

DOI: 10.19783/j.cnki.pspc.210112

# 基于数据预测启发式算法的光伏电池参数识别

刘斌, 谈竹奎, 唐赛秋, 林呈辉, 高吉普

(贵州电网有限责任公司电力科学研究院, 贵州 贵阳 550002)

**摘要:** 为进一步提高对太阳能的利用率以降低对于化石燃料的依赖, 需要对光伏(Photovoltaic, PV)电池进行精确的参数识别和建模, 以实现最优的PV系统优化运行和控制。然而, PV电池的高度非线性和多模态特性使得传统优化方法很难获得最优解, 同时实测电流-电压(Current-Voltage,  $I-V$ )数据量不足也会导致建模不够精确。为此, 提出了一种基于数据预测的启发式算法(Data Prediction based Meta-heuristic Algorithm, DPMhA)来实现PV电池的参数识别。特别地, 利用极限学习机(Extreme Learning Machine, ELM)对实测数据进行训练和预测, 为启发式算法(Meta-heuristic Algorithm, MhA)提供更为准确可靠的适应度函数, 从而增强其全局探索和局部搜索能力。最后, 采用双二极管PV电池模型进行参数识别, 其结果表明, DPMhA具有准确性高、收敛速度快等优点。

**关键词:** 参数识别; 光伏电池; 数据预测; 启发式算法; 极限学习机

## Photovoltaic cell parameter extraction using data prediction based on a meta-heuristic algorithm

LIU Bin, TAN Zhukui, TANG Saiqiu, LIN Chenghui, GAO Jipu

(Electric Power Research Institute of Guizhou Power Grid Co., Ltd., Guiyang 550002, China)

**Abstract:** To improve solar energy efficiency and reduce the dependence on fossil fuels, accurate parameter extraction and modelling of Photovoltaic (PV) cells are needed to achieve optimal design and control. However, the highly nonlinear and multi-modal characteristics of PV cells make traditional optimization methods inadequate to obtain an optimal solution. In addition, insufficient measured current-voltage ( $I-V$ ) data also leads to imprecise modelling. Therefore, a Data Prediction-based Meta-Heuristic Algorithm (DPMhA) is proposed to realize the parameter extraction from a PV cell. In particular, an Extreme Learning Machine (ELM) is used to train and predict measured data, so as to provide a more accurate and reliable fitness function for the algorithm. Then global exploration and local exploitation can be simultaneously enhanced. Finally, a PV cell model with double diodes is employed to identify unknown parameters. Case studies show that DPMhA has advantages of high accuracy and fast convergence.

This work is supported by the National Natural Science Foundation of China (No. 52067004) and the Science and Technology Project of Guizhou Power Grid Co., Ltd. (No. 066600KK52180051).

**Key words:** parameter extraction; PV cell; data prediction; meta-heuristic algorithm; extreme learning machine

## 0 引言

光伏(Photovoltaic, PV)系统因具有低污染、储量大、分布广等优点而受到全球的广泛关注<sup>[1-4]</sup>。因此, 准确地构建PV电池电气特性模型对PV系统进行分析、预测、最大功率点跟踪(Maximum Power Point Tracking, MPPT)和故障诊断从而提高其整体能源利用率显得尤为重要<sup>[5]</sup>。

一般地, PV电池最为常见的模型有单二极管模型(Single Diode Model, SDM)<sup>[6]</sup>、双二极管模型(Double Diode Model, DDM)<sup>[7]</sup>和三二极管模型(Three Diode Model, TDM)<sup>[8]</sup>。单二极管具有控制结构简单、实现成本低等特点, 但其计算精度差, 输出特性不均匀, 复制精确 $I-V$ 曲线的效率低<sup>[6]</sup>。三二极管可以清楚地确定PV电池的各种电流成分, 曲线拟合精度最高, 但其建模复杂度高, 执行时间长, 硬件实现复杂<sup>[8]</sup>。根据上述问题, 本文采用双二极管模型。双二极管具有曲线拟合精度高、硬件实现简单、实现成本和电路复杂度低等优点<sup>[7]</sup>, 目

**基金项目:** 国家自然科学基金项目资助(52067004); 贵州电网有限责任公司科技项目资助(066600KK52180051)

前双二极管已广泛用于低辐照水平的环境下, 需要精确输出  $I$ - $V$  特性和适应不同的环境条件的实际应用中。

由于 PV 电池参数识别是一个多变量、多峰值的非线性函数优化问题, 解析法和传统优化算法难以获得最优解。另一方面, 启发式算法(Meta-heuristic Algorithm, MhA)因具有收敛速度快以及无需系统精确模型等优点成为解决该难题的另一条思路。文献[9]采用回溯搜索算法(Backtracking Search Algorithm, BSA)提高了种群质量, 从而提高了 PV 电池参数识别的精度。文献[10]采用灰狼优化算法(Grey Wolf Optimization, GWO)减小了陷入局部最优的概率, 提高了 PV 电池参数识别的全局搜索能力。文献[11]采用飞蛾扑火优化算法(Moth Flame Optimizer, MFO)减少了运算量, 显著提高了 PV 电池参数识别的速度, 减少了运行时间。文献[12]采用混合蛙跳算法(Shuffled Frog Leaping Algorithm, SFLA), 误差小, 更新策略方向性强, 能有效解决 PV 电池参数识别中早熟的问题。

另外, 测量数据的样本量和精度对于 PV 电池参数识别也至关重要。实际工程中通常难以获取大量的实测电流-电压(current-voltage,  $I$ - $V$ )数据, 从而导致 PV 电池建模精度不可避免地下降。为解决这一难题, 需对有限的实测数据进行合理的数据开发。近年来, 人工神经网络(Artificial Neural Network, ANN)和深度学习在数据分析和预测方面展现出令人满意的处理效果<sup>[13-15]</sup>。

因此, 本文采用单隐层前馈神经网络(Single-hidden Layer Feedforward neural Network, SLFN)<sup>[16-17]</sup>的极限学习机(Extreme Learning Machine, ELM)进行  $I$ - $V$  数据预测, 以获取 MhA 更加可靠的适应度函数。将 MhA 和 ELM 结合, 其中, ELM 的引入可以克服 PV 电池中由于参数选取不当或不足导致的收敛性差的缺点, 还能显著提高预测精度和泛化能力。另外, MhA 能够模拟生物规律进行随机搜索, 增强全局探索和局部搜索能力, 以较少的耗时、更高的准确性实现 PV 电池参数识别。通过对 DDM 模型进行仿真研究, 对比不同训练数据量所得结果, 验证了所提方法的有效性。

## 1 PV 电池建模

目前, 不同 PV 电池的电路模型具有较大的差异, 而实际工程中往往采用 DDM, 因此本文针对 DDM 进行分析。DDM 模型如图 1 所示。

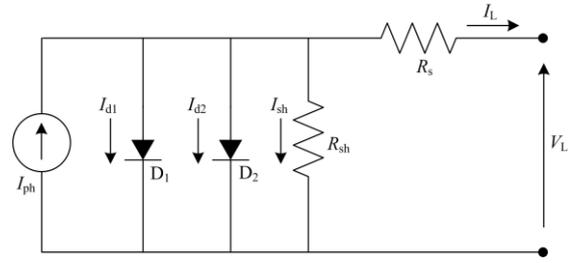


图 1 DDM 模型图

Fig. 1 DDM model diagram

### 1.1 双二极管模型

PV 电池的输出电流为

$$I_L = I_{ph} - I_{d1} \left[ \exp \left( \frac{q(V_L + I_L R_s)}{a_1 V_T} \right) - 1 \right] - I_{d2} \left[ \exp \left( \frac{q(V_L + I_L R_s)}{a_2 V_T} \right) - 1 \right] - \frac{V_L + I_L R_s}{R_{sh}} \quad (1)$$

式中:  $I_L$  是 PV 电池的输出电流;  $V_L$  是 PV 电池的输出电压;  $I_{ph}$  是光生电流;  $I_{d1}$  和  $I_{d2}$  分别是两个二极管的反向饱和电流;  $R_s$  是串联电阻;  $R_{sh}$  是并联电阻;  $q$  是电子电荷量 ( $1.6022 \times 10^{-19} \text{C}$ );  $a_1$  和  $a_2$  是两个二极管的理想因子;  $V_T$  为热电压, 可由式(2)来表示<sup>[18]</sup>。

$$V_T = \frac{KT}{q} \quad (2)$$

式中:  $K$  是玻尔兹曼常数 ( $1.3806 \times 10^{-23} \text{J/K}$ );  $T$  是 PV 电池温度(K)。

### 1.2 目标函数

DDM 需要识别以下七个参数:  $I_{ph}$ 、 $I_{d1}$ 、 $I_{d2}$ 、 $R_s$ 、 $R_{sh}$ 、 $a_1$ 、 $a_2$ <sup>[19]</sup>, 其目标函数选取均方根误差(Root Mean Square Error, RMSE)以进行定量分析, 定义如式(3)。

$$\text{RMSE}_x = \sqrt{\frac{1}{N} \sum_{k=1}^N [f(V_L, I_L, x)]^2} \quad (3)$$

式中:  $x$  表示需要识别的未知参数解;  $N$  为实验数据组数。

为便于求解未知参数, 式(1)可改写为

$$f_{\text{DDM}}(V_L, I_L, x) = I_{ph} - I_{d1} \left[ \exp \left( \frac{q(V_L + I_L R_s)}{a_1 V_t} \right) - 1 \right] - I_{d2} \left[ \exp \left( \frac{q(V_L + I_L R_s)}{a_2 V_t} \right) - 1 \right] - \frac{V_L + I_L R_s}{R_{sh}} - I_L \quad (4)$$

为了最小化实验数据与模拟数据之间的误差, 根据式(3)和式(4), 构建优化解向量  $x$  的目标函数

RMSE(x), 其值越小, 所得的参数越精确。

## 2 基于数据预测的启发式算法

### 2.1 极限学习机的数据预测

#### 2.1.1 极限学习机原理

ELM是一类基于SLFN构建的机器学习系统或方法<sup>[20]</sup>, 主要由广义逆矩阵理论所支撑<sup>[21]</sup>。在优化过程中随机初始化隐含层节点的权重和偏置值, 不存在迭代调优的过程。与误差反向传播(Back Propagation, BP)算法等常规前馈网络学习策略相比<sup>[22]</sup>, ELM可以显著提高鲁棒性、学习速度、训练精度和泛化能力<sup>[23-25]</sup>。

对于  $N$  个任意不同的样本  $(x_i, y_i)$ , 其中  $x_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in R^n, y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in R^m$ , 假设SLFN具有  $K$  个隐含层节点, 其激励函数可表示为

$$y_i = \sum_{j=1}^K \beta_j g_j(x_i) = \sum_{j=1}^K \beta_j g(\omega_j \cdot x_i + b_j), j=1, 2, 3, \dots, N \quad (5)$$

式中:  $\omega_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{im}]^T$  表示第  $i$  个隐含层节点与输入层节点之间的权值向量;  $b_i$  表示第  $i$  个隐含层节点的阈值;  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$  表示连接输出层与第  $i$  个隐含层节点的权值向量。

另外, 由  $K$  个隐含层节点构成的SLFN, 其具有以零误差预测样本的能力, 即  $\sum_{i=1}^N \|y_i - t_i\| = 0$ , 因此  $\omega_i$ 、 $\beta_i$  和  $b_i$  满足如下关系:

$$t_j = \sum_{i=1}^K \beta_i g(\omega_i \cdot x_j + b_i), j=1, 2, 3, \dots, N \quad (6)$$

将式(6)转化为矩阵表达形式:

$$H\beta = T \quad (7)$$

$$H = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{bmatrix} = \begin{bmatrix} g(\omega_1 \cdot x_1 + b_1) \cdots g(\omega_K \cdot x_1 + b_K) \\ \vdots \\ g(\omega_1 \cdot x_N + b_1) \cdots g(\omega_K \cdot x_N + b_K) \end{bmatrix} \quad (8)$$

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_K \end{bmatrix}_{K \times m}, T = \begin{bmatrix} t_1 \\ \vdots \\ t_K \end{bmatrix}_{K \times m} \quad (9)$$

式中:  $H$  表示神经网络的隐含层输出矩阵;  $T$  表示期望输出矩阵;  $\beta$  表示由最小二乘范数求解的输出权值矩阵<sup>[26]</sup>。

$$\|H\tilde{\beta} - T\| = \min_{\beta} \|H\beta - T\| \quad (10)$$

当隐含层输出矩阵为列满秩时, 可得

$$\tilde{\beta} = \operatorname{argmin}_{\beta} \|H\beta - T\| = H^{\dagger}T \quad (11)$$

式中,  $H^{\dagger}$  表示为隐含层输出矩阵  $H$  的 Moore-

Penrose 广义逆矩阵, 简称伪逆矩阵。

#### 2.1.2 输出 $I$ - $V$ 数据预测

为进一步提高PV电池参数识别精度, 可通过测量输出电流和电压实现<sup>[27]</sup>。本文选取PV电池电压和电流分别作为ELM的输入和输出, 以实现基于ELM的输出  $I$ - $V$  数据预测。

## 2.2 基于数据预测的启发式算法

### 2.2.1 基于数据预测的适应度函数

基于预测数据, MhA 可通过不断更新适应度函数以充分发挥自己的全局优化能力。经过数据预测处理后, 生成更可靠的目标函数为  $RMSE_x$ , 且所有优化变量均限定在所属的上界和下界内, 如式(12)。

$$RMSE_x = \sqrt{\frac{1}{N + N_p} \sum_{k=1}^{N+N_p} (f(V_L, I_L, x))^2} \quad (12)$$

式中,  $N_p$  表示预测数据的数量。

### 2.2.2 执行过程

DPMhA 的整体运行框架主要由三部分组成, 如图2所示。首先, 将各PV电池实测输出  $I$ - $V$  数据输入至ELM; 随后, 利用实测数据训练ELM以预测新的数据, 从而建立更可靠的适应度函数来评估各MhA的优化性能; 最后, MhA通过更新最优位置和最优适应度值来获得最优的PV电池参数。

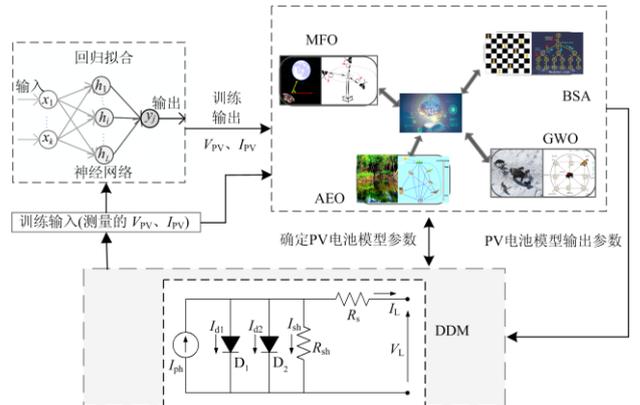


图2 基于ELM数据预测的PV电池参数识别框架

Fig. 2 Framework of ELM-based data prediction for PV cell parameter extraction

图3给出了DPMhA的基本流程, 不同算法之间的主要区别在于进行全局搜索和局部搜索的个体以及搜索机制的不同。

## 3 算例研究

本文运用四种MhA, 即BSA<sup>[9]</sup>、GWO<sup>[10]</sup>、MFO<sup>[11]</sup>以及人工生态系统优化算法(Artificial Ecosystem-based Optimization, AEO)<sup>[28]</sup>对PV电池进行参数识别以验证该方法的有效性。天气条件设定为  $G=1000 \text{ W/m}^2, T=33 \text{ }^\circ\text{C}$ , 在直径为57 mm的R.T.C.

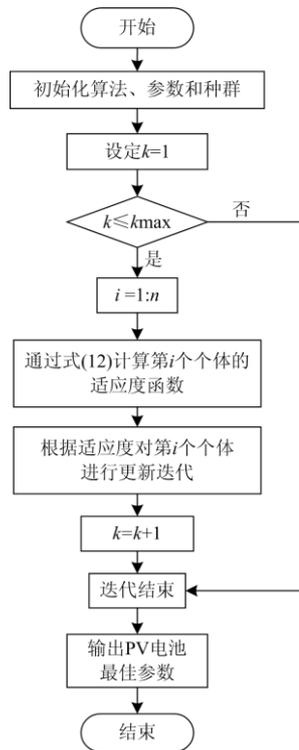


图 3 DPMhA 流程图

Fig. 3 DPMhA flow chart

France PV 电池中取 26 组测量数据用于模拟  $I-V$  数据<sup>[29]</sup>。为验证 MhA 在测量数据不足情况下的优化性能, 再从 26 组测量数据中随机抽取 50%、60%、70%、80%、90% 和 100% 的数据。为获得 MhA 可靠的适应度函数, 将每次使用的训练数据和预测数据的总数设为 50 组, 例如, 对于 100% 的数据, 训练数据为 26 组, 预测数据为 24 组。另外, 对每种 MhA 在两种工况下进行评估, 即无数据预测(只有选定的测量数据)和有数据预测。

为公平比较, 所有 MhA 的最大迭代数( $k_{max}=120$ )和种群大小( $n=50$ )均相同。在 PV 电池模型中各自独立运行 100 次。

表 1 显示了不同训练数据量下 4 种算法运行 100 次得到的 RMSE 平均值, 其中符号“Y”表示采用数据预测的 MhA, “N”表示不采用数据预测。表 2 给出了训练数据量为 50% 情况下的参数识别结果。从表中可以看出, 各 MhA 通过有数据预测得到的平均 RMSE 明显小于无数据预测得到的 RMSE。例如, 在 50% 训练数据量下采用 GWO 算法, 有数据预测的 RMSE 平均值比无数据预测的低 48.19%。这说明 DPMhA 具有良好的全局搜索能力。

表 1 各启发式算法得到的平均 RMSE

Table 1 Average RMSE obtained by various MhA

算法		训练数据量					
		50%	60%	70%	80%	90%	100%
BSA	N	$1.30 \times 10^{-2}$	$1.26 \times 10^{-2}$	$1.01 \times 10^{-2}$	$1.18 \times 10^{-2}$	$1.19 \times 10^{-2}$	$1.04 \times 10^{-2}$
	Y	$8.97 \times 10^{-3}$	$1.02 \times 10^{-2}$	$8.48 \times 10^{-3}$	$1.11 \times 10^{-2}$	$7.29 \times 10^{-3}$	$1.02 \times 10^{-2}$
GWO	N	$2.22 \times 10^{-2}$	$1.87 \times 10^{-2}$	$1.53 \times 10^{-2}$	$1.54 \times 10^{-2}$	$1.70 \times 10^{-2}$	$1.50 \times 10^{-2}$
	Y	$1.15 \times 10^{-2}$	$1.58 \times 10^{-2}$	$1.46 \times 10^{-2}$	$1.52 \times 10^{-2}$	$1.26 \times 10^{-2}$	$1.43 \times 10^{-2}$
MFO	N	$4.88 \times 10^{-3}$	$2.79 \times 10^{-3}$	$2.78 \times 10^{-3}$	$3.61 \times 10^{-3}$	$2.43 \times 10^{-3}$	$2.71 \times 10^{-3}$
	Y	$3.64 \times 10^{-3}$	$2.55 \times 10^{-3}$	$2.46 \times 10^{-3}$	$2.74 \times 10^{-3}$	$2.43 \times 10^{-3}$	$2.50 \times 10^{-3}$
AEO	N	$2.12 \times 10^{-3}$	$1.77 \times 10^{-3}$	$1.77 \times 10^{-3}$	$1.78 \times 10^{-3}$	$1.76 \times 10^{-3}$	$1.73 \times 10^{-3}$
	Y	$1.97 \times 10^{-3}$	$1.73 \times 10^{-3}$	$1.81 \times 10^{-3}$	$1.70 \times 10^{-3}$	$1.74 \times 10^{-3}$	$1.77 \times 10^{-3}$

表 2 各启发式算法的参数识别结果

Table 2 Parameter extraction results by various MhA

算法		训练数据量为 50% 时的参数						
		$I_{ph}/A$	$I_{s1}/A$	$R_s/\Omega$	$R_{sh}/\Omega$	$a_1$	$I_{s2}/A$	$a_2$
BSA	N	0.761 2	$3.26 \times 10^{-7}$	0.036 0	54.596 6	1.790 6	$2.49 \times 10^{-7}$	1.463 8
	Y	0.760 6	$9.49 \times 10^{-8}$	0.034 1	65.613 9	1.623 0	$4.69 \times 10^{-7}$	1.528 8
GWO	N	0.759 0	$3.47 \times 10^{-7}$	0.035 3	70.197 1	1.664 8	$2.04 \times 10^{-7}$	1.459 2
	Y	0.761 1	$5.64 \times 10^{-7}$	0.035 4	72.360 3	1.609 5	$6.70 \times 10^{-8}$	1.404 9
MFO	N	0.760 9	$9.99 \times 10^{-7}$	0.037 7	57.056 9	1.872 7	$1.13 \times 10^{-7}$	1.396 2
	Y	0.761 2	$8.12 \times 10^{-7}$	0.036 8	44.722 6	1.739 8	$7.06 \times 10^{-8}$	1.370 6
AEO	N	0.761 2	$2.23 \times 10^{-7}$	0.036 4	51.798 9	1.454 4	$2.65 \times 10^{-7}$	1.737 1
	Y	0.760 1	$3.12 \times 10^{-7}$	0.036 0	54.483 2	1.662 5	$1.83 \times 10^{-7}$	1.446 9



图 4 比较了 6 种不同训练数据量下 4 种算法的总平均 RMSE 值。当实验数据通过预测数据扩展后，每种算法均能更容易地找到全局最优值，从而更准确、更稳定地进行 PV 电池参数识别。

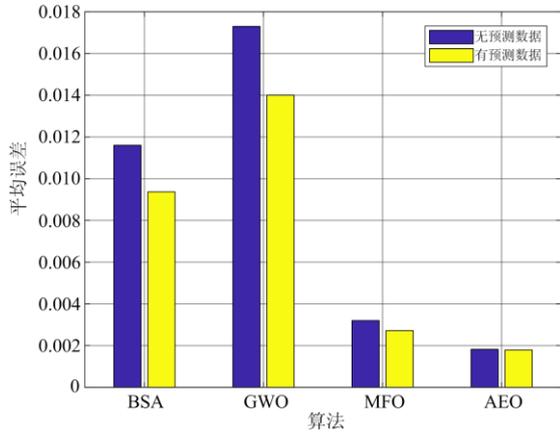


图 4 6 种不同训练数据量下的总平均 RMSE 值的比较  
Fig. 4 Comparison of total average RMSE values obtained under six different training datasets

图 5 给出了各种算法的箱形图。可以发现，100% 训练数据量下的算法与 50% 训练数据量下的算法相比，RMSE 中的异常值更少，上界和下界也更小。这表明，在 PV 电池参数识别中，增加基于数据预测的训练数据可有效提高求解质量和寻优稳定性。其中，AEO 具有最佳的参数识别性能。

图 6 和图 7 分别是在 50% 训练数据量和 100% 训练数据量下，AEO 依据最优数据预测和实际数据得到的  $I-V$  曲线和  $P-V$  曲线。由图可见，AEO 得到的模型曲线与实际数据具有较高的一致性。

此外，图 8 给出了所有算法进行数据预测的收敛曲线，可见在训练数据量低于 50% 的情况下，GWO 收敛速度最慢，MFO 收敛速度最快。在两种训练数据量下，AEO 的误差值均为最小。

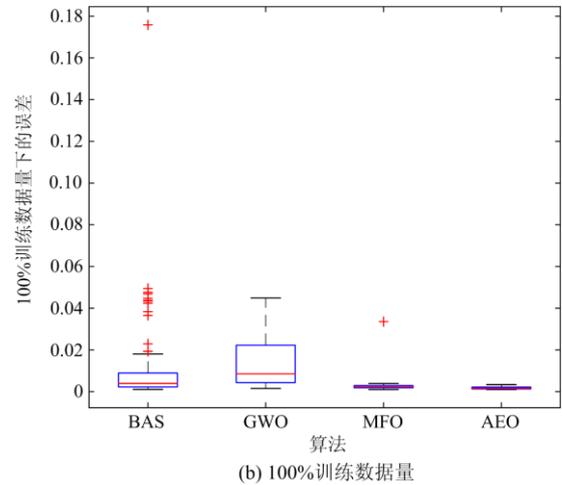
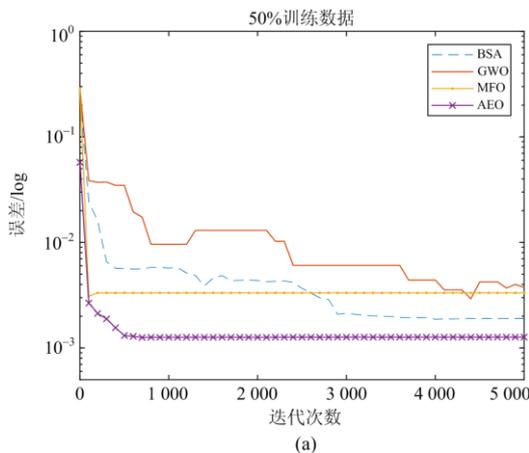


图 5 各启发式算法在不同训练数据量下获得的 RMSE  
Fig. 5 Boxplot of RMSE obtained by various MhA in different training datasets

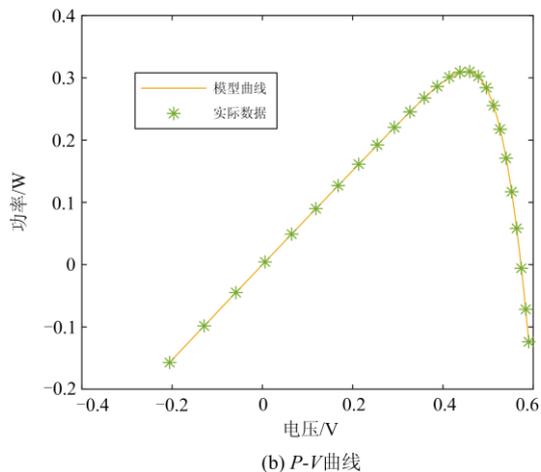
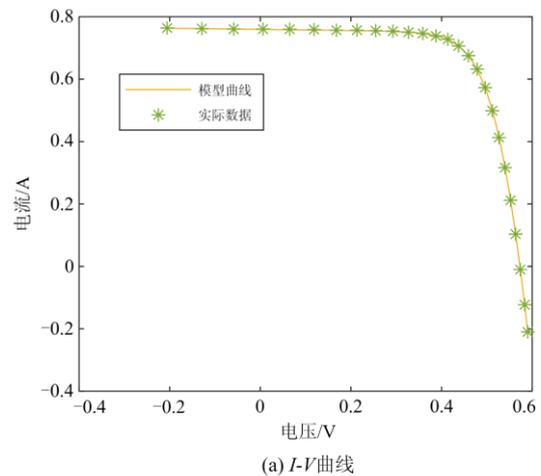
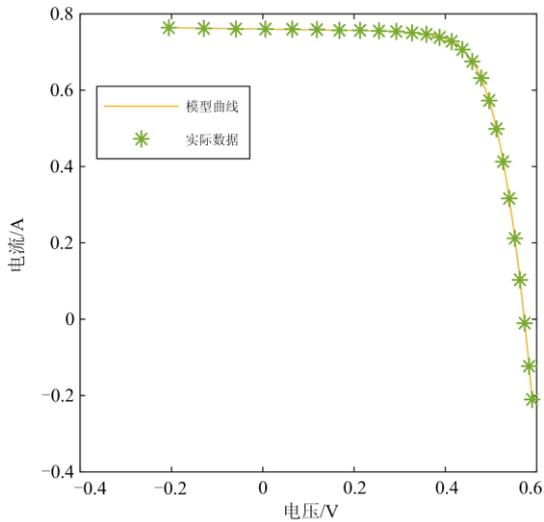
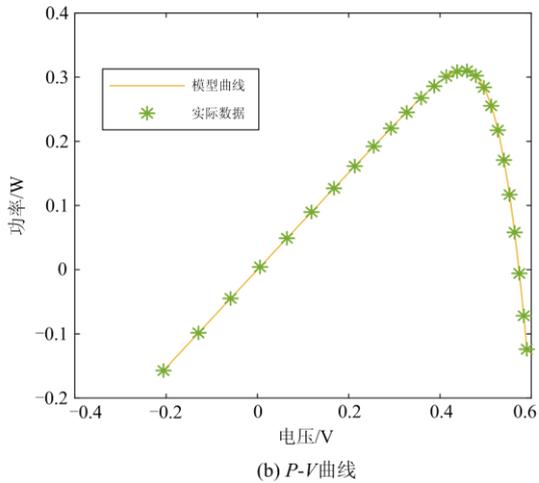


图 6 在 50% 训练数据量下 AEO 的模型曲线与实际数据比较  
Fig. 6 Comparison between actual data and model curve obtained AEO in 50% training datasets



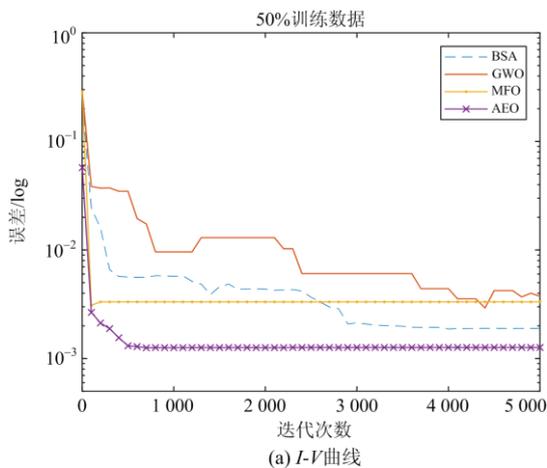
(a)  $I$ - $V$ 曲线



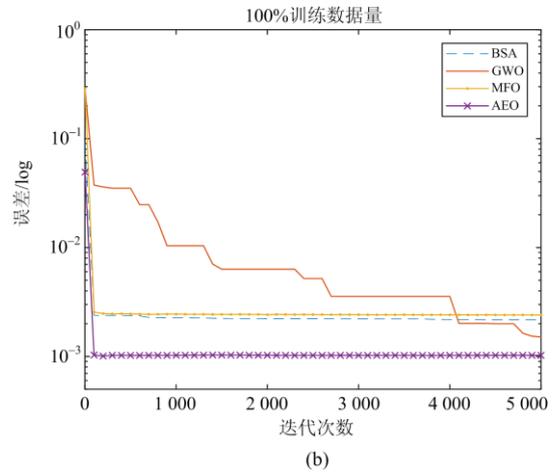
(b)  $P$ - $V$ 曲线

图 7 在 100% 训练数据量下 AEO 的模型曲线与实际数据比较

Fig. 7 Comparison between actual data and model curve obtained by AEO in 100% training datasets



(a)  $I$ - $V$ 曲线



(b)

图 8 各启发式算法的收敛性

Fig. 8 Convergence of various MhA

最后, 图 9 给出了 6 组不同训练数据量下各 MhA 的平均 RMSE 雷达图, 其中符号 '+' 表示有数据预测。可以看出, 在不同训练数据量下, 通过数据预测得到的每一种算法的平均 RMSE 都比不采用数据预测得到的要小, 从而验证了 DPMhA 在 PV 电池参数识别中的有效性。

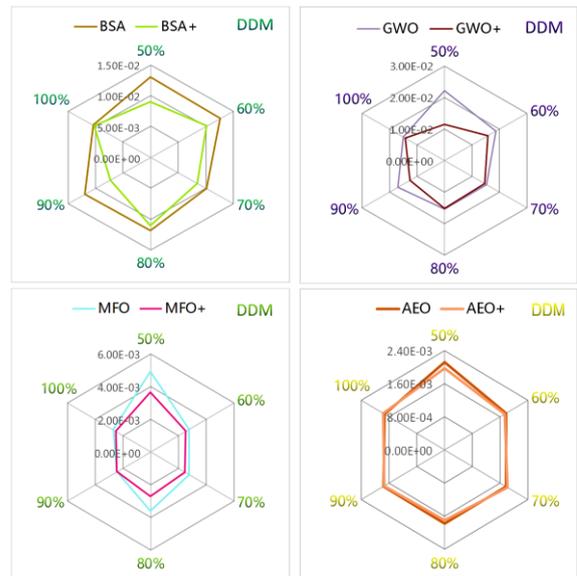


图 9 不同启发式算法的平均 RMSE 雷达图

Fig. 9 Radar of average RMSE achieved by different MhA

#### 4 结论

本文针对 PV 电池提出了一种基于数据预测的启发式算法参数识别策略, 其贡献可概括为以下三个方面:

- 1) 基于 ELM 的数据预测使得各 MhA 能够在测

量输出  $I-V$  数据不足的情况下, 对 PV 电池参数识别进行更有效的全局探索和局部搜索;

2) 在 PV 电池参数识别中, DPMhA 能够扩大数据范围, 相比于 MhA 有更高的收敛精度和更小的误差;

3) 算例研究表明, 与基于原始测量输出的  $I-V$  数据相比, DPMhA 可显著提高 PV 电池参数识别的准确性、鲁棒性和收敛速度。

在未来的研究中, 需要充分利用各种算法在 PV 电池参数识别中的优势, 如 SA 基本不受辐照水平变化的影响。通过有效地结合不同方法的优点, 开发和应用一些新的混合方法, 以进一步获得更好的性能。

### 参考文献

- [1] 马维锋. 太阳能并网光伏发电系统装置的设计与应用[J]. 机械管理开发, 2019, 34(12): 15-16, 26.  
MA Weifeng. Design and application of solar grid-connected photovoltaic power[J]. Mechanical Management and Development, 2019, 34(12): 15-16, 26.
- [2] 王素娥, 吴永斌, 熊连松, 等. 基于功频下垂控制的光伏并网发电系统惯量阻尼机理研究[J]. 智慧电力, 2020, 48(12): 20-25, 39.  
WANG Su'e, WU Yongbin, XIONG Liansong, et al. Research on inertia and damping mechanism of grid-tied photovoltaic power generation system based on power frequency droop control[J]. Smart Power, 2020, 48(12): 20-25, 39.
- [3] 薛振宇, 益西措姆, 李敬如, 等. 扶贫光伏发电典型接入方式及经济效益评估[J]. 供用电, 2019, 36(4): 79-85.  
XUE Zhenyu, YIXI Cuomu, LI Jingru, et al. The typical access mode and economic benefit evaluation of photovoltaic generation for poverty alleviation[J]. Distribution & Utilization, 2019, 36(4): 79-85.
- [4] 袁晓冬, 郁正纲, 张宸宇, 等. 计及光伏区间预测和储能 SOC 均衡的配电网优化[J]. 全球能源互联网, 2019, 2(6): 598-607.  
YUAN Xiaodong, YU Zhenggang, ZHANG Chenyu, et al. Optimization operation of distribution network considering photovoltaic interval prediction and energy storage SOC equilibrium[J]. Journal of Global Energy Interconnection, 2019, 2(6): 598-607.
- [5] 王志豪, 李自成, 王后能, 等. 基于 RBF 神经网络的光伏系统 MPPT 研究[J]. 电力系统保护与控制, 2020, 48(6): 85-91.  
WANG Zhihao, LI Zicheng, WANG Houneng, et al. MPPT study of solar PV power system based on RBF neural network algorithm[J]. Power System Protection and Control, 2020, 48(6): 85-91.
- [6] 董润楠, 刘石, 郭芳. 基于 PVPT 控制的小型光伏微电网混合控制研究[J]. 电力系统保护与控制, 2019, 47(5): 77-87.  
DONG Runnan, LIU Shi, GUO Fang. Research on hybrid control method of the small-scale photovoltaic microgrid based on PVPT control[J]. Power System Protection and Control, 2019, 47(5): 77-87.
- [7] 简献忠, 魏凯, 郭强. 蜂群算法在光伏电池双二极管五参数模型中的应用[J]. 光子学报, 2015, 44(1): 174-178.  
JIAN Xianzhong, WEI Kai, GUO Qiang. Artificial bee swarm algorithm in the application of photovoltaic cell five-parameter double-diode model[J]. Acta Photonica Sinica, 2015, 44(1): 174-178.
- [8] QAIS M H, HASANIEN H M, ALGHUWAINEM S. Identification of electrical parameters for three-diode photovoltaic model using analytical and sunflower optimization algorithm[J]. Applied Energy, 2019, 250: 109-117.
- [9] YU K J, LIANG J J, QU B Y, et al. Multiple learning backtracking search algorithm for estimating parameters of photovoltaic models[J]. Applied Energy, 2018, 226: 408-422.
- [10] 徐明, 焦建军, 龙文. 改进灰狼优化算法辨识光伏模型参数[J]. 中国科技论文, 2019, 14(8): 917-921, 926.  
XU Ming, JIAO Jianjun, LONG Wen. Parameter identification of photovoltaic model using improved grey wolf optimizer algorithm[J]. China Science Paper, 2019, 14(8): 917-921, 926.
- [11] ALLAM D, YOUSRI D A, ETEIBA M B. Parameters extraction of the three diode model for the multi-crystalline solar cell/module using moth-flame optimization algorithm[J]. Energy Conversion and Management, 2016, 123: 535-548.
- [12] 徐岩, 高兆, 朱晓荣. 基于混合蛙跳算法的光伏阵列参数辨识方法[J]. 太阳能学报, 2019, 40(7): 1903-1911.  
XU Yan, GAO Zhao, ZHU Xiaorong. Parameter identification method of photovoltaic array based on shuffled frog leaping algorithm[J]. Acta Energetica Sinica, 2019, 40(7): 1903-1911.
- [13] ZHENG X, ZHANG Y, ZHANG H, et al. An RBF neural network-based dynamic virtual network embedding algorithm[J]. Concurrency and Computation: Practice and Experience, 2019, 31(23): 393-396.
- [14] 侯宇青阳, 全吉成, 王宏伟. 深度学习发展综述[J]. 舰船电子工程, 2017, 37(4): 5-9, 111.  
HOU Yuqingyang, QUAN Jicheng, WANG Hongwei.

- Review of deep learning development[J]. *Ship Electronic Engineering*, 2017, 37(4): 5-9, 111.
- [15] 马天男, 王超, 彭丽霖, 等. 计及需求响应和深度结构多任务学习的电力系统短期负荷预测[J]. *电测与仪表*, 2019, 56(16): 50-60.  
MA Tiannan, WANG Chao, PENG Lilin, et al. Short-term load forecasting of power system considering demand response and multi-task learning based on deep structure[J]. *Electrical Measurement & Instrumentation*, 2019, 56(16): 50-60.
- [16] HAN F, JIANG J, LING Q H, et al. A survey on metaheuristic optimization for random single-hidden layer feedforward neural network[J]. *Neurocomputing*, 2019, 335: 261-273.
- [17] QI J, DU J, SINISCALCHI S M, et al. A theory on deep neural network based vector-to-vector regression with an illustration of its expressive power in speech enhancement[J]. *Neurocomputing*, 2019, 27(12): 1932-1943.
- [18] 张俊红, 魏学业, 祝天龙. 光伏阵列建模和仿真特性研究[J]. *计算机仿真*, 2014, 31(3): 134-138.  
ZHANG Junhong, WEI Xueye, ZHU Tianlong. Research on modeling and characteristic simulation of photovoltaic array[J]. *Computer Integrated Manufacturing Systems*, 2014, 31(3): 134-138.
- [19] 范瑞祥, 尹国明, 苗洁蓉, 等. 基于参数辨识的光伏组件快速 MPPT 方法[J]. *太阳能学报*, 2020, 41(2): 296-302.  
FAN Ruixiang, YIN Guoming, MIAO Jierong, et al. A quick MPPT method of PV panel based on parameter identification[J]. *Acta Energetica Solaris Sinica*, 2020, 41(2): 296-302.
- [20] LI L, SUN R, CAI S, et al. A review of improved extreme learning machine methods for data stream classification[J]. *Multimedia Tools and Applications*, 2019, 78(23): 33375-33400.
- [21] 徐睿, 梁循, 齐金山, 等. 极限学习机前沿进展与趋势[J]. *计算机学报*, 2019, 42(7): 1640-1670.  
XU Rui, LIANG Xun, QI Jinshan, et al. Advances and trends in extreme learning machine[J]. *Chinese Journal of Computers*, 2019, 42(7): 1640-1670.
- [22] 赵志勇, 李元香, 喻飞, 等. 基于极限学习的深度学习算法[J]. *计算机工程与设计*, 2015, 36(4): 1022-1026.  
ZHAO Zhiyong, LI Yuanxiang, YU Fei, et al. Improved deep learning algorithm based on learning machine[J]. *Computer Engineering and Design*, 2015, 36(4): 1022-1026.
- [23] 靳果, 朱清智, 孟阳, 等. 基于多层极限学习机的电能质量扰动多标签分类算法[J]. *电力系统保护与控制*, 2020, 48(8): 96-105.  
JIN Guo, ZHU Qingzhi, MENG Yang, et al. Power quality disturbances multi-label classification algorithm based on a multi-layer[J]. *Power System Protection and Control*, 2020, 48(8): 96-105.
- [24] 周海, 李登宣, 尹万思, 等. 基于极限学习机的光伏发电短期预测校正方法[J]. *电网与清洁能源*, 2020, 36(6): 64-69, 77.  
ZHOU Hai, LI Dengxuan, YIN Wansi, et al. Short-term forecasting correction method of photovoltaic power based on extreme learning machine[J]. *Power System and Clean Energy*, 2020, 36(6): 64-69, 77.
- [25] 韩立芳, 赵中义. 基于极限学习机的燃煤热值预测研究[J]. *热力发电*, 2020, 49(4): 44-149.  
HAN Lifang, ZHAO Zhongyi. Study on calorific value prediction of coal combustion based on extreme learning machine[J]. *Thermal Power Generation*, 2020, 49(4): 144-149.
- [26] RAZAVIFAR R, CHAKRABARTI S, SAIF M, et al. Extreme learning machine based prognostics of battery life[J]. *International Journal on Artificial Intelligence Tools*, 2018, 27(8).
- [27] 杨宏超, 程若发, 吕彩艳, 等. 光伏组件内部参数辨识与输出特性研究[J]. *电子技术应用*, 2018, 44(1): 125-128.  
YANG Hongchao, CHEN Ruofa, LÜ Caiyan, et al. Study on internal parameter identification and output characteristics of photovoltaic module[J]. *Application of Electronic Technique*, 2018, 44(1): 125-128.
- [28] ZHAO W, WANG L, ZHANG Z. Artificial ecosystem-based optimization: a novel nature-inspired meta-heuristic algorithm[J]. *Neural Computing and Applications*, 2020, 32: 9383-9425.
- [29] YANG B, WANG J B, ZHANG X S, et al. Comprehensive overview of meta-heuristic algorithm applications on PV cell parameter identification[J]. *Energy Conversion and Management*, 2020, 208.

收稿日期: 2021-01-26; 修回日期: 2021-03-04

作者简介:

刘斌(1988—), 男, 硕士研究生, 工程师, 主要从事智能电网、新能源系统相关工作; E-mail: 1144384158@qq.com

谈竹奎(1975—), 男, 硕士研究生, 教授级高级工程师, 主要从事智能电网、配网自动化相关工作; E-mail: tanzk@163.com

唐赛秋(1993—), 男, 硕士研究生, 工程师, 主要从事智能电网、新能源系统相关工作。E-mail: 335973622@qq.com

(编辑 魏小丽)