



Ferdowsi
University of
Mashhad

Journal of Applied and Computational Sciences in Mechanics

Page Journal: mechanic-ferdowsi.um.ac.ir



Society of
Manufacturing
Engineering of Iran

Parameter Optimization of Various Solar Cell Models by Neural Network Algorithm*

Research Article

Ali Sadollah¹, Javad Riazat²

DOI: [10.22067/jacsm.2023.81702.1176](https://doi.org/10.22067/jacsm.2023.81702.1176)

1- Introduction

The necessity of renewable energy in recent years has significantly risen due to the daily price hike of fossil fuels, such as oil and gas, along with the increasing environmental pollution following the use of these fuels. Solar energy has been widely investigated among renewable energies because of the deplete availability of this energy. Lately, accurate modeling of the voltage (I-V) of solar cells has attracted the attention of many researchers. The main drawback in precise modeling is the absence of information about the accurate values of the model parameters to create a good coordination between the experimental data and the results of the models, and this variable identification is performed well with the assistance of an optimization technique. So far, several models have been proposed and expanded to demonstrate the behavior of the system under different exploitation conditions. In order to indicate the performance of the solar cell, three solar cell models are extensively used in practice, namely the single-diode, double-diode, and triple-diode models containing five, seven, and nine unknown variables, respectively. The solution key in deriving an effective mathematical model is the precise estimation of these parameters, and therefore, these parameters must be extracted and calculated with

high accuracy to reach a correct balance between the current (I) and voltage (V) of the solar cell outputs. In this article, the neural network optimization algorithm (NNA) is used to achieve the optimal values of the unknown variables of commercial silicon solar cell models (R.T.C. France) with a diameter of 57 mm for the single-diode, double-diode, and triple-diode models. To evaluate the performance of NNA, the optimization results obtained from this method were compared with the results obtained by the other optimization algorithms recently used for this problem. It was proved that applying the NNA method led to the best results compared to other approaches.

2- Solar Cells Diode Circuit Models

Investigating several solar models revealed the triple-diode model among all existing solar cell models as the most accurate model. It solved the drawbacks of other

models by taking into account almost all the physical details and leakages in actual solar cells, leading to the improved accuracy of the results. However, complexity and time consumption are the main defects of this model. The theoretical relations of this model have been described briefly as follows.

Triple-Diode Model

The nodal current equation at the entrance terminal can be written as Eq. (1) utilizing Kirchhoff's law for the triple-diode model, where the constant q is the charge of the electron (1.6021×10^{-19}); C , K represents the constant of the Boltzmann (1.2806×10^{-23}); and J/K and T is the temperature of the junction in Kelvin.

$$I_t = I_{ph} - I_{sd1} \left[\exp\left(\frac{qC}{n_1 K T} \frac{I_t}{I_{sd1}}\right) - 1 \right] - I_{sd2} \left[\exp\left(\frac{qC}{n_2 K T} \frac{I_t}{I_{sd2}}\right) - 1 \right] - I_{sd3} \left[\exp\left(\frac{qC}{n_3 K T} \frac{I_t}{I_{sd3}}\right) - 1 \right] - \frac{V_t}{R_{sh}} \frac{I_t}{I_{sd3}} \quad (1)$$

In Eq. (1), $x = [I_{ph}, I_{sd1}, I_{sd2}, I_{sd3}, R_s, R_{sh}, n_1, n_2, n_3]$ is the unknown parameter matrix of the triple diode model which reflects the solar cell model performance against the actual solar cell behavior. Each parameter of this matrix indicates a distinct physical element of the model circuit. Moreover, I_t and V_t refer to the terminal current and voltage, respectively. Applying nine design variables in the triple-diode model has made this model more capable and efficient for estimating the actual performance of the solar cell in practice compared to the single- and double-diode models having five and seven unknown parameters, respectively.

3- Optimization Model and Optimizer

The first step of the optimization process is to define each extracted solution by a solution vector, namely x , where $x = [I_{ph}, I_{sd1}, I_{sd2}, I_{sd3}, R_s, R_{sh}, n_1, n_2, n_3]$ for the triple-

*Manuscript received: April 5, 2023. Revised, May 28, 2023, Accepted, July 26, 2023.

¹ Corresponding Author: Assistant Professor, Department of Mechanical Engineering, University of Science and Culture, Tehran, Iran. **Email:** sadollah@usc.ac.ir.

² M.Sc. Department of Mechanical Engineering, University of Science and Culture, Tehran, Iran.

diode model. The error function of the considered models is as follows:

$$E(I_t, V_t, x) = I_{Measured} - I_{Calculated} \quad (2)$$

where $I_{Measured}$ is obtained from the experimental datasheets of recent sources and $I_{Calculated}$ will be calculated based on parameters extracted from the optimization algorithm and Eq. (1). Now, using Eq. (2) the root mean square error (RMSE) which is the objective function can be defined by the following relation:

$$RMSE = \sqrt{\frac{1}{N_c} \sum_{i=1}^{N_c} (E(I_t, V_t, x))^2} \quad (3)$$

where N_c is the number of the coupled experimented data. The domain of the solution vector for each unknown parameter is compiled from the literature and the cost function is minimized during the optimization based on this parameter domain limitation. In the last step, the RMSE function of all three models will be imported to the NNA as the objective function in order to extract the optimal unknown parameters for each model.

Neural Network Algorithm

The NNA is a newly created metaheuristics motivated by the unique structure of artificial neural networks (ANNs) and biological system-inspired optimizers. To produce new candidate solutions, the NNA benefits from the complex nature of ANNs and operators. For other metaheuristic optimization algorithms, the NNA starts with an initial population called the population of the pattern solution. Inspired by ANNs, each iteration in the NNA assumes the best solution achieved (i.e., time-optimal solution) as the target data, and the aim is to minimize the error between target data and other predicted pattern solutions. Therefore, based on the given definition, the NNA is programmed to minimize optimization problems (i.e., reduce the error between the target and the model solutions). It should be emphasized that at each iteration this target solution will be updated.

4- Results and Discussions

MATLAB software environment was used to identify the unknown parameters of the reported solar cell models. The

optimization task was performed for 30 independent runs using the NNA for all three models and optimized parameters extracted from the corresponding best RMSE. In the case of the triple-diode model, the best RMSE value is $9.84e-04$. For this model, the NNA has the lowest RMSE value, showing that the nine extracted parameters by this method are closer to those in practice.

Therefore, the calculated currents are determined for all three models and compared with the measured current as can be seen in Fig. 1. Existence of such a matching level between results means that the variables extracted from the NNA are very accurate for all three solar cell models and are so close to the real values. Other characteristics, such as relative error and voltage-power, can be extracted using the calculated currents in order to evaluate the accuracy of estimated parameters by NNA.

5- Conclusions

In this paper, NNA was studied to obtain accurate results of single-, double-, and triple-diode solar cell models. The NNA could provide an effective optimization model for solving optimization problems by taking the idea of the unique structure of neural networks in the human brain. The proposed algorithm was used to identify the design and unknown parameters of a solar cell with a 57 mm diameter (R.T.C. France). The obtained optimization results by the proposed algorithm are quite promising and overcome the results reported in the literature. In all three diode models, the NNA suggested more accurate and optimal solutions. This is especially evident in the double- and triple-diode models, where the number of unknown design parameters is higher (the nonlinear complexity of the problem is higher). It shows the successful performance of the proposed algorithm in solving more complex problems with a nonlinear nature. As a result, the NNA can be considered as a suitable candidate for solving the optimization problems of the solar cell systems.




Fig. 1. Current-Voltage characteristic diagrams (*I-V*) obtained from *c)* Triple-Diode model, *d)* Comparison of the calculated currents of all three models with the measured current



بهینه‌سازی فرایند شناسایی پارامتر مدل‌های تک دیودی، دو دیودی، و سه دیودی سلول خورشیدی مدل R.T.C. توسط الگوریتم بهینه‌سازی شبکه عصبی*

مقاله پژوهشی

علی سعداله^(۱) و جواد ریاضت^(۲)

DOI: 10.22067/jacsm.2023.81702.1176

چکیده شناخت دقیق متغیرهای مجهول برای انواع سلول‌های خورشیدی با استفاده از داده‌های آزمایشگاهی اهمیت حیاتی در طراحی، کنترل، کیفیت، برآورد هزینه، و پیش‌بینی عملکرد سلول‌های خورشیدی دارد. گسترش مشخصه‌های یک سلول خورشیدی واحد به مجموعه‌ای از سلول‌ها (پنل خورشیدی) معمولاً بر اساس یک نقطه عملیاتی واحد بر روی منحنی مشخصه جریان-ولتاژ یکی از این سلول‌ها انجام می‌شود. در سال‌های اخیر، یک روش جدید برای پیش‌بینی عملکرد سلول و غربالگری سلولی با مدل‌سازی سلول با استفاده از یک مدار الکتریکی معادل ارائه شده است که در آن، هر متغیر، مربوط به یک پدیده فیزیکی در سلول خورشیدی است. این مدل‌های تحلیلی می‌توانند با یک مدل پنج، هفت، و اخیراً نه متغیری نشان داده شوند. به واسطه غیرخطی بودن و ناتوانی روش‌های بهینه‌سازی سنتی در شناسایی دقیق متغیرهای ناشناخته سیستم، اخیراً الگوریتم‌های بهینه‌سازی هوشمند، توجهات چشم‌گیری را در حل این نوع مسائل مهندسی به خود جلب کرده‌اند. الگوریتم شبکه عصبی یک الگوریتم فراابتکاری است که از عملکرد شبکه عصبی مغز انسان الهام گرفته است. در این مقاله، تکنیک شناسایی پارامتر بهینه یک سلول خورشیدی تجاری برای مدل تک دیودی، دو دیودی، و سه دیودی توسط الگوریتم شبکه عصبی انجام گرفته است. نتایج به دست آمده از روش پیشنهادی دارای دقت پاسخ بهتری نسبت به الگوریتم‌های بهینه‌سازی اخیر در منابع است. این بهبود عملکرد به ترتیب برای مدل‌های تک دیودی، دو دیودی، و سه دیودی به میزان ۰،۴۴، ۰،۰۸۵، و ۱۷،۹۷ درصد نسبت به بهترین روش مطالعه شده در منابع حاصل شده است.

واژه‌های کلیدی سلول خورشیدی، بهینه‌سازی، الگوریتم‌های فراابتکاری، شناسایی پارامتر، الگوریتم شبکه عصبی.

Parameter Optimization of Various Solar Cell Models by Neural Network Algorithm*

Ali Sadollah

Javad Riazat

Abstract Precise recognition of unknown variables for different types of solar cells is important in design, control, quality, cost estimation, and prediction of solar cell performance. Aggregation and development of a single solar cell to a set of cells (solar panels) is usually based on a single operating point on the current-voltage characteristic curve. In recent years, a new method to predict cell performance and cell screening by modeling the cell is represented using an equivalent electrical circuit in which each variable corresponds to a physical phenomenon in the solar cell. These analytical models can be represented by a five-variable, seven-variable, and recently nine-variable models. Due to the nonlinearities and inability of traditional methods in introducing and identifying the unknown variables of the system, recently intelligent algorithms have attracted considerable attentions in solving engineering and industrial problems. Neural network algorithm (NNA) is a metaheuristic optimization algorithm that is inspired by the function of the neural network of human brain. In this article, the optimum parameter identification technique of a silicon commercial solar cell is used for single diode, two diode, and three diode models. The obtained optimization results of this research are compared with other optimizers in the literature and the surrounding discussions are carried out. The attained numerical optimization results of the proposed NNA method have the highest accuracy among the other optimizers in the literature. Therefore, the NNA can be considered as a suitable optimizer in solar industry where high accuracy is needed.

Keywords Solar cell; Optimization; Metaheuristics; Parameter identification; Neural network algorithm.

* تاریخ دریافت مقاله ۱۴۰۲/۱/۱۶ و تاریخ پذیرش آن ۱۴۰۲/۵/۷ می‌باشد.

Email: sadollah@usc.ac.ir

(۱) نویسنده مسئول، استادیار، دانشکده مهندسی مکانیک، دانشگاه علم و فرهنگ، تهران.

(۲) کارشناس ارشد، دانشکده مهندسی مکانیک، دانشگاه علم و فرهنگ، تهران.

مقدمه

به واسطه افزایش قیمت روزانه سوخت‌های فسیلی نظیر نفت، گاز و همچنین افزایش آلودگی‌های محیطی به سبب استفاده از این سوخت‌ها، تقاضای استفاده از انرژی‌های تجدیدپذیر در سال‌های اخیر افزایش چشم‌گیری را در بین دولت‌های مختلف داشته است. اما، انرژی‌های خورشیدی در این بین به دلیل دسترسی آسان در نرخ‌های بسیار بالا، مورد آزمایش و بررسی قرار گرفته‌اند. به طور جزئی‌تر، سیستم‌های مبتنی بر انرژی خورشیدی به طور گسترده‌ای برای دستیابی به بهترین بهره‌برداری از این نوع از منابع انرژی تجدیدپذیر بررسی و مورد ارزیابی قرار گرفته‌اند [1]. علی‌رغم این واقعیت که سلول‌های خورشیدی مزایای زیادی را برای شبکه‌های تولیدی بازار جهانی برق به ارمغان آورده‌اند [2,3]، اخیراً یک چالش جدید و قابل توجه در رابطه با عدم تطبیق بازدهی تخمینی و بازدهی عملی آن‌ها به وجود آمده است که با شرایط آب و هوایی‌ای که تحت آن عمل می‌کنند متناسب است [4,5]، که این مورد افزون بر هزینه‌های بالای تعمیر و نگهداری آن‌ها محسوب می‌شود [6,7].

به تازگی، مدل‌سازی دقیق جریان به ولتاژ (I-V) سلول‌های خورشیدی برای حل این چالش جدید، توجه محققان مختلف را به خود جلب کرده است [8-11]. اشکال اصلی در مدل‌سازی دقیق، فقدان اطلاعات در مورد مقادیر دقیق پارامترهای مدل، به منظور ایجاد یک هماهنگی خوب بین داده‌های تجربی و نتایج مدل‌ها است و این شناسایی متغیر با کمک یک تکنیک بهینه‌سازی به خوبی انجام می‌شود. مدل‌سازی سلول‌های خورشیدی در قدم اول شامل فرموله کردن نمودار غیر خطی جریان به ولتاژ (V-I) است. روش‌های تعیین متغیرهای معادله سلول خورشیدی از داده‌های تجربی می‌تواند به دو دسته طبقه‌بندی شود: روش‌هایی که از نقاط انتخاب شده مشخصه (I-V) استفاده می‌کنند و روش‌هایی که از تمام نقاط آزمایش استفاده می‌کنند.

تا به حال چندین مدل برای نمایش رفتار سیستم تحت شرایط بهره‌برداری مختلف ارائه و توسعه داده شده است. مدل‌های متفاوتی از جمله مدل‌هایی با فرضیات ساده تا مدل‌هایی پیشرفته به همراه تعداد زیادی از متغیرهای فیزیکی وجود دارند. با این وجود سه نوع مدل سلول خورشیدی به

صورت گسترده در عمل به کار گرفته می‌شوند، که عبارتند از: مدل تک دیودی، مدل دو دیودی، و مدل سه دیودی.

دو مدل تک دیودی و دو دیودی هر دو از عناصر الکترونیکی تشکیل شده‌اند که یک مدار الکتریکی را می‌سازند که می‌تواند ماهیت غیرخطی را در سلول خورشیدی آنالیز و ترکیب کند. هر دو مدل تک دیودی و دو دیودی شامل مجموعه‌ای از مؤلفه‌ها نظیر جریان اشباع دیودی، جریان تولید شده، مقاومت شنت، مقاومت سری، و فاکتور ایدئال‌گرایی مربوط به دیود می‌باشند. برای مدل تک‌دیودی، پنج متغیر مجهول و برای مدل دو دیودی هفت متغیر مجهول برای نمایش عملکرد سلول خورشیدی وجود دارند. نکته کلیدی در استخراج یک مدل ریاضی کارآمد، تخمین دقیق این پارامترها است و بنابراین این پارامترها برای رسیدن به یک تعادل صحیح بین جریان (I) و ولتاژ (V) خروجی سلول خورشیدی باید با دقت بسیار بالا استخراج و محاسبه شوند.

علی‌رغم توانایی این دو مدل برای فراهم آوردن تحلیل‌های بهتر برای سلول‌های خورشیدی، استفاده از آن‌ها محدود به کاربردهای آزمایشگاهی بوده؛ به این معنی که عملکرد پویای آن‌ها در طول زمان فقط برای تعداد محدودی از شرایط عملیاتی آزمایش شده است. بنابراین، برای حل این مشکل مدل سه دیودی سلول خورشیدی به تازگی ارائه شده است [12]. مدل سه دیودی، ۹ متغیر را برای نمایش عملکرد سلول خورشیدی با یکدیگر ترکیب می‌کند. استفاده از ۹ متغیر در مدل سه دیودی، این مدل را برای تخمین عملکرد واقعی سلول خورشیدی در عمل و در کاربردهای صنعتی با دقت بسیار بالا و بازدهی بهبود یافته نسبت به دو مدل دیگر تواناتر و کاراتر کرده است. در حقیقت، شناسایی متغیرها به کمک یک تکنیک بهینه‌سازی قابل استفاده و توانمند امری ضروری و مهم قلمداد می‌شود.

دو رویکرد اصلی برای حل مشکل شناسایی متغیرهای بهینه در ادبیات مربوط به مدل‌سازی سلول خورشیدی وجود دارد، که عبارتند از: رویکرد تحقیقاتی مرسوم (ستتی) [13-16] و رویکرد تحقیقاتی فراابتکاری [17-19]. در مدل‌سازی مرسوم یا ستتی از یک رویکرد تخمینی مبتنی بر حداقل مربعات غیرخطی بهبود یافته خطا که بر پایه روش نیوتون توسعه یافته شده است استفاده می‌شود [13]، تا متغیرهای سلول خورشیدی استخراج و شناسایی شوند. وابستگی به نقطه آغازین که در این روش

روش‌ها محسوب می‌شوند [27].

در مقایسه با الگوریتم ژنتیک، مزیت‌های الگوریتم بهینه‌سازی تجمعی ذرات این است که پیاده‌سازی آن آسان است و چند متغیر برای تنظیم آن وجود دارد. با این وجود، این الگوریتم نیز اشکالاتی دارد. عملکرد الگوریتم بهینه‌سازی تجمعی ذرات به شدت بستگی به متغیرهای تنظیم شونده آن دارد، ممکن است به راحتی تنوع را در منطقه‌های جست و جو از دست بدهد و همچنین ممکن است تحت تأثیر هم‌گرایی زودرس قرار گیرد.

الگوریتم فرایند بازپخت شبیه‌سازی شده یک روش فراابتکاری دیگر است که تلاش می‌کند فرایند بازپخت را در متالورژی شبیه‌سازی کند. به خاطر این حقیقت که در الگوریتم فرایند باز پخت شبیه‌سازی شده، فرایند جست‌وجو توسط تنها یک عملگر جست‌وجوگر انجام می‌شود که عملکرد آن نسبت به نقطه شروع جست‌وجو حساس است. علاوه بر این، هیچ پایه نظری دقیقی برای تعیین متغیرهای این روش به خصوص متغیرهای روش خنک‌کاری وجود ندارد. انتخاب این متغیرها بسیار دشوار است و طراح باید به گونه‌ای این متغیرها را انتخاب کند که بهینه‌سازی مناسب در یک مدت زمان محاسباتی معقول انجام شده و پاسخ نهایی متغیرهای مجهول مدار به دست بیایند.

چالش غیر خطی بودن مجهولات سلول خورشیدی انتظار استفاده از یک تکنیک بهینه‌سازی با عملکرد بسیار مناسب را دارد. موفقیت یک الگوریتم بهینه‌سازی به توانایی ارائه یک تعادل خوب بین اکتشاف (Exploration) و بهره‌برداری (Exploitation) بستگی دارد. اکتشاف به تولید راه‌حل‌های جدید از محدوده مناطق دیده نشده فضای جست‌وجو اشاره دارد و بهره‌برداری یعنی تمرکز جست‌جوی الگوریتم در مجاورت راه حل‌های مناسب فعلی. ناتوانی الگوریتم برای ایجاد یک تعادل خوب بین اکتشاف و بهره‌برداری منجر به هم‌گرایی زودرس، افتادن در دام پاسخ محلی و رکود خواهد شد.

در این مقاله از الگوریتم بهینه‌سازی شبکه عصبی (Neural Network Algorithm, NNA)، برای دست‌یابی به مقادیر بهینه متغیرهای مجهول مدل‌های یک سلول خورشیدی تجاری سیلیکونی با قطر ۵۷ میلی‌متر برای مدل تک دیودی، دو دیودی، و سه دیودی استفاده شده است. به منظور ارزیابی عملکرد

استفاده می‌شود تفاوت بسیار بزرگ این رویکرد با رویکردهای دیگر است. به علاوه، این نوع روش بهینه‌سازی در ماهیت، به صورت محلی است و اگر راه‌حل و جواب موجود باشد ممکن است به جای مقادیر بهینه شده کلی (جهانی) مقادیر بهینه شده محلی را به دست آورد که یک نقص بزرگ در این رویکرد به شمار می‌آید [14-16]. علاوه بر این، روش‌های بهینه‌سازی سنتی نیازمند پیوستگی در مدل و محاسبات سنگین ریاضیاتی هستند، باید شرایط تعمر در منحنی و مشتق‌پذیر بودن را برای کاربردی بودن داشته باشند. روش‌های سنتی نسبت به حل و شرایط حل اولیه حساس و وابسته هستند و اغلب هم به یک مقدار بهینه محلی می‌انجامند. غیرخطی بودن ویژگی‌ها و متغیرهای سلول خورشیدی دلیل دیگری بر ناتوانی روش‌های مرسوم یا سنتی برای حل مؤثر مشکل شناسایی متغیرهای اصلی در این زمینه محسوب می‌شود. در نتیجه، برای حل مشکلات بهینه‌سازی در سلول خورشیدی در راستای احتمال تر شدن دست‌یابی به یک پاسخ کلی (جهانی) و دقیق و در مدت زمان معقول روش‌های تحقیقاتی فراابتکاری پیشنهاد داده شده‌اند [20-23].

پیشینه و منابعی که برای روش و رویکرد تحقیقاتی فراابتکاری وجود دارند، حل مسئله شناسایی متغیرهای اصلی در سلول‌های خورشیدی را به الگوریتم ژنتیک [18]، الگوریتم بهینه‌سازی تجمعی ذرات [17]، و الگوریتم فرایند بازپخت شبیه‌سازی شده [19] ارجاع می‌دهند و تقریباً این روش‌ها، اولین الگوریتم‌هایی فراابتکاری محسوب می‌شوند که برای حل بهینه سلول‌های خورشیدی به کار گرفته شده‌اند. علاوه بر این، ثابت شده است که تکنیک‌های بهینه‌سازی فراابتکاری با تلفیق معیارهای مختلف مانند دقت، ثبات، سرعت هم‌گرایی، بازدهی محاسبات، و تعداد متغیرهای کنترلی کاهش یافته، پاسخ‌هایی بی‌نقص و تا حد ممکن نزدیک به حل دقیق را برای مدل‌های سلول خورشیدی ارائه می‌دهند [24-26].

اگرچه الگوریتم‌های فراابتکاری نتایج بهتری را نسبت به روش‌های مرسوم یا سنتی در پی دارند اما محدودیت‌هایی نسبی نیز به همراه دارند [27]. به عنوان رایج‌ترین الگوریتم فراابتکاری، الگوریتم ژنتیک مکرراً فضای جست‌وجو را برای دستیابی به یک پاسخ مناسب به سرعت پیدا می‌کند، اما دارای اشکالاتی است. عدم وجود جست‌وجوهای مناسب محلی در این الگوریتم و تعیین پارامترهای اولیه از جمله معایب این گونه

شاکلی برای جریان دیود و جایگزین کردن جریان مقاومت شنت و تعمیم رابطه بالا مدل تک دیودی می‌تواند به صورت زیر فرموله شود [18]:

$$I_t = I_{ph} - I_{SD1} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n \cdot K \cdot T} \right) - 1 \right] - \frac{(V_t + R_s I_t)}{R_{sh}} \quad (2)$$

که I_{SD1} جریان اشباع دیودی، V_t نماد ولتاژ ترمینال، R_s و R_{sh} نمادهای مقاومت‌های سری و شنت، q نماد شارژ الکترونیک، K نماد ثابت بولتزمن، و T نیز نماد دمای سلول می‌باشند. همان‌طور که در معادله (۲) مشاهده می‌شود، شناسایی متغیرها در این مدل به شناسایی پنج متغیر مجهول به نام‌های R_s ، I_{ph} ، I_{SD1} ، R_{sh} و n ختم می‌شود.

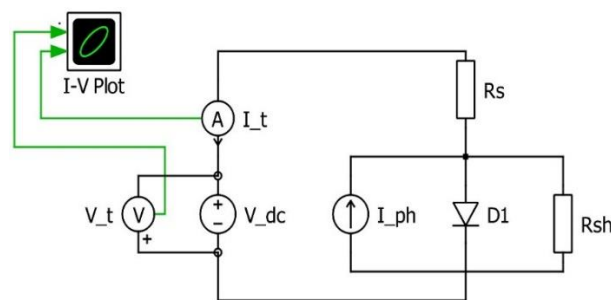
مدل دو دیودی

در حالت ایدئال، برای مدل‌سازی یک سلول خورشیدی تحت تابش خورشید، منبع جریان الکتریکی تولید شده توسط نور خورشید با یک دیود یک‌سو کننده موازی می‌شود. با این وجود، در عمل برای در نظر گرفتن فاصله شارژ شدن جریان بازترکیبی در مدار، منبع جریان با یک دیود دیگر و یک مقاومت نشتی شنت موازی می‌شود که این کار به منظور دخیل نمودن اتصال کوتاه‌های جزئی مسیر جریان (که در نزدیکی لبه‌های سلول انجام می‌شوند و مربوط به ناخالصی‌های موجود در ماده نیمه هادی به کار رفته در سلول و غیر ایدئال بودن آن می‌باشند) در داخل محاسبات و افزایش دقت در نتایج حاصله انجام می‌شود. در واقع این ویژگی، برتری اصلی مدل دو دیودی نسبت به مدل تک دیودی می‌باشد و در واقع اضافه شدن دیود دوم در این مدل تا حدودی نشتی‌های جریان در سلول خورشیدی واقعی را جبران کرده و تأثیر آن در نتایج این مدل نشان داده می‌شود. اما با این وجود باز هم نشتی جریان در این مدل به طور کامل جبران نشده و باز هم اختلافی اندک میان نتایج این مدل و سلول خورشیدی واقعی وجود دارد. علاوه بر این، به دلیل اتصالات فلز سلول خورشیدی و مقاومت عمده مواد نیمه هادی، یک مقاومت سری با عناصر شنت سلول متصل است. مدار معادل مدل دو دیودی در شکل (۲) نشان داده شده است.

الگوریتم شبکه عصبی، نتایج حاصل از این روش با نتایج به دست آمده از روش‌های الگوریتم ژنتیک (Genetic algorithms, GAs)، الگوریتم بهینه‌سازی تجمعی ذرات (Particle swarm algorithm, PSO)، الگوریتم فرایند بازیخت شبیه‌سازی شده (Simulated annealing, SA)، الگوریتم جست‌وجوی هارمونیک (Harmony Search, HS) و الگوریتم جست‌وجوی الگویی (Pattern Search, PS) مقایسه شده‌اند.

مدل‌سازی ریاضی مسئله سلول خورشیدی مدل تک دیودی

مدل تک دیودی به طور گسترده برای نشان دادن رفتار سلول خورشیدی مورد استفاده قرار می‌گیرد. این مدل با ترکیب جریان دو دیود موجود در مدل دو دیودی با یکدیگر یک ضریب غیر فیزیکی به اسم n معرفی می‌کند. پیچیدگی کمتر، سادگی در کاربرد و نتایج به نسبت دقیق از مزایای اصلی این مدل به حساب می‌آیند. اما در مقابل، این مدل برای پیش‌بینی عملکرد سلول‌های خورشیدی واقعی در صنعت مدل نسبتاً ضعیفی است و شامل تقریب‌های نسبتاً زیادی می‌باشد که باعث می‌شود نتایج حاصل از این مدل با نتایج سلول خورشیدی واقعی، اختلاف زیادی داشته باشد. مدار معادل این مدل در شکل (۱) نمایش داده شده است.




شکل ۱ شماتیک مدار معادل مدل تک‌دیودی سلول خورشیدی

جریان پایانه I_t را با توجه به شکل (۱) می‌توان با کمک قانون گره در ورودی ترمینال به صورت زیر نوشت:

$$I_t = I_{ph} - I_{D1} - I_{sh} \quad (1)$$

که I_{ph} نماد جریان خالص تولیدی حاصل از تابش نور، I_{D1} نماد جریان عبوری از تک دیود، I_t جریان پایانه و I_{sh} نیز به جریان مقاومت شنت اشاره دارد. با در نظر گرفتن معادله

سلول خورشیدی بسیار ضروری و مورد نیاز است. مدل سه - دیودی به نسبت دو مدل قبلی برای کاربردهای صنعتی مناسب تر است. مقادیر متغیرهای n_1 و n_2 نشان دادند که مدل دو دیودی برای نمایش اجزای مختلف جریان الکتریکی عبوری از سلول خورشیدی کافی نیستند. تأثیرات افزایش مرزهای سلول خورشیدی در اثر انبساطهای طولی (ناشی از تغییرات دمایی) و همچنین اتلاف جریان ناشی از نشت جریان داخل مدار، در مدل سه دیودی در نظر گرفته شده‌اند. مدار الکتریکی معادل مدل سه دیودی بعد از اتصال موازی دیود سوم به مدل دو دیودی در شکل (۳) نمایش داده شده است.




شکل ۳ شماتیک مدار معادل مدل سه دیودی سلول خورشیدی

به واسطه باز ترکیب‌هایی که در نواحی دچار نقص سلول رخ داده است و انرژی‌هایی که آزاد می‌شوند، هدف افزودن دیود سوم همراه با دو دیود دیگر، بررسی سهم جریان اتلافی دیود سوم است. در واقع در این مدل تمام جوانب و احتمالات ناشی جریان در نظر گرفته شده‌اند و نتایج استخراج شده از این مدل اختلاف اندکی با نتایج تک سلول واقعی صنعتی دارد که مزیت اصلی این مدل در مقایسه با دو مدل دیگر محسوب می‌شود. اما در نقطه مقابل پیچیدگی استفاده، ازدیاد متغیرها و محاسبات سنگین ریاضیاتی، از محدودیت‌های این مدل قلمداد می‌شوند. جریان پایانه I_t را با توجه به شکل (۳) می‌توان با کمک قانون گره در ورودی ترمینال به صورت زیر نوشت:

$$I_t = I_{ph} - I_{D1} - I_{D2} - I_{D3} - I_{sh} \quad (5)$$

در معادله (۵)، I_{ph} نماد جریان خالص تولیدی حاصل از تابش نور، I_{D1} نماد جریان عبوری از دیود اول، I_{D2} نماد جریان عبوری از دیود دوم، I_{D3} نماد جریان عبوری از دیود سوم و I_{sh} نیز نشان‌دهنده جریان مقاومت شنت می‌باشد. با در نظر گرفتن معادله شاکلی برای جریان‌های سه دیود و جایگزینی جریان مقاومت شنت، معادله (۵) در قالب معادله (۶) بازنویسی



شکل ۲ شماتیک مدار معادل مدل دو دیودی سلول خورشیدی

جریان پایانه را با توجه به شکل (۲) می‌توان به کمک قانون گره در ورودی ترمینال به صورت زیر نوشت:

$$I_t = I_{ph} - I_{D1} - I_{D2} - I_{sh} \quad (3)$$

در معادله (۳)، I_{ph} نماد جریان خالص تولیدی حاصل از تابش نور، I_{D1} نماد جریان عبوری از دیود اول، I_{D2} نماد جریان عبوری از دیود دوم و I_{sh} نیز به جریان مقاومت شنت اشاره دارد. با در نظر گرفتن معادله شاکلی برای جریان‌های دیودها و جایگزین کردن جریان مقاومت شنت، معادله (۳) به شکل زیر بازنویسی می‌شود [12]:

$$I_t = I_{ph} - I_{SD1} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_1 \cdot K \cdot T} \right) - 1 \right] - I_{SD2} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_2 \cdot K \cdot T} \right) - 1 \right] - \frac{(V_t + R_s I_t)}{R_{sh}} \quad (4)$$

در معادله (۴)، I_{SD1} و I_{SD2} به ترتیب نمادهای جریان دیفیوژن و جریان اشباع، V_t نماد ولتاژ ترمینال، R_s و R_{sh} نمادهای مقاومت‌های سری و شنت، q نماد شارژ الکترونیک، K نماد ثابت بولتزمن، n_1 و n_2 نمایانگر ضرایب ایدئال‌گرایی دیفیوژن و بازترکیبی، و T نیز نماد دمای سلول می‌باشند. معادله (۴) هفت متغیر مجهول به نام‌های R_{sh} ، I_{D1} ، I_{D2} ، I_{ph} ، R_s ، n_1 و n_2 را در بر می‌گیرد که برای منعکس کردن عملکرد واقعی سلول خورشیدی و سیستم تحت عنوان نتایج آزمایش، شناسایی این متغیرها ضروری و حائز اهمیت بالایی است.

مدل سه دیودی

این مدل، مدل دقیقی از تک سلول‌های خورشیدی و ماژول‌های فوتولتائیک است که برای تحلیل قوانین انرژی برای سیستم

می‌شود [12]:

فرایند بهینه‌سازی مدل ریاضی

متغیرهای مجهول را می‌توان با کمک روش بهینه‌سازی و مجموعه‌ای از داده‌های تجربی I-V که از یک سیستم واقعی به دست آمده‌اند شناسایی کرد. تکنیک بهینه‌سازی به کار رفته در این مقاله الگوریتم بهینه‌سازی شبکه عصبی (NNA) است که در ادامه به تفصیل به آن پرداخته خواهد شد. تعداد ۲۶ داده آزمایشگاهی I-V برای ولتاژ و جریان اندازه‌گیری شده از روی نمونه آزمایش به همراه مقدار I_t محاسبه شده از روابط (۲)، (۴)، و (۶) برای هر جفت داده جریان تجربی (I_t) و ولتاژ تجربی (V_t) برای هر سه مدل تک دیودی، دو دیودی و سه دیودی در جدول (۱) آورده شده است.

در الگوریتم‌های بهینه‌سازی، هر جواب توسط یک بردار راه‌حل مانند X تعریف می‌شود که X در مدل‌های تک دیودی، دو دیودی، و سه دیودی به ترتیب توسط معادلات (۷) تا (۹) بیان شده‌اند:

$$X = [R_s, R_{sh}, I_{ph}, I_{SD}, n_1] \quad (۷)$$

$$[R_s, R_{sh}, I_{ph}, I_{SD3}, I_{SD2}, I_{SD1}, n_1, n_2, n_3] \quad (۹)$$

$$I_t = I_{ph} - I_{SD1} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_1 \cdot K \cdot T} \right) - 1 \right] - I_{SD2} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_2 \cdot K \cdot T} \right) - 1 \right] - I_{SD3} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_3 \cdot K \cdot T} \right) - 1 \right] - \frac{(V_t + R_s I_t)}{R_{sh}} \quad (۶)$$

که در معادله (۶)، I_{SD1} ، I_{SD2} و I_{SD3} به ترتیب نمادهای جریان دیفیوژن، جریان اشباع بازترکیبی، و جریان نشتی-بازترکیبی، V_t نماد ولتاژ ترمینال، R_s و R_{sh} نمادهای مقاومت‌های سری و شنت، q نماد شارژ الکترونیکی، K نماد ثابت بولتزمن، n_1 ، n_2 و n_3 نمایانگر ضرایب ایدئال‌گرایی دیفیوژن، بازترکیبی، و نشتی-بازترکیبی، و T نیز نماد دمای سلول می‌باشند. معادله (۶)، ۹ متغیر مجهول به نام‌های R_s ، I_{SD1} ، I_{SD2} ، I_{SD3} ، I_{ph} ، R_s ، n_1 ، n_2 و n_3 را در بر می‌گیرد که استخراج آن‌ها برای نمایش و تخمین عملکرد سلول خورشیدی که تحت آزمایش‌ها و بررسی‌های مکرر قرار گرفته است، از اهمیت بالایی برخوردار است.

جدول ۱ داده‌های تجربی جریان و ولتاژ اندازه‌گیری شده برای یک سلول خورشیدی تجاری سیلیکونی با قطر ۵۷ میلی‌متر برای مدل تک دیودی،

دو دیودی و سه دیودی

اندازه‌گیری	V_t (V)	I_t (A)	اندازه‌گیری	V_t (V)	I_t (A)
1	-0.2057	0.764	14	0.4137	0.728
2	-0.1291	0.762	15	0.4373	0.7065
3	-0.0588	0.7605	16	0.459	0.6755
4	0.0057	0.7605	17	0.4784	0.632
5	0.0646	0.760	18	0.496	0.573
6	0.1185	0.759	19	0.5119	0.499
7	0.1678	0.757	20	0.5265	0.413
8	0.2132	0.757	21	0.5398	0.3165
9	0.2545	0.7555	22	0.5521	0.212
10	0.2924	0.754	23	0.5633	0.1035
11	0.3269	0.7505	24	0.5736	0.010
12	0.3585	0.7465	25	0.5833	0.123
13	0.3873	0.7385	26	0.590	0.210

بهینه‌سازی، تابع هدف با توجه به محدوده پارامترها به حداقل می‌رسد. الگوریتم شبکه عصبی (NNA) برای بهینه‌سازی متغیرهای مجهول به گونه‌ای که پاسخ به دست آمده تابع هدف را به حداقل مقدار خود برساند، در ادامه استفاده خواهد شد. حد بالایی و پایینی پارامترهای طراحی، در جدول (۲) نشان داده شده‌اند. متغیرهای طراحی مدل (پنج، هفت، و نه بر اساس مدل دیود انتخاب شده) به ترتیب توسط الگوریتم بهینه‌سازی شبکه عصبی تا زمانی که معیار پایانی و قابل قبول برآورده شود، انتخاب و در معادلات استفاده می‌شوند. واضح است که هر چه مقدار تابع هدف کوچک‌تر باشد، راه‌حل بهتر و دقیق‌تری حاصل شده است.

جدول ۲ حدود بالا و پایین برای هر یک از متغیرهای طراحی سلول خورشیدی در مدل‌های تک دیودی، دو دیودی، و سه دیودی

متغیرهای طراحی	حد پایین	حد بالا
$R_s (\Omega)$	0	0.5
$R_{sh} (\Omega)$	0	100
$I_{ph} (A)$	0	1
$I_{SD1}, I_{SD2}, I_{SD3} (\mu A)$	0	1
n_1, n_2, n_3	1	2

روش بهینه‌سازی الگوریتم شبکه عصبی

مقدمه

الگوریتم شبکه عصبی یک الگوریتم بهینه‌سازی فرا ابتکاری جدید و الهام گرفته از سیستم‌های عصبی زیستی و شبکه‌های عصبی مصنوعی (Artificial Neural Networks, ANNs) است که برای حل مسائل بهینه‌سازی پیچیده پیشنهاد شده است [28]. روش پیشنهادی با نام الگوریتم شبکه عصبی (Neural Network Algorithm, NNA) بر اساس ساختار منحصر به فرد شبکه‌های عصبی مصنوعی توسعه داده شده است. الگوریتم شبکه عصبی از ساختار پیچیده شبکه‌های عصبی مصنوعی و عملگرهایش برای تولید راه‌حل‌های جدید بهره می‌گیرد. تا کنون چندین مسئله طراحی مهندسی در دامنه محدودی مورد بررسی قرار گرفته است تا کارایی الگوریتم شبکه عصبی برای جستجو در محدوده دامنه در مسائل بهینه‌سازی دارای قید و

در قدم بعدی برای تعریف تابع هدف، معادلات (۲)، (۴) و (۶) در فرم همگن آن‌ها به صورت زیر بازنویسی می‌شوند. برای مدل تک دیودی تابع خطا از معادله (۲) به شکل زیر محاسبه می‌شود:

$$f(I_t, V_t, X) = I_t - I_{ph} + I_{SD} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n \cdot K \cdot T} \right) - 1 \right] + \frac{(V_t + R_s I_t)}{R_{sh}} \quad (10)$$

تابع خطا برای مدل دو دیودی از معادله (۴) عبارت است از:

$$f(I_t, V_t, X) = I_t - I_{ph} + I_{SD1} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_1 \cdot K \cdot T} \right) - 1 \right] + I_{SD2} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_2 \cdot K \cdot T} \right) - 1 \right] + \frac{(V_t + R_s I_t)}{R_{sh}} \quad (11)$$

و در نهایت از معادله (۶) برای مدل سه دیودی تابع خطا عبارت است از:

$$f(I_t, V_t, X) = I_t - I_{ph} + I_{SD1} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_1 \cdot K \cdot T} \right) - 1 \right] + I_{SD2} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_2 \cdot K \cdot T} \right) - 1 \right] + I_{SD3} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_3 \cdot K \cdot T} \right) - 1 \right] + \frac{(V_t + R_s I_t)}{R_{sh}} \quad (12)$$

مقدار f که همان تابع خطای نسبی است، در ادامه و در بخش نتایج برای مدل‌های تک دیودی، دو دیودی، و سه دیودی برای هر جفت از داده‌های تجربی داده شده محاسبه می‌شود. در معادلات (۱۰) تا (۱۲) متغیرهای I_t و V_t مقادیر واقعی اندازه‌گیری شده برای ولتاژ و جریان پایانه‌ها هستند. از خطای مجذور مربعات میانگین ریشه (Root Means Square Error, RMSE) به عنوان معیاری برای تعیین کیفیت و تفاوت بین نتایج مدل و داده‌های تجربی استفاده می‌کنیم و در واقع RMSE، تابع هدف یا هزینه در مسئله بهینه‌سازی سلول خورشیدی است. RMSE توسط معادله (۱۳) تعریف می‌شود:

$$RMSE = \sqrt{\frac{1}{N} \sum_i^N (f_i(I_t, V_t, X))^2} \quad (13)$$

که N تعداد داده‌های تجربی است. در طول فرایند

ماتریس وزن

با استفاده از یک جمع‌بندی ساده، یک سلول عصبی، مقادیر وزنی این مسیرهای ورودی را ترکیب می‌کند. وزن‌های اولیه در شبکه‌های عصبی مصنوعی اعداد تصادفی هستند و وقتی که شمارنده تکرار در حال افزایش است، با توجه به خطای محاسبه شده شبکه، به روز می‌شوند. ماتریس وزنی W در رابطه (۱۵) برای جمعیت راه‌حل‌های الگو نمایش داده شده است:

$$W(t) = [w_1, w_2, w_3, \dots, w_D] \quad (15)$$

که W یک ماتریس مربعی $N_{pop} \times N_{pop}$ با w_{ij} درایه است که در حین تکرار اعداد تصادفی را به طور یک‌نواخت بین صفر تا یک تولید می‌کند و t یک شاخص تکرار است. زیرنویس اول وزن مربوط به شمارنده راه‌حل الگوی آن می‌شود و زیرنویس دوم وزن مربوط به مقادیر وزنی راه‌حل‌های الگوی دیگر است. هر راه‌حل الگو دارای وزن مربوط به خودش می‌باشد که برای تولید یک راه‌حل جدید به کار گرفته می‌شود. با این حال، محدودیتی برای مقادیر وزن وجود دارد. قید تحمیل شده، به این صورت است که مجموع وزن‌ها برای یک راه‌حل الگو نباید از عدد یک تجاوز کند که از نظر ریاضی می‌تواند به شکل رابطه (۱۶) تعریف شود:

$$\sum_{j=1}^{N_{pop}} w_{ij}(t) = 1, \quad i = 1, 2, 3, \dots, N_{pop} \quad (16)$$

وجود چنین محدودیتی برای مقادیر وزن، ناشی از کنترل انحراف از تولید راه‌حل‌های الگوی جدید در منطقه بهینه محلی است. پس از تشکیل ماتریس وزن (W)، راه‌حل‌های الگوی جدید (X^{NEW}) با استفاده از معادله (۱۷) که از تکنیک جمع وزن مورد استفاده در شبکه‌های عصبی مصنوعی الهام گرفته شده، محاسبه می‌شود [28]:

$$\bar{X}_j^{NEW}(t+1) = \sum_{i=1}^{N_{pop}} w_{ij}(t) \times \bar{X}_i(t), \quad j = 1, 2, 3, \dots, N_{pop} \quad (17)$$

$$\bar{X}_i(t+1) = \bar{X}_i(t) + \bar{X}_i^{NEW}(t+1), \quad i = 1, 2, 3, \dots, N_{pop} \quad (18)$$

که در آن t شاخص تکرار است. بنابراین راه‌حل الگوی جدید برای تکرار $(t+1)$ ام با استفاده از معادلات (۱۴) و (۱۵) به روز شده است. پس از ایجاد راه‌حل‌های الگوی جدید از جمعیت الگوهای قبلی بر مبنای بهترین مقدار وزن که وزن

شرط را مورد اعتبارسنجی قرار دهد. عدم نیاز به تنظیم پارامترهای اولیه می‌تواند الگوریتم شبکه عصبی را نسبت به سایر الگوریتم‌های بهینه‌ساز مطالعه شده دیگر تمایز و برتری بسیاری ببخشد.

ایده اولیه

با الهام از شبکه‌های عصبی مصنوعی، در الگوریتم شبکه عصبی (NNA) بهترین راه‌حل به دست آمده در هر تکرار (یعنی راه‌حل بهینه موقتی) به عنوان داده‌های هدف فرض می‌شوند و هدف از این کار کاهش خطا بین داده‌های هدف و سایر راه‌حل‌های الگوی پیش‌بینی شده است. بر اساس مفهوم تعریف شده، الگوریتم شبکه عصبی برای به حداقل رساندن خطا بین راه‌حل‌های هدف و الگو توسعه داده شده است.

تولید جمعیت اولیه

در یک مسئله بهینه‌سازی D بعدی، یک راه‌حل الگو (Pattern Solution)، یک ماتریس سطری $1 \times D$ است که داده‌های ورودی را در الگوریتم شبکه عصبی نشان می‌دهد. این بردار به صورت $[x_1, x_2, x_3, \dots, x_D]$ تعریف می‌شود. برای شروع الگوریتم بهینه‌سازی یک انتخاب تصادفی از ماتریس الگوی راه‌حل با اندازه $N_{pop} \times D$ تولید می‌شود. از این رو ماتریس X که به طور تصادفی بین مرزهای بالایی و پایینی یک دامنه ایجاد می‌شود، یک ماتریس $N_{pop} \times D$ خواهد بود. هزینه یک راه‌حل الگو برای تکرارهای متوالی با ارزیابی تابع هزینه (تابع برازش C) برای راه‌حل الگوی مربوطه به شرح زیر است:

$$C_i = f(x_1^i, x_2^i, \dots, x_D^i) \quad i = 1, 2, 3, \dots, N_{pop} \quad (14)$$

که در رابطه (۱۴) f همان تابع هدف است. بعد از محاسبه تابع هزینه برای تمامی راه‌حل‌های الگو، مرحله بعدی پیدا کردن بهترین راه‌حل الگو است، که منظور از بهترین راه‌حل در این الگوریتم، یک راه‌حل بهینه جهانی با کمترین مقدار تابع هدف می‌باشد. سپس، بعد از تنظیم راه‌حل هدف (X^{TARGET}) از بین راه‌حل‌های الگو، وزن هدف (W^{TARGET}) متناظر با راه‌حل هدف باید از بین جمعیت وزن (ماتریس وزن) انتخاب شود.

نزدیک تر شدن به بهترین راه حل (راه حل هدف) انجام می شود. بنابراین رابطه (۲۱) به عنوان یک عملگر انتقال برای روش پیشنهاد شده برای هر عضو از جمعیت به صورت زیر تعریف می شود:

$$\vec{X}_i^*(t+1) = TF(\vec{X}_i(t+1)) = \vec{X}_i(t+1) + 2 \times \text{Rand} \times (\vec{X}^{\text{Target}}(t) - \vec{X}_i(t+1)) \quad (21)$$

اخیرا الگوریتم بهینه سازی شبکه عصبی در کاربردهای مختلف مهندسی از قبیل پریتراه های سه بعدی [29]، سلول های سوختی [30,31] و مسایل بهینه سازی مهندسی و چند هدفه [23-34] مورد استفاده قرار گرفته است.

نتایج و مباحث

در این مقاله، مشخصه جریان- ولتاژ (I-V) یک سلول خورشیدی سیلیکونی ۵۷ میلی متری تجاری (R.T.C. فرانسه) برای شناسایی پارامترهای مجهول طراحی مبتنی بر الگوریتم شبکه عصبی (NNA) در نظر گرفته شده است. داده های تجربی از سیستمی که زیر تابش ۱ سان (مقداری معادل 1000 W/m^2) و در دمای ۳۳ درجه سانتی گراد قرار دارد، استخراج شده اند. در این تحقیق از روش تاگوچی [35] برای تعیین پارامترهای بهینه الگوریتم شبکه عصبی (تعداد اعضای جمعیت و بیشترین تعداد تکرار) استفاده شده است. پارامترهای تنظیم الگوریتم شبکه عصبی (NNA) برای هر سه مدل سلول خورشیدی شامل جمعیت اولیه ۵۰ و ماکزیمم مقدار محاسبه تابع هدف به میزان 10000 برای انجام فرایند بهینه سازی در نظر گرفته شده اند. تعداد دفعات اجرای بهینه سازی و الگوریتم برای شناسایی متغیرهای مجهول طراحی ۳۰ بار تکرار در نظر گرفته شده است. همچنین، از محیط نرم افزار MATLAB جهت شناسایی پارامترهای مجهول مدل سلول خورشیدی استفاده شده است. جدول (۳) نتایج آماری به دست آمده توسط روش الگوریتم شبکه عصبی را برای ۳ مدل در نظر گرفته شده سلول خورشیدی نشان می دهد.

جدول (۴) پارامترهای طراحی بهینه شده و مقدار RMSE را برای مدل های تک دیودی، دو دیودی، و سه دیودی را که توسط الگوریتم NNA استخراج شده اند، در مقایسه با سایر

هدف نامیده می شود، ماتریس وزن نیز باید به خوبی به روزرسانی شده باشد. رابطه (۱۹)، یک معادله به روزرسانی - شده برای ماتریس وزن را پیشنهاد می دهد:

$$\vec{W}_i^{\text{Updated}}(t+1) = \vec{W}_i(t) + 2 \times \text{rand} \times (\vec{W}^{\text{Target}}(t) - \vec{W}_i(t)), \quad i = 1, 2, 3, \dots, N_{\text{pop}} \quad (19)$$

عملگر تصادفی

در الگوریتم شبکه عصبی (NNA)، عملگر تصادفی درصد معینی از راه حل های الگو را در جمعیت جدیدی از الگو اصلاح می کند، به این معنا که راه حل الگوی جدید $\vec{X}_1^{\text{NEW}}(t+1)$ و ماتریس وزن به روز شده $\vec{W}_i^{\text{Updated}}(t+1)$ باز هم اصلاح خواهند شد. برای این منظور، پارامتر β که همان ضریب اصلاح می باشد تعریف می شود، که درصد راه حل های الگویی را که باید تغییر یابند را تعیین می کند. مقدار اولیه β بر روی ۱ تنظیم شده (یعنی ۱۰۰ درصد احتمال برای اصلاح همه افراد در جمعیت در تکرار اول) و مقدار آن به طور تطبیقی در هر تکرار با استفاده از فرمول کاهشی که در ادامه پیشنهاد شده است، به دست خواهد آمد:

$$\beta(t+1) = \beta(t) \times 0.99 \quad t = 1, 2, 3 \dots \text{Max. Iteration} \quad (20)$$

عملگر تصادفی به طور تطبیقی کاهش می یابد تا به الگوریتم اجازه جستجو برای راه حل بهینه نزدیک به راه حل هدف را بدهد و همچنین از تغییرات شدید در راه حل های الگوی در تکرارهای نهایی اجتناب کند.

عملگر انتقال

در الگوریتم شبکه عصبی (NNA)، برخلاف شبکه های عصبی مصنوعی (ANNs)، عملگر انتقال، راه حل های الگوی جدید را در جمعیت، از موقعیت فعلی خود در فضای جستجو به موقعیت های جدید به منظور به روز رسانی و تولید راه حل های با کیفیت بهتر به سمت راه حل هدف انتقال می دهد. بهبود راه حل ها با حرکت راه حل های الگوی جدید فعلی و

روش‌های بهینه‌سازی فراابتکاری نشان می‌دهد. همچنین در جدول (۴)، درصد بهبود برای الگوریتم‌های مطالعه شده به منظور ارزیابی میزان بهبود نتایج و دقت پارامترهای استخراج شده به کمک الگوریتم شبکه عصبی و مقایسه دقت این روش با روش‌های دیگر، آورده شده است.

در جدول (۴) نتایج مدل‌های تک دیودی، دو دیودی، و سه دیودی با نتایج روش‌های الگوریتم بهینه‌سازی ذرات تصادفی (CPSO) [17]، الگوریتم ژنتیک (GAs) [18]، الگوریتم بهینه‌سازی انبوه لانه زنبوری به صورت مصنوعی (ABSO) [36]، الگوریتم‌های جستجوی الگو محور (PS) [37]، روش بازپخت شبیه‌سازی شده (SA) [19] و جستجوی هارمونیک (HS) [38] مقایسه و نمایش داده شده‌اند. همان طور که از جدول (۴) مشاهده می‌شود، مقادیر RMSE حاصل از الگوریتم شبکه عصبی در میان روش‌های دیگر، پایین‌ترین مقدار را دارد. با توجه به روابط بخش مدل‌سازی سلول خورشیدی می‌توان به این نکته پی برد که نزدیکی مقادیر پارامترهای استخراج شده به پارامترهای سلول خورشیدی واقعی، منجر به کم شدن اختلاف میان جریان محاسبه شده و جریان اندازه‌گیری شده می‌شود. با در نظرگیری این موضوع می‌توان ذکر کرد که الگوریتم شبکه عصبی (NNA) نتایجی بهتر و دقیق‌تری را برای مدل‌های تک - دیودی، دو دیودی، و سه دیودی نسبت به الگوریتم‌های بررسی شده ارائه داده است. این عملکرد در خصوص چهار روش PS، SA، CPSO، و GAs به مراتب محسوس‌تر است. در خصوص نتایج به دست آمده توسط دو روش ABSO و

روش‌های بهینه‌سازی فراابتکاری نشان می‌دهد. همچنین در جدول (۴)، درصد بهبود برای الگوریتم‌های مطالعه شده به منظور ارزیابی میزان بهبود نتایج و دقت پارامترهای استخراج شده به کمک الگوریتم شبکه عصبی و مقایسه دقت این روش با روش‌های دیگر، آورده شده است.

در ادامه، مقادیر جریان محاسبه شده که به کمک متغیرهای استخراج شده از روش الگوریتم شبکه عصبی و روابط مدل‌سازی برای هر جفت داده جریان-ولتاژ به دست آمده‌اند به همراه جریان اندازه‌گیری شده و همچنین متغیر خطای نسبی که از رابطه (۲۰) محاسبه می‌شود، برای سه مدل تک دیودی، دو دیودی، و سه دیودی استخراج شده که در جداول (۵) تا (۷) آورده شده‌اند.

جدول ۳ نتایج آماری بهینه‌سازی به دست آمده برای مدل‌های مختلف سلول خورشیدی توسط روش NNA

مدل سلول خورشیدی	بدترین RMSE	میانگین RMSE	انحراف معیار RMSE	بهترین RMSE	ضریب تغییرات * RMSE
تک دیودی	0.003838	0.0017789	0.0005161	0.00098666	0.29012
دو دیودی	0.005485	0.0014478	0.0008677	0.00098262	0.59932
سه دیودی	0.008652	0.0014278	0.0014483	0.00098435	1.014147

* ضریب تغییرات برابر است با انحراف معیار داده‌ها تقسیم بر میانگین

جدول ۴ متغیرهای مجهول طراحی استخراج شده برای مدل‌های تک‌دیودی، دو دیودی، و سه دیودی توسط روش NNA و مقایسه با یافته‌های مطالعات قبلی

متغیرهای طراحی مدل تک دیودی	NNA (مطالعه حاضر)	ABSO [28]	HS [30]	CPSO [17]	PS [29]	SA [19]	GAs [18]
$R_S(\Omega)$	0.036452	0.0365	0.0366	0.0354	0.0313	0.0345	0.0299
$R_{Sh}(\Omega)$	53.206652	52.290	53.594	59.012	64.102	43.103	42.372
$I_{Ph}(A)$	0.760784	0.7608	0.7607	0.7607	0.7617	0.762	0.7619
$I_{sd}(\mu A)$	0.317032	0.3062	0.3049	0.004	0.998	0.4798	0.8087
n	1.479304	1.4758	1.4753	1.5033	1.6000	1.5172	1.5751
RMSE	9.866e-04	9.91e-4	9.95e-4	0.00139	0.01494	0.01900	0.01908
رتبه	1	2	3	4	5	6	7
درصد بهبود	-	0.443%	0.844%	29.02%	93.39%	94.807%	94.829%
متغیرهای طراحی مدل دو دیودی	NNA (مطالعه حاضر)	ABSO [28]	MFO [40]	HS [30]	GWO [39]	PS [29]	SA [19]
$R_S(\Omega)$	0.036675	0.03657	0.0345	0.03545	0.0335	0.0320	0.0345
$R_{Sh}(\Omega)$	55.376133	54.6219	60	46.8269	56.7361	81.3008	43.1034
$I_{Ph}(A)$	0.760778	0.76078	0.7609	0.76176	0.7614	0.7602	0.7623
$I_{sd1}(\mu A)$	0.237307	0.26713	0.286	0.12545	0.337	0.9889	0.4767
$I_{sd2}(\mu A)$	0.651648	0.38191	0.306	0.25470	0.246	0.0001	0.0100
n1	1.455202	1.46512	1.4906	1.49439	1.5431	1.6000	1.5172
n2	1.995709	1.98152	1.6617	1.49989	1.5442	1.1920	2.0000
RMSE	9.826e-04	4-9.834e	0.0011	0.00126	0.0014	0.01518	0.01664
رتبه	1	2	3	4	5	6	7
درصد بهبود	-	0.085%	10.67%	22.015%	29.81%	93.52%	94.09%
متغیرهای طراحی مدل سه دیودی	NNA (مطالعه حاضر)	GWO [39]	ALO [44]	MVO [43]	MFO [40]	SCA [42]	WOA [41]
$R_S(\Omega)$	0.036988	0.0346	0.0338	0.0351	0.0300	0.0302	0.0488
$R_{Sh}(\Omega)$	56.97410	58.9166	54.8311	59.1165	50	60	58.6704
$I_{Ph}(A)$	0.760778	0.7611	0.7615	0.7614	0.7605	0.7560	0.7667
$I_{sd1}(\mu A)$	0.175548	0.30297	0.3897	0.3327	0.200	0.200	0.223
$I_{sd2}(\mu A)$	1.227080	0.2238	0.3738	0.3997	0.400	0.359	0.390
$I_{sd3}(\mu A)$	3.545e-10	0.30436	0.3742	0.2217	0.399	0.400	0.390
n1	1.430222	1.9892	1.8705	1.9463	1.5863	2	1.9539
n2	1.999999	1.6676	1.5059	1.5218	2	2	1.7596
n3	1.000000	1.4925	1.9555	1.6737	1.5358	1.5081	1.5185
RMSE	9.843e-4	0.0012	0.0015	0.0030	0.0038	0.0059	0.0179
رتبه	1	2	3	4	5	6	7
درصد بهبود	-	17.97%	34.38%	67.19%	74.09%	83.31%	94.5%

جدول ۵ داده‌های تجربی و محاسبه شده جریان به همراه خطای نسبی برای یک سلول خورشیدی تجاری سیلیکونی با قطر ۵۷ میلی‌متر برای مدل تک دیودی

اندازه‌گیری	I_t (A) محاسبه شده	I_t (A) اندازه‌گیری شده	خطای نسبی	اندازه‌گیری	I_t (A) محاسبه شده	I_t (A) اندازه‌گیری شده	خطای نسبی
1	0.764126	0.764	-1.661e-4	14	0.727386	0.728	8.428e-4
2	0.762688	0.762	-9.037e-4	15	0.707001	0.7065	-7.092e-4
3	0.761368	0.7605	-11.417e-4	16	0.675330	0.6755	2.511e-4
4	0.760155	0.7605	4.530e-4	17	0.630819	0.632	18.670e-4
5	0.759046	0.760	12.550e-4	18	0.571987	0.573	17.676e-4
6	0.758023	0.759	12.862e-4	19	0.499648	0.499	-12.996e-4
7	0.757064	0.757	-8.534e-5	20	0.413661	0.413	-16.012e-4
8	0.756107	0.757	11.795e-4	21	0.317491	0.3165	-31.313e-4
9	0.755047	0.7555	5.9915e-4	22	0.212109	0.212	-5.166e-4
10	0.753621	0.754	5.013e-4	23	0.102194	0.1035	126.14e-4
11	0.751350	0.7505	-11.338e-4	24	-0.008758	-0.01	124.14e-3
12	0.747321	0.7465	-11.008e-4	25	-0.125513	-0.123	-204.31e-4
13	0.740100	0.7385	-21.665e-4	26	-0.208422	-0.21	75.12e-4

جدول ۶ داده‌های تجربی و محاسبه شده جریان به همراه خطای نسبی برای یک سلول خورشیدی تجاری سیلیکونی با قطر ۵۷ میلی‌متر برای مدل دو دیودی

اندازه‌گیری	I_t (A) محاسبه شده	I_t (A) اندازه‌گیری شده	خطای نسبی	اندازه‌گیری	I_t (A) محاسبه شده	I_t (A) اندازه‌گیری شده	خطای نسبی
1	0.763987	۰,۷۶۴	1.639e-5	14	0.727263	0.728	10.113e-4
2	0.762605	0.762	-7.945e-4	15	0.706859	0.7065	-5.091e-4
3	0.761336	0.7605	-11.00e-4	16	0.675207	0.6755	4.324e-4
4	0.760170	0.7605	4.332e-4	17	0.630745	0.632	19.843e-4
5	0.759102	0.76	11.808e-4	18	0.571972	0.573	17.937e-4
6	0.758115	0.759	11.659e-4	19	0.499683	0.499	-13.695e-4
7	0.757181	0.757	-2.403e-4	20	0.413719	0.413	-17.427e-4
8	0.756237	0.757	10.066e-4	21	0.317546	0.3165	-33.057e-4
9	0.75517	0.7555	4.309e-4	22	0.212138	0.212	-6.522e-4
10	0.753724	0.754	3.656e-4	23	0.102188	0.1035	126.71e-4
11	0.75140	0.7505	-12.088e-4	24	-0.008772	-0.01	0.12274
12	0.747315	0.7465	-10.927e-4	25	-0.125538	-0.123	-0.02063
13	0.740028	0.7385	-20.699e-4	26	-0.208398	-0.21	76.263e-4

جدول ۷ داده‌های تجربی و محاسبه شده جریان به همراه خطای نسبی برای یک سلول خورشیدی تجاری سیلیکونی با قطر ۵۷ میلی‌متر برای مدل سه دیودی

اندازه‌گیری	I_t (A) محاسبه شده	I_t (A) اندازه‌گیری شده	خطای نسبی	اندازه‌گیری	I_t (A) محاسبه شده	I_t (A) اندازه‌گیری شده	خطای نسبی
1	0.763893	0.764	1.390e-4	14	0.727148	0.728	11.692e-4
2	0.762550	0.762	-7.223e-4	15	0.706754	0.7065	-3.607e-4
3	0.761316	0.7605	-10.742e-4	16	0.675147	0.6755	5.218e-4
4	0.760182	0.7605	4.169e-4	17	0.630747	0.632	19.823e-4
5	0.759142	0.76	11.276e-4	18	0.572028	0.573	16.952e-4
6	0.758178	0.759	10.823e-4	19	0.499768	0.499	-15.401e-4
7	0.757261	0.757	-3.449e-4	20	0.413793	0.413	-19.201e-4
8	0.756322	0.757	8.950e-4	21	0.317577	0.3165	-34.043e-4
9	0.755249	0.7555	3.309e-4	22	0.212110	0.212	-5.207e-4
10	0.753773	0.754	3.000e-4	23	0.102111	0.1035	134.14e-4
11	0.751414	0.7505	-12.191e-4	24	-0.008837	-0.01	1162.1e-4
12	0.747272	0.7465	-10.346e-4	25	-0.125570	-0.123	-209.0e-4
13	0.739938	0.7385	-19.484e-4	26	-0.208312	-0.21	80.375e-4

ارائه داده است. در معادله (۲۲)، خطای نسبی محاسبه شده برای داده‌ها آورده شده است:

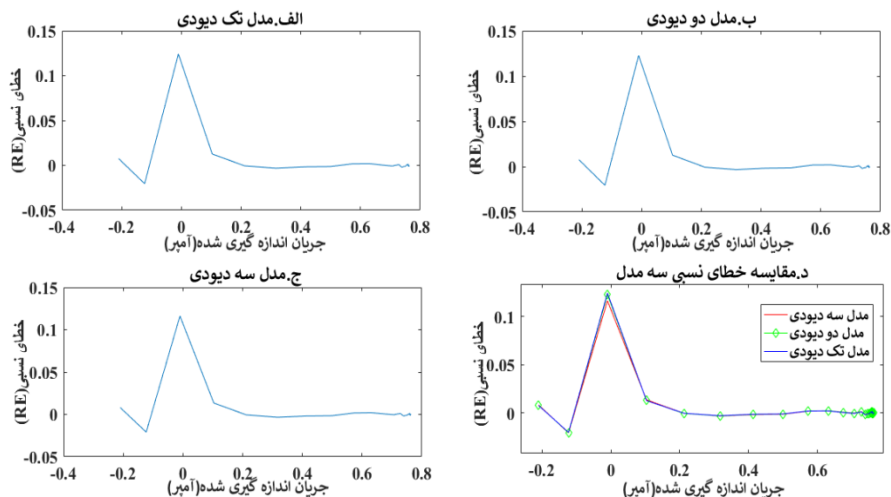
خطای نسبی (RE)

$$RE = \frac{I_C - I_m}{I_m} \quad (22)$$

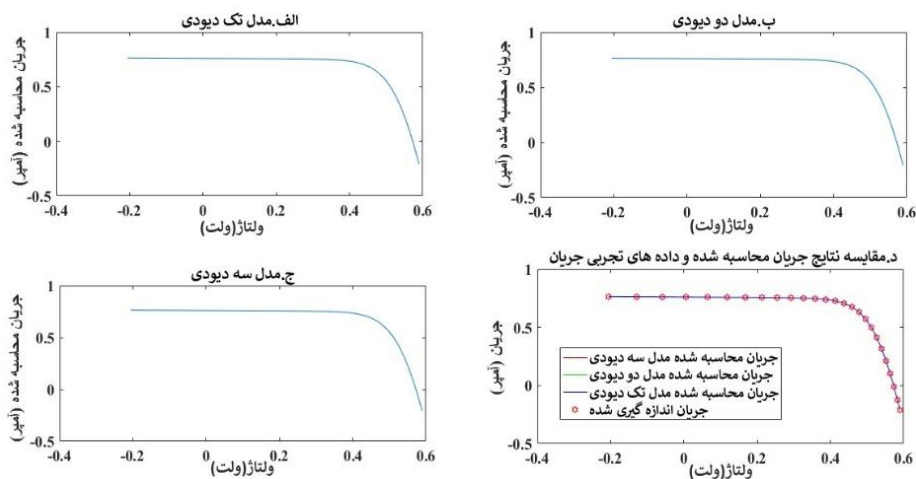
همچنین مشخصه‌های ولتاژ-جریان (I-V) و ولتاژ-توان (P-V) برای هر سه مدل تک دیودی، دو دیودی، و سه دیودی در قالب نمودار، به همراه نمودار مقایسه‌ای این دو مشخصه با داده‌های تجربی برای هر سه مدل (نمودارهای د-۵ و د-۶)، با استفاده از داده‌های تجربی و محاسباتی به منظور مقایسه اختلاف بین داده‌های تجربی و محاسباتی برای این دو مشخصه، به ترتیب در شکل‌های (۵) و (۶) نمایش داده شده‌اند. همان‌طور که در شکل‌های (د-۵) و (د-۶) مشاهده می‌شود، مطابقت بسیار خوبی میان نتایج داده‌های تجربی و نتایج داده‌های محاسبه شده به کمک متغیرهای استخراج شده از روش الگوریتم شبکه عصبی برای هر دو مشخصه ولتاژ-جریان (V-I) و ولتاژ-توان (P-V) وجود دارد. این تطابق به این معناست که متغیرهای استخراج شده از الگوریتم شبکه عصبی برای هر سه مدل سلول خورشیدی دقت بسیار بالایی داشته و به مقادیر واقعی بسیار نزدیک می‌باشند.

همچنین می‌توان با استفاده از مقادیر به دست آمده از جریان محاسبه شده و مقادیر خطای نسبی برای هر جفت داده آزمایشگاهی که در جداول (۵) تا (۷) آورده شده‌اند، نمودار خطای نسبی برای مقادیر اندازه‌گیری شده و محاسبه شده برای سه مدل سلول خورشیدی را ترسیم و همچنین با یکدیگر مقایسه کرد. در شکل (۴) نمودار خطای نسبی سه مدل سلول خورشیدی به همراه نمودار مقایسه‌ای آن‌ها در یک نمودار (نمودار د-۴) نمایش داده شده‌اند. همان‌طور که در نمودار (د-۴) دیده می‌شود، مقدار بیشینه متغیر خطای نسبی برای هر جفت داده تجربی جریان-ولتاژ و به تناظر آن هر جفت داده جریان اندازه‌گیری شده-جریان محاسبه شده در مجاورت جریان اندازه‌گیری شده صفر آمپر اتفاق می‌افتد.

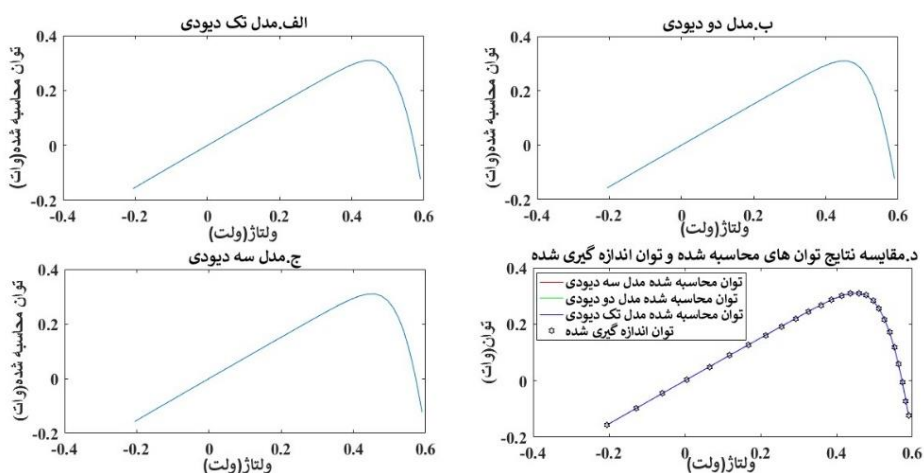
این مقدار خطای نسبی در جریان محاسبه شده برای هر سه مدل به این معناست که در مجاورت جریان صفر آمپر در عمل یا در اندازه‌گیری پدیده تکنیکی اتفاق می‌افتد و مقدار جریان محاسبه شده با جریان اندازه‌گیری شده در این محدوده بیشترین اختلاف را داراست و مدل‌ها در این محدوده نیازمند اصلاح می‌باشند. همچنین در نمودار (د-۴) مشاهده می‌شود که میزان خطای نسبی مدل سه دیودی از دو مدل دیگر در مجاورت جریان صفر آمپر پایین‌تر است و مقادیر محاسبه شده از این مدل به مقادیر واقعی یا اندازه‌گیری شده نزدیک هستند و یعنی مدل سه دیودی مدل‌سازی دقیق تری را نسبت به دو مدل دیگر



شکل ۴ نمودار خطای نسبی (RE-I) برای مقادیر اندازه‌گیری شده و محاسبه شده مدل: الف) تک دیودی، ب) دو دیودی، ج) سه دیودی، و د) مقایسه خطای نسبی هر سه مدل در یک نمودار



شکل ۵ نمودارهای مشخصه ولتاژ-جریان محاسبه شده (I-V) برای الف) مدل تک دیودی، ب) مدل دو دیودی، ج) مدل سه دیودی، و د) مقایسه جریان‌های محاسبه شده هر سه مدل با جریان اندازه‌گیری شده



شکل ۶ نمودارهای مشخصه ولتاژ-توان محاسبه شده (P-V) برای الف) مدل تک دیودی، ب) مدل دو دیودی، ج) مدل سه دیودی، و د) مقایسه جریان‌های محاسبه شده هر سه مدل با جریان اندازه‌گیری شده

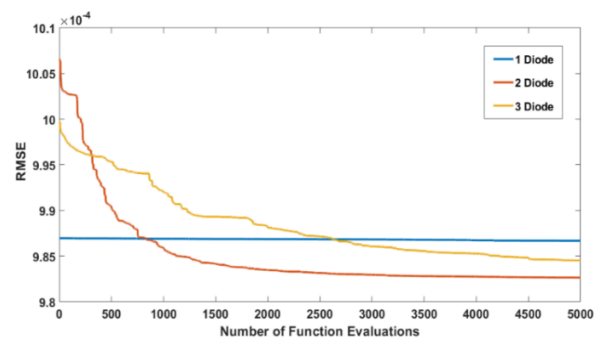
بهینه‌سازی ارائه دهد. الگوریتم پیشنهادی برای شناسایی پارامترهای طراحی و مجهول یک سلول خورشیدی با قطر ۵۷ میلی‌متر (R.T.C. فرانسه) مورد استفاده قرار گرفته است. نتایج به دست آمده توسط الگوریتم پیشنهادی کاملاً امیدوارکننده بوده و بر نتایجی که از منابع گزارش شده است، غلبه می‌کند. در هر ۳ مدل دیودی، الگوریتم شبکه عصبی جواب‌های دقیق‌تر و بهینه‌تری را پیشنهاد داده است. این امر به ویژه در مدل دو و سه دیودی که تعداد پارامترهای مجهول طراحی بیشتر است (پیچیدگی غیرخطی مسئله بالاتر است) بارزتر است که نشان از عملکرد موفق الگوریتم پیشنهادی در حل مسائل پیچیده‌تر با ماهیت غیرخطی دارد. در نتیجه، الگوریتم بهینه‌سازی شبکه عصبی می‌تواند جایگزین خوبی برای حل مسائل بهینه‌سازی سیستم‌های سلول خورشیدی قلمداد شود. به عنوان تحقیقات آتی، با بهبود راندمان عملگرهای جستجوی الگوریتم بهینه‌سازی شبکه عصبی، می‌توان به دقت‌های بالاتری دست یافت. همچنین، از مدل‌های سلول خورشیدی با تعداد دیود بیشتر (پیچیده‌تر شدن مسئله بهینه‌سازی) نیز می‌توان استفاده کرد. استفاده از چندین تابع هدف علاوه بر بالا بردن دقت مدل سلول خورشیدی از قبیل کاهش مصرف انرژی، کاهش ابعاد سیستم، می‌توان مدل‌های بهینه‌سازی چند هدفه واقعی‌تر و کاربردی‌تری در این حوزه تحقیقاتی فعال و اثرگذار تعریف کرد.

واژه نامه

Solar cell	سلول خورشیدی
Optimization	بهینه‌سازی
Metaheuristics	الگوریتم‌های فراابتکاری

تقدیر و تشکر

همچنین فرایند هم‌گرایی به سمت جواب بهینه در الگوریتم شبکه عصبی (NNA) برای مدل تک، دو، و سه دیودی برای ۵۰۰۰ بار تکرار در نمودار شکل (۷) به تصویر کشیده شده است. همان‌طور که در شکل (۷) دیده می‌شود، سرعت بالای هم‌گرایی روش NNA در مقدار تابع در مراحل ابتدایی نشان از سرعت و دقت این روش بهینه‌سازی برای حل مسایل بهینه‌سازی در صنعت سلول‌های خورشیدی دارد. همان‌طور که در شکل (۷) دیده می‌شود، در مدل تک دیودی به دلیل تعداد کم متغیرهای طراحی و ساده‌تر بودن مدل بهینه‌سازی، الگوریتم بهینه‌سازی شبکه عصبی در همان تکرارهای اول جواب بهینه جهانی را به دست آورده و تا انتهای تکرار تغییرات جزئی بر روی جواب بهینه اعمال کرده است. در صورتی که این روند برای مدل‌های بهینه‌سازی دو و سه دیودی دیده نمی‌شود که نشان از پیچیده‌تر شدن فضای جستجو دارد.



شکل ۷ فرایند هم‌گرایی و روند کاهش تابع هدف توسط الگوریتم شبکه عصبی (NNA) برای شناسایی پارامترهای مجهول در مدل‌های تک دیودی، دو دیودی، و سه دیودی

نتیجه‌گیری و کارهای آتی

در این مقاله، الگوریتم بهینه‌سازی شبکه عصبی (Neural Network Algorithm, NNA) برای به دست آوردن نتایج دقیق مدل‌های تک، دو، و سه دیودی سلول‌های خورشیدی مورد مطالعه قرار گرفته است. الگوریتم بهینه‌سازی شبکه عصبی با ایده گرفتن از ساختار منحصر به فرد شبکه‌های عصبی در مغز انسان توانسته است یک مدل بهینه‌سازی کارا برای حل مسایل

مراجع

- [1] Arshad, M. "Clean and sustainable energy technologies." In *Clean energy for sustainable development*, pp. 73-89. Academic Press (2017).

- [2] Q. Li, S. Yu, A. S. Al-Sumaiti, K. Turitsyn, "Micro Water-Energy Nexus: Optimal Demand-Side Management and Quasi-Convex Hull Relaxation", *IEEE Transactions on Control of Network Systems*, vol. 6, no. 4, pp. 1313-1322, (2018).
- [3] B. Mohandes, S. Acharya, M. S. El Moursi, A. S. Al-Sumaiti, H. Doukas, S. Sgouridis, "Optimal Design of an Islanded Microgrid with Load Shifting Mechanism Between Electrical and Thermal Energy Storage Systems", *IEEE Transactions on Power Systems*, vol. 35, no. 4, pp. 2642-2657, (2020).
- [4] T. Ma, H. Yang, L. Lu, "Solar Photovoltaic System Modeling and Performance Prediction", *Renewable and Sustainable Energy Reviews*, Vol. 36, pp. 304-315, (2014).
- [5] A. Al-Sumaiti, M. H. Ahmed, S. Rivera, M. S. El Moursi, M. M. A. Salama, T. S. Alsumaiti, "A Stochastic PV Model for Power System Planning Applications", *IET Renewable Power Generation*, vol. 13, no. 16, pp. 3168-3179, (2019).
- [6] V. Lo Brano, A. Orioli, G. Ciulla, A. Di Gangi, "An Improved Five-Parameter Model for Photovoltaic Modules", *Solar Energy Materials and Solar Cells*, vol. 94, no. 8, pp. 1358-1370, (2010).
- [7] A. S. Al-Sumaiti, M. M. A. Salama, S. Reddy, A. Kavousi-Fard, "A Guided Procedure for Governance Institutions to Regulate Funding Requirements of Solar PV Projects", *IEEE Access*, vol. 7, pp. 54203-54217, (2019).
- [8] B. Amrouche, A. Guessoum, M. Belhamel, "A Simple Behavioural Model for Solar Module Electric Characteristics Based on the First Order System Step Response for MPPT study and comparison", *Applied Energy*, vol. 91, no. 1, pp. 395-404, (2012).
- [9] A. Orioli, A. Di Gangi, "A Procedure to Calculate the Five-Parameter Model of Crystalline Silicon Photovoltaic Modules on the Basis of the Tabular Performance Data", *Applied Energy*, vol. 102, pp. 1160-1177, (2013).
- [10] L. Sandrolini, M. Artioli, U. Reggiani, "Numerical Method for the Extraction of Photovoltaic Module Double-Diode Model Parameters Through Cluster Analysis", *Applied Energy*, vol. 87, no. 2, pp. 442-451, (2010).
- [11] F. Bonanno, G. Capizzi, G. Graditi, G. Napoli, G. M. Tina, "A Radial Basis Function Neural Network Based Approach for the Electrical Characteristics Estimation of A Photovoltaic Module", *Applied Energy*, vol. 97, pp. 956-961, (2012).
- [12] V. Khanna, B. k. Das, D. Bisht, D. Singh, vandana, P. K. Singh, "A Three Diode Model for Industrial Solar Cells and Estimation of Solar Cell Parameters Using PSO Algorithm", *Renewable Energy*, vol. 78, pp. 105-113, (2015).
- [13] T. Easwarakhanthan, J. Bottin, I. Bouhouch, C. Boutrit, "Nonlinear Minimization Algorithm for Determining the Solar Cell Parameters with Microcomputers", *International journal of Solar Energy*, vol. 4, no. 1, pp. 1-12, (1986).
- [14] A. Jain, A. Kapoor, "Exact Analytical Solutions of the Parameters of Real Solar Cells Using Lambert W-Function", *Solar Energy Materials and Solar Cells*, vol. 81, no. 2, pp. 269-277, (2004).
- [15] S. Haneefa, S. Karmalkar, "An Analytical Method to Extract the Physical Parameters of a Solar Cell From Four Points on the Illuminated J-V Curve", *IEEE Electron Device Letters*, vol. 30, no. 4, pp. 349-352, (2009).
- [16] D. S. H. Chan, J. R. Phillips, J. C. H. Phang, "A Comparative Study of Extraction Methods for Solar Cell Model Parameters", *Solid-State Electronics*, vol. 29, no. 3, pp. 329-337, (1986).
- [17] H. Wei, J. Cong, X. Lingyun, S. Deyun, "Extracting Solar Cell Model Parameters Based on Chaos Particle Swarm

- Algorithm”, *International conference on electric information and control engineering, IEEE, Wuhan*, pp. 398-402, 15-17 April, (2011).
- [18] M. R. AlRashidi, M. F. AlHajri, K. M. El-Naggar, A. K. Al-Othman, “A New Estimation Approach for Determining the I–V Characteristics of Solar Cells”, *Solar Energy*, vol. 85, no. 7, pp. 1543-1550, (2011).
- [19] K. M. El-Naggar, M. R. AlRashidi, M. F. AlHajri, A. K. Al-Othman, “Simulated Annealing Algorithm for Photovoltaic Parameters Identification”, *Solar Energy*, vol. 86, no. 1, pp. 266-274, (2012).
- [20] M. Gómez, M. López, F. Jurado, “Optimal Placement and Sizing From Standpoint of the Investor of Photovoltaics Grid-Connected Systems Using Binary Particle Swarm Optimization”, *Applied Energy*, vol. 87, no. 6, pp. 1911-1918, (2010).
- [21] O. Ekren, B. Y. Ekren, “Size Optimization of A PV/Wind Hybrid Energy Conversion System with Battery Storage Using Simulated Annealing”, *Applied Energy*, vol. 87, no. 2, pp. 592-598, (2010).
- [22] C. R. S. Reinoso, M. Cutrera, M. Battioni, D. Milone, R. Buitrago, “Photovoltaic Generation Model as a Function of Weather Variables Using Artificial Intelligence Techniques”, *International journal of hydrogen energy*, vol. 37, no. 19, pp. 14781-14785, (2012).
- [23] T. Niknam, S. I. Taheri, J. Aghaei, S. Tabatabaei, M. Nayeripour, “A Modified Honey Bee Mating Optimization Algorithm for Multiobjective Placement of Renewable Energy Resources”, *Applied Energy*, vol. 88, no. 12, pp. 4817-4830, (2011).
- [24] T. R. Ayodele, A. S. O. Ogunjuyigbe, E. E. Ekoh, “Evaluation of Numerical Algorithms Used in Extracting the Parameters of a Single-Diode Photovoltaic Model”, *Sustainable Energy Technologies and Assessments*, vol. 13, pp. 51-59, (2016).
- [25] D. Oliva, M. Abd Elaziz, A. H. Elsheikh, A. A. Ewees, “A Review on Meta-Heuristics Methods for Estimating Parameters of Solar Cells”, *Journal of Power Sources*, vol. 435, p. 126683, (2019).
- [26] G. Xiong, J. Zhang, X. Yuan, D. Shi, Y. He, “Application of Symbiotic Organisms Search Algorithm for Parameter Extraction of Solar Cell Models”, *Applied Sciences*, vol. 8, no. 11, pp. 2155, (2018).
- [27] C. Dai, W. Chen, Y. Zhu, “Seeker Optimization Algorithm for Digital IIR Filter Design”, *IEEE transactions on industrial electronics*, vol. 57, no. 5, pp. 1710-1718, (2009).
- [28] A. Sadollah, H. Sayyaadi, A. Yadav, “A Dynamic Metaheuristic Optimization Model Inspired By Biological Nervous Systems: Neural Network Algorithm”, *Applied Soft Computing*, vol. 71, pp. 747-782, (2018).
- [29] J. S. Chohan, N. Mittal, R. Kumar, S. Singh, S. Sharma, J. Singh, K. V. Rao, M. Mia, D. Y. Pimenov, S. P. Dwivedi, “Mechanical Strength Enhancement of 3D Printed Acrylonitrile Butadiene Styrene Polymer Components Using Neural Network Optimization Algorithm”, *Polymers*, vol. 12, no. 10, pp. 2250, (2020).
- [30] M. S. AbouOmar, H-J. Zhang, Y. Su, “Fractional Order Fuzzy PID Control of Automotive PEM Fuel Cell Air Feed System Using Neural Network Optimization Algorithm”, *Energies*, vol. 12, no. 8, p. 1435, (2019).
- [31] M. Fawzi, A. El-Fergany, H. M. Hasanien, “Effective Methodology Based on Neural Network Optimizer for Extracting Model Parameters of PEM Fuel Cells”, *International Journal of Energy Research*, vol. 43, no. 14, pp. 8136-8147, (2019).

- [32] Y. Zhang, Z. Jin, Y. Chen, "Hybrid Teaching–Learning-Based Optimization and Neural Network Algorithm for Engineering Design Optimization Problems", *Knowledge-Based Systems*, vol. 187, pp. 104836, (2020).
- [33] Z. Yiying, Z. Jin, Y. Chen, "Hybridizing Grey Wolf Optimization with Neural Network Algorithm for Global Numerical Optimization Problems", *Neural Computing and Applications*, vol. 32, pp. 10451-10470, (2020).
- [34] D. Khurana, A. Yadav, A. Sadollah, "A Non-Dominated Sorting Based Multi-Objective Neural Network Algorithm", *MethodsX*, vol. 10, pp. 102152, (2023).
- [35] D. C. Montgomery, C. St, "Design and Analysis of Experiments", *John Wiley and Sons*, (2005).
- [36] A. Askarzadeh, A. Rezaadeh, "Artificial Bee Swarm Optimization Algorithm for Parameters Identification of Solar Cell Models", *Applied Energy*, vol. 102, pp. 943-949, (2013).
- [37] M. AlHajri, K. El-Naggar, M. AlRashidi, A. Al-Othman, "Optimal Extraction of Solar Cell Parameters Using Pattern Search", *Renewable Energy*, vol. 44, pp. 238-245, (2012).
- [38] A. Askarzadeh, A. Rezaadeh, "Parameter Identification for Solar Cell Models Using Harmony Search-Based Algorithms", *Solar Energy*, vol. 86, no. 11, pp. 3241-3249, (2012).
- [39] S. Mirjalili, S. M. Mirjalili, A. Lewis, "Grey Wolf Optimizer", *Advances in Engineering Software*, vol. 69, pp. 46-61, (2014).
- [40] S. Mirjalili, "Moth-Flame Optimization Algorithm: A Novel Nature-Inspired Heuristic Paradigm", *Knowledge-based systems*, vol. 89, pp. 228-249, (2015).
- [41] D. Oliva, M. Abd El Aziz, A. E. Hassanien, "Parameter Estimation of Photovoltaic Cells Using an Improved Chaotic Whale Optimization Algorithm", *Applied Energy*, vol. 200, pp. 141-154, (2017).
- [42] S. Mirjalili, "SCA: A Sine Cosine Algorithm for Solving Optimization Problems", *Knowledge-based systems*, vol. 96, pp. 120-133, (2016).
- [43] S. Mirjalili, S. M. Mirjalili, A. Hatamlou, "Multi-Verse Optimizer: A Nature-Inspired Algorithm for Global Optimization", *Neural Computing and Applications*, vol. 27, pp. 495-513, (2016).
- [44] S. Mirjalili, "The Ant Lion Optimizer", *Advances in Engineering Software*, vol. 83, pp. 80-98, (2015).
- [45] E. H. Houssein, G. N. Zaki, A. A. Z. Diab, E. M. G. Younis, "An Efficient Manta Ray Foraging Optimization Algorithm for Parameter Extraction of Three-Diode Photovoltaic Model", *Computers & Electrical Engineering*, vol. 94, pp. 107304, (2021).