位置。图 3 为基于 EQWOA 的 MPPT 控制算法的流程图。

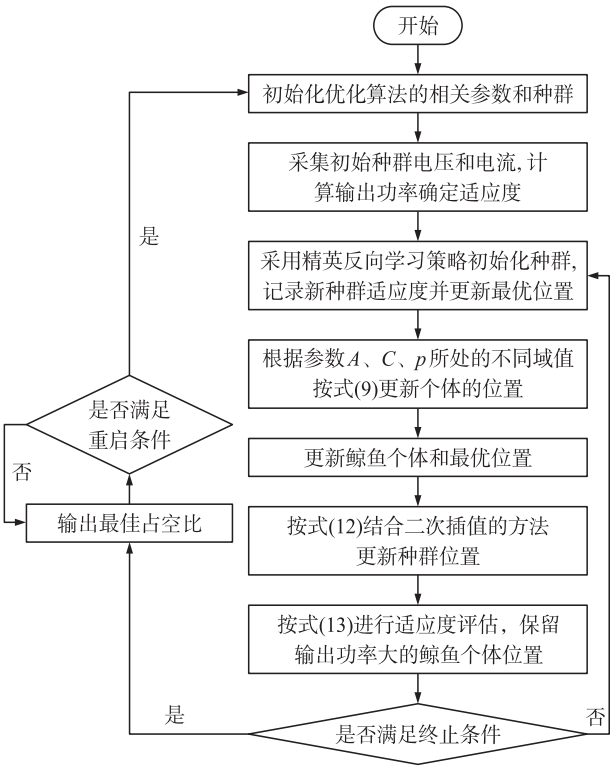

图 3　基于 EQWOA 的 MPPT 流程图

3　改进鲸鱼优化算法的仿真实验和性能校验

3.1　初始参数与测试函数设置设置

本文选取了粒子群算法(PSO)、基本的鲸鱼优化算发(WOA)和本文提出的 EQWOA 算法进行比对,所有算法的种群规模数 N 设为 30,最大迭代次数 T 设为 500,其余共有参数保持一致。为了校验提出的精英反向学习与二次插值改进的鲸鱼优化算法的寻优性能和稳定性。本文选取多个不同特点的测试函数进行比对测试,其中 $f_1\sim f_3$ 为单模态函数,$f_4\sim f_7$ 为多模态函数,如表 2 所示。

表 2 测试函数

函数	维度	范围	最优值
$f_1=\sum_{i=1}^{n}x_i^2$	30	[-100,100]	0
$f_2=\sum_{i=1}^{n}\left(\sum_{j-1}^{i}x_j\right)^2$	30	[-100,100]	0
$f_3=\sum_{i=1}^{n}(x_i+0.5)^2$	30	[-100,100]	0
$f_4=\sum_{i=1}^{n}-x_i\sin(\sqrt{\lvert x_i\rvert})$	30	[-500,500]	-418.982
$f_5=\sum_{i=1}^{n}[x_i^2-10\cos(2\pi x_i)+10]$	30	[-5.12,5.12]	0
$f_6=\sum_{i=1}^{n}\left[a_i-\frac{x_1(b_i^2+b_ix_2)}{b_i^2+b_ix_3+x_4}\right]$	4	[-5,5]	0.00030
$f_7=\sum_{i=1}^{n}\left[\frac{1}{500}+\sum_{j=1}^{25}\frac{1}{j+\sum_{i=1}^{2}(x_i-a_{ij})^6}\right]^{-1}$	2	[-65,65]	1

3.2 结果对比分析

为验证 EQWOA 算法的寻优有效性和稳定性，对 PSO、WOA 和本文提出的 EQWOA 通过上述 7 个测试函数进行测试对比，结果如表 3 所示。

表 3 测试函数的结果

函数	算法	最优值	平均值	标准差
f_1	PSO	6.05e-13	2.61e-06	6.06e-06
	WOA	3.21e-85	1.50e-68	8.22e-68
	EQWOA	5.56e-99	8.91e-89	3.42e-88
f_2	PSO	1.24e+03	6.04e+03	2.92e+03
	WOA	8.68e+03	4.22e+04	1.43e+04
	EQWOA	2.92e-01	3.11e+01	0
f_3	PSO	2.76e+02	8.80e+02	3.47e+02
	WOA	8.73e-02	3.42e-01	1.80e-01
	EQWOA	7.80e-21	4.13e-16	9.64e-16
f_4	PSO	-7.19e+03	-5.84e+03	6.37e+02
	WOA	-1.25e+04	-1.04e+04	1.77e+03
	EQWOA	-1.25e+04	-1.10e+04	1.80e+03
f_5	PSO	6.19e+01	1.04e+02	1.8e+01
	WOA	0	0	0
	EQWOA	0	0	0
f_6	PSO	3.07e-04	2.01e-02	5.00e-03
	WOA	3.07e-04	2.25e-03	6.62e-04
	EQWOA	3.07e-04	2.03e-03	4.37e-04
f_7	PSO	0.998	5.5828	0.32e-01
	WOA	0.998	2.3096	0.26e-01
	EQWOA	0.998	0.998	2.959e-16

在表 2 的七个测试函数中，f_1~f_3 为单模态函数，一般用于检测函数的开发能力。根据表 3 结果所示，对于函数 f_1~f_3，EQWOA 可以搜索到的最优值皆小于 WOA 和 PSO，其寻优效果最好，WOA 寻优效果次之，PSO 寻优效果最差。相较于 WOA 和 PSO 算法，EQWOA 三个单模态函数的寻优标准差皆为最小，尤其对于 f_2，寻优标准差值为 0，说明 EQOWA 改进算法的寻优值较为聚集，离散程度小，算法鲁棒性好稳定性较强。f_4~f_7 为多模态函数，多模态函数具有多极值的特点，优化算法在寻优过程中很容易遇到陷入局部最优且难以跳出的问题，一般用于检测函数的探索能力。对于函数 f_4~f_5，WOA 和 EQWOA 能直接搜索到函数最优质，PSO 表现较差，对于函数 f_6~f_7，PSO、WOA 和 EQWOA 均能直接搜索到最优值。此外在多模态函数的测试中，EQWOA 的寻优平均值优于 PSO 和 WOA，其标准差小于 PSO 和 WOA。说明在多模态函数的寻优过程中 EQWOA 具有较好的寻优能力，且鲁棒性好稳定性较强。

为了进一步验证本文改进 EQWOA 算法的寻优速度与性能，本文选取单模态函数 f_2、f_3 以及多模态函数 f_6、f_7 的收敛曲线直观地体现 EQWOA 的寻优性能。图 4(a)和图 4(b)的收敛曲线显示 EQWOA 的收敛精度最大。其中图 4(a)中 PSO 的收敛速度虽然快于 EQWOA，但收敛精度即远远不如 EQWOA。图 4(c)和图 4(d)的收敛曲线显示 EQWOA 的收敛速度和收敛精度明显优于 PSO 和 WOA。说明本文提出的 EQWOA 算法在尽量保证寻优速度的情况下提高了算法的寻优精度，并在迭代过程中不易陷入局部最优值。

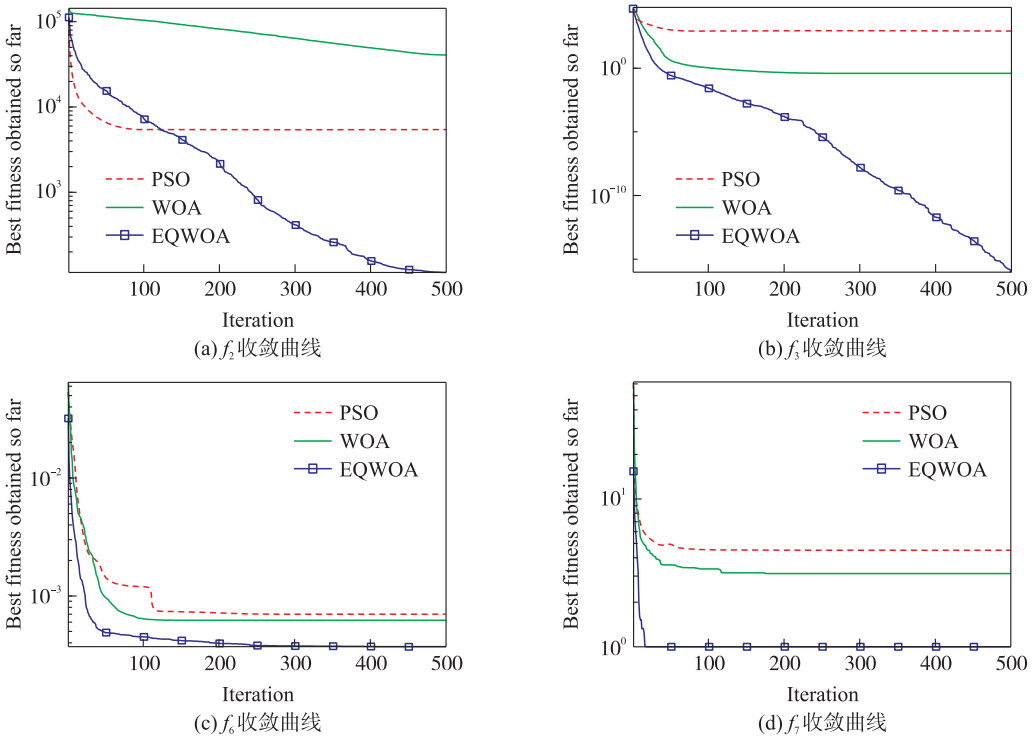

(a) f_2收敛曲线　(b) f_3收敛曲线

(c) f_6收敛曲线　(d) f_7收敛曲线

图 4　测试函数的收敛曲线

4　光伏系统仿真与结果分析

为了验证 EQWOA 算法应用于光伏阵列的最大功率的追踪性能,依次在静态局部遮荫和动态局部遮荫两种条件下,分别对麻雀搜索算法[13](Sparrow Search Algorithm,SSA)、PSO、WOA 和 EQWOA 进行光伏阵列最大输出功率追踪的仿真分析和追踪效果对比。

在 MATLAB/Simulink 的环境下搭建图 5 所示的 5×1 的光伏阵列仿真模型,系统采样时间设定为 1 ms。在静态局部遮荫条件下,光伏阵列所受温度为 25 ℃,设置的光伏阵列 5 个光伏模块的光照强度依次为 1 000 W/m^2、900 W/m^2、800 W/m^2、700 W/m^2、600 W/m^2,系统仿真时间为 4 s,采样周期为 1 ms,其输出特性曲线如图 6(a)所示,在此工况下,光伏阵列的输出最大功率为 726.2 W。在动态局部遮荫条件下,光伏阵列所受温度为 25 ℃,在 $t=0$ s 时,5 个光伏模块的光照强度依次为 1 000 W/m^2、900 W/m^2、800 W/m^2、700 W/m^2、600 W/m^2,在 $t=2$ s 时候,各个光伏模块的光照强度依次突变为 800 W/m^2、800 W/m^2、700 W/m^2、400 W/m^2、300 W/m^2,系统仿真时间为 4 s,采样周期为 1 ms。其输出特性曲线如图 6(b)所示,在此工况下,光伏阵列的输出最大功率为 424.2 W。

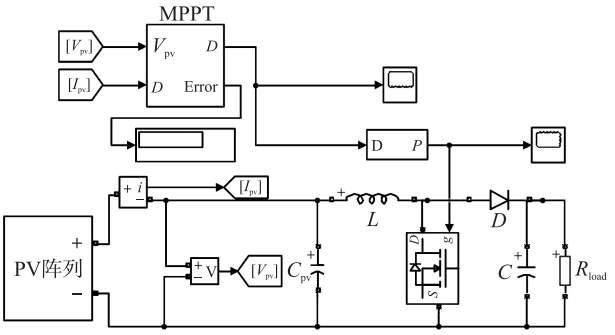

图 5　光伏系统仿真模型

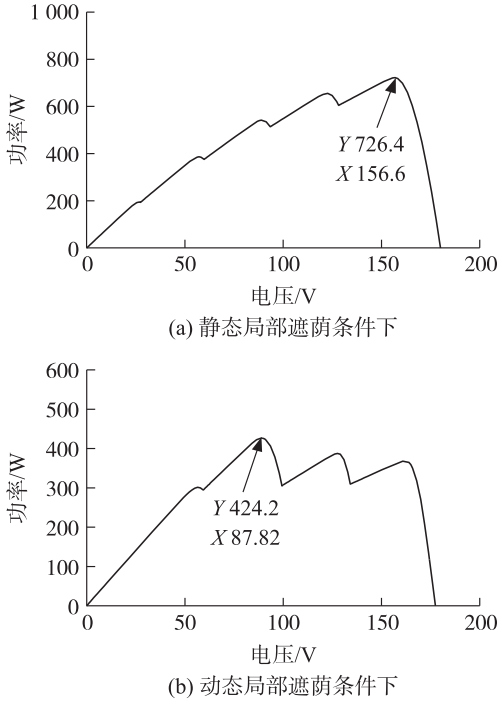

(a) 静态局部遮荫条件下

(b) 动态局部遮荫条件下

图 6　光伏阵列特性曲线

4.1 静态局部遮荫条件下的仿真分析

在静态局部遮荫条件下,仿真结果如图 7 所示,其中图 7(a)~图 7(d)分别为 SSA 算法、PSO 算法、WOA 算法和 EQWOA 算法在静态局部遮荫条件下的输出功率曲线图。四种算法在局部遮荫条件下都不会陷入局部最优点,分别在 0.56 s、1.276 s、0.67 s 和 0.466 s 跟踪到最大功率点。在趋稳过程中,对比 EQWOA 算法,其他三种算法需要较多的迭代次数,其中 SSA 算法和 WOA 算法在寻优过程中存在较为严重的振荡过程,不利于系统的稳定性,且在达到最大功率点后其功率输出有一定波动,易导致系统不稳定。PSO 算法虽然在振荡过程中振幅小于其他三种算法,系统稳定性较好,但寻优效率较差,于 1.276 s 首次达到最大功率点。综上,EQWOA 算法不仅跟踪时间较短,寻优效率较高,在趋稳过程中振幅小、振荡频次少,能较快地精准跟踪到最大功率点。

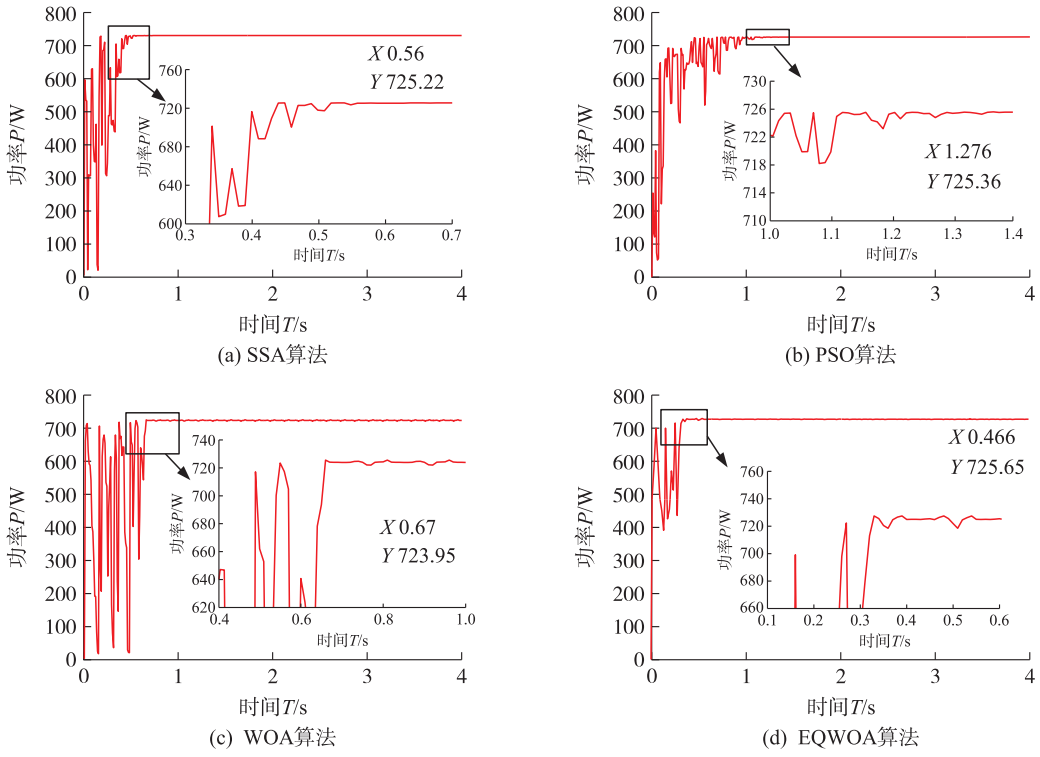

图 7 静态局部遮荫条件下系统输出功率曲线

4.2 动态局部遮荫条件下的仿真分析

在动态局部遮荫条件下,光伏阵列的最大功率点会随光照突变而改变。如图 8 所示,其中图 8(a)~图 8(d)分别为 SSA 算法、PSO 算法、WOA 算法和 EQWOA 算法在动态局部遮荫条件下的输出功率曲线图。

在图 8(a)中 SSA 算法在光照强度突变后,于 2.015 s 首次达到最大功率点附近。在再次寻找最大功率的过中,SSA 算法趋稳过程较为平缓,但会在最大功率点附近持续振荡,与系统理想最大功率点相差较大,约为 83 W。对比其他算法,SSA 算法容易陷入了局部极值且追踪精度的误差较大,无法适用于动态局部遮荫条件下的最大功率点跟踪。由图 8(b)、图 8(c)可知,PSO 算法和 WOA 算法在光照强度突变后的趋稳过程中存在较大的振荡,分别于 2.72 s 和 2.156 s 首次达到最大功率点 393.16 W 和 411.16 W,追踪精度分别约为 92.63%和 96.93%。两种算法对比 SSA 算法在光照强度突变后,再次进行寻优后追踪精度有所提高,但在趋稳过程中需要经历一定范围内的连续振荡且振幅较大,容易影响系统稳定性。

在图 8(d)中,本文所提出的 EQWOA 算法在光照强度突变后于 2.185 s 重新找到最大功率 422.32 W。对比 PSO 和 WOA 算法,寻优时间比 PSO 算法减少了 0.535 s,寻优效率与 WOA 算法相仿。但在寻优过程中,EQWOA 算法振荡频次和振幅明显小于 PSO 和 WOA 算法。EQWOA 算法最终达到的最大功率点 422.32 W,与理想最大功率点相差 2.05 W,追踪精度约为 99.56%,较于 PSO 和 WOA 算法追踪精度分别提升了约 6.93%和 2.63%。

综上,在动态局部遮荫条件下,当光照强度发生突变,本文所提出的 EQWOA 算法具有良好的追踪性能,跟踪时间短,寻优效率高,在寻优过程中系统稳定性强,且在的追踪到最大功率点后,功率输出稳定。

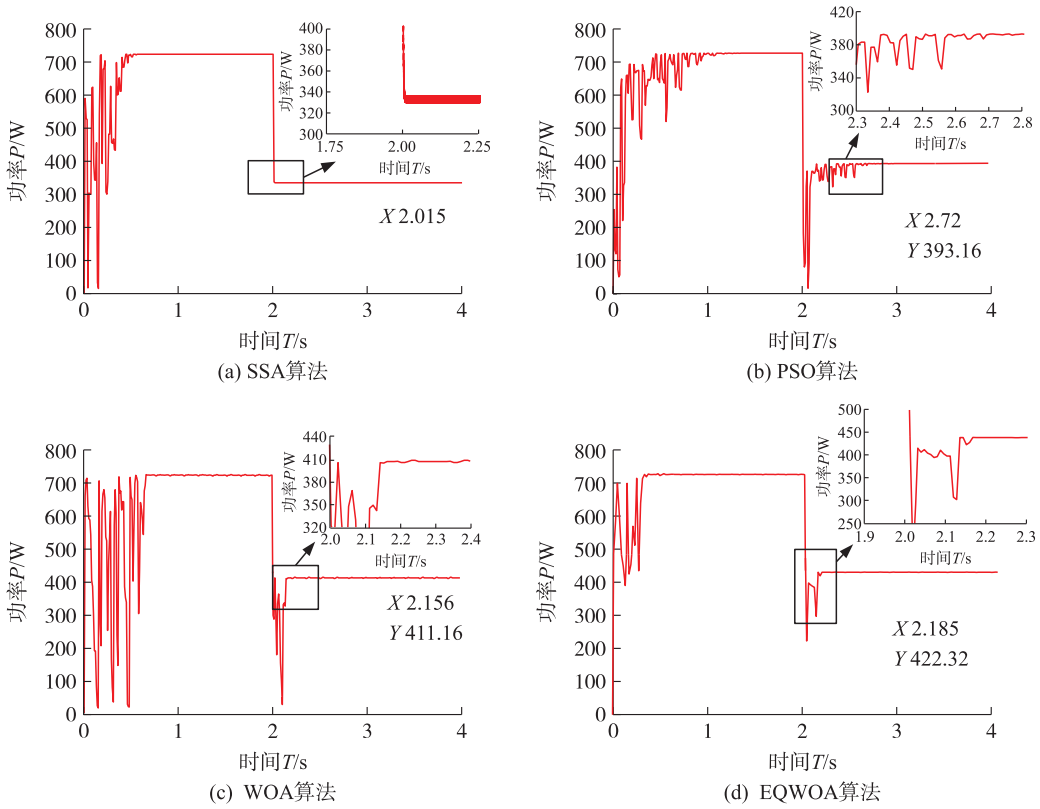

(a) SSA算法　(b) PSO算法　(c) WOA算法　(d) EQWOA算法

图 8　动态局部遮荫条件下系统输出功率曲线图

5　结论

受外界影响在局部遮荫的条件下,光伏阵列输出 *P*-*U* 曲线存在若干个局部最大功率点,传统的控制方法容易陷入局部极值。针对该问题,本文提出一种改进鲸鱼优化算法的 MPPT 控制方法,通过精英反向学习策略优化初始种群提升全局搜索能力,避免陷入局部极值。并通过二次插值方法提升算法的收敛速度和寻优效率。分别与麻雀搜索算法、粒子群算法和传统的鲸鱼算法进行仿真分析和追踪效果对比。静态遮荫条件下,EQWOA 算法对比其他算法跟踪时间较短,寻优效率更高,复杂遮荫环境下追踪精度达 99.56%,明显优于其他算法,具有良好的追踪性能,能够快速稳定且精准地追踪到全局最大功率点,有效避免光伏系统在复杂阴影条件陷入局部极值。

参考文献:

[1] 邵文权,王猛,吴朝俊,等. 基于改进滑模控制的光伏系统 MPPT 控制策略[J]. 太阳能学报,2021,42(10):87-93.

[2] 徐伟,郑建立. 基于 BP 神经网络的最大功率跟踪研究[J]. 电工技术,2020(12):62-65.

[3] 毛明轩,许钊,崔立闯,等. 基于改进灰狼优化算法的光伏阵列多峰 MPPT 研究[J]. 太阳能学报,2023,44(3):450-456.

[4] Mohanty S, Subudhi B, Ray P K. A Grey Wolf-Assisted P&O MPPT Algorithm for a PV System[J]. IEEE Transactions on Energy Conversion,2017,32(1):340-347.

[5] Singh P,Shukla N,Gaur P. Modified Variable Step Incremental-Conductance MPPT Technique for Photovoltaic System[J]. International Journal of Information Technology,2021,13(6):2483-2490.

[6] Subha R,Himavathi S. Accelerated Particle Swarm Optimization Algorithm for Maximum Power Point Tracking in Partially Shaded PV Systems[C]//2016 3rd International Conference on Electrical Energy Systems,Chennai,India,2016:232-236.

[7] Mirjalili S, Lewis A. The Whale Optimization Algorithm [J]. Advances in Engineering Software, 2016, 95(5): 51-67.

[8] 徐珊珊,金玉华,张庆兵. 全局判据的改进量子粒子群优化算法[J]. 系统工程与电子技术,2018,40(9):2131-2137.

[9] 李志军,张奕楠,王丽娟,等. 基于改进量子粒子群算法的光伏多峰 MPPT 研究[J]. 太阳能学报,2021,42(5):221-229.

[10] Tizhoosh H R. Opposition-Based Learning: A New Scheme for Machine Intelligence[C]//2005 International Conference on Computational Intelligence for Modelling,Control and Automation,and International Conference on Intelligent Agents,

Web Technologies and Internet Commerce, Vienna, Austria, IEEE, 2005: 695-701.

[11] Seif Z, Ahmadi M B. An Opposition-Based Algorithm For-function Optimization [J]. Engineering Applications of Artificial Intelligence, 2015, 37(10): 293-306.

[12] Chen X, Mei C L, Xu B, et al. Quadratic Interpolation Based Teaching-Learning-Based Optimization for Chemical Dynamic System Optimization [J]. Knowledge-Based Systems. 2018.145(4): 250-263.

[13] 李争, 罗晓瑞, 张杰, 等. 基于改进麻雀搜索算法的光伏功率短期预测 [J]. 太阳能学报, 2023, 44(6): 284-289.

胡皓轩(2000—), 男, 江西上饶人, 硕士研究生, 主要研究领域为机器人控制与算法;

张春燕(1980—), 女, 安徽淮北人, 教授, 硕士研究生导师, 主要研究领域为电力电子与电力传动, cyzhang@ sues.edu.cn。