

DOI:10.19651/j.cnki.emt.2312832

改进人工生态系统优化算法解决光伏模型参数辨识问题^{*}

张伟伟 余晓秋 张卫正 文笑雨 王晓

(郑州轻工业大学计算机与通信工程学院 郑州 450002)

摘要: 光伏模型同时具有非线性和多模态的特点,传统算法在对其参数识别时易陷入局部最优,且识别精度不足。提出了一种改进的人工生态系统优化算法(IAEO),通过引入非线性控制参数调整策略来平衡探索与开发的关系,利用混沌的遍历性和非重复性来增强算法的探索能力。仿真实验表明,在单、双和三极管和光伏组件模型上,改进算法的参数识别精度均超过99.9%,相较于原算法的RMSE值在四种模型上平均提高5.5%,和五种先进算法对比具有较强的优势。采用厂商真实数据对薄膜、单晶和多晶3种光伏组件在不同的光照和温度条件下进行测试,改进算法在不同环境中依然保持较高的准确性和稳定性。

关键词: 改进的人工生态系统优化算法;非线性控制参数调整策略;光伏模型;参数识别;进化算法

中图分类号: TP18 **文献标识码:** A **国家标准学科分类代码:** 470.4031

Improved artificial ecosystem optimization algorithm to solve PV model parameter identification problem

Zhang Weiwei Yu Xiaoqiu Zhang Weizheng Wen Xiaoyu Wang Xiao

(College of Computer and Communication Engineering, Zhengzhou University of Light Industry, Zhengzhou 450002, China)

Abstract: Photovoltaic models are both nonlinear and multimodal, and traditional algorithms are prone to fall into local optimality and insufficient recognition accuracy when identifying their parameters. In this paper, an improved artificial ecosystem optimization (IAEO) algorithm is proposed to balance exploration and exploitation by introducing a nonlinear control parameter adjustment strategy to enhance the exploration capability of the algorithm by exploiting the ergodic and non-repetitive nature of chaos. Simulation experiments show that the parameter identification accuracy of the improved algorithm exceeds 99.9% on both single, dual and triple diode and PV module models, and the RMSE value is improved by 5.5% on average on the four models compared to the original algorithm, which has a strong advantage compared to the five advanced algorithms. The improved algorithm still maintains high accuracy and stability in different environments when tested under different lighting and temperature conditions using real manufacturer data for three types of PV modules: thin-film, mono-crystalline and multi-crystalline.

Keywords: improved artificial ecosystem optimization algorithm; nonlinear control parameter tuning strategy; photovoltaic model; parameter identification; evolutionary algorithm

0 引言

光伏系统能够将太阳光辐射转化为电能,被成功应用于照明、取暖等许多领域^[1]。光伏模型能够有效的描述光伏系统的非线性行为,其准确性主要受到相关参数的影响。这些参数不仅对于光伏模型的性能评估和质量控制至关重要,而且在光伏系统的最大功率点追踪中也具有重要作用。

因此,准确快速地识别光伏模型未知参数至关重要。

由于光伏模型的多模态和非线性特性,传统的解析式方法^[2]在进行参数识别时容易陷入局部最优,且搜索精度较低。由于不要求问题的显式表述,善于处理多模态和非线性问题等优点,元启发式算法^[3-4]在光伏参数识别领域取得了瞩目的研究成果。文献[5]提出了一种基于自适应的集成差分进化算法,通过结合3种不同的变异策略和自适

收稿日期:2023-02-16

*基金项目:国家自然科学基金(51905494)、河南省高等教育改革研究与实践项目(2021SJGLX115Y)资助

应方案平衡全局和局部搜索。针对粒子群算法早熟收敛的缺点,增强型领导粒子群优化算法^[6]被提出,并引入了自适应变异策略和五阶段连续变异策略。另外,新型的智能优化算法也不断地被应用在光伏模型参数识别中。Yu 等^[7]提出了一种具有多元学习的回溯搜索算法,通过引入多元学习和混沌局部搜索策略优化每个子种群。Farah 等^[8]提出了一种综合学习 Rao-1 优化算法,采用 3 个互斥搜索方程解决 Rao-1 算法过早收敛和多样性不足问题。虽然这些算法在光伏模型参数识别问题上取得了不错的成绩,但仍然存在容易陷入局部最优、控制参数过多、CPU 运算时间长等问题。其次,很多研究^[4-8]停留在对单二极管和双二极管模型的参数识别,缺乏在更复杂的模型(如三二极管模型)上的测试。最后,光伏系统需要露天放置,但不同温度和光照等极端天气状况下的光伏参数识别还有待深入研究。

基于人工生态系统的优化算法(artificial ecosystem-based optimization, AEO)^[9]模仿了生产、消耗和分解阶段生物体的自然模式,具有结构简单、控制参数少等优点,并且对初始值不敏感,吸引了许多研究人员的注意,被成功应用于许多领域^[10-11]。本文比较了 5 种典型的基础优化算法在光伏模型参数识别问题上的表现。实验结果表明,相较于其他典型优化算法,AEO 在光伏模型参数识别上具有显著优势。然而,基本的 AEO 仍存在收敛速度和精度不足,易陷入局部最优解的问题。因此,本文在 AEO 中引入了非线性控制参数调整策略,取代原本的线性权重系数,提出了一种改进的人工生态系统优化算法(improved algorithms for artificial ecosystem optimization, IAEAO)。利用混沌的遍历性和非重复性,更好的平衡探索与开发之间的关系。通过与五种先进的算法对比,IAEAO 在更复杂的双二极管和三二极管模型上明显具有更高的精度和稳定性。另外,本文利用制造商的真实数据表中的三种光伏组件进行仿真实验,验证了算法在不同的温度和光照强度条件下的稳定性。

1 光伏模型

1.1 单二极管光伏模型

如图 1(a)所示,单二极管模型的光伏电池由光生电流、并联二极管、串联和并联电阻组成,其输出电流为^[12]:

$$I = I_{ph} - I_{sd} \left[\exp\left(\frac{q(V_t + I_t R_s)}{z_1 kT}\right) - 1 \right] - \frac{(V_t + I_t R_s)}{R_{sh}} \quad (1)$$

1.2 双二极管光伏模型

双二极管模型(如图 1(b)所示)通过并联二极管解决了载流子在耗散区产生复合损失的问题,其精确度高于单二极管模型。双二极管光伏电池的输出电流为:

$$I = I_{ph} - I_{sd1} \left[\exp\left(\frac{q(V_t + I_t R_s)}{z_1 kT}\right) - 1 \right] - I_{sd2} \left[\exp\left(\frac{q(V_t + I_t R_s)}{z_2 kT}\right) - 1 \right] - \frac{(V_t + I_t R_s)}{R_{sh}} \quad (2)$$

1.3 三二极管光伏模型

如图 1(c)所示,三二极管光伏模型比双二极管光伏模型多一个分流电阻,可以避免 P-N 结电中性区、空间电荷区和缺陷区域的重组产生的损耗,从而更准确地描述光伏电池的内部特性,其输出电流如下:

$$\begin{aligned} I &= I_{ph} - I_{sd1} \left[\exp\left(\frac{q(V_t + I_t R_s)}{z_1 kT}\right) - 1 \right] - \\ &I_{sd2} \left[\exp\left(\frac{q(V_t + I_t R_s)}{z_2 kT}\right) - 1 \right] - \\ &I_{sd3} \left[\exp\left(\frac{q(V_t + I_t R_s)}{z_3 kT}\right) - 1 \right] - \frac{V_t + I_t R_s}{R_{sh}} \end{aligned} \quad (3)$$

其中, I_{ph} 是光产生的电流, I_{sd} , I_{sd1} , I_{sd2} , I_{sd3} 是二极管反向饱和电流, I_t 和 V_t 分别是电池输出电流和电压, R_s 和 R_{sh} 分别是串联和并联电阻, z , z_1 , z_2 和 z_3 是理想系数, k 是玻尔兹曼常数, q 是电子电荷, T 是光伏电池的绝对温度。

从光伏模型结构可以看出,单二极管模型有 5 个未知参数(I_{ph} , I_{sd} , z , R_s 和 R_{sh}),双二极管模型有 7 个未知参数(I_{ph} , I_{sd1} , I_{sd2} , z_1 , z_2 , R_s 和 R_{sh}),而三二极管模型有 9 个未知参数(I_{ph} , I_{sd1} , I_{sd2} , I_{sd3} , z_1 , z_2 , z_3 , R_s 和 R_{sh})需要确定。

1.4 光伏面板模型

光伏面板(如图 1(d)所示)通过多个光伏电池的串联或者并联以提高其输出电压和(或者)输出电流。光伏面板模型中的光伏电池输出电流如下:

$$\begin{aligned} I/N_p &= I_{ph} - I_{sd} \left[\exp\left(\frac{q(V_t/N_s + I_t R_s/N_p)}{z kT}\right) - 1 \right] - \\ &\frac{(V_t/N_s + I_t R_s/N_p)}{R_{sh}} \end{aligned} \quad (4)$$

其中, N_s 为串联单二极管个数, N_p 为并联单二极管个数。

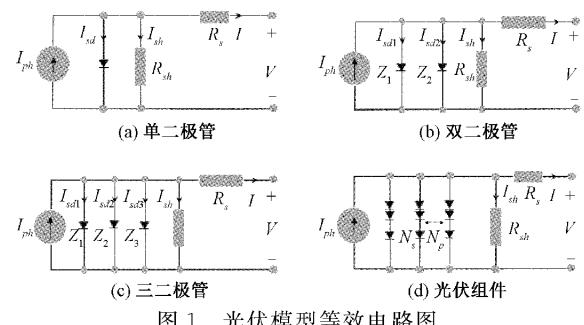


图 1 光伏模型等效电路图

1.5 光伏面板模型目标函数定义

识别光伏模型参数的主要目标是提高参数精度,减少测量值和预测值之间的电流数据差异^[12]。本文采用均方根误差(RMSE)作为光伏模型的目标函数。

$$RMSE(X) = \sqrt{\frac{1}{N} \sum_{k=1}^N f_k(V, I, X)^2} \quad (5)$$

其中, $\sum_{k=1}^N f_k(V, I, X)$ 是光伏模型的测量值和预测值

的误差函数, N 为实验数据的大小, X 是模型需要估计的参数。

2 改进的人工生态系统优化算法

2.1 人工生态系统优化算法

人工生态系统优化算法是基于生态系统中能量流动的思想提出的^[9]。生态系统包含生产者、消费者和分解者, 其优化过程经历生产、消费和分解 3 个阶段。

在生产阶段, 生产者(最差的个体)利用决策空间的上下界和分解者(最好的个体)进行更新。在消费阶段, 消费者共分为 3 种类型, 分别是食草动物、食肉动物和杂食动物, 其中食草动物捕食生产者, 肉食动物随机选择能量水平较高的消费者, 杂食动物可以捕食生产者和能量水平高的随机消费者。在分解阶段, 每个生物体在生态系统中都会被分解者分解。

将基础 AEO 算法应用于光伏模型参数识别, 其参数识别效果与领域内典型的优化算法进行对比分析。图 2 展示了 AEO 和 JAYA 算法、灰狼算法(GWO)、回溯搜索算法(BSA)和克隆选择算法(CSA)在 4 种光伏模型上的实验结果的 Friedman 排名。可以看出, 相较于其他算法, 基础的 AEO 在光伏模型识别问题上已经具备较大优势。

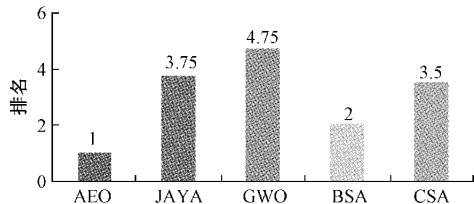


图 2 5 种基础算法在光伏模型上的 Friedman 测试排名

2.2 改进的人工生态系统优化算法

1) 非线性控制参数调整策略

在 AEO 中, 生产者 X_1 (最差的个体)根据分解者(最好的个体 X_{best})进行更新, 更新方式如下:

$$X_1(t+1) = (1 - \alpha)X_{best}(t) + \alpha X_{rand}(t) \quad (6)$$

其中, $\alpha = (1 - FES/MaxFes)r_1$ 为线性权重系数, $MaxFes$ 和 FES 分别是最大和当前评价次数, r_1 为 $[0, 1]$ 之间的随机数, X_{rand} 是在决策空间中随机产生的个体。可以看出, 生产者阶段的探索和开发能力的平衡主要依赖参数 α 来控制。 α 的值越高, 越有利于对搜索空间全局性的探索, 而 α 值越低, 越倾向于局部的精确寻优。随着迭代次数的增加, 参数 α 取值范围从 1 逐渐下降到 0。图 3 展示了参数 α 随迭代次数的变化的取值情况。从图中可以看出, 参数 α 大于 0.5 的比例很小, 尤其随着迭代次数的增加, 其值越小。这将导致其全局搜索能力的下降, 在解决多峰值函数问题时容易陷入局部最优, 导致早熟收敛。

因此, 本文提出了一种非线性控制参数调整机制, 利用混沌的遍历性和非重复性来增强算法的探索能力, 避免陷

入局部最优解。在改进的生态系统优化算法中, 非线性控制权重描述如下:

$$\beta^{t+1} = \begin{cases} \frac{\beta^t}{P}, & 0 \leq \beta^t \leq P \\ \frac{\beta^t - P}{0.5 - P}, & P \leq \beta^t \leq 0.5 \\ \frac{1 - P - \beta^t}{0.5 - P}, & 0.5 \leq \beta^t \leq 1 - P \\ \frac{1 - \beta^t}{P}, & 1 - P \leq \beta^t \leq 1 \end{cases} \quad (7)$$

其中, 参数 P 设置为 0.4, β 初始值为 $[0, 1]$ 之间的随机数。与原始参数 α 相比, 非线性控制参数 β 更侧重于迭代期间的探索。图 3 展示了非线性控制参数 β 与原始参数 α 的取值情况对比。可以看到, 参数 β 的取值范围更大。根据式(7), 在迭代过程中非线性控制参数的值越高, 表明其更倾向于进行全局的探索, 能够增加种群的多样性, 更不易陷入局部最优。

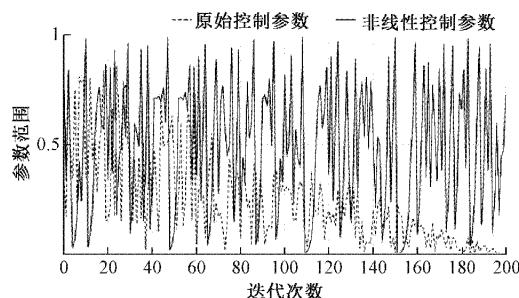


图 3 原始控制参数和非线性控制参数对比

2) 改进的人工生态系统优化算法的具体步骤

本文基于非线性控制参数调整策略提出了改进的人工生态系统优化算法 IAEO, 其具体步骤如下:

步骤(1): 初始化人工生态种群, 并计算种群中个体的适应度值, 根据适应度值将种群中的个体按降序排列。

步骤(2): 进入生产者阶段, 采用非线性控制参数调整策略, 根据式(6)、(7)更新种群中的生产者。

步骤(3): 进入消费者阶段, 种群中每个个体按照相同概率被随机划分为食草动物、杂食动物和肉食动物, 分别根据式(8)~(10)进行更新。

$$X_i(t+1) = X_i(t) + K(X_i(t) - X_1(t)) \quad (8)$$

其中, $i = [2, \dots, NP]$, NP 表示种群规模, $K = v_1/2|v_2|$ 为基于莱维飞行改进的消费因子, v_1 和 v_2 为服从标准正态分布的随机数。

$$X_i(t+1) = X_i(t) + K \cdot (X_i(t) - X_v(t)) \quad (9)$$

其中, X_v 为能量水平较高的随机消费者, v 表示 $[2, i-1]$ 之间的随机数。

$$X_i(t+1) = X_i(t) + K(r_2(X_i(t) - X_1(t)) + (1 - r_2)(X_i(t) - X_v(t))) \quad (10)$$

其中, r_2 表示 $[0, 1]$ 范围内的随机数。

步骤(4):进入分解阶段,计算种群中个体的适应度值找到最佳个体,根据式(11)分解所有的消费者。

$$X_i(t+1) = X_{best}(t) + D(eX_n(t) - h \cdot X_i(t)) \quad (11)$$

其中, $D=3u$ 为分解系数, u 为服从标准正态分布的随机数, $e=r_3 \cdot rand([1,2])-1$, $i=[1, \dots, NP]$, r_3 为 $[0,1]$ 之间的随机数, $h=2 \cdot r_3-1$ 。

步骤(5):判断算法是否满足停止条件,若达到最大函数评价次数,则输出全局最优解,否则进入步骤(2)更新循环,直到满足终止条件。

3 实验分析

3.1 实验设置

为了评估所提 IAEo 提取光伏模型参数的准确性,采用单、双和三二极管模型以及光伏组件对其进行测试。分别采用 RTC France 光伏电池和 Photowat-WP201 光伏组件进行实验。各个模型参数的取值范围可参照文献^[13]。另外,针对光伏模型的参数识别易受到极端天气的影响,采用从制造商的数据表中获取的光伏组件^[14](薄膜 ST40、单晶 SM55 和多晶 KC200GT)在 5 种不同光照水平(1 000、800、600、400、200 w/m²)和不同温度水平(ST40 在 25 °C、40 °C、55 °C、70 °C 的条件,SM55 在 25 °C、40 °C、60 °C 的条件,KC200 T 在 25 °C、50 °C、75 °C 的条件)下的电流电压曲线中提取的真实数据进行测试。

本文将 5 种先进的算法与所提出的 IAEo 进行比较,包括 IJAYA^[15]、PGJAYA^[16]、MLBSA^[7]、STLBO^[17] 和 COOT^[18]。为了比较的公平性,所有参与比较的算法的最大评价数被设定为 50 000,其相关参数的设定与原文保持一致,每一次实验独立运行 30 次。实验结果中最优的 RMSE 值以粗体表示。

3.2 与基本 AEO 算法实验对比

表 1 的最后两列展示了基本 AEO 和改进的算法在不同光伏模型上的实验效果。可以看出,采用所提策略中的

混沌序列替代基本 AEO 中的线性参数,使得算法在面对复杂的非线性多模态问题时探索能力明显增强,相较于原算法的 RMSE 值在四种模型上平均提高 5.5%。

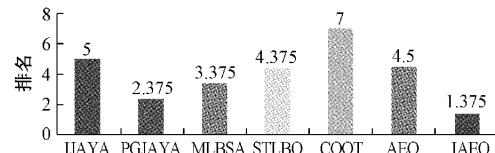


图 4 不同算法在 Friedman 测试上的排名

3.3 与 5 种先进算法实验对比

表 1 的前 5 列展示了 5 种先进算法在光伏模型上的实验结果。可以看出,IAEO 算法在 4 个模型上参数识别的误差都很小。从单二极管的实验结果可以看出 IAEo、MLBSA 和 STLBO 的 RMSE 值都达到了最小精度 $9.860\ 218 \times 10^{-4}$,并且这 3 个算法的参数也几乎一致,但在 RMSE 值的方差上面,只有 IAEo 的标准差最小达到了 $1.747\ 0 \times 10^{-15}$,其次是 MLBSA 达到了 $2.734\ 0 \times 10^{-13}$ 。双二极管模型的实验结果可以看出只有 IAEo 算法的 RMSE 值达到了最小精度 $9.847\ 310\ 5 \times 10^{-4}$,MLBSA 的标准差稍微领先于 IAEo。在更复杂的三二极管模型中,IAEO 依然能达到最好的精度 $9.861\ 037 \times 10^{-4}$,其次是 PGJAYA、MLBSA 和 IJAYA 算法。在光伏组件模型中,IAEO 以较小的差距获得了第一名,但是依然获得了最小的方差。图 4 显示了对比算法在四个光伏模型上的平均结果的 Friedman 测试排名。所提出的 IAEo 获得了第一名,其次是 PGJAYA、MLBSA、STLBO、AEO、IJAYA 和 COOT。

综上所述,在较简单的光伏模型中,IAEO、PGJAYA 和 MLBSA 算法都可以较高的精度,但是当模型的复杂度增加时,例如在双二极管模型和三二极管模型中,IAEO 算法中的非线性控制参数在面对复杂的多模态问题时体现了更高的优越性。

表 1 IAEo 与五种先进算法在单二极管、双二极管、三二极管和光伏组件模型上参数识别的结果对比

参数	IJAYA	PGJAYA	MLBSA	STLBO	COOT	AEO	IAEO
I_{ph}/A	0.760 8	0.760 8	0.760 8	0.760 8	0.759 1	0.760 8	0.760 8
$I_{sd}/\mu A$	$3.396\ 8 \times 10^{-7}$	$3.229\ 7 \times 10^{-7}$	$3.230\ 2 \times 10^{-7}$	$3.232\ 7 \times 10^{-7}$	$5.199\ 5 \times 10^{-7}$	$3.239\ 9 \times 10^{-7}$	$3.230\ 2 \times 10^{-7}$
R_s	0.036 2	0.036 4	0.036 4	0.036 4	0.034 5	0.036 4	0.036 4
R_{sh}	55.221 2	53.712 2	53.718 5	53.735 4	99.140 5	53.800 5	53.718 9
z	1.486 3	1.481 2	1.481 2	1.481 3	1.530 6	1.481 5	1.481 2
RMSE	$9.900\ 714 \times 10^{-4}$	$9.860\ 240 \times 10^{-4}$	$9.860\ 218 \times 10^{-4}$	$9.860\ 218 \times 10^{-4}$	$3.180\ 148 \times 10^{-3}$	$9.860\ 937\ 2 \times 10^{-4}$	$9.860\ 218 \times 10^{-4}$
方差	$3.766\ 8 \times 10^{-6}$	$8.014\ 7 \times 10^{-9}$	$2.734\ 0 \times 10^{-13}$	$5.494\ 2 \times 10^{-8}$	$1.468\ 7 \times 10^{-3}$	$2.659\ 4 \times 10^{-8}$	$1.747\ 0 \times 10^{-15}$

续表 1

参数	IJAYA	PGJAYA	MLBSA	STLBO	COOT	AEO	IAEO
双二极管	I_{ph}/A	0.760 0	0.760 9	0.760 8	0.760 4	0.773 0	0.760 8
	$I_{sd1}/\mu\text{A}$	8.465 3 \times 10^{-8}	3.262 9 \times 10^{-7}	1.221 9 \times 10^{-7}	6.150 1 \times 10^{-7}	3.119 0 \times 10^{-7}	2.215 9 \times 10^{-7}
	R_s	0.037 0	0.036 2	0.036 5	0.033 7	0.028 8	0.036 5
	R_{sh}	73.171 8	54.128 5	54.051 6	100.000 0	14.400 4	54.280 1
	z_1	1.390 7	1.483 3	1.431 1	1.663 4	1.568 0	1.455 7
	$I_{sd2}/\mu\text{A}$	5.908 0 \times 10^{-7}	5.601 0 \times 10^{-8}	2.561 1 \times 10^{-7}	2.342 6 \times 10^{-7}	6.007 8 \times 10^{-7}	0.000 0 $2.511 1\times 10^{-7}$
	z_2	1.680 1	1.830 8	1.562 9	1.496 9	1.617 0	1.669 4
	RMSE	1.025 579 \times 10^{-3}	9.876 820 \times 10^{-4}	9.850 870 \times 10^{-4}	1.144 954 \times 10^{-3}	4.543 915 \times 10^{-3}	1.0 254 469 \times 10^{-3}
	方差	5.706 0 \times 10^{-5}	1.074 9 \times 10^{-5}	1.312 3 \times 10^{-6}	3.321 7 \times 10^{-4}	2.067 9 \times 10^{-3}	1.472 7 \times 10^{-5}
三二极管	I_{ph}/A	0.761 0	0.760 8	0.760 8	0.760 7	0.757 0	0.760 8
	$I_{sd1}/\mu\text{A}$	4.737 5 \times 10^{-7}	1.000 0 \times 10^{-6}	3.232 6 \times 10^{-7}	0.000 0	1.087 0 \times 10^{-7}	4.662 7 \times 10^{-10}
	R_s	0.036 6	0.036 8	0.036 4	0.035 3	0.036 1	0.036 3
	R_{sh}	54.044 1	56.337 7	53.744 7	73.192 5	52.659 1	53.942 8
	z_1	1.690 0	2.000 0	1.481 3	2.000 0	1.595 6	1.965 4
	$I_{sd2}/\mu\text{A}$	1.239 2 \times 10^{-7}	1.994 5 \times 10^{-7}	0	4.655 8 \times 10^{-7}	2.032 2 \times 10^{-7}	3.254 3 \times 10^{-7}
	z_2	1.415 1	1.440 7	1.231 6	1.518 8	1.448 4	1.481 9
	$I_{sd3}/\mu\text{A}$	5.038 9 \times 10^{-8}	9.165 0 \times 10^{-7}	0	1.000 0 \times 10^{-6}	2.700 5 \times 10^{-7}	8.723 1 \times 10^{-7}
	z_3	1.310 5	1.680 0	1.995 5	2.000 0	1.792 6	1.051 0
	RMSE	1.002 895 \times 10^{-3}	9.864 200 \times 10^{-4}	9.877 058 \times 10^{-4}	1.059 407 \times 10^{-3}	3.927 560 \times 10^{-3}	1.204 272 2 \times 10^{-4}
	方差	1.034 3 \times 10^{-5}	3.003 7 \times 10^{-6}	1.292 1 \times 10^{-5}	1.540 7 \times 10^{-4}	2.223 8 \times 10^{-3}	8.532 6 \times 10^{-5}
光伏组件	I_{ph}/A	1.030 3	1.030 5	1.030 5	1.030 5	1.029 1	1.030 6
	$I_{sd}/\mu\text{A}$	3.517 9 \times 10^{-6}	3.485 1 \times 10^{-6}	3.482 3 \times 10^{-6}	3.501 8 \times 10^{-6}	4.920 4 \times 10^{-6}	3.460 0 \times 10^{-6}
	R_s	1.199 5	1.201 2	1.201 3	1.200 7	1.168 4	1.201 8
	R_{sh}	992.772 6	983.048 4	981.982 3	988.283 5	1628.928 1	969.570 9
	z	48.682 2	48.645 9	48.642 8	48.664 2	50.000 0	48.618 4
	RMSE	2.431 335 \times 10^{-3}	2.425 387 \times 10^{-3}	2.474 218 \times 10^{-3}	2.427 363 \times 10^{-3}	3.228 500 \times 10^{-2}	2.425 775 7 \times 10^{-3}
	方差	5.349 5 \times 10^{-6}	1.049 8 \times 10^{-6}	2.322 0 \times 10^{-4}	7.129 6 \times 10^{-6}	8.506 0 \times 10^{-2}	3.262 9 \times 10^{-7}

3.4 制造商的数据表中真实数据的实验结果

图 5 绘制了 3 种光伏组件在 25 ℃ 和不同光照强度下的 I_V 特性曲线。从图 5 可知, IAEO 在各种光照强度下所预测参数产生的电流电压与实测数据均能较高程度拟

合, 这表明了 IAEO 算法拥有很好的鲁棒性。

图 6 绘制了 3 种光伏组件在 1 000 W/m² 光照强度和不同温度水平下的 I_V 特性曲线。从图 6 可以看出预测数据与实际的电流电压数据的拟合程度非常高, 表明

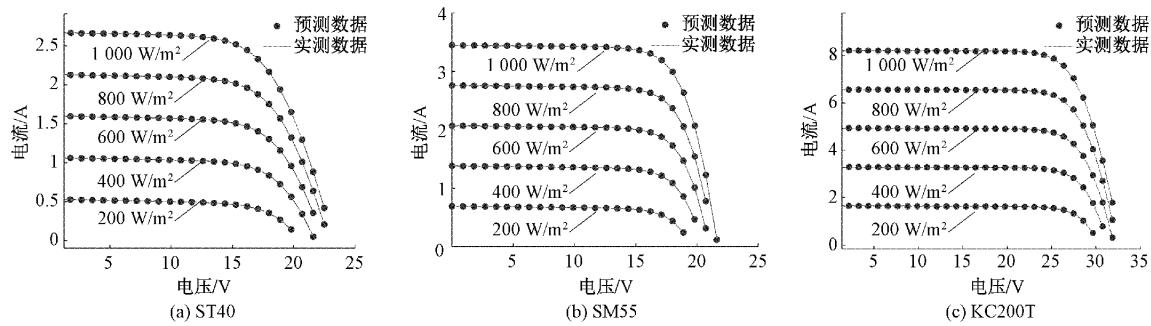
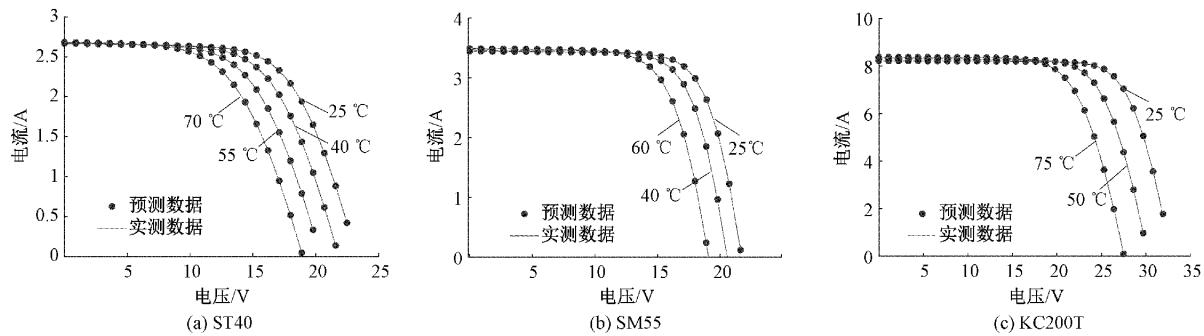


图 5 在 25 °C 温度和不同光照水平下的测量数据和仿真数据的(I-V)特性比较

图 6 在 1000 w/m² 光照强度和不同温度水平下的测量数据和仿真数据的(I-V)特性比较

IAEO 在 3 种光伏组件参数识别上都有很高的准确性。

4 结 论

本文提出了一种改进的人工生态系统优化算法(IAEO)并应用到光伏模型参数识别问题,不但继承了基本 AEO 结构简单、控制参数少的优点,而且能够更加精确稳定的识别未知参数。在 IAEO 中,本文提出了一种新的非线性控制参数调整策略,通过调整算法中探索与开发的关系,增强算法的探索能力和跳出局部最优的可能性。实验表明,IAEO 不但在简单的光伏模型参数识别上有较好的表现,而且在复杂的模型上(如双二极管模型和三二极管模型)有更大的优势,厂商真实数据进一步证明了 IAEO 在面对不同环境条件下的稳定性。因此,本文所提的 IAEO 算法在光伏模型参数识别领域可以作为一种有效的选择方法。

参考文献

- [1] PILLAI D S, RAJASEKAR N. Metaheuristic algorithms for PV parameter identification: A comprehensive review with an application to threshold setting for fault detection in PV systems [J]. Renewable and Sustainable Energy Reviews, 2018, 82:3503-3525.
- [2] SILVA E A, BRADASCHIA F, CAVALCANTI M C, et al. Parameter estimation method to improve the accuracy of photovoltaic electrical model [J]. IEEE Journal of Photovoltaics, 2015, 6(1): 278-285.
- [3] 薛田良, 王一诺, 曾阳阳. 一种改进的差分进化算法与电解电容器参数辨识[J]. 电子测量技术, 2021, 44(22):56-61.
- [4] 张峰, 王强. 基于模糊粒子群 PID 算法的温控系统研究[J]. 电子测量技术, 2022, 45(13):109-114.
- [5] LIANG J, QIAO K, YU K, et al. Parameters estimation of solar photovoltaic models via a self-adaptive ensemble-based differential evolution [J]. Solar Energy, 2020, 207:336-346.
- [6] JORDEHI A R. Enhanced leader particle swarm optimisation (ELPSO): An efficient algorithm for parameter estimation of photovoltaic (PV) cells and modules[J]. Solar Energy, 2018, 159:78-87.
- [7] YU K, LIANG J, QU B et al. Multiple learning backtracking search algorithm for estimating parameters of photovoltaic models [J]. Applied energy, 2018, 226: 408-422.
- [8] FARAH A, BELAZI A, BENABDALLAH F, et al. Parameter extraction of photovoltaic models using a comprehensive learning Rao-1 algorithm[J]. Energy Conversion and Management, 2022, 252:115057.
- [9] ZHAO W, WANG L, ZHANG Z. Artificial ecosystem-based optimization: A novel nature-inspired meta-heuristic algorithm[J]. Neural Computing and Applications, 2020, 32(13):9383-9425.

- [10] IZCI D, HEKIMO LU B, EKINCI S. A new artificial ecosystem-based optimization integrated with Nelder-Mead method for PID controller design of buck converter[J]. Alexandria Engineering Journal, 2022, 61(3): 2030-2044.
- [11] SAHLOL A T, ABD ELAZIZ M, TARIQ JAMAL A, et al. A novel method for detection of tuberculosis in chest radiographs using artificial ecosystem-based optimization of deep neural network features [J]. Symmetry, 2020, 12(7):1146.
- [12] 张伟伟,陶聪,范岩,等.改进回溯搜索算法解决光伏模型参数识别问题[J].计算机应用,2021, 41(4): 1199-1206.
- [13] ABDEL-BASSET M, EL-SHAHAT D, SALLAM K M, et al. Parameter extraction of photovoltaic models using a memory-based improved gorilla troops optimizer[J]. Energy Conversion and Management, 2022, 252:115134.
- [14] JIAO S, CHONG G, HUANG C, et al. Orthogonally adapted Harris hawks optimization for parameter estimation of photovoltaic models, Energy, 2020, 203:117804.
- [15] YU K, LIANG J, QU B, et al. Parameters identification of photovoltaic models using an improved JAYA optimization algorithm[J]. Energy Conversion and Management, 2017, 150:742-753.
- [16] YU K, QU B, YUE C, et al. A performance-guided JAYA algorithm for parameters identification of photovoltaic cell and module [J]. Applied Energy, 2019, 237:241-257.
- [17] NIU Q, ZHANG H, LI K. An improved TLBO with elite strategy for parameters identification of PEM fuel cell and solar cell models[J]. International Journal of Hydrogen Energy, 2014, 39(8):3837-3854.
- [18] NARUEI I, KEYNIA F. A new optimization method based on coot bird natural life model[J]. Expert Systems with Applications, 2021, 183(2):115352.

作者简介

张伟伟,博士,副教授,主要研究方向为智能计算等。
E-mail:anqikeli@126.com
余晓秋,硕士研究生,主要研究方向为智能计算。
E-mail:rachelby@163.com