

基于协方差自适应和单纯形的雾凇算法在光伏模型参数辨识中的应用

吕锦扬

温州大学计算机与人工智能学院，浙江 温州

收稿日期：2025年4月14日；录用日期：2025年5月15日；发布日期：2025年5月23日

摘要

进入新世纪信息时代以来，全球人口和全球经济增长迅速，这也导致了人类对能源的需求不断增加。在所有的能源获取方式中，太阳能是能源不断获取的清洁能源，所以光伏系统模型设计的准确性和高效性对于研究人员来说更是至关重要，太阳能光伏(PV)电池建模的关键在于电池参数的精确性。准确识别太阳能光伏模型的参数对于提升光伏系统运行效率具有决定性作用。针对光伏系统参数辨识这一关键问题，本研究从群智能优化算法角度展开深入探索。本文在雾凇优化算法(RIME)的基础上，加入协方差矩阵自适应进化策略(CMA-ES)，提升算法整体解的质量，从而使种群总体向最优解区域靠近，同时引入单纯形法。该架构充分发挥RIME机制的高维空间覆盖优势，结合CMA-ES的协方差变异策略提升动态环境追踪效率，并应用在多种不同条件下提取商业光伏组件未知参数。

关键词

群智能优化算法，光伏系统，参数辨识

Application of Covariance Adaptive and Simplex Based Rime Algorithm in Parameter Identification of Photovoltaic Models

Jinyang Lyu

School of Computer and Artificial Intelligence, Wenzhou University, Wenzhou Zhejiang

Received: Apr. 14th, 2025; accepted: May 15th, 2025; published: May 23rd, 2025

Abstract

Since entering the information age of the new century, the rapid growth of global population and

文章引用：吕锦扬. 基于协方差自适应和单纯形的雾凇算法在光伏模型参数辨识中的应用[J]. 计算机科学与应用, 2025, 15(5): 624-636. DOI: 10.12677/csa.2025.155135

economic expansion has led to an ever-increasing demand for energy. Among all energy acquisition methods, solar energy stands out as a continuously available clean energy source. Therefore, the accuracy and efficiency of photovoltaic (PV) system model design are of paramount importance to researchers. The key to modeling solar PV cells lies in the precision of cell parameters. Accurate identification of solar PV model parameters plays a decisive role in improving the operational efficiency of PV systems. To address this critical issue of parameter identification in PV systems, this study conducts an in-depth exploration from the perspective of swarm intelligence optimization algorithms. Building upon the Rime Optimization Algorithm (RIME), this paper incorporates the Covariance Matrix Adaptation Evolution Strategy (CMA-ES) to enhance the overall solution quality of the algorithm, thereby guiding the population toward the optimal solution region. Additionally, the simplex method is introduced. This framework leverages RIME's strength in high-dimensional space coverage while combining CMA-ES's covariance mutation strategy to improve tracking efficiency in dynamic environments. The proposed approach is applied to extract unknown parameters of commercial PV modules under various conditions.

Keywords

Swarm Intelligence Optimization Algorithm, Photovoltaic System, Parameter Identification

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

光伏电池参数识别是光伏系统建模与优化中的关键技术之一，其核心目标是通过实验数据或仿真模型，精确提取光伏电池的关键参数。这些参数的准确识别对于提高光伏系统的仿真精度、优化系统设计以及实现高效能量管理具有重要意义。传统解决这类无梯度问题主要利用解析法和数值优化法，这些方法在精度、效率和鲁棒性方面存在不足，近年来，研究者开始将群智能算法引入光伏电池参数识别领域。这类算法通过观察并模拟生物群体行为。群智能算法在光伏电池参数识别中的应用，提高了参数识别的精度和效率。在面对参数数量较多和非线性问题等 NP 难问题，传统方法难以在有限的时间内得到好的结果，而群智能算法通过全局搜索机制，能够有效处理高维参数空间，显著提高参数识别的精度。

雾凇算法(RIME) [1]是一种基于自然界雾凇形成物理机制的新型元启发式优化算法，其创新性地模拟了软雾凇和硬雾凇在大气环境中的差异化形成过程。该算法通过建立雾凇微粒的动力学模型，精确描述了微粒在布朗运动作用下的随机扩散行为及其粘附沉积特性，相比传统优化算法，RIME 具有参数敏感性低、全局搜索能力强和鲁棒性强等显著优势，Zhong [2]等人改进了 RIME，在初始化阶段引入拉丁超立方体采样提高种群质量，同时嵌入了基于距离的选择机制，最终在解决工程优化问题时表现优秀。Abu [3]等人将雾凇算法进行二进制改编，用于解决特征选择问题，在十种可靠的优化算法上进行了测试。先进的 RIME 架构在全局优化和 FS 任务中表现出卓越的性能。Hakmi [4]等人提出了加强版的 RIME，集成了多项式微分学习算子(PDLO)，与传统的 RIME 方法相比，增强了其适应性、收敛速度和全局搜索能力，在确定光伏模型的未知参数时有不错的效果。Zhou [5]等人通过结合改进的软雾凇搜索策略和共享信息突变机制，提出 ERIME，并通过实验证明其在光伏模型参数识别中的具有优越性。

虽然该算法在各种领域都表现出了潜力在优化任务中，但算法的缺点之一是全局探索能力不足，这可能会导致陷入局部最优。为此本章提出了一种名为 ENMRIME 的改进优化算法，该算法在 RIME 的基础上，利用协方差自适应策略在勘探阶段更新种群，增强种群多样性。并加入 NMs 机制提高算法进行到

后期的局部搜索精度。

2. 光伏器件建模理论与优化框架

2.1. 光伏太阳能电池模型

光伏系统性能的核心其实就是需要合理的太阳能电池参数。好的光伏组件不仅效率高，抗干扰能力也极强，因此为了构建高效、稳健且精确的光伏模型成为能量高效捕获的关键，众多专家和学者基于光伏器件的电流 - 电压特性，开发了多种光伏电路模型。其中，单二极管模型(SDM)、双二极管模型(DDM)及三极管模型(TDM)是文献中最常采用的等效电路模型。

2.1.1. 单二极管模型

单二极管模型(SDM)因其结构简洁、工程易用性突出而成为光伏建模的常用选择。如图 1 所示，该模型由三个关键部件构成：1) 用于表征漏电流的并联电阻；2) 与二极管并联的光生电流源；3) 表征线路损耗与过载效应的串联电阻。SDM 的输出电流由式(1)定义。

$$I_L = I_{ph} - I_{sd} \cdot \left[\exp\left(\frac{q \cdot (V_L + R_s \cdot I_L)}{n \cdot k \cdot T}\right) - 1 \right] - \frac{V_L + R_s \cdot I_L}{R_{sh}} \quad (1)$$

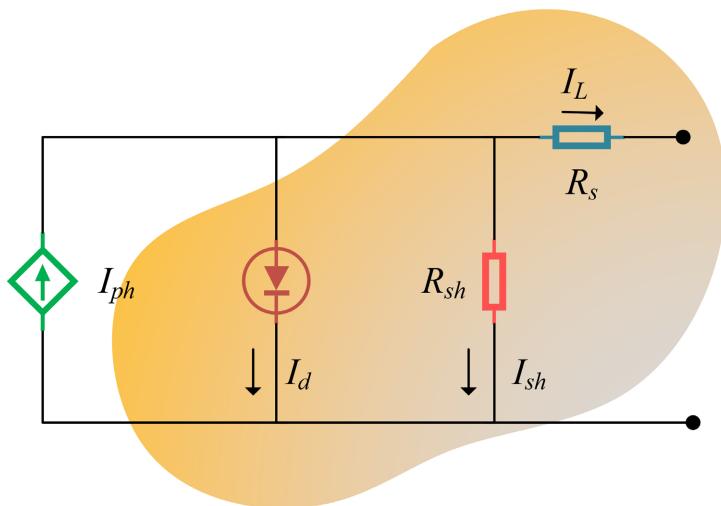


Figure 1. The equivalent circuit of single diode model.

图 1. 单二极管模型的等效电路图

2.1.2. 双二极管模型

虽然单二极管模型(SDM)计算流程简便，但其等效电路在弱光照工况下的仿真精度受限，难以精确表征光伏电池的动态特性。因此，研究焦点逐步转向双二极管模型(DDM)以提升光伏系统建模的精细度。如图 2 所示，DDM 在电路拓扑上具有更高复杂度：光生电流源与双二极管并联，这种设计使该模型在复杂环境下的电流 - 电压特性预测具有更高的吻合度，其输出电流特性可由式(2)完整描述。

$$I_L = I_{ph} - I_{sd1} \cdot \left[\exp\left(\frac{q \cdot (V_L + R_s \cdot I_L)}{n_1 \cdot k \cdot T}\right) - 1 \right] - I_{sd2} \cdot \left[\exp\left(\frac{q \cdot (V_L + R_s \cdot I_L)}{n_2 \cdot k \cdot T}\right) - 1 \right] - \frac{V_L + R_s \cdot I_L}{R_{sh}} \quad (2)$$

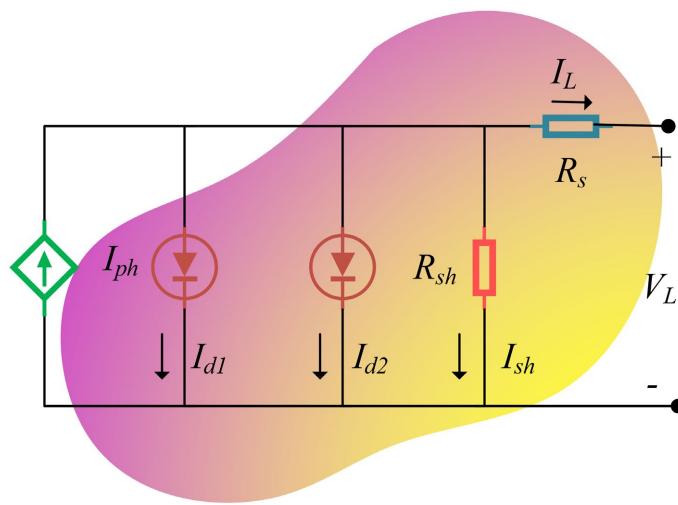
**Figure 2.** The equivalent circuit of double diode model.

图 2. 双二极管模型的等效电路图

2.1.3. 三二极管模型

尽管双二极管模型(DDM)在精度上取得显著提升，但在规模化光伏发电系统中，其仍存在局限性：微小误差会被系统放大，且难以准确分解实验模块中各电流分量。为提升大规模问题的求解能力，研究界提出了三二极管模型(TDM)。该模型在 DDM 基础上引入第三支二极管，构建了由光生电流源、三支二极管、串联电阻和并联电阻组成的等效电路网络(如图 3 所示)。这种扩展结构通过增加载流子输运路径，实现了更精细的电流分量表征，其输出电流特性可由公式(3)。

$$I_L = I_{ph} - I_{sd1} \cdot \left[\exp\left(\frac{q \cdot (V_L + R_s \cdot I_L)}{n_1 \cdot k \cdot T}\right) - 1 \right] - I_{sd2} \cdot \left[\exp\left(\frac{q \cdot (V_L + R_s \cdot I_L)}{n_2 \cdot k \cdot T}\right) - 1 \right] - I_{sd3} \cdot \left[\exp\left(\frac{q \cdot (V_L + R_s \cdot I_L)}{n_3 \cdot k \cdot T}\right) - 1 \right] - \frac{V_L + R_s \cdot I_L}{R_{sh}} \quad (3)$$

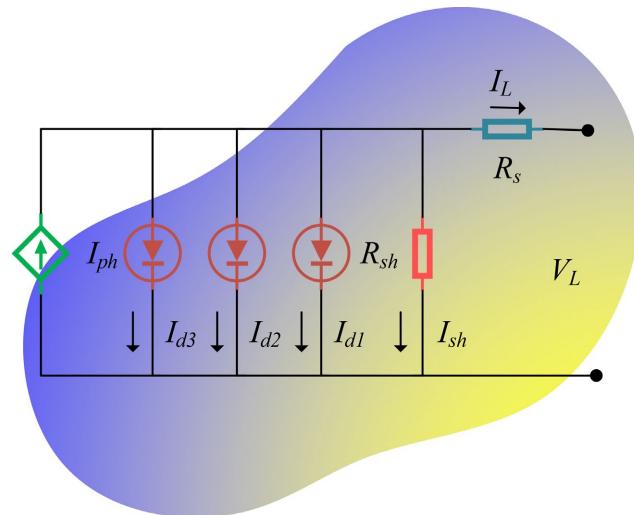
**Figure 3.** The equivalent circuit of three diode model

图 3. 三二极管模型的等效电路图

2.1.4. 光伏组件模型

在实际的工程实践中，使用纯粹的单二极管模型无法满足实际环境下的实验。所以我们将采用串并联复合连接方案可显著改善集成化光伏模组的电输出品质。光伏组件由不同规格的太阳能电池不同的方式连接而成。光伏组件的输出电路特性可由公式(4)描述。

$$\begin{aligned} I_L &= I_{ph}N_p - I_{sd1} \bullet N_p \bullet \left[\exp \left(\frac{q \bullet \left(\frac{V_L}{N_s} + N_s \bullet R_s \bullet \frac{I_L}{N_p} \right)}{n_1 \bullet k \bullet T \bullet N_s} \right) - 1 \right] - \\ &I_{sd2} \bullet N_p \bullet \left[\exp \left(\frac{q \bullet \left(\frac{V_L}{N_s} + N_s \bullet R_s \bullet \frac{I_L}{N_p} \right)}{n_2 \bullet k \bullet T \bullet N_s} \right) - 1 \right] - \\ &\frac{\frac{V_L}{N_s} + N_s \bullet R_s \bullet \frac{I_L}{N_p}}{\frac{R_{sh} \bullet N_s}{N_p}} \end{aligned} \quad (4)$$

2.2. 优化目标函数

从上述分析可知，太阳能参数辨识问题的核心在于确定目标模型中关键参数的最优值，即寻找一组参数 X ，使计算得到的电流电压值与实际测量值之间的差异最小化。因此，我们需要构建一个精确且计算可行的目标函数，测量点的实测数据与模拟数据之间的均方根误差(RMSE)被作为目标函数，其数学表达式如式(5)所示。

$$RMSE(X) = \sqrt{\frac{1}{N} \sum_{i=1}^N f_i^2(V_L, I_L, X)}, i = 1, 2, \dots, N; \quad (5)$$

3. 雾凇算法

雾凇算法利用软硬雾凇双机制协同，避免早熟收敛，以参数动态调整使算法在早期偏向全局搜索，后期聚焦局部优化，在复杂优化问题中表现出高效性和鲁棒性。RIME 的主要步骤如下：第一步，利用软雾凇搜索公式更新种群。

$$R_{ij}^{new} = R_{best,j} + r_1 \cos \theta * \beta * \left(h * (Ub_{ij} - Lb_{ij}) + Lb_{ij} \right), r_2 < E \quad (6)$$

R_{new} 表示更新后的第 i 个个体在第 j 维的新位置； Ub 和 Lb 解的上界与下界； R_{best} 为当前最个体的第 j 维位置； $r1$ 、 $r2$ 和 h 都是独立生成的随机数，它们的取值范围均为 $(-1, 1)$ ；另外的参数根据公式(7)、(8)和(9)生成的自适应参数：

$$\theta = \pi * \frac{t}{10 * T} \quad (7)$$

$$\beta = 1 - \frac{w * t}{T} / w \quad (8)$$

$$E = \sqrt{t/T} \quad (9)$$

其中 t 为当前迭代次数, w 为一个常数 5, T 为整个算法所允许的最大迭代次数。

第二步: 硬雾凇刺穿机制模拟霜颗粒凝结成这种状态时硬霜的生长。其种群更新公式如下:

$$R_{ij}^{new} = R_{best,j}, r_3 < F^{normr}(S_i) \quad (10)$$

其中 R_{new} 是当前个体的新的更新位置。 r_3 是(-1, 1)范围内的随机数。 F^{normr} 是当前个体的适应值的归一化值。

第三步: 在种群个体以两种不同更新机制产生新群体后, 将其与原个体比较, 按照公式(11)在两个个体中选择适应度好的个体, 并更新种群最佳个体。

$$\begin{cases} F(R_I) = F(R_i^{new}), F(R_i^{new}) < F(R_i) \\ R_i = R_i^{new} \end{cases} \quad (11)$$

4. 基于协方差自适应进化和 NM 型的雾凇算法

4.1. 协方差自适应进化机制

协方差矩阵自适应进化策略(CMA-ES)采用独特的自适应机制, 通过动态调整搜索分布来优化目标函数, 其核心流程包含三个关键组成部分。

(1) 取样操作: 算法首先生成一个初始种群, 其采样过程基于多元正态分布模型。种群个体的表示方式如式(12)所示

$$X_i(t+1) \sim m(t) + \sigma(t) * N(0, C(t)), i = 1, 2, \dots, popsize \quad (12)$$

其中 X_i 是种群中的第 i 个个体。 t 是算法当前进化迭代数, m 代表种群分布的中心位置(均值向量)。 N 是多项式正态分布, C 的初始化通常设置为单位矩阵, 其本征向量决定了搜索椭球的主轴方向, 而本征值则对应于各主轴长度的平方。

(2) 重新选择阶段: 根据适应度值对种群进行排序, 选取表现最优几个个体构成精英子群。随后, 通过加权重组计算新一代的均值向量如式(13)所示。

$$m(t+1) = \sum_{i=1}^{\mu} w_i * X_i(t+1) \quad (13)$$

w_i 是预设的权重系数, 权重之和为 1。 X_i 是在群体中选中的第 i 个体。公式(13)表明下一代种群的分布中心将向亚种群移动, 并接近亚种群的最优解。

(3) 参数更新操作: 通过结合 *Rank-1-update* 更新和 *Rank- μ -update* 更新两种互补策略来实现种群参数的动态优化。该算法的核心在于其独特的协方差矩阵更新公式:

$$C(t+1) = (1 - c_1 - c_\mu) * C(t) + c_1 * P_c(t+1) * (P_c(t+1))^T + c_\mu * \sum_{i=1}^{\mu} w_i * Y_i(t+1) * (Y_i(t+1))^T \quad (14)$$

方程右边的和的第二部分是 *Rank-1-update* 模式, 第三部分是 *Rank- μ -update* 模式。 μ_{eff} 为影响方差的选择集, 可由式(15)导出。

$$\mu_{eff} = \left(\sum_{i=1}^{\mu} w_i^2 \right)^{-1} \quad (15)$$

式(16)展示了 P_c 的更新的过程如。

$$P_c(t+1) = (1 - c_1) * P_c(t) + \sqrt{c_c * (2 - c_c) * \mu_{eff}} \left[\frac{m(t+1) - m(t)}{\sigma(t)} \right] \quad (16)$$

其中 C_c 是进化路径的学习速率。

式(16)中的步长也需要更新, 如式(18)所示。

$$\sigma(t+1) = \sigma(t) \exp\left(\frac{c_\sigma}{d_\sigma} \left(\frac{\|P_\sigma(t+1)\|}{E \|N(0, I)\|} - 1 \right)\right) \quad (17)$$

这里 E 是数学期望函数。 I 是单位矩阵; d 为每步更新时的阻尼系数。 P 是步长的演化路径, 初始等于 0, 更新后的方程如下:

$$P_c(t+1) = (1 - c_1) * P_c(t) + \sqrt{c_c * (2 - c_c) * \mu_{eff}} C(t)^{\frac{1}{2}} \left[\frac{m(t+1) - m(t)}{\sigma(t)} \right] \quad (18)$$

4.2. 改进的雾凇算法的结构

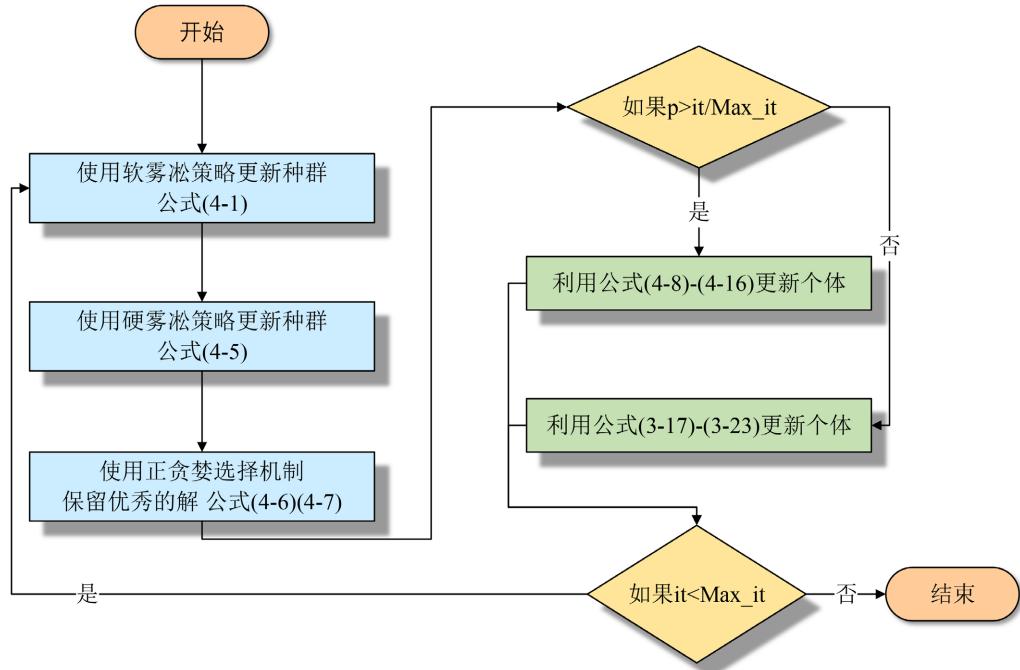
本文提出的 ENMRIME 算法创新性地将协方差矩阵自适应进化策略(CMA-ES)与 NMs 有机结合, 有效克服了传统雾凇算法的固有缺陷。通过深入分析发现, 原始 RIME 算法在个体更新过程中过度依赖对当前最优解的随机贪心学习, 这使得算法在求解具有多个极值点的复杂优化问题时, 其全局搜索性能受到显著限制, 往往难以跳出局部最优。为此, ENMRIME 算法在架构设计上进行了三重优化: 首先, 在算法初期阶段引入 CMA-ES 的种群生成机制, 通过协方差矩阵自适应调整产生具有良好多样性的候选解集, 其次, 在算法后期嵌入 Nelder-Mead 单纯形法的局部搜索框架, 利用其反射、扩展、收缩等几何操作增强最优解邻域的精细搜索能力; 最后, 通过动态权重调整机制实现两种策略的无缝衔接, 确保算法在不同优化阶段都能保持最佳性能。

提出的改进后的算法伪代码如算法 1 所示, 算法流程图如图 4 所示。

算法 1: ENMRIME 的伪代码

```

1: 输入: 搜索范围, 最大迭代次数 Max_Iter, 设置当前迭代 iter = 1, 种群大小 N, 个体维度 D;
3: 输出: Best_R;
2: 初始化雾凇种群 R, Best_R, lb, ub;
4: While (iter < Max_Iter)
5: For i = 1: N
6: For j = 1: D
7: If r2 < E
8: 根据公式(4-1)更新个体;
9: If r3 < Fnorm(Si)
10: 根据公式(4-5)更新个体;
11: End For
12: End For
13: For i = 1:N
14: For j = 1: D
15: 利用公式(4-6)和公式(4-7) 更新个体;
16: End For
17: End For
18: iter = iter + 1;
19: If p < iter/Max_Iter
20: 利用公式(4-8)-(4-16)更新个体;
21: else
22: 利用公式(3-17)-(3-23)更新个体;
23: End if
24: End While
25: 输出最优个体, Best_X;
```

**Figure 4.** ENMRIME 的流程图**图 4.** ENMRIME flowchart

5. 固定光照与温度下光伏模型参数辨识实验结果

为了系统验证 ENMRIME 算法在光伏系统参数辨识中的性能优势，本研究设计了全面的对比实验方案。实验选取了四种典型的光伏模型作为测试基准，以全面评估算法在不同复杂度场景下的适用性。在对比算法选择方面，我们精心挑选了七种当前性能优异的优化算法作为参照，包括 IJAYA、GOTLBO、ABC、MLBSA、GWO、WOA 以及 EHHO，确保对比实验的科学性和说服力。

表 1 所示的实验结果从多个维度进行了详细分析。通过 Max(最差精度)、Min(最优精度)和 Mean(平均精度)三个指标评估算法的优化能力；其次，利用标准差和 30 次实验的成功率考察算法的稳定性。实验数据表明，ENMRIME 在所有测试模型中均展现出卓越的性能，特别是在 DDM 和 TDM 等复杂模型。虽然在 SDM 和 PV 模型中 ENMRIME 与 MLBSA 的平均精度相近，但其标准差降低 15%~20%，表现出更优异的稳定性。

Table 1. Comparison of statistical results of different algorithms on four models**表 1.** 不同算法在四种模型上统计结果的比较

模型	算法	RMSE				
		Max	Mean	Min	Std	SR
SDM	ENMRIME	9.8602E-04	9.8602E-04	9.8602E-04	4.0690E-12	30
	IJAYA	1.8847E-03	9.9030E-04	1.1118E-03	1.9018E-04	30
	GOTLBO	1.4985E-03	9.8931E-04	1.1965E-03	1.6256E-04	30
	ABC	6.1237E-02	2.1630E-02	4.0169E-02	1.0973E-02	0
	MLBSA	1.5261E-03	9.8602E-04	1.0148E-03	9.8758E-05	30
	GWO	4.5335E-02	1.6651E-03	1.3972E-02	1.5665E-02	21
	WOA	5.0927E-02	1.9832E-03	2.0071E-02	1.8471E-02	14
	EHHO	7.5055E-02	1.0219E-03	7.9533E-03	1.6296E-02	27

续表

	ENMRIME	9.8725E-04	9.8248E-04	9.8419E-04	1.9028E-06	30
DDM	IJAYA	2.3519E-03	9.8680E-04	1.1462E-03	2.6047E-04	30
	GOTLBO	1.8592E-03	9.9351E-04	1.3618E-03	2.8046E-04	30
	ABC	4.9378E-02	1.1557E-02	3.4278E-02	8.9741E-03	0
	MLBSA	1.5379E-03	9.8309E-04	1.0381E-03	1.0952E-04	30
	GWO	3.6536E-02	1.4119E-03	7.1209E-03	9.3717E-03	27
	WOA	5.0717E-02	1.4105E-03	2.0100E-02	1.8608E-02	15
	EHHO	5.2957E-02	1.2473E-03	8.7985E-03	1.2028E-02	24
	ENMRIME	9.8804E-04	9.8248E-04	9.8455E-04	1.6600E-06	30
TDM	IJAYA	1.7904E-03	1.0190E-03	1.2640E-03	1.9645E-04	30
	GOTLBO	2.7969E-03	1.0357E-03	1.5723E-03	4.1966E-04	30
	ABC	5.2908E-02	8.8405E-03	3.3117E-02	1.3474E-02	1
	MLBSA	2.4018E-03	9.8465E-04	1.1285E-03	2.8575E-04	30
	GWO	4.7016E-02	1.6056E-03	8.9431E-03	1.0933E-02	23
	WOA	2.1959E-01	2.7268E-03	2.4297E-02	3.9454E-02	11
	EHHO	1.0833E-01	1.6194E-03	9.2943E-03	1.9295E-02	25
	ENMRIME	2.4251E-03	2.4251E-03	2.4251E-03	2.0789E-12	30
PV	IJAYA	5.6848E-03	2.4266E-03	2.5932E-03	5.9354E-04	30
	GOTLBO	2.9116E-03	2.4254E-03	2.4605E-03	8.8185E-05	30
	ABC	1.8263E-01	6.8668E-03	6.0827E-02	3.6891E-02	1
	MLBSA	4.0394E-03	2.4251E-03	2.4947E-03	2.9507E-04	30
	GWO	1.2753E-02	2.6083E-03	3.2483E-03	1.8651E-03	29
	WOA	2.7459E-01	2.5539E-03	6.0451E-02	9.9907E-02	17
	EHHO	3.1161E-01	5.2085E-03	1.1969E-01	1.2018E-01	4

5.1. 单二极管太阳能电池模型

在本部分实验中，我们将 ENMRIME 等算法应用于 SDM 模型，统计实验结果后，进行详细分析。表 2 展示了每种算法在 30 次随机运行后计算得到的 RMSE 值。从表中可以看出，ENMRIME 与 MLBSA 拥有好的收敛精度。相比之下，其他算法的收敛曲线都过早陷入停滞，最终在算法后期难有建树。ENMRIME 在算法的早中期阶段跳出局部最优，并在后期仍拥有强大的开发能力，从而进一步提高了求解的精度，最终超越了其他优秀算法。表 3 提供了基于模拟 SDM 数据获得的 IAE 值结果，显示了总的 IAE 值。

Table 2. RMSE values measured by ENMRIME and other algorithms on SDM

表 2. ENMRIME 与其他算法在 SDM 上测得的 RMSE 值

算法名	I_{ph} (A)	I_{sd} (μ A)	R_s (Ω)	R_{sh} (Ω)	n	RMSE	Sig
ENMRIME	0.760776	3.23024	0.036377	53.71951	1.48118	9.8602E-04	
IJAYA	0.760739	3.29051	0.036308	54.42445	1.48307	9.9030E-04	+
GOTLBO	0.760719	3.34733	0.036243	54.96254	1.48476	9.8931E-04	+
ABC	0.746049	8.31426	0.028639	100	1.59179	2.1630E-02	+
MLBSA	0.760776	3.23021	0.036377	53.71848	1.48118	9.8602E-04	=
GWO	0.762212	4.86860	0.034598	47.04507	1.52399	1.6651E-03	+
WOA	0.763306	2.40458	0.036853	31.80841	1.45254	1.9832E-03	+
EHHO	0.760539	2.93714	0.036816	54.85728	1.47160	1.0219E-03	+

Table 3. IAE measured by ENMRIME on SDM
表 3. ENMRIME 在 SDM 上测得的 IAE

Item	Monitor data		Simulated current data		Simulated power data	
	V(V)	I(A)	I _s (A)	IAE _I (A)	P _s (W)	IAE _P (W)
1	-0.2057	0.7640	0.76408766021	0.000087660	-0.157172832	0.000018032
2	-0.1291	0.7620	0.76266306868	0.000663069	-0.098459802	0.000085602
3	-0.0588	0.7605	0.76135531364	0.000855314	-0.044767692	0.000050292
4	0.0057	0.7605	0.76015401951	0.000345980	0.004332878	0.000001972
5	0.0646	0.7600	0.75905525746	0.000944743	0.049034970	0.000061030
6	0.1185	0.7590	0.75804241212	0.000957588	0.089828026	0.000113474
7	0.1678	0.7570	0.75709173746	0.000091737	0.127039994	0.000015394
8	0.2132	0.7570	0.75614146329	0.000858537	0.161209360	0.000183040
9	0.2545	0.7555	0.75508698411	0.000413016	0.192169637	0.000105113
10	0.2924	0.7540	0.75366400004	0.000336000	0.220371354	0.000098246
11	0.3269	0.7505	0.75139109538	0.000891095	0.245629749	0.000291299
12	0.3585	0.7465	0.74735398308	0.000853983	0.267926403	0.000306153
13	0.3873	0.7385	0.74011735139	0.001617351	0.286647450	0.000626400
14	0.4137	0.7280	0.72738234716	0.000617653	0.300918077	0.000255523
15	0.4373	0.7065	0.70697276261	0.000472763	0.309159189	0.000206739
16	0.4590	0.6755	0.67528025060	0.000219749	0.309953635	0.000100865
17	0.4784	0.6320	0.63075836160	0.001241638	0.301754800	0.000594000
18	0.4960	0.5730	0.57192844118	0.001071559	0.283676507	0.000531493
19	0.5119	0.4990	0.49960709778	0.000607098	0.255748873	0.000310773
20	0.5265	0.4130	0.41364886764	0.000648868	0.217786129	0.000341629
21	0.5398	0.3165	0.31751017593	0.001010176	0.171391993	0.000545293
22	0.5521	0.2120	0.21215498599	0.000154986	0.117130768	0.000085568
23	0.5633	0.1035	0.10225132415	0.001248676	0.057598171	0.000703379
24	0.5736	-0.0100	-0.00871758547	0.001282415	-0.005000407	0.000735593
25	0.5833	-0.1230	-0.12550753075	0.002507531	-0.073208543	0.001462643
26	0.5900	-0.2100	-0.20847251890	0.001527481	-0.122998786	0.000901214
Sum of IAE	NA	NA	NA	0.021526665	NA	0.008730759

5.2. 双二极管太阳能电池模型

实验设计部分采用 ENMRIME 算法对双二极管模型(DDM)进行参数辨识研究。同样的将 ENMRIME 与当前主流智能优化算法在相同实验条件下进行 30 次独立仿真测试，统计结果如表 4 所示。ENMRIME 与 MLBSA 展现出显著优势，其均方根误差(RMSE)指标稳定处于最低水平，ENMRIME 达到了最佳的收敛精度，ENMRIME 通过动态调整勘探 - 开采平衡因子，增强了跳出局部最优的能力，这种自适应性机制使其在维持解集多样性的同时，确保了解空间的深度搜索能力。实证研究表明，ENMRIME 在 DDM 参数辨识任务中展现出竞争优势，算法时间复杂度较传统智能优化算法降低约 40%。这种效率与精度的协同提升，标志着该算法在复杂光伏系统参数辨识领域具有重要应用价值。关于 IAE 值的详细统计数据，请参见表 5。

Table 4. Comparison results based on different DDM algorithms
表 4. 基于 DDM 不同算法的比较结果

算法	I _{ph} (A)	I _{sd1} (μA)	I _{sd2} (μA)	R _s (Ω)	R _{sh} (Ω)	n ₁	n ₂	RMSE
ENMRIME	0.760781	0.22597	0.74934	0.036740	55.48545	1.45102	2	9.8248E-04

续表

IJAYA	0.760833	0.29562	0.16061	0.036445	53.72704	1.47367	1.958108	9.8680E-04
GOTLBO	0.760738	0.66082	0.24751	0.036527	55.39161	1.99945	1.459307	9.9351E-04
ABC	0.757549	0.89096	0.56084	0.024368	22.33128	1.69266	1.610771	1.1557E-02
MLBSA	0.760782	0.25810	0.46224	0.036605	54.74426	1.46219	1.989851	9.8309E-04
GWO	0.759681	0.49201	0.00214	0.034585	86.98847	1.52485	1.628562	1.4119E-03
WOA	0.759974	0.52320	0.92940	0.034458	87.09255	1.53123	1.602165	1.4105E-03
EEHO	0.761106	0.32607	0.72675	0.035484	63.98137	1.48750	1.987401	1.2473E-03

Table 5. IAE measured by ENMRIME on DDM**表 5.** ENMRIME 在 DDM 上测得的 IAE

Item	Monitor data		Simulated current data		Simulated power data	
	V(V)	I(A)	I _s (A)	IAE _I (A)	P _s (W)	IAE _P (W)
1	-0.20570	0.76400	0.763983415	0.000016585	-0.157151388	0.000003412
2	-0.12908	0.76200	0.762604099	0.000604099	-0.098452189	0.000077989
3	-0.05882	0.76050	0.761337701	0.000837701	-0.044766657	0.000049257
4	0.00569	0.76050	0.760173791	0.000326209	0.004332991	0.000001859
5	0.06455	0.76000	0.759107683	0.000892317	0.049038356	0.000057644
6	0.11847	0.75900	0.758121423	0.000878577	0.089837389	0.000104111
7	0.16775	0.75700	0.757188617	0.000188617	0.127056250	0.000031650
8	0.21322	0.75700	0.756243610	0.000756390	0.161231138	0.000161262
9	0.25454	0.75550	0.755177306	0.000322694	0.192192624	0.000082126
10	0.29241	0.75400	0.753722358	0.000277642	0.220388418	0.000081182
11	0.32689	0.75050	0.751399140	0.000899140	0.245632379	0.000293929
12	0.35847	0.74650	0.747301451	0.000801451	0.267907570	0.000287320
13	0.38728	0.73850	0.740010670	0.001510670	0.286606132	0.000585082
14	0.41373	0.72800	0.727246963	0.000753037	0.300862069	0.000311531
15	0.43732	0.70650	0.706850309	0.000350309	0.309105640	0.000153190
16	0.45900	0.67550	0.675210554	0.000289446	0.309921644	0.000132856
17	0.47838	0.63200	0.630760767	0.001239233	0.301755951	0.000592849
18	0.49601	0.57300	0.571994740	0.001005260	0.283709391	0.000498609
19	0.51189	0.49900	0.499706138	0.000706138	0.255799572	0.000361472
20	0.52647	0.41300	0.413733672	0.000733672	0.217830778	0.000386278
21	0.53978	0.31650	0.317546201	0.001046201	0.171411439	0.000564739
22	0.55212	0.21200	0.212122990	0.000122990	0.117113103	0.000067903
23	0.56334	0.10350	0.102163270	0.001336730	0.057548570	0.000752980
24	0.57356	-0.01000	-0.008791754	0.001208246	-0.005042950	0.000693050
25	0.58332	-0.12300	-0.125543433	0.002543433	-0.073229484	0.001483584
26	0.59000	-0.21000	-0.208371581	0.001628419	-0.122939233	0.000960767
Sum of IAE	NA	NA	NA	0.021275205	NA	0.008776633

5.3. 三二极管太阳能电池模型

采用 ENMRIME 在三二极管模型下进行参数辨识。**表 6** 的统计数据显示，在 30 次独立重复实验中，ENMRIME 展现出显著的优化稳定性，其均方根误差(RMSE)达到 9.8248E-04。由此我们可以得出结论，ENMRIME 在本实验中表现卓越，展现了处理 TDM 模型时的高精度和强有效性。**表 7** 提供了 IAE 值的详细统计信息。结果表明，ENMRIME 能够准确识别实验模型中的未知参数。

Table 6. Comparison results based on different TDM algorithms**表 6.** 基于 TDM 不同算法的比较结果

算法	ENMRIME	IJAYA	GOTLBO	ABC	MLBSA	GWO	WOA	EHHO
I_{ph} (A)	0.760781	0.760568	0.761050	0.754274	0.760766	0.760225	0.761065	0.761465
I_{sd1} (μ A)	0.05587	0.03632	0.05589	0.22069	0.27869	0.20147	0.28351	0.00036
I_{sd2} (μ A)	0.22598	0.30177	0.45707	0.21658	0.18825	0.17519	0.75819	0.55548
I_{sd3} (μ A)	0.69347	0.31201	0.28211	0.28645	0.02544	0.23752	0.01653	0.00220
R_s (Ω)	0.036740	0.036126	0.036233	0.041331	0.036475	0.034017	0.030696	0.033869
R_{sh} (Ω)	55.48541	60.47975	57.03900	67.94136	54.37768	96.81651	76.71971	54.98131
n_1	2.00000	1.87163	1.92405	1.44415	1.47006	1.58268	1.61009	1.46572
n_2	1.45102	1.47733	1.99817	2.00000	1.97428	1.52461	1.61064	1.53804
n_3	2.00000	1.96970	1.47131	1.75407	1.62691	1.54451	1.72282	1.84265
RMSE	9.825E-04	1.019E-03	1.036E-03	8.84E-03	9.85E-04	1.606E-03	2.727E-03	1.619E-03
Sig		+	+	+	+	+	+	+

Table 7. IAE measured by ENMRIME on TDM**表 7.** ENMRIME 在 TDM 上测得的 IAE

编号	测量数据		模拟电流数据		模拟电功率数据	
	$V(V)$	$I(A)$	$I_{sim}(A)$	$IAE_I(A)$	$P_{sim}(W)$	$IAE_P(W)$
1	-0.2057	0.7640	0.763983414	0.000016586	-0.157151388	0.000003412
2	-0.1291	0.7620	0.762604097	0.000604097	-0.098452189	0.000077989
3	-0.0588	0.7605	0.761337698	0.000837698	-0.044766657	0.000049257
4	0.0057	0.7605	0.760173787	0.000326213	0.004332991	0.000001859
5	0.0646	0.7600	0.759107679	0.000892321	0.049038356	0.000057644
6	0.1185	0.7590	0.758121418	0.000878582	0.089837388	0.000104112
7	0.1678	0.7570	0.757188611	0.000188611	0.127056249	0.000031649
8	0.2132	0.7570	0.756243604	0.000756396	0.161231136	0.000161264
9	0.2545	0.7555	0.755177299	0.000322701	0.192192623	0.000082127
10	0.2924	0.7540	0.753722351	0.000277649	0.220388416	0.000081184
11	0.3269	0.7505	0.751399133	0.000899133	0.245632377	0.000293927
12	0.3585	0.7465	0.747301443	0.000801443	0.267907567	0.000287317
13	0.3873	0.7385	0.740010662	0.001510662	0.286606129	0.000585079
14	0.4137	0.7280	0.727246955	0.000753045	0.300862065	0.000311535
15	0.4373	0.7065	0.706850301	0.000350301	0.309105637	0.000153187
16	0.4590	0.6755	0.675210546	0.000289454	0.309921640	0.000132860
17	0.4784	0.6320	0.630760760	0.001239240	0.301755947	0.000592853
18	0.4960	0.5730	0.571994733	0.001005267	0.283709388	0.000498612
19	0.5119	0.4990	0.499706134	0.000706134	0.255799570	0.000361470
20	0.5265	0.4130	0.413733670	0.000733670	0.217830778	0.000386278
21	0.5398	0.3165	0.317546203	0.001046203	0.171411440	0.000564740
22	0.5521	0.2120	0.212122993	0.000122993	0.1171113104	0.000067904
23	0.5633	0.1035	0.102163274	0.001336726	0.057548572	0.000752978
24	0.5736	-0.0100	-0.008791754	0.001208246	-0.005042950	0.000693050
25	0.5833	-0.1230	-0.125543437	0.002543437	-0.073229487	0.001483587
IAE 和	NA	NA	NA	0.021275219	NA	0.008776635

6. 总结与展望

太阳能作为一种重要的可再生能源，其开发利用日益受到广泛关注。在光伏系统研究中，精确高效的建模方法对提高太阳能光伏电池的性能评估至关重要，其中参数辨识的准确性直接影响着组件的运行效率评估。针对光伏系统参数辨识这一关键问题，本研究对雾凇优化算法(RIME)进行了两方面的改进：首先，引入协方差矩阵自适应进化策略(CMA-ES)，显著提升了算法解的质量，使种群分布更集中于最优解区域；其次，结合 NMs 单纯形法，充分发挥 RIME 算法在高维空间的全局搜索能力，同时利用 CMA-ES 的协方差变异策略，有效提高了算法在动态环境下的追踪性能。实验结果表明，算法在光伏组件的参数辨识中取得了与实测数据高度吻合的结果。尽管本研究提出的改进元启发式算法在光伏参数提取方面表现出色，但仍存在若干需要完善之处。在算法性能方面，需要进一步提升其可扩展性以适应更复杂的环境参数变化；同时，与其他元启发式算法类似，本算法在相同环境下的重复实验仍可能出现结果波动。在研究范围上，当前工作主要聚焦于温度和辐照度对光伏参数的影响，而实际应用中还存在光照角度、阴影遮挡、机械故障等多种干扰因素。未来研究将致力于构建多维度环境因子分析体系，建立环境变量的动态权重机制，从而增强实验数据与实际工况的一致性。

致 谢

本研究及论文的顺利完成，离不开众多师长、同学、朋友及家人的支持与帮助。在此，我谨向他们致以最诚挚的谢意。

参考文献

- [1] Su, H., Zhao, D., Heidari, A.A., Liu, L., Zhang, X., Mafarja, M., et al. (2023) RIME: A Physics-Based Optimization. *Neurocomputing*, **532**, 183-214. <https://doi.org/10.1016/j.neucom.2023.02.010>
- [2] Zhong, R., Yu, J., Zhang, C. and Munetomo, M. (2024) SRIME: A Strengthened RIME with Latin Hypercube Sampling and Embedded Distance-Based Selection for Engineering Optimization Problems. *Neural Computing and Applications*, **36**, 6721-6740. <https://doi.org/10.1007/s00521-024-09424-4>
- [3] Abu Khurma, R., Braik, M., Alzaqebah, A., Gopal Dhal, K., Damaševičius, R. and Abu-Salih, B. (2024) Advanced RIME Architecture for Global Optimization and Feature Selection. *Journal of Big Data*, **11**, Article No. 89. <https://doi.org/10.1186/s40537-024-00931-8>
- [4] Hakmi, S.H., Alnami, H., Moustafa, G., Ginidi, A.R. and Shaheen, A.M. (2024) Modified Rime-Ice Growth Optimizer with Polynomial Differential Learning Operator for Single- And Double-Diode PV Parameter Estimation Problem. *Electronics*, **13**, Article 1611. <https://doi.org/10.3390/electronics13091611>
- [5] Zhou, T. and Shang, C. (2024) Parameter Identification of Photovoltaic Models by an Enhanced RIME Algorithm. *International Journal of Energy Research*, **2024**, Article ID: 9777345. <https://doi.org/10.1155/2024/9777345>