

# مدل سازی نیروگاه خورشیدی با استفاده از شبکه عصبی مبتنی بر مدار معادل تک دیود

علیرضا رئیسی و روح اله عبداللهی

[۵] و [۶].

به طور کلی می توان گفت که مدل سازی دقیق مشخصه های ولتاژ- جریان برای طراحی و بهره برداری بهینه نیروگاه های PV متصل به شبکه، اهمیت حیاتی دارد. تاکنون روش های مختلفی جهت مدل سازی پنل های خورشیدی ارائه شده [۷] تا [۱۰] که به طور کلی به سه دسته روش های مبتنی بر هوش مصنوعی، روش های مبتنی بر مدار معادل و روش های ترکیبی تقسیم بندی می شوند.

در روش های مبتنی بر هوش مصنوعی، معمولاً از شبکه های عصبی جهت مدل سازی یا شناسایی پنل خورشیدی استفاده می شود. در این نوع مدل سازی، شرایط جوی (شدت نور و دما) معمولاً ورودی های شبکه عصبی می باشند و خروجی ها منحنی مشخصه ولتاژ- جریان پنل خورشیدی هستند. دقت مدل سازی پنل های خورشیدی در مقایسه با روش های دیگر کمتر است [۱۰] و [۱۱]. در برخی از مقالات جهت بهبود دقت علاوه بر شرایط جوی، ولتاژ نیز به عنوان ورودی لحاظ شده و خروجی فقط جریان یا توان است؛ اما چندان بهبودی در دقت مدل سازی ایجاد نشد. لذا مدل سازی پنل های خورشیدی با این روش ها کمتر مورد توجه قرار گرفته اند و در موضوعاتی مانند تشخیص خطا [۱۲]، پیش بینی انرژی تولیدی [۱۳]، تخمین برخی پارامترها مثل دمای سلول خورشیدی [۱۴]، میزان تابش روزهای ابری [۱۵] و تلفات ناشی از کثیفی [۱۶] بیشتر مورد استفاده قرار گرفته اند.

دسته دوم، روش های مبتنی بر مدار معادل هستند [۱۷]. در این روش ها که هدف مدل سازی مشخصه های ولتاژ- جریان است، پنل خورشیدی توسط یک مدار غیرخطی شامل منبع جریان وابسته، دیودها و مقاومت ها مدل سازی می شود [۱۸]. محاسبه یا استخراج پارامترهای مجهول این مدار غیرخطی، چالش اصلی این نوع مدل سازی است؛ چرا که وابسته به شرایط جوی هستند. معمولاً جهت ساده سازی، فقط مقادیر جریان فتوولتائیک و جریان اشباع دیود به صورت تابعی از شرایط جوی لحاظ می گردند و مقادیر مقاومت های سری و موازی و ثابت ایده آلی دیود، عدد ثابت در نظر گرفته می شوند؛ اما عملاً این سه پارامتر ثابت نیستند [۱۹] و [۲۰] و این امر منجر به کاهش دقت مدل سازی می گردد. چالش دیگر وابسته بودن محاسبه پارامترهای مجهول به داده های کارخانه سازنده (کاتالوگ) پنل خورشیدی است. این داده ها با گذر زمان تغییر می کنند؛ لذا دقت مدل سازی در این روش با گذر زمان کم می شود. این موارد در دقت مدل سازی نیروگاه خورشیدی که از اتصال پنل های خورشیدی تشکیل شده اند، بیشتر نمایان می شود.

دسته سوم، روش های ترکیبی هستند که معایب روش های قبلی را ندارند. در این روش ها، هم از مدار معادل و هم از شبکه های عصبی برای مدل سازی مشخصه های ولتاژ- جریان پنل های خورشیدی استفاده شده

چکیده: روش های مختلفی جهت مدل سازی پنل های خورشیدی ارائه شده است؛ اما مدل سازی نیروگاه خورشیدی با استفاده از آنها با چالش هایی همراه می باشد. مدل سازی در روش های مبتنی بر مدار معادل، وابسته به داده های کارخانه سازنده است که با گذر زمان تغییر می کنند. مدل سازی مشخصه ولتاژ- جریان با استفاده از روش های هوشمند مانند شبکه عصبی به علت دقت پایین مدل سازی کمتر مورد توجه قرار گرفت. در این مقاله، روشی مستقل از داده های کارخانه سازنده جهت مدل سازی نیروگاه خورشیدی ارائه می شود؛ چنان که امکان مدل سازی دقیق نیروگاه های خورشیدی چند سال نصب شده نیز فراهم می باشد. روش پیشنهادی شامل دو مرحله است؛ در مرحله اول ولتاژ مدار باز، نقطه حداکثر توان و جریان اتصال کوتاه برحسب شرایط جوی با استفاده از شبکه عصبی مدل می شوند. در مرحله دوم پارامترهای مجهول مدار معادل توسط روابط تحلیل مداری و با استفاده از خروجی های شبکه عصبی تعیین می شوند. نهایتاً جهت ارزیابی روش پیشنهادی، مدل سازی یک نیروگاه خورشیدی ۳ کیلووات انجام شد که نتایج، دقت مناسب روش پیشنهادی جهت مدل سازی نیروگاه خورشیدی را نشان می دهند.

کلیدواژه: مدل سازی، نیروگاه خورشیدی، شبکه عصبی، مدار معادل تک دیود.

## ۱- مقدمه

اخیراً سیستم های تولید برق فتوولتائیک (PV) به عنوان یکی از مهم ترین فناوری های استفاده از انرژی خورشیدی به طور گسترده در سیستم های قدرت ادغام شده اند. این ادغام گسترده به دلیل چندین مزیت سیستم های PV از جمله نصب و بهره برداری آسان، هزینه کم و راندمان و طول عمر بالا در مقایسه با سایر منابع انرژی تجدیدپذیر و سازگاری با محیط زیست است [۱] و [۲]. با این حال این ادغام در کنار مزایای فراوان، چالش هایی را برای ریز شبکه ها داشته است؛ چرا که از یک سو توان تولید این نیروگاه ها وابسته به نور خورشید است؛ یعنی متناوب و غیرقابل برنامه ریزی است و از سوی دیگر توان این نیروگاه ها در مدیریت مصرف و کنترل بار فرکانس ریز شبکه ها تأثیر دارد [۳] و [۴]. به عبارت دیگر داشتن یک مدل دقیق از رفتار و عملکرد یک پنل خورشیدی تحت شرایط جوی متغیر سالانه جهت طراحی بهینه و بهره برداری مناسب منجر به توسعه به کارگیری این نوع از منابع تجدیدپذیر در سیستم های قدرت خواهد شد

این مقاله در تاریخ ۲ شهریور ماه ۱۴۰۲ دریافت و در تاریخ ۲۱ فروردین ماه ۱۴۰۳ بازنگری شد.

علیرضا رئیسی (نویسنده مسئول)، گروه مهندسی برق، دانشگاه ملی مهارت، تهران، ایران، (email: areisi@tvu.ac.ir).

روح اله عبداللهی، گروه مهندسی برق، دانشگاه ملی مهارت، تهران، ایران، (email: abdollahi@tvu.ac.ir).

## ۲- بیان مسئله

روش‌های دقیق مدل‌سازی پنل‌های خورشیدی عمدتاً مبتنی بر مدار معادل هستند. شکل ۱ مدار معادل یک پنل خورشیدی را نشان می‌دهد. با در نظر گرفتن پارامترهای شکل ۱ و روابط تحلیل مداری، مشخصه پنل خورشیدی عبارت است از [۲۴]

$$I = I_S - I_O \left[ \exp \frac{V + R_S I}{a V_t} - 1 \right] - \frac{V + R_S I}{R_p} \quad (۱)$$

که  $I_S$  جریان فتولتائیک،  $I_O$  جریان اشباع معکوس،  $V_t = N_S K T / q$  ولتاژ حرارتی،  $q$  بار الکترون،  $K$  ثابت بولتزمن،  $T$  دمای سلول،  $a$  ثابت ایده‌آلی دیود،  $N_S$  تعداد سلول‌های سری شده و  $R_S$  و  $R_p$  مقاومت معادل‌های سری و موازی پنل خورشیدی هستند که  $I_O$  و  $I_{PV}$  با شدت نور و تغییر دما به صورت زیر مرتبط می‌باشند

$$I_S = (I_{S,n} + K_I \Delta T) \frac{G}{G_n} \quad (۲)$$

$$I_O = \frac{I_{SC,n} + K_I \Delta T}{\exp(V_{OC,n} + K_V \Delta T) - 1} \frac{1}{a V_t} \quad (۳)$$

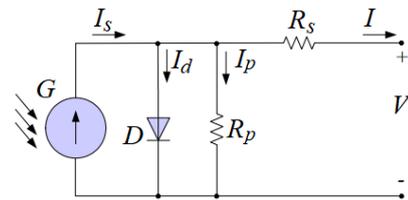
که در آن  $I_{S,n}$  جریان فتولتائیک در شرایط استاندارد ( $T_n = 25^\circ C$ ) و  $T_n = 25^\circ C$  و  $G_n = 1000 W/m^2$ ،  $K_I$  ضریب نسبت جریان اتصال کوتاه به دما،  $\Delta T = T - T_n$  میزان اختلاف دما با دمای استاندارد و  $G$  شدت نور هستند. همچنین  $I_{SC,n}$  و  $V_{OC,n}$  به ترتیب جریان اتصال کوتاه و ولتاژ مدار باز در شرایط استاندارد و  $K_V$  ضریب نسبت ولتاژ مدار باز به دما می‌باشند. ولتاژ مدار باز و جریان اتصال کوتاه از نقاط مهم مشخصه I-V پنل خورشیدی هستند که با تغییر شرایط جوی تغییر می‌کنند. با استفاده از (۴) و (۵) که از روابط مدل استخراج می‌شوند می‌توان جریان اتصال کوتاه و ولتاژ مدار باز را در شرایط جوی مختلف محاسبه کرد

$$I_{SC} = (I_{SC,n} + K_I \Delta T) \frac{G}{G_n} \quad (۴)$$

$$V_{OC} = V_{OC,n} + K_V \Delta T \quad (۵)$$

در برگه اطلاعات سازنده یک ماژول PV، اطلاعاتی مانند ولتاژ مدار باز ( $V_{OC}$ )، جریان اتصال کوتاه ( $I_{SC}$ )، مقدار حداکثر توان ( $P_{MPP}$ )، مقادیر جریان و ولتاژ در MPP و ضرایب دمایی ولتاژ و جریان ( $K_V$  و  $K_I$ ) فهرست شده‌اند. اما در کاتالوگ‌ها اطلاعاتی مربوط به عملکرد سلول خورشیدی مانند جریان نوری ( $I_S$ )، جریان اشباع ( $I_O$ )، ضریب ایده‌آل بودن دیود ( $a$ )، مقاومت سری ( $R_S$ ) و مقاومت شنت ( $R_p$ ) ارائه نشده و این مقادیر مجهول هستند. این در حالی است که این پارامترهای مجهول برای مدل‌سازی یک ماژول PV ضروری هستند.

تاکنون روش‌های مختلفی بر اساس مدار معادل شکل ۱ جهت مدل‌سازی پنل خورشیدی ارائه شده که این روش‌ها در تعیین و استخراج پارامترهای مجهول با هم متفاوت هستند. در روش‌های تحلیلی، استخراج پارامترها مبتنی بر داده‌های کارخانه‌ای مثل  $K_V$ ،  $K_I$ ،  $I_{SC,n}$  و  $V_{OC,n}$  است؛ اما این داده‌ها برای پنل خورشیدی با گذر زمان تغییر می‌کنند و لذا خطای مدل‌سازی افزایش می‌یابد. چالش روش‌های ترکیبی در مدل‌سازی پنل‌های خورشیدی، جمع‌آوری داده‌ها برای آموزش شبکه عصبی است و این در حالی است که مقادیر پارامترهای مجهول قابل اندازه‌گیری نیستند و باید به نحوی محاسبه شوند. به عبارت دیگر، مدل‌سازی یک نیروگاه خورشیدی با روش‌های تحلیلی و روش‌های ترکیبی امکان‌پذیر نیست.



شکل ۱: مدار معادل تک‌دیود پنل خورشیدی.

است [۲۱] و [۲۲]. در این روش‌ها نخست شبکه عصبی برحسب شرایط جوی، پارامترهای مجهول مدار معادل را تعیین می‌کند. سپس این پارامترها در رابطه اصلی مدار معادل غیرخطی قرار می‌گیرند و امکان محاسبه مشخصه ولتاژ-جریان شامل ولتاژ مدار باز، جریان اتصال کوتاه و نقطه حداکثر توان فراهم می‌گردد. چالش اصلی این روش‌ها، نحوه آموزش شبکه عصبی است. شبکه عصبی برای آموزش، نیاز به مجموعه‌ای از داده‌های ورودی و خروجی متناظر دارد؛ اما اندازه‌گیری و جمع‌آوری این داده‌ها عملاً امکان‌پذیر نیست.

روش‌های مختلف مدل‌سازی پنل‌های خورشیدی، هر کدام چالش‌هایی دارند. مدل‌سازی منحنی مشخصه ولتاژ-جریان با استفاده از شبکه‌های عصبی علاوه بر پیچیدگی، با دقت کم همراه است. مدل‌سازی پنل‌های خورشیدی بر اساس روش‌های تحلیلی مبتنی بر مدار معادل وابسته به داده‌های کارخانه سازنده است. این داده‌ها با گذر زمان تغییر می‌کنند و در دسترس نیستند. همچنین مدل‌سازی پنل‌های خورشیدی به روش‌های ترکیبی که در [۲۳] ارائه شده‌اند، اگرچه وابسته به داده‌های کارخانه نیستند و همچنین دقت مطلوبی ارائه می‌دهند، اندازه‌گیری و جمع‌آوری داده‌های مورد نیاز (پارامترهای مجهول مدار معادل) برای نیروگاه‌های خورشیدی عملاً امکان‌پذیر نیست.

در این راستا، این مقاله یک روش ترکیبی جدید جهت مدل‌سازی نیروگاه خورشیدی ارائه می‌کند که هم دقت مناسبی دارد، هم مستقل از داده‌های کاتالوگ است و هم پیاده‌سازی و اجرای آن ساده می‌باشد. روش ارائه‌شده در این مقاله، ترکیبی از روش‌های تحلیل مداری و شبکه عصبی است؛ چنان که امکان مدل‌سازی نیروگاه‌های خورشیدی چند سال نصب‌شده فراهم می‌گردد. در روش پیشنهادی، نخست با استفاده از شبکه عصبی، سه نقطه مهم منحنی مشخصه ولتاژ-جریان (ولتاژ مدار باز، جریان اتصال کوتاه و حداکثر توان) برحسب شرایط جوی به‌عنوان مقادیر ورودی شبکه عصبی مدل‌سازی می‌شوند. پس از آن با استفاده از این سه نقطه و به کمک روابط تحلیل مداری، پنج پارامتر مجهول محاسبه می‌شوند. در روش پیشنهادی، شرایط جوی، ورودی و پنج پارامتر مجهول، خروجی الگوریتم می‌باشند که هر پنج پارامتر مجهول، متغیر و تابعی از شرایط جوی هستند. به‌طور خلاصه نوآوری‌های این مقاله عبارت هستند از

- روش جدید، ساده و کاربردی جهت مدل‌سازی نیروگاه خورشیدی مبتنی بر مدار معادل تک‌دیود
- مدل‌سازی سه نقطه مهم مشخصه I-V با استفاده از شبکه عصبی
- مدل‌سازی بر اساس داده‌های روزانه و مستقل از داده‌های کاتالوگ
- بحث و بررسی اثر نوع داده‌ها و اثر گذر زمان بر الگوریتم مدل‌سازی بخش‌های بعدی مقاله حاضر بدین شرح ساماندهی شده است: در بخش دوم، بیان مسئله آورده شده و بخش سوم به تشریح روش پیشنهادی می‌پردازد. عملکرد روش پیشنهادی در بخش چهارم ارائه و بحث می‌شود. در بخش انتهایی، نتایج کلی حاصل از مطالعه حاضر جمع‌بندی می‌گردند.

برای شروع فرایند آموزش در ابتدا مقادیر وزن ها و بایاس به صورت تصادفی، مقداردهی اولیه می شوند. در فرایند آموزش همواره مقادیر گرادیان و شاخص های عملکردی RMSE محاسبه شده و بر اساس آنها الگوریتم آموزش، مقدار وزن ها را به روزرسانی می کند. این به روزرسانی وزن ها تا رسیدن به مقدار بهینه شاخص عملکرد RMSE ادامه می یابد. الگوریتم آموزش به کاررفته در این مقاله، LMA<sup>۱</sup> است که فرایند آموزش را برای به دست آوردن یک مجموعه وزن بهینه  $\{w_k\}$  و مجموعه بایاس  $\{b\}$  ادامه می دهد تا عملکرد شاخص RMSE بین خروجی های شبکه و مقدار هدف مربوط را به حداقل برساند.

لازم به ذکر است که دمای استفاده شده در این مقاله، دمای سلول می باشد که با اندازه گیری دمای پشت پنل خورشیدی به دست آمده است.

### ۲-۳ تحلیل مداری

برای ترسیم مشخصه های V-I پنل خورشیدی، لازم است پنج پارامتر  $a, I_S, I_O, R_S, R_P$  محاسبه یا استخراج شوند. ضریب  $a$  مقداری بین ۱ و ۲ دارد که در اینجا به صورت (۱۶)، معکوس ضریب پرکنندگی، لحاظ می شود

$$a = \frac{I_{SC}^{NN} \times V_{OC}^{NN}}{P_m^{NN}} \quad (۷)$$

با مقایسه  $I_{SC}^{NN}$  و  $V_{OC}^{NN}$  با (۴) و (۵) و جایگذاری آنها در (۳) داریم

$$I_O = \frac{I_{SC}^{NN}}{\exp(V_{OC}^{NN}/aV_t) - 1} \quad (۸)$$

همچنین با استفاده از نسبت  $I_{S,n}/I_{SC,n} = (R_P + R_S)/R_P$  [۲۴]، رابطه زیر جایگزین (۲) خواهد شد

$$I_S = I_{SC}^{NN} \times \frac{R_P + R_S}{R_P} \quad (۹)$$

با توجه به اینکه مقادیر ولتاژ و جریان در نقطه حداکثر توان به ترتیب تقریباً برابر با ۰٫۷ ولتاژ مدار باز و ۰٫۹ جریان اتصال کوتاه هستند  $(I_m \approx ۰٫۹ \times I_{SC}$  و  $V_m \approx ۰٫۷ \times V_{OC})$ ، می توان مقادیر اولیه مقاومت های  $R_P$  و  $R_S$  را توسط (۱۰) و (۱۱) تعیین کرد

$$R_P = \frac{V_m}{I_{SC} - I_m} \approx ۷ \times \frac{V_{OC}}{I_{SC}} \quad (۱۰)$$

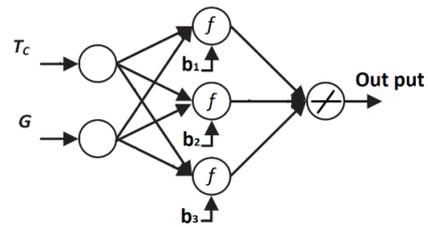
$$R_S = \frac{V_{OC} - V_m}{I_m} \approx ۰٫۳۴ \times \frac{V_{OC}}{I_{SC}} \quad (۱۱)$$

برای محاسبه دو پارامتر  $R_S$  و  $R_P$ ، نقاط مدار باز و اتصال کوتاه را در (۱) جایگذاری می کنیم

$$0 = I_S - I_O \left[ \exp \frac{V_{OC}}{aV_t} - 1 \right] - \frac{V_{OC}}{R_P} \quad (۱۲)$$

$$I_{SC} = I_S - I_O \left[ \exp \frac{R_S I_{SC}}{aV_t} - 1 \right] - \frac{R_S I_{SC}}{R_P} \quad (۱۳)$$

در نتیجه، الگوریتم روش پیشنهادی مبتنی بر شبکه عصبی و تحلیل مداری، (۷) تا (۱۳) برای تعیین مشخصه های ولتاژ-جریان بر اساس (۱) به صورت شکل ۳ است.



شکل ۲: ساختار شبکه عصبی.

در بخش بعدی، روش پیشنهادی ارائه می شود. بر اساس این روش، ابتدا ولتاژ و جریان سه نقطه اتصال کوتاه، مدار باز و حداکثر توان برحسب شرایط جوی مدل می شوند. در مرحله بعد با استفاده از خروجی های شبکه عصبی و روابط تحلیل مداری، پارامترهای مجهول استخراج می گردند.

### ۳- روش پیشنهادی

روش پیشنهادی جهت مدل سازی نیروگاه خورشیدی، بدون نیاز به داده های کاتالوگ، شامل دو مرحله شبکه عصبی و تحلیل مداری است. در مرحله اول با استفاده از شبکه عصبی، سه نقطه مهم مشخصه ولتاژ-جریان برحسب شرایط جوی مدل می شود. در مرحله دوم بر اساس روابط تحلیل مداری و با استفاده از خروجی های شبکه عصبی، پارامتر مجهول مدار معادل محاسبه می شود. در ادامه هر کدام از مراحل شرح داده شده اند.

#### ۳-۱ شبکه عصبی

شبکه های عصبی، تکنیکی قدرتمند جهت مدل سازی رفتار سیستم های غیرخطی هستند. از این تکنیک به طور قابل توجهی برای مدل سازی و پیش بینی پدیده های مختلف سیستم های فتوولتائیک استفاده شده و از این رو در این مقاله جهت مدل سازی سه نقطه مهم مشخصه I-V نیروگاه خورشیدی از این شبکه ها استفاده می شود.

یک شبکه عصبی از مجموعه ای نورون ها تشکیل شده که پیام ها بین آنها مبادله می شوند. ارتباط بین نورون ها با وزن ها تنظیم و مشخص می شود. مدل پرسپترون چندلایه (MLP)، نوعی شبکه عصبی است که از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه پنهان ساخته شده است. تعداد نورون ها در لایه های ورودی و خروجی به ترتیب با تعداد متغیرهای ورودی و خروجی برابر هستند؛ اما تعداد نورون های لایه های پنهان قابل تنظیم می باشند. شکل ۲ ساختار این نوع شبکه عصبی را نشان می دهد. در ساختار این نوع شبکه ها در هر لایه پنهان یک ورودی قابل تنظیم با عنوان بایاس نیز وجود دارد که به تمام نورون های لایه بعدی متصل است.

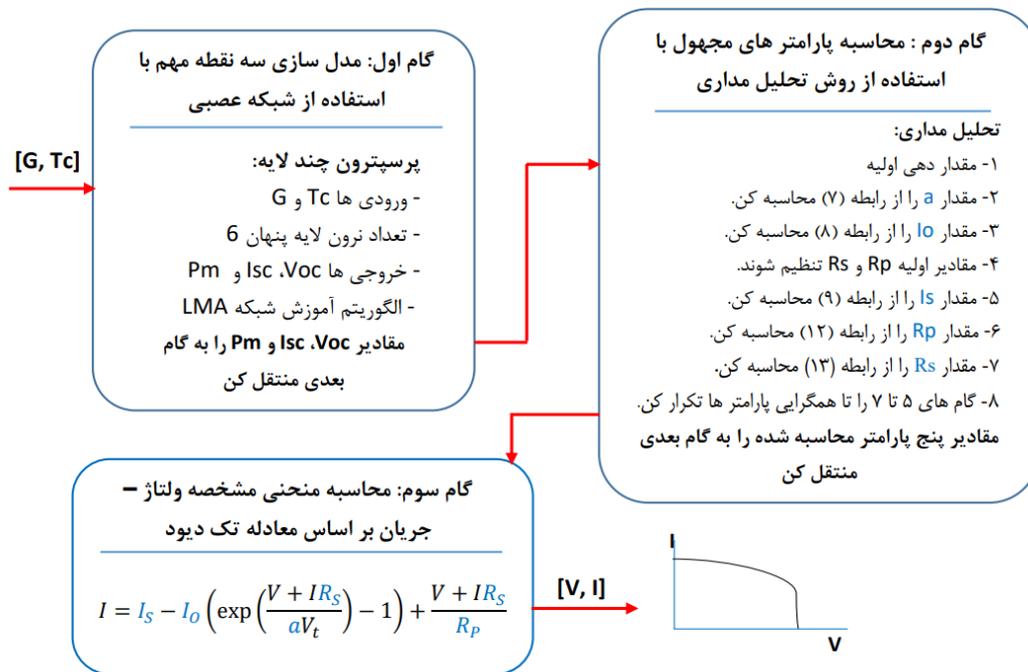
در الگوریتم پیشنهادی تابش ( $G$ ) و دما سلول خورشیدی ( $T_c$ ) به عنوان مقادیر ورودی  $I$ ، ولتاژ مدار باز، جریان اتصال کوتاه و حداکثر توان پارامترهای خروجی  $O$  هستند. تعداد نورون لایه پنهان HL برابر با ۶ است. به عنوان مثال روابط مربوط به شبکه عصبی برای خروجی ولتاژ حداکثر توان عبارتند از

$$I = [I_1, I_7]$$

$$HL = [f(\sum_{i=1}^n I_i \times w_{i,1} + b_{i,1}), \dots, f(\sum_{i=1}^n I_i \times w_{i,6} + b_{i,6})] \quad (۶)$$

$$V_{OC} = O = [HL]_{1 \times 6} \times [w_{i,0}]_{6 \times 1}$$

که در آن  $I_i$  مقدار ورودی نورون  $i$ ام،  $w_{i,j}$  وزن بین نورون های  $i$  و  $j$  و  $f$  تابع انتقال است. خروجی هر نورون از طریق یک تابع انتقال که در اینجا تابع انتقال سیگموئید است به نورون بعدی منتقل می شود.



شکل ۳: الگوریتم کلی روش پیشنهادی شامل سه گام مجزا.

جدول ۲: نتایج تحلیل مدار.

<i>a</i>	<i>I<sub>s</sub></i> (A)	<i>I<sub>o</sub></i> (μA)	<i>R<sub>s</sub></i> (Ω)	<i>R<sub>p</sub></i> (Ω)
۱,۴۱	۱۰,۱۹	۰,۰۳۹	۳,۴۴	۱۳۷,۶
۱,۴۱	۱۳,۴۷	۰,۰۴۰	۳,۴۴	۱۳۷,۶
۱,۴۱	۱۴,۰۸	۰,۰۴۷	۳,۴۲	۱۳۷,۰
۱,۴۲	۱۸,۰۹	۰,۰۷۵	۳,۳۹	۱۳۵,۷
۱,۴۳	۱۹,۹۱	۰,۰۸۴	۳,۳۸	۱۳۵,۵
۱,۴۳	۲۰,۵۹	۰,۰۸۹	۳,۳۸	۱۳۵,۴
۱,۴۳	۲۲,۹۲	۰,۱۰۶	۳,۳۷	۱۳۵,۱
۱,۴۵	۲۷,۳۳	۰,۲۰۰	۳,۳۳	۱۳۳,۳
۱,۴۵	۲۷,۸۷	۰,۱۹۵	۳,۳۳	۱۳۳,۵
۱,۴۵	۲۹,۶۲	۰,۲۲۱	۳,۳۳	۱۳۳,۳
۱,۴۵	۲۹,۱۲	۰,۲۵۴	۳,۳۱	۱۳۲,۷
۱,۴۵	۳۰,۰۵	۰,۲۶۱	۳,۳۲	۱۳۲,۸

جدول ۱: نتایج شبیه‌سازی برای داده‌های آزمون.

ورودی NN		خروجی NN		
<i>G</i> (W/m <sup>2</sup> )	°C	<i>V<sub>oc</sub></i> (V)	<i>I<sub>sc</sub></i> (A)	<i>P<sub>m</sub></i> (kW)
۳۱۱,۷۳	۱۸,۸۱	۱۱۴,۸۰	۹,۹۴	۰,۷۷۰۴
۴۰۹,۳۶	۲۰,۹۵	۱۱۰,۵۱	۱۳,۱۴	۱,۰۲۵۵
۴۲۷,۰۰	۲۲,۰۷	۱۱۰,۳۷	۱۳,۷۴	۱,۰۶۷۶
۵۴۴,۹۱	۲۶,۲۳	۱۰۹,۹۴	۱۷,۶۵	۱,۳۵۹۹
۵۹۸,۳۳	۲۷,۴۶	۱۰۹,۹۹	۱۹,۴۲	۱,۴۹۳۸
۶۱۸,۳۷	۲۷,۹۵	۱۰۹,۹۸	۲۰,۰۸	۱,۵۴۳۴
۶۸۷,۰۹	۲۹,۵۷	۱۰۹,۹۵	۲۲,۳۶	۱,۷۱۲۵
۸۱۵,۴۴	۳۴,۱۸	۱۰۹,۰۵	۲۶,۶۷	۲,۰۰۵۸
۸۳۱,۴۸	۳۴,۱۲	۱۰۹,۲۱	۲۷,۱۹	۲,۰۴۷۸
۸۸۲,۷۹	۳۵,۱۶	۱۰۹,۱۵	۲۸,۹۰	۲,۱۶۹۱
۸۶۷,۳۸	۳۵,۸۹	۱۰۸,۷۲	۲۸,۴۱	۲,۱۱۲۰
۸۹۴,۸۷	۳۶,۲۰	۱۰۸,۷۹	۲۹,۳۲	۲,۱۸۹۰

### ۴-۱ شبیه‌سازی

جدول ۱ و ۲ نتایج شبیه‌سازی را برای داده‌های آزمون و تحلیل مدار نشان می‌دهند. بعد از آموزش شبکه عصبی توسط داده‌های جمع‌آوری شده، شبکه عصبی آموزش‌دیده توسط داده‌های آزمون ارزیابی می‌شود. دو شاخص آماری جذر میانگین مربعات خطا (RMSE) و ضریب تعیین  $R^2$  مطابق روابط زیر برای ارزیابی شبکه عصبی استفاده شده است

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_o - y_p)^2}{N_s}} \quad (14)$$

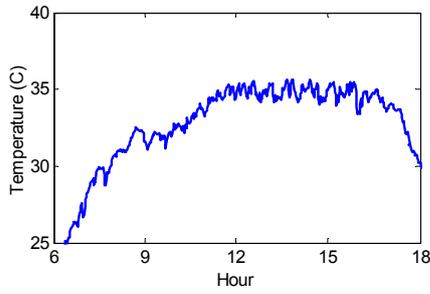
$$R^2 = 1 - \frac{\sum_{i=1}^N (y_o - y_p)^2}{\sum_{i=1}^N (y_o - \bar{y})^2} \quad (15)$$

که در آن  $N_s$  تعداد نمونه‌ها،  $y_o$  داده‌های مشاهده‌شده حاصل از انجام آزمایش‌های عملی،  $y_p$  داده‌های به‌دست‌آمده متناظر با استفاده از شبکه

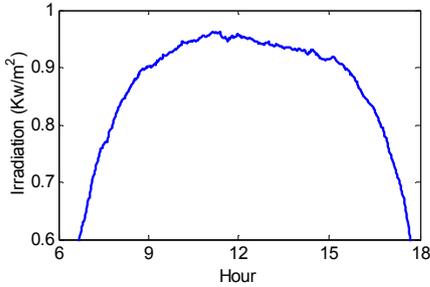
الگوریتم روش پیشنهادی را می‌توان با الگوریتم [۲۳] مقایسه و ارزیابی کرد. در الگوریتم پیشنهادی، شبکه عصبی جهت مدل‌سازی سه نقطه مهم بر اساس دمای سلول و تابش سطح استفاده شده است؛ اما در الگوریتم [۲۳]، شبکه عصبی جهت تعیین برخی ضرایب و پارامترهای مجهول استفاده شده است. همچنین در الگوریتم پیشنهادی از روش تحلیل مدار و در الگوریتم [۲۳] از روش بهینه‌سازی استفاده شده است.

### ۴- شبیه‌سازی و بحث

در این بخش، عملکرد الگوریتم پیشنهادی برای مدل‌سازی یک نیروگاه ۳ کیلووات که چند سال از زمان نصب آن می‌گذرد، ارزیابی می‌گردد. بدین منظور نخست شبکه عصبی با داده‌های مربوط به یک روز آفتابی آموزش داده می‌شود؛ چنان‌که سه نقطه ولتاژ مدار باز، جریان اتصال کوتاه و حداکثر توان برحسب دمای سلول و تابش سطح مدل شوند. پس از آن بر اساس خروجی شبکه عصبی و با استفاده از تحلیل مدار، پارامترهای مجهول جهت مدل‌سازی مشخصه ولتاژ-جریان استخراج می‌گردند.

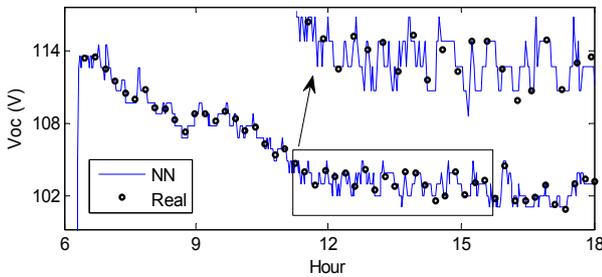


(الف)

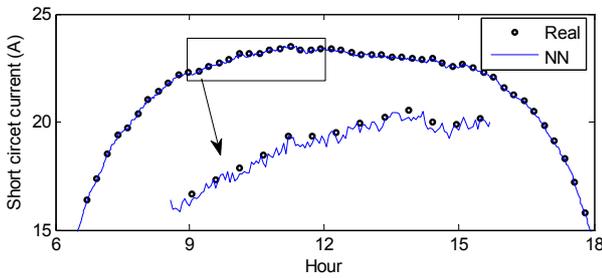


(ب)

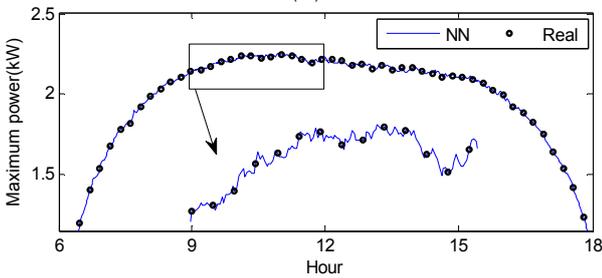
شکل ۵: شرایط جوی دما و تابش.



(الف)



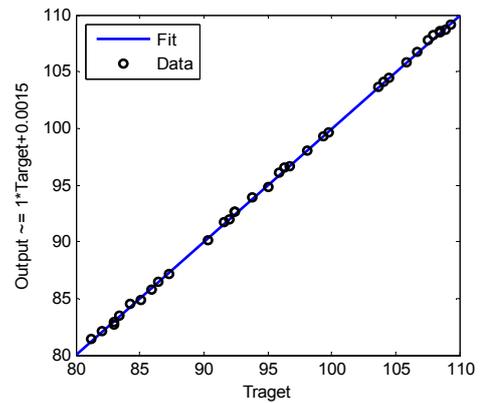
(ب)



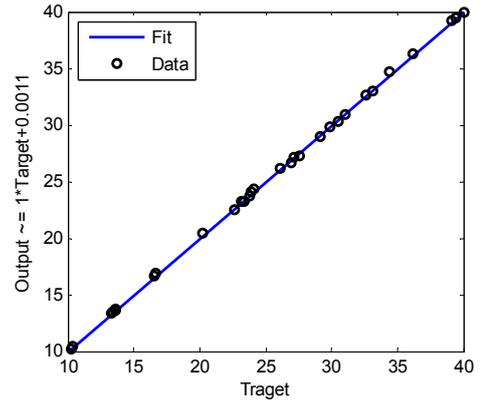
(ج)

شکل ۶: مدل‌سازی نیروگاه خورشیدی (الف)  $V_{OC}$ ، (ب)  $I_{SC}$  و (ج)  $P_m$ .

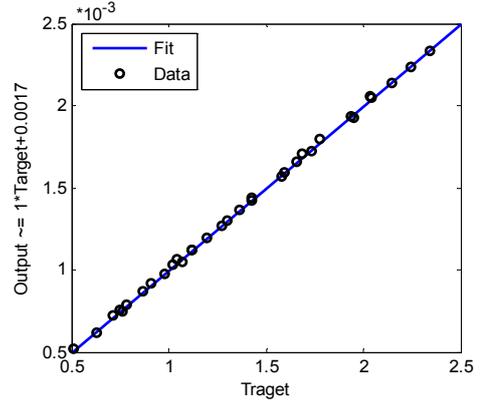
پس از آموزش شبکه عصبی برای ارزیابی عملکرد آن، یک روز آفتابی با شرایط جوی نشان‌داده‌شده در شکل ۵ مد نظر قرار گرفت. شکل ۶ عملکرد روش پیشنهادی را جهت مدل‌سازی نیروگاه خورشیدی، ولتاژ مدار باز، جریان اتصال کوتاه و حداکثر توان برای این روز نشان می‌دهد. شکل ۷ مشخصه‌های ولتاژ-جریان را نشان می‌دهد. چنان که مشاهده می‌شود، نتایج با دقت زیاد بر داده‌های اندازه‌گیری منطبق هستند که دلیل



(الف)



(ب)



(ج)

شکل ۴: تطبیق مناسب نتایج مدل‌سازی توسط شبکه عصبی با مقادیر واقعی (الف)  $V_{OC}$ ، (ب)  $I_{SC}$  و (ج)  $P_m$ .

جدول ۳: مقادیر شاخص آماری متناظر با کمیت‌های مدل‌شده.

شاخص آماری	$V_{OC}$ (V)	$I_{SC}$ (A)	$P_m$ (kW)
RMSE	۰٫۰۱۴۷	۰٫۰۱۷۲	۰٫۰۲۱۶
$R^2$	۰٫۹۹۹۹	۰٫۹۹۹۸	۰٫۹۹۹۷

عصبی و  $\bar{r}$  میانگین داده‌ها هستند. مقادیر شاخص آماری شامل RMSE و  $R^2$  متناظر با هر کمیت در جدول ۳ گزارش شده است.

شکل ۴ تطبیق مناسب داده‌های تخمین‌زده‌شده را به کمک شبکه عصبی با داده‌های اندازه‌گیری‌شده نشان می‌دهد. مقدار حداکثر خطا برای داده‌های آموزش ۰٫۰۰۲۳ و برای داده‌های تست ۰٫۰۰۳۱ است. علت این دقت مناسب مدل‌سازی با داده‌های کم را می‌توان رابطه متناسب و تقریباً خطی ولتاژ مدار باز، جریان اتصال کوتاه و حداکثر توان با تغییرات شرایط جوی دانست.

قدیمی تر حذف و داده‌های جدیدتر اضافه می‌شوند و توسط فرایند آموزش، وزن‌های شبکه عصبی به‌روز می‌شوند.

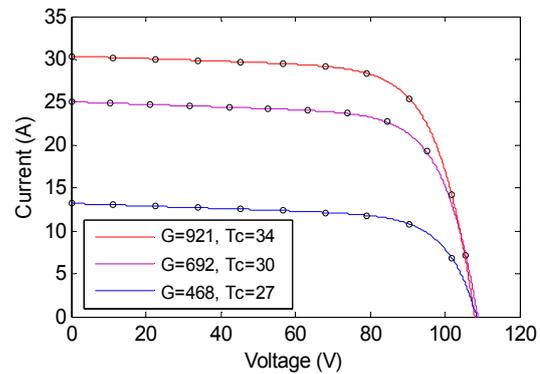
**بررسی و مقایسه:** روش پیشنهادی از جهت محاسبه پارامترهای مجهول و به‌کارگیری شبکه عصبی با روش‌های [۲۱] تا [۲۳] قابل مقایسه می‌باشد. در الگوریتم [۲۱] و [۲۲] از شبکه عصبی جهت تعیین پارامترهای مجهول استفاده شده است. چالش این روش، جمع‌آوری داده‌ها برای آموزش شبکه عصبی است؛ زیرا پارامترهای مجهول قابل اندازه‌گیری نیستند. این روش‌ها مبنای روش‌های دیگر مانند روش پیشنهادی و روش [۲۳] هستند. در روش [۲۳] جهت تعیین پارامترهای مجهول از روش‌های بهینه‌سازی استفاده شده است. در الگوریتم این روش برای کاهش زمان اجرای بهینه‌سازی از شبکه عصبی استفاده شده است. چالش این روش آن است که برای هر بار اجرای الگوریتم، نقاط مختلف منحنی I-V باید اندازه‌گیری شوند که این کار توسط یک مدار انجام می‌شود. این در حالی است که در الگوریتم روش پیشنهادی، سه نقطه مهم منحنی I-V متناظر با شرایط جوی، دمای سلول و تابش سطح، فقط در چند روز اندازه‌گیری می‌شوند. سپس از آموزش شبکه عصبی برای آموزش این داده‌ها استفاده می‌شود. در الگوریتم پیشنهادی از روش تحلیل مداری جهت استخراج پارامترهای مجهول استفاده شده است؛ در نتیجه الگوریتم پیشنهادی ساختاری ساده‌تری دارد و پیاده‌سازی آن آسان‌تر می‌باشد.

## ۵- نتیجه‌گیری

مدل‌سازی دقیق نیروگاه خورشیدی هم از دید نیروگاه جهت تشخیص عیب، برنامه‌ریزی تعمیر و نگهداری و بهبود راندمان عملکرد و هم از دیدگاه شبکه‌های هوشمند جهت مدیریت تولید و مصرف، کنترل فرکانس و پایدار مهم است. در این مقاله با استفاده از شبکه عصبی چندلایه، سه نقطه مهم مشخصه‌های ولتاژ-جریان برحسب شرایط جوی مدل‌سازی شده‌اند. برای آموزش شبکه عصبی از داده‌های یک روز نیروگاه خورشیدی شامل شرایط جوی به‌عنوان متغیرهای ورودی و سه نقطه ولتاژ مدار باز، جریان اتصال کوتاه و حداکثر توان به‌عنوان مقادیر خروجی استفاده شده‌اند. سپس با استفاده از روش تحلیل مداری و برحسب مقادیر خروجی شبکه عصبی، پنج پارامتر مجهول مدل تک‌دیود با دقت بالا و بدون نیاز به داده‌های کارخانه سازنده استخراج شده‌اند. نهایتاً روش پیشنهادی یک نیروگاه ۳ کیلووات شبیه‌سازی شد، نتایج شبیه‌سازی‌ها مؤثر بود روش پیشنهادی جهت استخراج پارامترهای مجهول مدل تک‌دیود و مدل‌سازی مشخصه ولتاژ-جریان نیروگاه‌های خورشیدی را نشان می‌دهد.

## مراجع

- [1] D. C. Jordan and S. R. Kurtz, "Field performance of 1.7 GW of photovoltaic systems," *IEEE J. of Photovoltaics*, vol. 5, no. 1, pp. 243-249, Jan. 2015.
- [2] M. Brenna, F. Foiadelli, M. Longo, and D. Zaninelli, "Energy storage control for dispatching photovoltaic power," *IEEE Trans. on Smart Grid*, vol. 9, no. 4, pp. 2419-2428, Jul. 2018.
- [3] S. Hara, H. Douzono, M. Imamura, and Tatsuya Yoshioka, "Estimation of photovoltaic cell parameters using measurement data of photovoltaic module string currents and voltages," *IEEE J. of Photovoltaics*, vol. 12, no. 2, pp. 540-545, Mar. 2022.
- [4] M. Ma, et al., "Photovoltaic module current mismatch fault diagnosis based on I-V data," *IEEE J. of Photovoltaics*, vol. 11, no. 3, pp. 779-788, May 2021.
- [5] K. Kamil, K. H. Chong, and H. Hashim, "Excess power rerouting in the grid system during high penetration solar photovoltaic," *Electric Power Systems Research*, vol. 214, Pt. A, Article ID: 108871, Jan. 2023.



شکل ۷: مشخصه I-V نیروگاه ۳ kW برای مقادیر واقعی و مدل شده.

آن، مدل‌سازی دقیق پنج پارامتر بر اساس روابط پیشنهادی است. در این حالت، پارامترها با تغییر شرایط جوی تغییر می‌کنند؛ چنان که پارامترهای  $R_p$ ،  $a$ ،  $R_s$  که معمولاً در روش‌های تحلیل، مقادیر ثابتی لحاظ می‌شوند در اینجا بر اساس فرمول‌های پیشنهادی، تغییرات متناسبی دارند. همچنین پارامترهای  $I_{PV}$  و  $I_0$  از یک سو تابعی از شرایط جوی و از سوی دیگر تابعی از نقاط ابتدا و انتهای مشخصه ولتاژ-جریان، متناسب با خروجی شبکه عصبی هستند.

## ۴-۲ بحث و بررسی

در بهره‌برداری از نیروگاه خورشیدی، مدل‌سازی مقادیر لحظه‌ای سه پارامتر توان ماکسیمم، ولتاژ مدار باز و جریان اتصال کوتاه مهم هستند. این مقادیر هم در فرایند کنترل و استخراج حداکثر توان و هم در ارزیابی عملکرد کنترل‌کننده مؤثر هستند. نوع داده‌ها و گذر زمان، عوامل مؤثر در مدل‌سازی این سه نقطه می‌باشند که در ادامه، این عوامل برای روش‌های مختلف بحث و ارزیابی می‌شوند. نهایتاً این بخش با بررسی و مقایسه روش پیشنهادی با دیگر روش‌ها خاتمه می‌یابد.

**اثر نوع داده‌ها:** در روش‌های تحلیلی، داده‌های مورد نیاز برای مدل‌سازی، متنوع و شامل داده‌های کارخانه (کاتالوگ پنل خورشیدی)، سه نقطه مهم مشخصه ولتاژ-جریان و شرایط جوی است. پس از مدل‌سازی، داده‌های ورودی، شرایط جوی و داده‌های خروجی، مشخصه ولتاژ-جریان است. با داشتن این مشخصه، امکان استخراج سه نقطه مهم فراهم می‌باشد. در مدل‌سازی به روش بهینه‌سازی، داده‌های مورد نیاز نقاط مختلف ولتاژ-جریان در یک شرایط جوی مشخص است. خروجی این روش، پنج پارامتر مجهول (۱) و به عبارتی مشخصه ولتاژ-جریان در شرایط جوی مشخص است؛ لذا امکان تعیین سه نقطه مهم در آن شرایط جوی مشخص فراهم می‌باشد. در روش پیشنهادی داده‌های مورد نیاز شامل مجموعه‌ای از سه نقطه مهم و شرایط جوی برای دو یا سه روز از سال است. پس از مدل‌سازی داده‌ها توسط شبکه عصبی، ورودی، شرایط جوی و داده‌های خروجی، سه نقطه مهم هستند. در گام بعد بر اساس داده‌های شبکه عصبی و با استفاده از تحلیل مداری، مقدار پارامترهای مجهول محاسبه می‌شوند.

**اثر گذر زمان:** با گذر زمان، پارامترها و ضرایب پنل‌های خورشیدی تغییر می‌کنند. این تغییرات، چالش اصلی روش‌های تحلیلی هستند؛ چرا که در این روش‌ها، استخراج پارامترها بر اساس داده‌های کارخانه سازنده انجام می‌شود؛ در حالی که در روش‌های بهینه‌سازی، گذر زمان نقشی ندارد و استخراج پارامترها همواره انجام می‌شود. در مدل‌سازی با روش پیشنهادی، گذر زمان لحاظ شده است؛ به این صورت که بعد از هر سرویس تعمیر-نگهداری دوره‌ای، یک یا دو بار در سال، داده‌های

- [18] V. L. Brano, A. Orioli, G. Ciulla, and A. D. Gangi, "An improved five-parameter model for photovoltaic modules," *Solar Energy Materials & Solar Cells*, vol. 94, no. 8, pp. 1358-1370, Aug. 2010.
- [19] Y. C. Hsieh, *et al.*, "Parameter identification of one-diode dynamic equivalent circuit model for photovoltaic panel," *IEEE J. of Photovoltaics*, vol. 10, no. 1, pp. 219-225, 2020.
- [20] Y. Mahmoud and W. Xiao, "Evaluation of shunt model for simulating photovoltaic modules," *IEEE J. of Photovoltaics*, vol. 8, no. 6, pp. 1818-1823, Nov. 2018.
- [21] E. Karatepe, M. Boztepe, and M. Colak, "Neural network based solar cell model," *Energy Conversion and Management*, vol. 47, no. 9-10, pp. 1159-1178, Jun. 2006.
- [22] A. N. Celik, "Artificial neural network modelling and experimental verification of the operating current of mono-crystalline photovoltaic modules," *Solar Energy*, vol. 85, no. 10, pp. 2507-2517, Oct. 2011.
- [23] X. J. Dong, J. N. Shen, Z. F. Ma, and Y. J. He, "Simultaneous operating temperature and output power prediction method for photovoltaic modules," *Energy*, vol. 260, Article ID: 124909, Dec. 2022.
- [24] M. G. Villalva, J. R. Gazoli, and E. R. Filho, "Comprehensive approach to modeling and simulation of photovoltaic arrays," *IEEE Trans. on Pow. Electr.*, vol. 24, no. 5, pp. 1198-1208, May 2009.
- [6] P. Chao, *et al.*, "A comprehensive review on dynamic equivalent modeling of large photovoltaic power plants," *Solar Energy*, vol. 210, pp. 87-100, Nov. 2020.
- [7] G. Ciulla, V. L. Brano, V. D. Dio, and G. Cipriani, "A comparison of different one-diode models for the representation of I-V characteristic of a PV cell," *Renewable and Sustainable Energy Reviews*, vol. 32, pp. 684-696, Apr. 2014.
- [8] A. Mellit and S. A. Kalogirou, "Artificial intelligence techniques for photovoltaic applications: a review," *Progress in Energy and Combustion Science*, vol. 34, no. 5, pp. 574-632, Oct. 2008.
- [9] K. Garud, S. Jayaraj, and M. Lee, "A review on modeling of solar photovoltaic systems using artificial neural networks, fuzzy logic, genetic algorithm and hybrid models," *International J. of Energy Research*, vol. 45, no. 1, Article ID: 5608, 2020.
- [10] F. Almonacid, C. Rus, L. Hontoria, M. Fuentes, and G. Nofuentes, "Review, characterisation of si-crystalline PV modules by artificial neural networks," *Renewable Energy*, vol. 34, no. 4, pp. 941-949, Apr. 2009.
- [11] F. Bonanno, G. Capizzi, G. Graditi, C. Napoli, and 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, Sept. 2012.
- [12] M. Laurino, M. Piliouge, and G. Spagnuolo, "Artificial neural network based photovoltaic module diagnosis by current-voltage curve classification," *Solar Energy*, vol. 236, pp. 383-392, Apr. 2022.
- [13] C. Huang and P. H. Kuo, "Multiple-input deep convolutional neural network model for short-term photovoltaic power forecasting," *IEEE Access*, vol. 7, pp. 74822-74834, 2019.
- [14] F. M. Khaleel, I. A. Hasan, and M. J. Mohammed, "PV panel system modelling method based on neural network," in *Proc. AIP Conf. Proc. 2386*, Article ID: 040029, 11 pp., 2022.
- [15] Z. Si, Y. Yu, M. Yang, and P. Li, "Hybrid solar forecasting method using satellite visible images and modified convolutional neural networks," *IEEE Trans. on Industry Applications*, vol. 57, no. 1, pp. 5-16, Jan./Feb. 2021.
- [16] W. Zhang, *et al.*, "Deep-learning-based probabilistic estimation of solar PV soiling loss," *IEEE Trans. on Sustainable Energy*, vol. 12, no. 4, pp. 2436-2444, Oct. 2021.
- [17] S. Shongwe and M. Hanif, "Comparative analysis of different single-diode PV modeling methods," *IEEE J. of Photovoltaics*, vol. 5, no. 3, pp. 938 - 946, May 2015.

**علیرضا رئیس** در سال ۱۳۸۸ مدرک کارشناسی مهندسی برق، در سال ۱۳۹۰ مدرک کارشناسی ارشد مهندسی برق و در سال ۱۳۹۶ مدرک دکتری مهندسی برق خود را از دانشگاه بوعلی سینا دریافت نمود. نام‌برده هم‌اکنون عضو هیأت علمی دانشگاه ملی مهارت می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: انرژی‌های تجدیدپذیر، الکترونیک قدرت و ماشین‌های الکتریکی، تحلیل سیستم‌های قدرت و بازار برق.

**روح‌اله عبداللهی** در سال ۱۳۸۶ مدرک کارشناسی مهندسی برق خود را از دانشگاه بوعلی سینا و در سال ۱۳۹۰ مدرک کارشناسی ارشد مهندسی برق خود را از دانشگاه علم و صنعت ایران دریافت نمود. نام‌برده هم‌اکنون عضو هیأت علمی دانشگاه ملی مهارت می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: تحلیل سیستم‌های قدرت، الکترونیک قدرت و ماشین‌های الکتریکی، کیفیت توان و انرژی‌های تجدیدپذیر.