

بهینه‌سازی فرایند شناسایی پارامتر مدل های تک‌دیودی، دودیودی، و سه‌دیودی سلول خورشیدی توسط الگوریتم بهینه‌سازی شبکه عصبی

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 براساس 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 مسایل 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 تک‌دیودی، دو دیودی، و سه دیودی توسط الگوریتم شبکه عصبی انجام گرفته است. نتایج بدست 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،۸۵، و ۱۷،۹۷ درصد نسبت به بهترین روش مطالعه شده در منابع حاصل شده است.

کلمات کلیدی

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

Optimal Parameter Estimation of Various Solar Cell Models Using Neural Network Optimization Algorithm

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. 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 presented 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 models, and recently nine-variable model. Due to the nonlinearities and inability of traditional methods in identifying the unknown variables of the system, recently intelligent algorithms have attracted considerable attentions in solving engineering 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 done. The improvement level reported by the NNA in comparison with the best reported results in the literature for one, two, and three diode models are 0.44, 0.085, and 17.97 percent, respectively. The obtained results of the proposed NNA method have the highest accuracy among the other optimizers in the literature.

Keywords

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

۱. 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 تجدید پذیر 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 [۱]. علی‌رغم این واقعیت که سلول‌های خورشیدی مزایای زیادی را برای شبکه‌های تولیدی بازار جهانی برق به ارمغان آورده‌اند [۲، ۳]، اخیراً یک چالش جدید و قابل توجه در رابطه با عدم تطبیق بازدهی تخمینی و بازدهی عملی آنها که متناسب با شرایط آب و هوایی‌ای که تحت آن عمل می‌کنند، به وجود آمده است [۴، ۵]، که این مورد افزون بر هزینه‌های بالای تعمیر و نگهداری آنها محسوب می‌شود [۶، ۷].

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 [۸-۱۱]. 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 طبقه بندی 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 بهره برداری 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 مولفه‌ها نظیر جریان اشباع دیودی، جریان تولید شده، مقاومت شنت، مقاومت سری، و فاکتور ایده‌آل‌گرایی 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، که به این معنی است 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 [۱۲]. 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 توانا تر و کارا تر کرده است. در حقیقت، اندازه‌گیری دقیق این متغیرهای مجهول نقش مهمی را در شبیه سازی، ارزیابی عملکرد، طراحی، بهینه سازی، و کنترل سلول‌های خورشیدی بازی می‌کند. از این رو، شناسایی متغیرها به کمک یک تکنیک بهینه سازی 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 (سنّتی) [۱۶-۱۳] و رویکرد تحقیقاتی فراابتکاری [۱۹-۱۷]. در مدلسازی مرسوم یا سنّتی از یک رویکرد تخمینی مبتنی بر حداقل مربعات غیرخطی بهبود یافته خطا که بر پایه روش نیوتون توسعه یافته شده است استفاده می‌شود [۱۳]. تا متغیرهای سلول خورشیدی استخراج و شناسایی شوند. وابستگی به نقطه آغازین که در این روش 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 راه حل و جواب موجود باشد ممکن است به جای مقادیر بهینه شده کلی (جهانی) مقادیر بهینه شده محلی را بدست آورد که یک نقص بزرگ در این رویکرد به شمار می‌آید [۱۶-۱۴]. علاوه بر این، روش‌های بهینه‌سازی سنّتی نیازمند پیوستگی در مدل و محاسبات سنگین ریاضیاتی هستند، باید شرایط تقرّر در منحنی و مشتق‌پذیر بودن را برای کاربردی بودن داشته باشند. همانطور که گفته شد، این روش‌ها 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 سنّتی برای حل موثر مشکل شناسایی متغیرهای اصلی در این زمینه محسوب می‌شود. در نتیجه، برای حل مشکلات بهینه‌سازی در سلول خورشیدی در راستای محتمل‌تر شدن دستیابی به یک پاسخ کلی (جهانی) و دقیق و در مدت زمان معقول روش‌های تحقیقاتی فراابتکاری پیشنهاد داده شده اند [۲۳-۲۰].

پیشینه و منابعی که برای روش و رویکرد تحقیقاتی فراابتکاری وجود دارند، حل مسئله شناسایی متغیرهای اصلی در سلول‌های خورشیدی را به الگوریتم ژنتیک [۱۸]، الگوریتم بهینه‌سازی تجمعی ذرات [۱۷]، و الگوریتم فرایند بازپخت شبیه‌سازی شده [۱۹] ارجاع می‌دهند و تقریباً این روش‌ها، اولین الگوریتم‌هایی فراابتکاری محسوب می‌شوند که برای حل بهینه‌سازی سلول‌های خورشیدی بکار 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 [۲۶-۲۴].

اگرچه الگوریتم‌های فراابتکاری نتایج بهتری را نسبت به روش‌های مرسوم یا سنّتی در پی دارند اما محدودیت‌های نسبی‌ای نیز به همراه دارند [۲۷]. به عنوان رایج‌ترین الگوریتم فراابتکاری، الگوریتم ژنتیک مکرراً فضای جستجو را برای دستیابی به یک پاسخ مناسب به سرعت پیدا می‌کند، اما دارای اشکالاتی است. عدم وجود جست و جوی مناسب محلی در این الگوریتم و تعیین پارامترهای اولیه از جمله معایب اینگونه روش‌ها محسوب می‌شوند [۲۷].

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 جوی دست‌دهد و همچنین ممکن است تحت تاثیر 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 بازپخت 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 بدست بیایند.

چالش غیرخطی 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 بهره برداری (Exploitation) بستگی دارد. اکتشاف به تولید راه‌حل‌های جدید از محدوده مناطق دیده نشده فضای جستجو اشاره دارد و بهره برداری یعنی تمرکز جستجوی الگوریتم در مجاورت راه‌حل‌های مناسب فعلی. ناتوانی الگوریتم برای ایجاد یک تعادل خوب بین اکتشاف و بهره برداری منجر به هم‌گرایی زودرس، افتادن در دام پاسخ محلی و رکود خواهد شد.

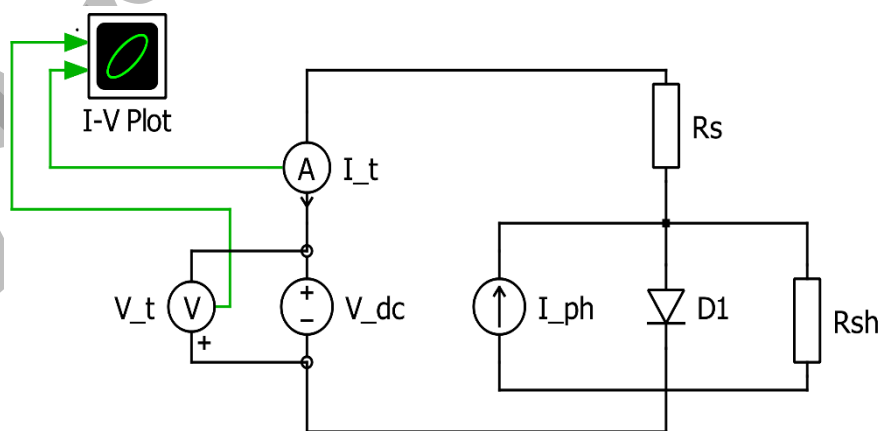
در این مقاله از الگوریتم بهینه‌سازی شبکه عصبی برای دستیابی به مقادیر بهینه متغیرهای مجهول مدل‌های یک سلول خورشیدی تجاری سیلیکونی با قطر ۵۷ میلی‌متر برای مدل تک دیودی، دو دیودی، و سه دیودی استفاده شده است. به منظور ارزیابی عملکرد الگوریتم شبکه عصبی (Neural Network Algorithm, NNA)، نتایج حاصل از این روش با نتایج بدست آمده از روش‌های الگوریتم ژنتیک (Genetic algorithms, GAs)، الگوریتم بهینه‌سازی تجمعی ذرات (Particle swarm algorithm, PSO)، الگوریتم فرایند بازپخت شبیه‌سازی شده (Simulated annealing, SA)، الگوریتم جستجوی هارمونیک (Harmony Search, HS) و الگوریتم جستجوی الگویی (Pattern Search, PS) مقایسه شده‌اند.

۲. مدل‌سازی ریاضی مسئله سلول خورشیدی

قبل از مرحله تخمین و پیش‌بینی نتایج، داشتن یک مدل ریاضی که مشخصات الکتریکی سلول خورشیدی و ماژول فوتوولتائیک را بدرستی نشان دهد ضروری است. با وجود این واقعیت که در چهار دهه اخیر مدل‌های زیادی برای توصیف رفتار سلول خورشیدی طراحی و پیشنهاد شده‌اند، اما سه مدل در عمل استفاده می‌شوند. در ادامه مختصراً به این مدل‌ها پرداخته خواهد شد.

۲-۱- 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 شاکلی برای جریان دیود و جایگزین کردن جریان مقاومت شنت و تعمیم رابطه بالا مدل تک دیودی می‌تواند به صورت زیر فرموله شود [۱۸]:

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

که I_{SD1} جریان اشباع دیودی، V_t نماد ولتاژ ترمینال، R_s و R_{sh} نمادهای مقاومت های 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 نام های R_s ، I_{SD1} ، I_{ph} ، R_{sh} ، و n ختم می‌شود.

۲-۲- مدل دو دیودی

در حالت ایده‌آل، برای مدلسازی یک سلول خورشیدی تحت تابش خورشید، منبع جریان الکتریکی تولید شده توسط نور خورشید با یک دیود یک سو 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 نشستی 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 ایده‌آل بودن آن می‌باشند) در داخل محاسبات و افزایش دقت در نتایج حاصله انجام می‌شود. در واقع این ویژگی، برتری اصلی مدل دودی نسبت به مدل تک دیودی می‌باشد و در واقع اضافه شدن دیود دوم در این مدل تا حدودی نشستی های جریان در سلول خورشیدی واقعی را جبران کرده و تاثیر آن در نتایج این مدل نشان داده می‌شود. اما با این وجود باز هم نشستی 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.



شکل ۲. شماتیک مدار معادل مدل دودی سلول خورشیدی.

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

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

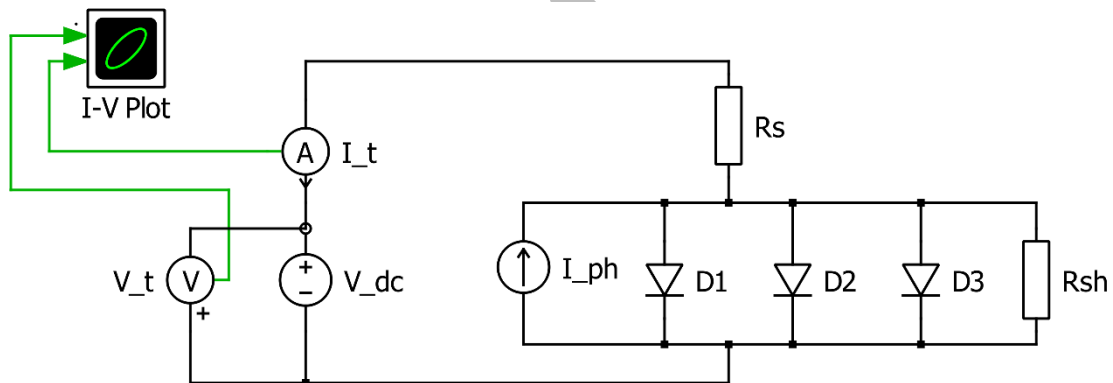
در معادله (۳)، I_{ph} نماد جریان خالص تولیدی حاصل از تابش نور، I_{D1} نماد جریان عبوری از دیود اول، I_{D2} نماد جریان عبوری از دیود دوم، و I_{sh} نیز به جریان مقاومت شنت اشاره دارد. با در نظر گرفتن معادله شاکلی برای جریان‌های دیودها و جایگزین کردن جریان مقاومت شنت، معادله (۳) به شکل زیر بازنویسی می‌شود [۱۲]:

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

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 مقاومت های سری و شنت، q نماد شارژ الکترونیک، K نماد ثابت بولتزمن، n_1 و n_2 نمایانگر ضرایب ایده آل گرای دیفیوژن و بازترکیبی، و T نیز نماد دمای سلول می باشند. معادله (۴) هفت متغیر مجهول به نام های R_s ، I_{ph} ، I_{D1} ، I_{D2} ، R_{sh} ، n_1 و n_2 را در بر می گیرد که برای منعکس کردن عملکرد واقعی سلول خورشیدی و سیستم تحت عنوان نتایج آزمایش، شناسایی این متغیرها ضروری و حائز اهمیت بالایی است.

۳-۲- مدل سه دیودی

این مدل، مدل دقیقی از تک سلول های خورشیدی و ماژول های فوتولتائیک است که برای تحلیل قوانین انرژی برای سیستم 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. تاثیرات افزایش مرزهای سلول خورشیدی در اثر انبساط های طولی (ناشی از تغییرات دمایی) و همچنین اتلاف جریان ناشی از نشت جریان داخل مدار، در مدل سه دیودی در نظر گرفته شده اند. 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 ترکیب هایی که در نواحی دچار نقص سلول رخ داده است و انرژی هایی که آزاد می شوند، هدف افزودن دیود سوم همراه با دو دیود دیگر، بررسی سهم جریان اتلاfi دیود سوم است. در واقع در این مدل تمام جوانب و احتمالات ناشی از نشتی جریان در نظر گرفته شده اند 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 می شود. اما در نقطه مقابل پیچیدگی استفاده، ازدیاد متغیرها و محاسبات سنگین ریاضیاتی، از محدودیت های این مدل قلمداد میشوند. جریان پایانه I_t را با توجه به شکل ۳ می توان 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 نشان دهنده جریان مقاومت شنت می باشد. با در نظر گرفتن معادله شاکلی برای جریان های سه دیود و جایگزینی جریان مقاومت شنت، معادله (۵) در قالب معادله (۶) بازنویسی می شود [۱۲]:

$$I_t = I_{ph} - I_{SD1} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_1 \cdot K \cdot T} \right) - 1 \right] - I_{SD2} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_2 \cdot K \cdot T} \right) - 1 \right] - I_{SD3} \left[\exp \left(\frac{q(V_t + R_s I_t)}{n_3 \cdot K \cdot T} \right) - 1 \right] - \frac{(V_t + R_s I_t)}{R_{sh}} \quad (6)$$

که در معادله (۶)، I_{SD1} ، I_{SD2} و I_{SD3} به ترتیب نمادهای جریان دیفیوژن، جریان اشباع باز ترکیبی، و جریان نشتی-باز ترکیبی، V_t نماد ولتاژ ترمینال، R_s و R_{sh} نمادهای مقاومت های سری و شنت، q نماد شارژ الکترونیک، K نماد ثابت بولتزمن، n_1 ، n_2 و n_3 نمایانگر ضرایب ایده آل گرای دیفیوژن، باز ترکیبی، و نشتی-باز ترکیبی، و T نیز نماد دمای سلول می باشند. معادله (۶)، ۹ متغیر مجهول به نام های R_s ، I_{SD1} ، I_{SD2} ، I_{SD3} ، I_{ph} ، n_1 ، n_2 و n_3 را در بر می گیرد که استخراج آنها برای نمایش و تخمین عملکرد سلول خورشیدی که تحت آزمایشات و بررسی های مکرر قرار گرفته است، از اهمیت بالایی است.

۲-۴- فرایند بهینه سازی مدل ریاضی

متغیرهای مجهول را می توان با کمک روش بهینه سازی و مجموعه ای از داده های تجربی I-V که از یک سیستم واقعی بدست آمده اند شناسایی کرد. تکنیک بهینه سازی به کار رفته در این مقاله الگوریتم بهینه سازی شبکه عصبی (NNA) است که در ادامه به تفصیل به پرداخته خواهد شد. تعداد ۲۶ داده آزمایشگاهی I-V برای ولتاژ و جریان اندازه گیری 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، دودیودی، و سه دیودی در جدول ۱ آورده شده است.

جدول ۱. داده های تجربی جریان و ولتاژ اندازه گیری شده برای یک سلول خورشیدی تجاری سیلیکونی با قطر ۵۷ میلی متر برای مدل تک دیودی، دودیودی، و سه دیودی.

اندازه گیری	V_t (V)	I_t (A)	اندازه گیری	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

در الگوریتم های بهینه سازی، هر جواب توسط یک بردار راه حل مانند X تعریف می شود که X در مدل های تک دیودی، دو دیودی، و سه دیودی به ترتیب توسط معادلات (۷) تا (۹) بیان شده اند:

$$X = [R_s, R_{sh}, I_{ph}, I_{SD}, n] \quad (7)$$

$$X = [R_s, R_{sh}, I_{ph}, I_{SD2}, I_{SD1}, n_1, n_2] \quad (8)$$

$$X = [R_s, R_{sh}, I_{ph}, I_{SD3}, I_{SD2}, I_{SD1}, n_1, n_2, n_3] \quad (9)$$

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

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

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

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

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

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

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

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

که N تعداد داده های تجربی است. در طول فرآیند بهینه سازی، تابع هدف با توجه به محدوده پارامترها به حداقل می رسد. الگوریتم شبکه عصبی (NNA) برای بهینه سازی متغیرهای مجهول به گونه ای که پاسخ بدست 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 شده اند. متغیرهای طراحی مدل (پنج، هفت، و نه بر اساس مدل دیود انتخاب شده) به ترتیب توسط الگوریتم بهینه سازی شبکه عصبی تا زمانی که معیار پایانی و قابل قبول برآورده شود، انتخاب و در معادلات استفاده می شوند. واضح است که هرچه مقدار تابع هدف کوچک تر باشد، راه حل بهتر و دقیق تری حاصل شده است. جدول ۲. حدود بالا و پایین برای هر یک از متغیرهای طراحی سلول خورشیدی در مدل های 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

۳- روش بهینه سازی الگوریتم شبکه عصبی

۳-۱- مقدمه

الگوریتم شبکه عصبی یک الگوریتم بهینه سازی فرا ابتکاری جدید و الهام گرفته از سیستم های عصبی زیستی و شبکه های عصبی مصنوعی (Artificial Neural Networks, ANNs) است که برای حل مسائل بهینه سازی پیچیده پیشنهاد شده است [۲۸]. روش پیشنهادی با نام الگوریتم شبکه عصبی (Neural Network Algorithm, NNA) براساس ساختار منحصر به فرد شبکه های عصبی مصنوعی توسعه داده شده است. الگوریتم شبکه عصبی از ساختار پیچیده شبکه های عصبی مصنوعی و عملگرهایش برای تولید راه حل های جدید بهره می گیرد. در مورد اثبات هم گرایی، رابطه بین بهره برداری تصادفی برای هر پارامتر، تحت یک فاصله زمانی نامتقارن بدست آمده و هم گرایی تکرار شونده الگوریتم شبکه عصبی به صورت تئوری اثبات شده است. علاوه بر این، تاکنون چندین مساله طراحی مهندسی در دامنه محدودی مورد بررسی قرار گرفته است تا کارایی الگوریتم شبکه عصبی برای جستجو در محدوده دامنه در مسائل بهینه سازی دارای قید و شرط را مورد اعتبارسنجی قرار دهد. عدم نیاز به تنظیم پارامترهای اولیه می تواند الگوریتم شبکه عصبی را نسبت به سایر الگوریتم های بهینه ساز مطالعه شده دیگر تمایز و برتری بسیاری ببخشد. از این رو می توان نتیجه گرفت که شبکه های عصبی مصنوعی و

ساختار خاص آن‌ها می‌توانند با موفقیت به عنوان یک روش بهینه‌سازی فراابتکاری به منظور اعمال در مسائل بهینه‌سازی مهندسی و مقید به کار گرفته شوند.

۳-۲- ایده اولیه

با الهام از شبکه‌های عصبی مصنوعی، در الگوریتم شبکه عصبی (NNA) بهترین راه حل بدست آمده در هر تکرار (یعنی راه حل بهینه موقتی) بعنوان 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. شایان ذکر است که این راه حل هدف در هر تکرار به روز می‌شود. در این بخش به کمک ساختار شبکه‌های عصبی مصنوعی، در قالب برخی از فرمول‌ها و مفاهیم ریاضی، به منظور تهیه یک الگوریتم بهینه‌سازی جدید بر اساس پیکربندی شبکه عصبی، شرح جزئیات و فرآیندهای این الگوریتم تحت عنوان الگوریتم شبکه عصبی ارائه خواهد شد.

۳-۳- تولید جمعیت اولیه

در یک مساله بهینه‌سازی D بعدی، یک راه حل الگو (Pattern Solution)، یک ماتریس سطری $1 \times D$ است که داده‌های ورودی را در الگوریتم شبکه عصبی نشان می‌دهد. این بردار بصورت $[x_1, x_2, x_3, \dots, x_D]$ تعریف می‌شود. در واقع جمعیت راه‌حل‌های الگو مطابق با داده‌های ورودی در شبکه‌های عصبی مصنوعی است. برای شروع الگوریتم بهینه‌سازی یک انتخاب تصادفی از ماتریس الگوی راه حل 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 (فرض می‌شود مرزهای پایین و بالا توسط یک تصمیم‌گیرنده تعریف شود) یک ماتریس $N_{pop} \times D$ خواهد بود. هر یک از مقادیر متغیرهای تصمیم‌گیری (x_1, x_2, \dots, x_D) می‌توانند بصورت عدد اعشاری نمایش داده شوند یا می‌توانند بصورت مجموعه‌ای از متغیرهای گسسته تعریف شوند. هزینه یک راه‌حل الگو برای تکرارهای متوالی با ارزیابی تابع هزینه (تابع برازش C) برای راه‌حل الگوی مربوطه به شرح زیر است:

$$C_i = f(x_1^i, x_2^i, \dots, x_D^i) \quad i = 1, 2, 3, \dots, N_{pop} \quad (11)$$

که در رابطه (۱۱)، f همان تابع هدف است. بعد از محاسبه تابع هزینه برای تمامی راه‌حل‌های الگو، مرحله بعدی پیدا کردن بهترین راه حل الگو است، که منظور از بهترین راه حل در این الگوریتم، یک راه حل بهینه جهانی با کمترین مقدار تابع هدف می‌باشد. سپس، بعد از تنظیم راه حل هدف (X^{TARGET}) از بین راه‌حل‌های الگو، وزن هدف (W^{TARGET}) متناظر با راه حل هدف باید از بین جمعیت وزن (ماتریس وزن) انتخاب شود.

۳-۴- ماتریس وزن

در شبکه‌های عصبی مصنوعی، سلول‌های عصبی مصنوعی یا واحدهای پردازش ممکن است چندین مسیر ورودی مطابق با شاخه‌های متعدد سلول‌های عصبی داشته باشند. با استفاده از یک جمع بندی 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 (۱۲) برای جمعیت راه‌حل‌های الگو نمایش داده شده است:

$$W_{(t)} = [w_1, w_2, w_3, \dots, w_D] \quad (12)$$

که W یک ماتریس مربعی $N_{pop} \times N_{pop}$ با w_{ij} درایه است که در حین تکرار اعداد تصادفی را بطور یکنواخت بین صفر تا یک تولید می‌کند و t یک شاخص تکرار است. زیر نویس اول وزن مربوط به شمارنده راه حل الگوی آن می‌شود و زیر نویس دوم وزن مربوط به مقادیر وزنی راه‌حل‌های الگوی دیگر است (بعنوان مثال W_{23} با راه حل الگوی سوم مشترک است). هر راه حل الگو دارای وزن مربوط

به خودش می‌باشد که برای تولید یک راه حل جدید بکار گرفته می‌شود. با این حال، محدودیتی برای مقادیر وزن وجود دارد. قید تحمیل شده، به این صورت است که مجموع وزن‌ها برای یک راه حل الگو نباید از عدد یک تجاوز کند که از نظر ریاضی می‌تواند به شکل رابطه (۱۳) تعریف شود:

$$\sum_{j=1}^{N_{pop}} w_{ij}(t) = 1, \quad i = 1, 2, 3, \dots, N_{pop} \quad (13)$$

وجود چنین محدودیتی برای مقادیر وزن، ناشی از کنترل انحراف از تولید راه حل‌های الگوی جدید در منطقه بهینه محلی است. بدون این محدودیت مقادیر وزن تمایل به رشد (مقادیر بیش از یک) در یک جهت خاص دارند، بنابراین الگوریتم در یک نقطه بهینه محلی متوقف خواهد شد. داشتن این محدودیت حرکت کنترل شده عوامل شبکه‌های عصبی مصنوعی را با انحراف خفیف (متغیر از صفر تا یک) را ارائه می‌دهد. پس از تشکیل ماتریس وزن (W)، راه حل‌های الگوی جدید (X^{NEW}) با استفاده از معادله (۱۴) که از تکنیک جمع وزن مورد استفاده در شبکه‌های عصبی مصنوعی الهام گرفته شده، محاسبه می‌شود [۲۸]:

$$\vec{X}_j^{NEW}(t+1) = \sum_{i=1}^{N_{pop}} w_{ij}(t) \times \vec{X}_i(t), \quad j = 1, 2, 3, \dots, N_{pop} \quad (14)$$

$$\vec{X}_i(t+1) = \vec{X}_i(t) + \vec{X}_i^{NEW}(t+1), \quad i = 1, 2, 3, \dots, N_{pop} \quad (15)$$

که در آن t شاخص تکرار است. بنابراین راه حل الگوی جدید برای تکرار ($t+1$) ام با استفاده از معادلات (۱۴) و (۱۵) به روز شده است. پس از ایجاد راه حل‌های الگوی جدید از جمعیت الگوهای قبلی بر مبنای بهترین مقدار وزن که وزن هدف نامیده می‌شود، ماتریس وزن نیز باید به خوبی به روزرسانی شده باشد. رابطه (۱۶)، یک معادله به روزرسانی شده برای ماتریس وزن را پیشنهاد می‌دهد:

$$\vec{W}_i^{Updated}(t+1) = \vec{W}_i(t) + 2 \times rand \times (\vec{W}^{Target}(t) - \vec{W}_i(t)), \quad i = 1, 2, 3, \dots, N_{pop} \quad (16)$$

۳-۵- عملگر تصادفی

در الگوریتم شبکه عصبی (NNA)، عملگر تصادفی در صد معینی از راه حل‌های الگو را در جمعیت جدیدی از الگو اصلاح می‌کند، به این معنا که راه حل الگوی جدید $\vec{X}_1^{NEW}(t+1)$ و ماتریس وزن به روز شده $\vec{W}_1^{Updated}(t+1)$ باز هم اصلاح خواهند شد. به عبارت دیگر، عملگر تصادفی در الگوریتم شبکه عصبی، روش دیگری برای کاوش در فضای جستجو است و مشابه عملگر جهش در الگوریتم ژنتیک عمل می‌کند. به طور کلی، عملگر تصادفی مانع از هم‌گرایی زودرس (به ویژه در تکرارهای اولیه) می‌شود و تعدادی از به اصطلاح افراد در جمعیت را اصلاح می‌کند. در حقیقت، عملگر تصادفی به عنوان یک فیلتر برای راه حل‌های الگوی جدید (رابطه (۱۵)) و ماتریس وزن به روز شده (رابطه (۱۶)) عمل می‌کند. برای این منظور، پارامتر β که همان ضریب اصلاح می‌باشد تعریف می‌شود، که در صد راه حل‌های الگویی را که باید تغییر یابند را تعیین می‌کند. 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، بدست خواهد آمد:

$$\beta(t+1) = \beta(t) \times 0.99 \quad t = 1, 2, 3 \dots Max. \text{ Iteration} \quad (17)$$

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

۳-۶- عملگر انتقال

در الگوریتم شبکه عصبی (NNA)، برخلاف شبکه‌های عصبی مصنوعی (ANNs)، عملگر انتقال، راه حل‌های الگوی جدید را در

جمعیت، از موقعیت فعلی خود در فضای جستجو به موقعیت‌های جدید به منظور به روز رسانی و تولید راه‌حل‌های با کیفیت بهتر به سمت راه‌حل هدف انتقال می‌دهد. بهبود راه‌حل‌ها با حرکت راه‌حل‌های الگوی جدید فعلی و نزدیک‌تر شدن به بهترین راه‌حل (راه حل هدف) انجام می‌شود. بنابراین، رابطه (۱۸) به عنوان یک عملگر انتقال برای روش پیشنهاد شده برای هر عضو از جمعیت به صورت زیر تعریف می‌شود:

$$\vec{X}_i^*(t+1) = TF(\vec{X}_i(t+1)) = \vec{X}_i(t+1) + 2 \times Rand \times (\vec{X}^{Target}(t) - \vec{X}_i(t+1)) \quad (18)$$

با استفاده از معادله (۱۸)، اندیس i ام راه‌حل الگوی جدید ($\vec{X}_i(t+1)$) از موقعیت فعلی خود در فضای جستجو به موقعیت به روز شده آن ($\vec{X}_i^*(t+1)$) منتقل می‌شود. در تکرارهای اولیه، احتمال بیشتری وجود دارد که عملگر تصادفی، راه‌حل‌های الگوی جدید و همچنین مقادیر وزنی جدید را ایجاد کند (فرصت‌های بیشتر برای کشف و شناسایی راه‌حل‌های الگوی دیده نشده). با این حال، هنگامی که تعداد تکرار افزایش می‌یابد، این شانس کاهش می‌یابد و عملگر انتقال نقش مهم‌تری را در الگوریتم شبکه عصبی به خصوص در تکرارهای نهایی ایفا می‌کند. اخیراً، الگوریتم بهینه‌سازی شبکه عصبی در کاربردهای مختلف مهندسی از قبیل پرینترهای سه بعدی [۲۹]، سلول‌های سوختی [۳۰، ۳۱]، و مسایل بهینه‌سازی مهندسی و چند هدفه [۳۲-۳۴] مورد استفاده قرار گرفته است.

۳-۷- مراحل الگوریتم شبکه عصبی

از آنجا که مقادیر کنونی متغیرهای طراحی بر مقادیر بعدی آن‌ها تاثیر می‌گذارند (یعنی همان بازخوردهای محلی و سراسری)، الگوریتم شبکه عصبی به عنوان یک مدل بهینه‌سازی پویا طبقه بندی می‌شود. از این رو، رفتار کلی الگوریتم شبکه عصبی را می‌توان در معادله (۱۹) توصیف کرد:

$$\vec{X}_i(t + \Delta t) = f(\vec{X}_i(t), P(t)) \quad , \quad i = 1, 2, 3, \dots, N_{pop} \quad (19)$$

که $\vec{X}_i(t)$ و $\vec{X}_i(t + \Delta t)$ به ترتیب نماد موقعیت‌های بعدی و کنونی راه حل الگوی i ام می‌باشند. $P(t)$ جمعیتی از راه‌حل‌های الگوی با وزن به روز شده است. معادله (۱۹) روند کلی الگوریتم شبکه عصبی را به عنوان یک مدل بهینه‌سازی پویا نشان می‌دهد و در نهایت به عنوان جمع‌بندی می‌توان مراحل روش پیشنهادی را به شرح زیر خلاصه کرد [۲۸]:

مرحله ۱: انتخاب تعداد راه‌حل‌های الگو (اندازه جمعیت) و حداکثر تعداد تکرار.

مرحله ۲: ایجاد یک جمعیت اولیه از راه حل الگو بین حد بالا و حد پایین پارامترهای طراحی.

مرحله ۳: محاسبه هزینه راه‌حل‌های الگوی اولیه.

مرحله ۴: تولید تصادفی ماتریس وزن (فاز آغازین) بین صفر و یک با در نظر گرفتن شرط قید شده (معادله (۱۳)).

مرحله ۵: تنظیم راه حل هدف (X^{Target}) (حداقل مقدار برای مسائل کمینه‌سازی) و وزن هدف متناظر با آن (W^{Target}).

مرحله ۶: ایجاد راه‌حل‌های الگوی جدید (X^{New}) و به روز رسانی راه‌حل‌های الگو با استفاده از معادلات (۱۴) و (۱۵).

مرحله ۷: به روز رسانی ماتریس وزن (W) با استفاده از معادله (۱۶) با در نظر گرفتن محدودیت‌های اعمال شده در معادله (۱۳).

مرحله ۸: بررسی وضعیت همگرایی. اگر $rand \leq \beta$ عملگر تصادفی برای راه‌حل‌های الگوی جدید و ماتریس وزن به روز رسانی شده اجرا می‌شود.

مرحله ۹: در غیر این صورت ($rand > \beta$) عملگر انتقال برای به روز رسانی موقعیت جدید راه‌حل‌های الگوی (X_i^*) با استفاده از معادله (۱۸) اعمال می‌شود.

مرحله ۱۰: محاسبه مقدار تابع هدف برای همه راه‌حل‌های الگوی به روز شده.

مرحله ۱۱: به روز رسانی راه حل هدف (یعنی بهترین راه حل زمانی) و وزن هدف متناظر آن.

گام ۱۲: به روزرسانی مقدار β با استفاده از فرمول کاهش پیشنهاد شده (رابطه ۱۸).

مرحله ۱۳: بررسی شرایط توقف از پیش تعیین شده. اگر معیار توقف ارضا شود، الگوریتم شبکه عصبی متوقف می‌شود. در غیر این صورت به مرحله ۶ باز می‌گردیم.

۴- نتایج و مباحث

در این مقاله، مشخصه جریان-ولتاژ (I-V) یک سلول خورشیدی سیلیکونی ۵۷ میلیمتری تجاری (R.T.C. فرانسه) برای شناسایی پارامترهای مجهول طراحی مبتنی بر الگوریتم شبکه عصبی (NNA) در نظر گرفته شده است. داده‌های تجربی از سیستمی که زیر تابش ۱ سان (مقداری معادل 1000 W/m^2) و در دمای ۳۳ درجه سانتیگراد قرار دارد، استخراج شده‌اند. در این تحقیق از روش تاگوچی [۳۵] برای تعیین پارامترهای بهینه الگوریتم شبکه عصبی (تعداد اعضای جمعیت و بیشترین تعداد تکرار) استفاده شده است. شایان ذکر است، الگوریتم حاضر به غیر از پارامترهای متداول بهینه سازی شامل تعداد اعضای جمعیت و بیشترین تکرار، پارامتر تنظیم دیگری ندارد، لذا سادگی در استفاده و برتری پاسخ بهینه از مزایای این روش بهینه سازی محسوب می‌شوند. 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 شده‌اند. تعداد دفعات اجرای بهینه سازی و الگوریتم برای شناسایی متغیرهای مجهول طراحی ۳۰ بار تکرار در نظر گرفته شده است. همچنین، از محیط نرم‌افزار MATLAB جهت شناسایی پارامترهای مجهول مدل سلول خورشیدی استفاده شده است. جدول ۳ نتایج آماری بدست آمده توسط روش الگوریتم شبکه عصبی را برای ۳ مدل در نظر گرفته شده سلول خورشیدی نشان می‌دهد.

جدول ۳. نتایج آماری بهینه سازی بدست آمده برای مدل‌های مختلف سلول خورشیدی توسط روش NNA.

مدل سلول خورشیدی	بدترین RMSE	میانگین RMSE	انحراف معیار RMSE	بهترین RMSE	ضریب تغییرات RMSE ^۱
تک دیودی	0.003838	0.0017789	۰,۰۰۰۵۱۶۱	0.00098666	۰,۲۹۰۱۲
دو دیودی	۰,۰۰۵۴۸۵	۰,۰۰۱۴۴۷۸	۰,۰۰۰۸۶۷۷	۰,۰۰۰۹۸۲۶۲	۰,۵۹۹۳۲
سه دیودی	۰,۰۰۸۶۵۲	۰,۰۰۱۴۲۷۸	۰,۰۰۱۴۴۸۳	۰,۰۰۰۹۸۴۳۵	۱,۰۱۴۱۴۷

جدول ۴ پارامترهای طراحی بهینه شده و مقدار RMSE را برای مدل‌های تک دیودی، دو دیودی، و سه دیودی را که توسط الگوریتم NNA استخراج شده‌اند، در مقایسه با سایر روش‌های بهینه سازی 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) [۱۷]، الگوریتم ژنتیک (GA) [۱۸]، الگوریتم بهینه‌سازی انبوه لانه زنبوری به صورت مصنوعی (ABSO) [۳۶]، الگوریتم‌های جستجوی الگو محور (PS) [۳۷]، روش بازپخت شبیه‌سازی شده (SA) [۱۹]، و جستجوی هارمونیک (HS) [۳۸] مقایسه و نمایش داده شده‌اند.

^۱ ضریب تغییرات برابر است با انحراف معیار داده‌ها تقسیم بر میانگین

همانطور که از جدول ۴ مشاهده می‌شود، مقادیر RMSE حاصل از الگوریتم شبکه عصبی در میان روش‌های دیگر، پایین‌ترین مقدار را دارد، به این معنی که پارامترهای استخراج شده از این روش، کمترین اختلاف را با پارامترهای یک سلول خورشیدی واقعی 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 نظر گیری این موضوع می‌توان ذکر کرد که الگوریتم شبکه عصبی (NNA) نتایجی بهتر و دقیق‌تری را برای مدل‌های تک دیودی، دودی، و سه دیودی نسبت به الگوریتم‌های برر سی شده ارائه داده است. این عملکرد در خصوص چهار روش PS، SA، CPSO، و GA به مراتب محسوس‌تر است.

جدول ۴. متغیرهای مجهول طراحی استخراج شده برای مدل‌های تک دیودی، 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]	GA [18]
$R_S(\Omega)$	0.036452	۰,۰۳۶۵	۰,۰۳۶۶	۰,۰۳۵۴	۰,۰۳۱۳	۰,۰۳۴۵	۰,۰۲۹۹
$R_{Sh}(\Omega)$	53.206652	۵۲,۲۹۰	۵۳,۵۹۴	۵۹,۰۱۲	۶۴,۱۰۲	۴۳,۱۰۳	۴۲,۳۷۲
$I_{ph}(A)$	0.760784	۰,۷۶۰۸	۰,۷۶۰۷	۰,۷۶۰۷	۰,۷۶۱۷	۰,۷۶۲	۰,۷۶۱۹
$I_{sd}(\mu A)$	0.317032	۰,۳۰۶۲	۰,۳۰۴۹	00۰,۴	۰,۹۹۸	۰,۴۷۹۸	۰,۸۰۸۷
n	1.479304	۱,۴۷۵۸	۱,۴۷۵۳	۱,۵۰۳۳	۱,۶۰۰۰	۱,۵۱۷۲	۱,۵۷۵۱
RMSE	9.866e-04	۹,۹۱e-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]
$R_S(\Omega)$	۰,۰۳۶۶۷۵	0.03657	0.0345	0.03545	0.0335	0.0320	0.0345
$R_{Sh}(\Omega)$	۵۵,۳۷۶۱۳۳	54.6219	60	46.8269	56.7361	81.3008	43.1034
$I_{ph}(A)$	۰,۷۶۰۷۷۸	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
$n1$	۱,۴۵۵۲۰۲	1.46512	1.4906	1.49439	1.5431	1.6000	1.5172
$n2$	۱,۹۹۵۷۰۹	1.98152	1.6617	1.49989	1.5442	1.1920	2.0000
RMSE	9.826e-04	9.834e-۴	0.0011	0.00126	0.0014	0.01518	0.01664
رتبه	1	۲	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 [۴۰]	SCA [42]	WOA [۴۱]
$R_S(\Omega)$	۰,۰۳۶۹۸۸	0.0346	0.0338	0.0351	0.0300	0.0302	0.0488
$R_{Sh}(\Omega)$	۵۶,۹۷۴۱۰	58.9166	54.8311	59.1165	50	60	58.6704
$I_{ph}(A)$	۰,۷۶۰۷۷۸	0.7611	0.7615	0.7614	0.7605	0.7560	0.7667
$I_{sd1}(\mu A)$	0.۱۷۵۵۴۸	0.30297	0.3897	0.3327	0.200	0.200	0.223
$I_{sd2}(\mu A)$	۱,۲۲۷۰۸۰	0.2238	0.3738	0.3997	0.400	0.359	0.390
$I_{sd3}(\mu A)$	۳,۵۴۵e-10	0.30436	0.3742	0.2217	0.399	0.400	0.390
$n1$	۱,۴۳۰۲۲۲	1.9892	1.8705	1.9463	1.5863	2	1.9539
$n2$	۱,۹۹۹۹۹۹	1.6676	1.5059	1.5218	2	2	1.7596
$n3$	۱,۰۰۰۰۰۰	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%

در خصوص نتایج بدست آمده توسط دو روش ABSO و HS برای مدل تک دیودی و دو دیودی، این نتایج به نتایج حاصله از الگوریتم پیشنهادی NNA نزدیک تر است و رقابت نزدیکتری میان این سه روش وجود دارد. همچنین، در جدول ۴ نتایج مدل سه دیودی بدست آمده از الگوریتم بهینه سازی شبکه عصبی با نتایج روش های الگوریتم بهینه سازی شعله-پروانه (MFO) [۴۰]، بهینه ساز مورچه شیر (ALO) [۴۴]، الگوریتم بهینه سازی سینوس-کسینوس (SCA) [۴۲]، بهینه سازی چند بیتی (MVO) [۴۳]، بهینه ساز گرگ خاکستری (GWO) [۳۹] و الگوریتم بهینه سازی نهنگ آشفته (WOA) [۴۱] که در منابع [۴۵] برای یک سلول خورشیدی ۵۷ میلی متری شرکت R.T.C فرانسه آورده شده اند، مقایسه شده اند. همان طور که مشاهده می شود، مقدار RMSE محاسبه شده توسط الگوریتم شبکه عصبی برای این مدل مقدار $9.843e-4$ است که این عدد پایین ترین مقدار در بین سایر روش ها محسوب می شود و این موضوع به این معناست که نتیجه مطالعه حاضر برای مدل سه دیودی نیز دقت بالاتری را نسبت به سایر روش ها دربردارد و متغیرهای استخراج شده از الگوریتم شبکه عصبی برای این مدل نیز به مقادیر واقعی متغیرهای سلول خورشیدی صنعتی، نزدیکترند. در واقع پایین بودن مقدار RMSE به این منزله است که متغیرهای استخراج شده از روش پیشنهادی، مقدار جریان محاسبه شده نزدیک تری را نسبت به جریان اندازه گیری شده که از مطالعه تجربی بر یک سلول خورشیدی R.T.C تجاری سیلیکونی با قطر ۵۷ میلیمتر بدست آمده است، استخراج می کند و این به معنی برتری روش الگوریتم بهینه سازی شبکه عصبی نسبت به سایر روش های ذکر شده است.

در ادامه، مقادیر جریان محاسبه شده که به کمک متغیرهای استخراج شده از روش الگوریتم شبکه عصبی و روابط بخش ۲ برای هر جفت داده جریان-ولتاژ بدست آمده اند به همراه جریان اندازه گیری شده و همچنین متغیر خطای نسبی که از رابطه (۲۰) محاسبه می شود، برای سه مدل تک دیودی، دو دیودی، و سه دیودی استخراج شده که در جداول ۵ تا ۷ آورده شده اند.

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

اندازه گیری	$I_t (A)$ محاسبه شده	$I_t (A)$ اندازه گیری شده	خطای نسبی	اندازه گیری	$I_t (A)$ محاسبه شده	$I_t (A)$ اندازه گیری 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

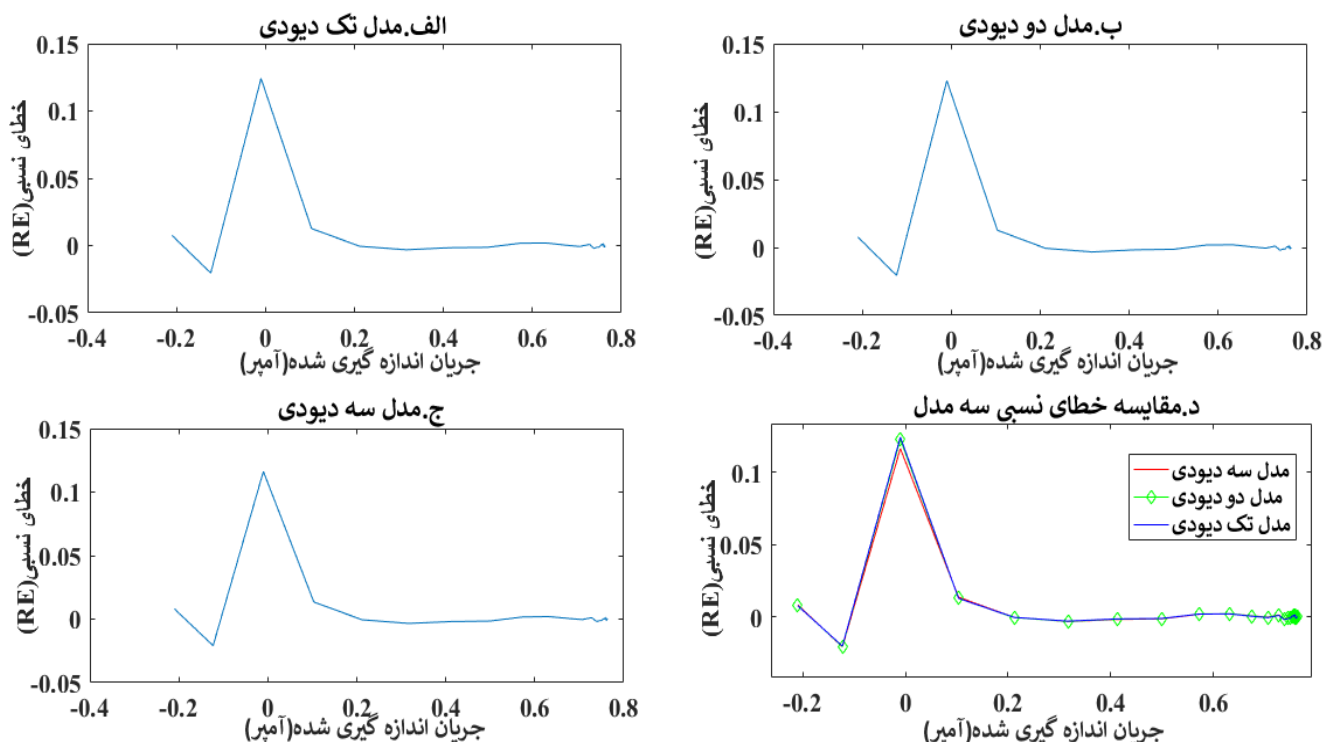
جدول ۶. داده های تجربی و محاسبه شده جریان به همراه خطای نسبی برای یک سلول خورشیدی تجاری سیلیکونی با قطر ۵۷ میلیمتر برای مدل دو دیودی.

اندازه گیری	$I_t (A)$ محاسبه شده	$I_t (A)$ اندازه گیری شده	خطای نسبی	اندازه گیری	$I_t (A)$ محاسبه شده	$I_t (A)$ اندازه گیری 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. داده های تجربی و محاسبه شده جریان به همراه خطای نسبی برای یک سلول خورشیدی تجاری سیلیکونی با قطر ۵۷ میلیمتر برای مدل سه دیودی.

اندازه گیری	$I_t (A)$ محاسبه شده	$I_t (A)$ اندازه گیری شده	خطای نسبی	اندازه گیری	$I_t (A)$ محاسبه شده	$I_t (A)$ اندازه گیری شده	خطای نسبی
1	0.763893	۰,۷۶۴	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

همچنین می توان با استفاده از مقادیر بدست آمده از جریان محاسبه شده و مقادیر خطای نسبی برای هر جفت داده آزمایشگاهی که در جداول ۵ تا ۷ آورده شده اند، نمودار خطای نسبی برای مقادیر اندازه گیری 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 مقایسه ای آن ها در یک نمودار (نمودار د-۴) نمایش داده شده اند. همانطور که در نمودار د-۴ دیده می شود، مقدار بیشینه متغیر خطای نسبی برای هر جفت داده تجربی جریان-ولتاژ و به تناظر آن هر جفت داده جریان اندازه گیری شده-جریان محاسبه شده در مجاورت جریان اندازه گیری شده صفر آمپر اتفاق می افتد.







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.





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 تکینگی 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 دقیق‌تری را نسبت به دو مدل دیگر ارائه داده است. در معادله (۲۰)، خطای نسبی محاسبه شده برای داده‌ها آورده شده است:

$$RE = \frac{I_c - I_m}{I_m} \quad (20)$$

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 (I-V) 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.



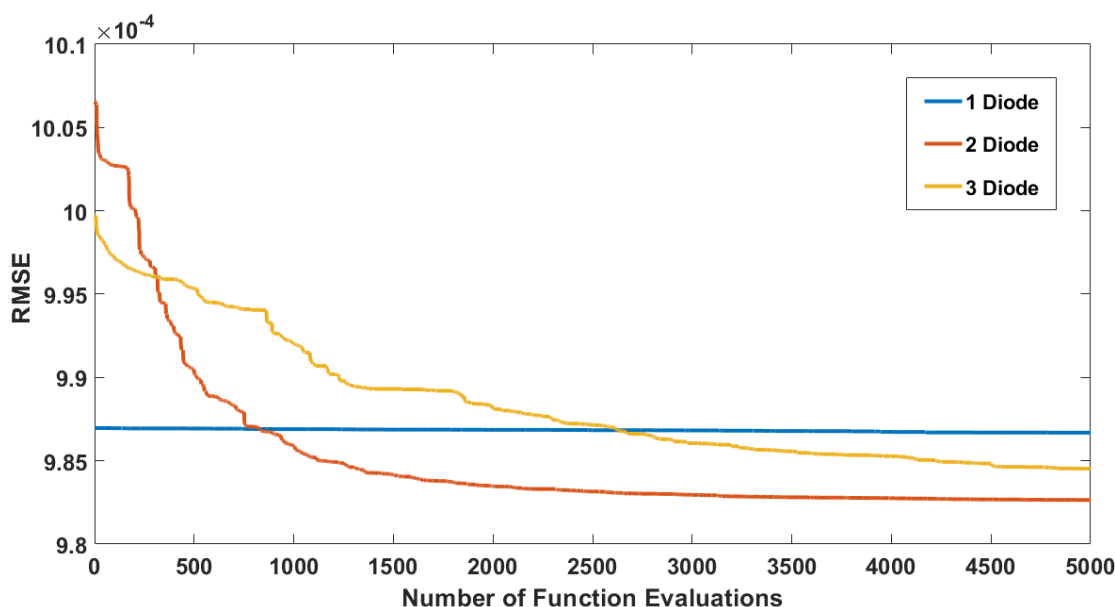
شکل ۵. نمودارهای مشخصه ولتاژ-جریان محاسبه شده (I-V) برای الف) مدل تک دیودی، ب) مدل دو دیودی، ج) مدل سه دیودی، و د) مقایسه جریان های محاسبه شده هر سه مدل با جریان اندازه گیری شده.



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 جریان های محاسبه شده هر سه مدل با جریان اندازه گیری شده.

همچنین فرآیند 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 می شود، سرعت بالای همگرایی روش NNA در مقدار

تابع در مراحل ابتدایی نشان از سرعت و دقت این روش بهینه سازی برای حل مسایل بهینه سازی در صنعت سلول های خورشیدی دارد. همانطور که در شکل ۷ دیده میشود، در مدل تک دیودی به دلیل تعداد کم متغیرهای طراحی و ساده تر بودن مدل بهینه سازی، الگوریتم بهینه سازی شبکه عصبی در همان تکرارهای اول جواب بهینه جهانی را بدست آورده و تا انتهای تکرار تغییرات جزئی بر روی جواب بهینه اعمال کرده است. در صورتیکه این روند برای مدل های بهینه سازی دو و سه دیودی دیده نمیشود که نشان از پیچیده تر شدن فضای جستجو دارد.



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

۵- نتیجه گیری و کارهای آتی

در این مقاله، الگوریتم بهینه سازی شبکه عصبی (Neural Network Algorithm, NNA) برای به دست آوردن نتایج دقیق مدل های تک، دو، و سه دیودی سلول های خورشیدی مورد مطالعه قرار گرفته است. الگوریتم بهینه سازی شبکه عصبی با ایده گرفتن از ساختار منحصر به فرد شبکه های عصبی در مغز انسان توانسته است یک مدل بهینه سازی کارا برای حل مسایل بهینه سازی 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 بدست آمده توسط الگوریتم پیشنهادی کاملاً امیدوارکننده بوده و بر نتایجی که از منابع گزارش شده است، غلبه می کند. در هر ۳ مدل دیودی، الگوریتم شبکه عصبی جواب های دقیق تر و بهینه تری را پیشنهاد داده است. این امر بویژه در مدل دو و سه دیودی که تعداد پارامترهای مجهول طراحی بیشتر است (پیچیدگی غیرخطی مساله بالاتر است) بارزتر است که نشان از عملکرد موفق الگوریتم پیشنهادی در حل مسایل پیچیده تر با ماهیت غیرخطی دارد. در نتیجه، الگوریتم بهینه سازی شبکه عصبی می تواند جایگزین خوبی برای حل مسایل بهینه سازی سیستم های سلول خورشیدی قلمداد شود. به عنوان تحقیقات آتی، با بهبود راندمان عملگرهای جستجوی الگوریتم بهینه سازی شبکه عصبی، میتوان به دقت های بالاتری دست یافت. همچنین، از مدل های سلول خورشیدی با تعداد دیود بیشتر (پیچیده تر شدن مساله بهینه سازی) 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 مدل های بهینه سازی چند هدفه واقعی تر و کاربردی تری در این حوزه تحقیقاتی فعال و اثرگذار تعریف کرد.

- [1] M. Arshad, Clean and sustainable energy technologies, in: Clean energy for sustainable development, Elsevier, 2017, pp. 73-89.
- [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*, 6(4) (2018) 1313-1322.
- [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*, 35(4) (2020) 2642-2657.
- [4] T. Ma, H. Yang, L. Lu, Solar photovoltaic system modeling and performance prediction, *Renewable and Sustainable Energy Reviews*, 36 (2014) 304-315.
- [5] A.S. Al-Sumaiti, M.H. Ahmed, S. Rivera, M.S. El Moursi, M.M. Salama, T. Alsumaiti, Stochastic PV model for power system planning applications, *IET Renewable Power Generation*, 13(16) (2019) 3168-3179.
- [6] V.L. Brano, A. Orioli, G. Ciulla, A. Di Gangi, An improved five-parameter model for photovoltaic modules, *Solar Energy Materials and Solar Cells*, 94(8) (2010) 1358-1370.
- [7] A.S. Al-Sumaiti, M. Salama, S.R. Konda, A. Kavousi-Fard, A guided procedure for governance institutions to regulate funding requirements of solar PV projects, *IEEE Access*, 7 (2019) 54203-54217.
- [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*, 91(1) (2012) 395-404.
- [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*, 102 (2013) 1160-1177.
- [10] L. Sandrolini, M. Artioli, U. Reggiani, Numerical method for the extraction of photovoltaic module double-diode model parameters through cluster analysis, *Applied Energy*, 87(2) (2010) 442-451.
- [11] F. Bonanno, G. Capizzi, G. Graditi, C. Napoli, G.M. Tina, A radial basis function neural network based approach for the electrical characteristics estimation of a photovoltaic module, *Applied Energy*, 97 (2012) 956-961.
- [12] V. Khanna, B. Das, D. Bisht, P. Singh, A three diode model for industrial solar cells and estimation of solar cell parameters using PSO algorithm, *Renewable Energy*, 78 (2015) 105-113.
- [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*, 4(1) (1986) 1-12.
- [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*, 81(2) (2004) 269-277.
- [15] H. Saleem, 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*, 30(4) (2009) 349-352.
- [16] D. Chan, J. Phillips, J. Phang, A comparative study of extraction methods for solar cell model parameters, *Solid-State Electronics*, 29(3) (1986) 329-337.
- [17] H. Wei, J. Cong, X. Lingyun, S. Deyun, Extracting solar cell model parameters based on chaos particle swarm algorithm, in: 2011 International conference on electric information and control engineering, IEEE, 2011, pp. 398-402.
- [18] M. AlRashidi, M. AlHajri, K. El-Naggar, A. Al-Othman, A new estimation approach for determining the I–V characteristics of solar cells, *Solar Energy*, 85(7) (2011) 1543-1550.
- [19] K.M. El-Naggar, M. AlRashidi, M. AlHajri, A. Al-Othman, Simulated annealing algorithm for photovoltaic parameters identification, *Solar Energy*, 86(1) (2012) 266-274.

- [20] M. Gómez, A. López, F. Jurado, Optimal placement and sizing from standpoint of the investor of photovoltaics grid-connected systems using binary particle swarm optimization, *Applied Energy*, 87(6) (2010) 1911-1918.
- [21] O. Ekren, B.Y. Ekren, Size optimization of a PV/wind hybrid energy conversion system with battery storage using simulated annealing, *Applied energy*, 87(2) (2010) 592-598.
- [22] C.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*, 37(19) (2012) 14781-14785.
- [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*, 88(12) (2011) 4817-4830.
- [24] T. Ayodele, A. Ogunjuyigbe, E. Ekoh, Evaluation of numerical algorithms used in extracting the parameters of a single-diode photovoltaic model, *Sustainable Energy Technologies and Assessments*, 13 (2016) 51-59.
- [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*, 435 (2019) 126683.
- [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*, 8(11) (2018) 2155.
- [27] C. Dai, W. Chen, Y. Zhu, Seeker optimization algorithm for digital IIR filter design, *IEEE transactions on industrial electronics*, 57(5) (2009) 1710-1718.
- [28] A. Sadollah, H. Sayyaadi, A. Yadav, A dynamic metaheuristic optimization model inspired by biological nervous systems: Neural network algorithm, *Applied Soft Computing*, 71 (2018) 747-782.
- [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*, 12(10) (2020) 2250.
- [30] M.S. AbouOmar, H.-J. Zhang, Y.-X. Su, Fractional order fuzzy PID control of automotive PEM fuel cell air feed system using neural network optimization algorithm, *Energies*, 12(8) (2019) 1435.
- [31] M. Fawzi, A.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*, 43(14) (2019) 8136-8147.
- [32] Y. Zhang, Z. Jin, Y. Chen, Hybrid teaching-learning-based optimization and neural network algorithm for engineering design optimization problems, *Knowledge-Based Systems*, 187 (2020) 104836.
- [33] Y. Zhang, Z. Jin, Y. Chen, Hybridizing grey wolf optimization with neural network algorithm for global numerical optimization problems, *Neural Computing and Applications*, 32 (2020) 10451-10470.
- [34] D. Khurana, A. Yadav, A. Sadollah, A non-dominated sorting based multi-objective neural network algorithm, *MethodsX*, 10 (2023) 102152.
- [35] D. Montgomery, *Design and Analysis of Experiments* (6th edn.) John Wiley and Sons, New York, NY, (2005).
- [36] A. Askarzadeh, A. Rezaadeh, Artificial bee swarm optimization algorithm for parameters identification of solar cell models, *Applied energy*, 102 (2013) 943-949.
- [37] M. AlHajri, K. El-Naggar, M. AlRashidi, A. Al-Othman, Optimal extraction of solar cell parameters using pattern search, *Renewable energy*, 44 (2012) 238-245.
- [38] A. Askarzadeh, A. Rezaadeh, Parameter identification for solar cell models using harmony search-based algorithms, *Solar Energy*, 86(11) (2012) 3241-3249.

- [39] S. Mirjalili, S.M. Mirjalili, A. Lewis, Grey wolf optimizer, *Advances in engineering software*, 69 (2014) 46-61.
- [40] S. Mirjalili, Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm, *Knowledge-based systems*, 89 (2015) 228-249.
- [41] D. Oliva, M. Abd El Aziz, A.E. Hassanien, Parameter estimation of photovoltaic cells using an improved chaotic whale optimization algorithm, *Applied energy*, 200 (2017) 141-154.
- [42] S. Mirjalili, SCA: a sine cosine algorithm for solving optimization problems, *Knowledge-based systems*, 96 (2016) 120-133.
- [43] S. Mirjalili, S.M. Mirjalili, A. Hatamlou, Multi-verse optimizer: a nature-inspired algorithm for global optimization, *Neural Computing and Applications*, 27 (2016) 495-513.
- [44] S. Mirjalili, The ant lion optimizer, *Advances in engineering software*, 83 (2015) 80-98.
- [45] E.H. Houssein, G.N. Zaki, A.A.Z. Diab, E.M. Younis, An efficient Manta Ray Foraging Optimization algorithm for parameter extraction of three-diode photovoltaic model, *Computers & Electrical Engineering*, 94 (2021) 107304.