

آنالیز حساسیت ۹ مدل جهت تخمین توان پنل‌های فتوولتایی مونوکریستال و پلی کریستال

استادیار، گروه مهندسی مکانیک، دانشگاه ولی عصر (عج)، رفسنجان، ایران، m.shafiey@vru.ac.ir

مربی، گروه مهندسی شیمی، دانشگاه ولی عصر (عج)، رفسنجان، ایران، m.zamani@vru.ac.ir

استادیار، گروه مهندسی شیمی، دانشگاه ولی عصر (عج)، رفسنجان، ایران، m.hosseini@vru.ac.ir

محمد شفیعی دهج*

مصطفی زمانی محی آبادی

سید محمد صادق حسینی

چکیده

از آنجا که میزان انرژی تولید شده توسط سیستم های فتوولتایی به صورت نمایی در حال رشد است، نیاز به پیش بینی توان تولید آنها بسیار مهم تر از گذشته است. در این مقاله با استفاده از شبکه عصبی، مدل سازی سیستم های فتوولتایی پنل های مونو و پلی کریستال نیروگاه ۲/۵ کیلووات سایت خورشیدی دانشگاه ولی عصر (عج) رفسنجان انجام شده است. هدف از این تحقیق به دست آوردن مدلی بهینه می باشد. مدل های به دست آمده با استفاده از شبکه های عصبی توسط داده های جمع آوری شده یک ساله سایت مورد نظر، باهم مقایسه گردیدند. در این مدل ها ورودی ها، دمای پنل و تابش مستقیم خورشید و خروجی ها توان تولیدی پنل های مونوکریستال و پلی کریستال می باشند. آنالیز حساسیت برای انواع ورودی و خروجی و نیز برای تعداد لایه های مختلف نرون ها و توابع مختلف نیز بررسی گردید. نتایج حاصله گویای مدل سازی دقیق پنل ها توسط شبکه عصبی مورد استفاده می باشد. نتایج نشان می دهد که مدل با ورودی دما و تابش و توان خروجی پنل مونوکریستال و پلی کریستال، از همه مدلها بهتر می باشد.

واژه های کلیدی: مدل سازی، شبکه عصبی، آنالیز حساسیت، پنل های فتوولتایی، ورودی ها، توان خروجی.

Sensitivity analysis of 9 models for estimating the power of photovoltaic monocrystal and polycrystalline panels

M. shafiey Dehaj

M. Zamani Mohiabadi

S. M. S. Hosseini

Department of Mechanical Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran

Department of Chemical Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran

Department of Chemical Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran

Abstract

As the energy generation with photovoltaic systems is exponentially growing, the need for prediction of generation power is much more important than ever. In this paper, based on the experimental data of the solar site along one-year, the photovoltaic systems of monocrystalline and polycrystalline panels for 2.5 kW solar power plant at Vali-e-Asr University of Rafsanjan, has been modelled with artificial neural network. To obtain the optimal model for the desired panels, different variables have been considered as the input and output of the model, while all variables are: panel temperature, direct radiation, the output power and the kind of panels (monocrystalline and polycrystalline). Also sensitivity analysis has been performed for different input and output parameters as well as for the number of different layers of neurons and functions. The results show that the model with the input of temperature and radiation and the output of the power of monocrystalline and polycrystalline panel is the most accurate model with lowest error.

Keywords: modeling, neural network, sensitivity analysis, photovoltaic panels, inputs, output power.

پلی کریستال و پنل های آمورف می باشند [۱]. پنل های فتوولتایی از جمله مهمترین تجهیزات در سیستم های خورشیدی می باشند که از مجموع سلول های کوچکتر تشکیل می شوند. سیستم های فتوولتایی جهت مصارف عمومی و کشاورزی، بصورت نیروگاه های مستقل از شبکه سراسری یا سیستم های متصل به شبکه سراسری با ساختار نصب ثابت و یا متحرک در واحدهای کوچک با توان پائین جهت تامین انرژی الکتریکی مورد نیاز ماشین حساب های کوچک تا سیستم های بزرگ نیروگاهی، به کار می روند. به دلیل وابستگی زیاد عملکرد پنل های فتوولتایی به در دسترس بودن تابش خورشید در محل مورد نیاز شایسته است که معماران برای طراحی این ساختمان ها، درک درستی از تابش خورشید و میزان کارایی پنل های فتوولتایی داشته باشند [۲]. یکی از لازم ترین موارد مورد نیاز تحقیقات در زمینه سیستم های فتوولتایی، مدل سازی این سیستم ها می باشد. مدل های مختلفی برای بدست آوردن پیش بینی توان سیستم های فتوولتایی با توجه به دقت لازم، افق پیش بینی، شرایط آب و هوا و ... وجود دارد.

۱- مقدمه

رشد سریع تقاضای انرژی و افزایش گرمایش جهانی و اثرات گلخانه ای ناشی از مصرف سوخت های فسیلی، توجهات بسیاری را در زمینه استفاده از انرژی های تجدیدپذیر پدید آورده است. انرژی خورشیدی با دسترسی آسان و توان قابل توجه یکی از بهترین انرژی های پاک محسوب می شود. خورشید به عنوان یک منبع بی پایان انرژی می تواند حل کننده مشکلات موجود در زمینه انرژی و محیط زیست باشد. متأسفانه انرژی ارزان و سود بانکی بالا هر دو باعث می شود که هزینه کردن در سیستم برق خورشیدی در کشور ما مقرون به صرفه به نظر نیاید در صورتی که در دراز مدت، سیستم های خورشیدی بسیار مقرون به صرفه هستند و تاثیر بسزایی در کم کردن آلودگی هوا نیز خواهند داشت. اساس کار سیستم های خورشیدی تولید برق بوسیله تابش خورشید از طریق پنل های فتوولتایی است. پنل های خورشیدی استفاده شده در سیستم های فتوولتایی شامل پنل های مونوکریستال، پنل های

* نویسنده مکاتبه کننده، آدرس پست الکترونیکی: m.shafiey@vru.ac.ir

تحقیقات کنونی به منظور آماده سازی بهتر سیستم تولید توان برای مدیریت نوسانات در توان خروجی پنل های فتوولتایی خورشیدی، بر روی پیش بینی دقیق تر تابش خورشیدی متمرکز شده است. بازه های زمانی پیش بینی تابش خورشیدی، به عنوان مثال، در ساعت، در طول روز و در روز قبل، برای فعالیت های مختلف اپراتور شبکه مانند حوادث احتمالی، تعهد واحد و بازارهای آینده برق مورد نیاز است [۳]. پیش بینی تابش افقی مکانی^۱ فرایند اساسی در اکثر ابزارهای پیش بینی توان سلولهای خورشیدی است. مجموعه داده های مورد استفاده در پیش بینی، بازه زمانی پیش بینی را تعیین می کند. توماس و همکاران [۴] با استفاده از داده های ماهواره ای هواشناسی و یک مدل عددی پیش بینی هوا برای بهبود پیش بینی تابش خورشیدی در طول روز را انجام دادند. پیش بینی بهبود یافته با استفاده از تصاویر زمینی از حرکت ابر توسط تیم و همکاران [۵] انجام شد. اگرچه پیش بینی های مبتنی بر مدلسازی های عددی می توانند پیش بینی های واقعی از تغییرات در شرایط آب و هوایی را بدست آورند اما در صورت محدود بودن فضا و زمان به دلیل تأکید زیاد برای دستیابی به انسجام کلی، کافی نمی باشند.

پیش بینی تابش خورشیدی کوتاه مدت و کارآمدتر و دقیق تر از نظر محاسباتی نیز مورد بررسی قرار گرفته است زیرا صحت مدل های آماری خطی و غیر خطی روز بعد بیشتر با الگوی غیرقابل پیش بینی هوا پیش بینی می شود که امروزه تجربه می شود و برای کاربرد در پیش بینی تابش خورشیدی مورد استفاده گسترده قرار می گیرد [۶]. به دلیل شکل گیری تصادفی و حرکت ابرها در آسمان، مدل های پیش بینی دقیق مبتنی بر استفاده از اندازه گیری های میدانی و داده های ارائه دهندگان پیش بینی هواشناسی به منظور بهینه سازی عملکرد این سیستم ها مورد نیاز است [۷].

ریندل و همکاران [۸] ارزش اقتصادی پیش بینی توان سلول های فتوولتایی را با استفاده از یک مطالعه موردی در کشور چین را ارزیابی کردند. آنها نشان دادند که حتی انحرافات جزئی از فرکانس پیش بینی درخواست شده و محدوده پیش بینی نیز می تواند که تأثیر مستقیمی بر درآمد اقتصادی داشته باشد و منجر به ضرر و زیان مالی شود. این امر باعث افزایش نیاز به پیش بینی دقیق هواشناسی در این زمینه می شود.

مالوانی و همکاران [۹] عملکرد دقیق تکنیک های پردازش داده ها را در یک مدل پیش بینی که ترکیبی از دو روش آماری بود را استفاده کردند. داده های اندازه گیری شده شامل تابش خورشیدی، دمای محیط و سرعت باد برای پیش بینی توان سیستم فتوولتایی در یک بازه زمانی یک روزه پیش رو واقع در پردیس دانشگاه سالنتو ایتالیا بود. آنها پنج رویکرد مختلف را انتخاب کردند و عملکرد آنها را از نظر میانگین خطا و توزیع احتمال به منظور شناسایی دقیق ترین پیش بینی ها مورد تجزیه و تحلیل قرار دادند. نتایج نشان داد که روش پیش بینی داده محور همراه با تکنیک های پردازش داده می تواند دقت پیش بینی را بهبود بخشد.

جونیر و همکاران [۱۰] سه راهبرد مختلف را برای به دست

آوردن پیش بینی های منطقه ای یک روزه از تولید برق پنل های فتوولتایی را ارزیابی کردند. این راهبردها بر اساس استفاده از پیش بینی هواشناسی، توان قبلی پنل و رگرسیون بردار پشتیبان بود. اولین راهبرد مبتنی بر طرحی بود که در آن می توان داده های محلی تولید برق پنل را بدست آورد. دومین راهبرد مبتنی بر طرحی بود که داده های تولید برق منطقه ای پنل در دسترس است و از کلیه داده های مربوط به پیش بینی آب و هوا استفاده می کند. راهبرد سوم از روش دوم مشتق شده بود، اما از آنالیزهای عددی برای انتخاب داده های پیش بینی هوا استفاده می کند.

در مدل های خطی رابطه بین متغیرهای ورودی و متغیر پیش بینی شده از طریق تحلیل آماری بدست می آید. با این حال، ویژگی های غیرخطی ناشی از تغییر در آب و هوا از جمله پوشش ابر و ذرات جوی بیشتر پیش بینی کوتاه مدت را پیچیده می کند [۱۱]. هوش مصنوعی یا تکنیک های یادگیری ماشین به طور گسترده ای به عنوان یک راه حل جایگزین برای تخمین فرایندهای مرتبط با توابع غیرخطی مورد بررسی قرار می گیرد. شبکه عصبی مصنوعی برای پیش بینی تابش خورشیدی کوتاه مدت بر اساس متغیر ورودی چندگانه مانند دما، رطوبت، فشار و باد عمل می کند [۱۲].

سیوانیان و همکاران [۱۳] الگوریتم بهبود یافته پیش بینی تابش خورشیدی بر اساس مدل شبکه عصبی مصنوعی با پیش پردازش منطق فازی را ارائه کردند. مدل ارائه شده همچنین شامل یک ضریب تصحیح خطا با هدف به حداقل رساندن خطای پیش بینی شده قبلی به لایه ورودی است. آنها از مدل آسمان صاف و داده های آب و هوایی به دست آمده از یک ایستگاه هواشناسی در سنگاپور برای آموزش مدل توسعه یافته استفاده کردند. آنها نشان دادند که ضریب تصحیح خطا همراه با یک شبکه عصبی خالص می تواند دقت پیش بینی تابش خورشیدی را به دلیل توانایی تصحیح خطای سازگار بهبود بخشد.

لیو و همکاران [۱۴] با استفاده از الگوریتم انتشار برگشتی یک مدل پیش بینی شبکه عصبی تطبیقی بهبود یافته را طراحی کردند. پارامترهای ورودی شامل شدت تابش خورشیدی ساعتی، بالاترین درجه حرارت روزانه، کمترین دمای روزانه، میانگین دمای روزانه و خروجی انرژی ساعتی سیستم فتوولتایی بود. پارامتر خروجی، توان تولید ساعتی سیستم فتوولتایی را از ۸ صبح تا ۶ عصر در روز بعد را نشان می داد.

ماندال و همکاران [۱۵] با استفاده از داده های تابش خورشیدی و دما، توان خروجی یک ساعته از یک سیستم فتوولتایی را با استفاده ترکیب تکنیک های تبدیل موجک و هوش مصنوعی پیش بینی کردند. صابریان و همکاران [۱۶] یک روش مدل سازی انرژی خورشیدی با استفاده از دو شبکه عصبی مصنوعی را ارائه کردند. هر دو شبکه عصبی دارای چهار ورودی و یک خروجی بودند. ورودی ها حداکثر دما، حداقل دما، میانگین دما و تابش و خروجی نیز توان بود. هادی و همکاران [۱۷] در یک تحقیق دیگر همین مدلسازی فوق را با پنج ورودی و یک خروجی انجام دادند. ورودی ها دمای محیط، دمای سلول، سرعت باد، رطوبت و تابش و خروجی نیز توان بود.

نسپولی و همکاران [۱۸] عملکرد پیش بینی شبانه روز پیش رو را با دو روش که معمولاً برای پیش بینی توان تولیدی سیستم های فتوولتایی استفاده می شود، را مقایسه کردند. هر دو روش مبتنی بر

^۱Global Horizontal Irradiance (GHI)

۲- شرایط مطلوب رفسنجان برای استفاده از انرژی

خورشیدی

شهرستان رفسنجان دارای طول و عرض جغرافیای $56^{\circ}05'E$ و $30^{\circ}30'N$ و ارتفاع ۱۴۶۹ متر از سطح دریا می باشد، اقلیم این منطقه در گروه مناطق خشک و گرم قرار دارد. میانگین ساعات آفتابی سالانه رفسنجان بیش از ۳۳۶۰ ساعت در سال می باشد در شکل ۱ میزان ساعات آفتابی ماهیانه رفسنجان از سال ۱۹۹۶ تا ۲۰۱۲ نشان داده شده است. این شهر دارای شرایط مطلوب برای استفاده از انرژی خورشیدی از جمله قرار داشتن بر روی کمربند خورشیدی جهان با میانگین ساعات آفتابی سالانه و میزان تابش خورشیدی بالا، عدم رطوبت بالا و گرد و غبار در جو، ارتفاع مناسب از سطح دریا، منطقه مناسب: استپ ها، بوته زارها و صحراهای نیمه خشک می باشد.

سیستم های فتوولتایی با توجه به تبدیل مستقیم انرژی خورشید به انرژی الکتریکی از یکطرف و فراوانی و سادگی نصب آنها نسبت به سایر سیستم ها در بازار کشور ایران دارای نقشی پر رنگ تر می باشند. اما با توجه به این که در حال حاضر حداقل در کشور ما فقط نسل اول سیستم های فتوولتایی به صورت تجاری موجود و قابل استفاده می باشد. تقریباً تمام سیستم های نصب شده در کشور از این نسل که شامل ویفرهای سیلیکونی بوده، می باشند. این سلول ها دارای بازدهی کمتر از ۲۰ درصد هستند. با توجه به اهمیت استفاده از انواع انرژی نو، یک نیروگاه خورشیدی ۲/۵ کیلوواتی در دانشگاه ولی عصر (عج) ایجاد گردید. همانطور که در شکل ۲ نیز مشخص است در این مجموعه از ۲ نوع پنل مونوکریستال (۵ عدد ۲۵۰ وات) و پلی کریستال (۶ عدد ۲۱۵ وات) استفاده شده است که هدف اصلی از ایجاد آن، تست این ۲ نوع پنل در شرایط آب و هوایی گرم و خشک می باشد. در این نیروگاه جهت جمع آوری داده ها از یک سیستم ثبت داده ها^۱ استفاده شده است که اطلاعات تابش خورشید، دمای محیط، توان، جریان و ولتاژ پنل ها را بصورت هر ۵ دقیقه یک مرتبه اندازه گیری و ذخیره می کند. همچنین داده های یکسان جهت آنالیز جمع آوری شده است. به جهت اینکه این نیروگاه از سال ۱۳۹۲ راه اندازی شده است و از همان زمان داده برداری آغاز شده است در صورتی که در یک روز داده ناقص بود، از داده های همان روز در سال قبل مورد استفاده قرار گرفت. در ابتدا داده های استفاده شده با یک نیروگاه موجود در منطقه مورد مقایسه قرار گرفت تا مورد اعتماد باشند و سپس در شبیه سازی ها مورد استفاده قرار گرفت.

شبکه های عصبی مصنوعی بودند که در همان مجموعه داده ها آموزش دیده اند.

مروج و همکاران [۱۹] برای شبیه سازی وقایع کیفیت توان به طور همزمان از دو روش مدل سازی ریاضی و داده های حاصل از شبیه سازی با نرم افزار PSCAD استفاده کردند. با توجه به عملکرد بسیار خوب شبکه های عصبی در کارهای تشخیص الگو و طبقه بندی، شبکه عصبی چند لایه برای طبقه بندی وقایع مورد استفاده قرار گرفت. آنها مقاومت شبکه عصبی در برابر اغتشاشات را در سطوح مختلف مورد بررسی قرار دادند.


فیروزنیا و همکاران [۲۰] پیش بینی بار کوتاه مدت یک فرآیند پایه در بهره برداری سیستم های تولید توان را بررسی کردند. آنها ابتدا سری زمانی بار از طریق یک تبدیل ریاضی مناسب (تبدیل موجک) را تجزیه کردند و سپس از سری های حاصل شده پارامترهای ورودی را برای آموزش شبکه عصبی استخراج نمودند.

شماری از شبکه های عصبی نیز مدل سازی ماژول های فتوولتایی را توسعه داده اند، در برخی از تحقیقات انجام گرفته در این زمینه، پارامترهای مدار معادل را تنها با دریافت تابش خورشید و دمای محیط پیش بینی کردند و سپس با استفاده از مدل تحلیلی جریان یا ولتاژ را محاسبه کردند [۲۱ و ۲۲].

مونتریو و همکاران [۲۳] به منظور پیش بینی اختلالات، به دلیل اتصال سیستم فتوولتاییک، از هفت الگوریتم متفاوت جهت آموزش در شبکه های عصبی مصنوعی استفاده کردند و در آن توان تولیدی و وضعیت شبکه توزیع را مورد تجزیه و تحلیل قرار دادند.

از آنجا که میزان انرژی تولید شده توسط سیستم های فتوولتایی به صورت نمایی در حال رشد است، نیاز به پیش بینی توان تولید آنها بسیار مهم تر از گذشته است. پیش بینی میزان تولید توان فتوولتایی با ابزار پیش بینی کننده معتبر با توجه به شرایط محیط، به منظور انتشار فن آوری های سیستم فتوولتایی و همچنین برای بهبود عملکرد سیستم های فتوولتایی در برنامه ریزی بسیار مهم است. به طور کلی، دو چالش اصلی پیش بینی تابش تابش در افق های مختلف زمانی و تبدیل صحیح تابش خورشیدی به توان خروجی واقعی سیستم فتوولتایی خورشیدی وجود دارد. بنابراین یک مقایسه همگن بین چند مدل پیش بینی کننده توان این سیستم ها مورد نیاز است، که تا بحال انجام نشده است. با توجه به توضیحات داده شده و تحقیقات انجام گرفته شده در این زمینه، دمای محیط و میزان تابش خورشیدی دو پارامتر اصلی اثر گذار بر روی توان تولدی پنل های فتوولتایی می باشد. به همین دلیل در ادامه از این دو پارامتر به عنوان ورودی مدل های شبکه عصبی استفاده گردیده است. در این تحقیق ۹ مدل با ورودی و خروجی های متعدد در نظر گرفته شده است. بطور کلی هدف از این تحقیق به دست آوردن مدلی بهینه با استفاده از الگوریتم شبکه عصبی برای پنل های موردنظر می باشد تا در مطالعات بعدی با استفاده از آن بتوان پژوهش هایی از جمله اثر دمای پنل بر روی سیستم موردنظر و اعمال فرایندهای کنترلی جهت به دست آوردن توان بهینه از مجموعه انجام گردد. یا به عبارت دیگر تولید مدلی است که برای متغیرهای خروجی کمترین خطا بین داده های واقعی و پیش بینی شده را ایجاد نماید.

¹ Data logger (sunny web box model)



شکل ۱- میزان ساعات آفتابی ماهیانه رفسنجان از سال ۱۹۹۶ تا ۲۰۱۲




شکل ۲- نیروگاه خورشیدی ۲/۵ کیلوواتی دانشگاه ولی عصر (عج)

۲-۱- شبکه های عصبی

شبکه های عصبی از روش های محاسباتی جدید می باشند که مزیت اصلی آنها سرعت بالا و دقت مطلوب در پیش بینی متغیرهای پیچیده با نداشت خطی و غیرخطی است. اصولاً شبکه های عصبی در حل مسایل پیچیده که مدل های تجربی یا نیمه تجربی در حل آنها کارایی مناسبی نداشته باشند بسیار کارا هستند. مطالعه بر روی شبکه های عصبی توسط مک کلاخ و پیتس در سال ۱۹۴۳ آغاز شد. شبکه های تک لایه، با توابع فعال سازی آستانه ای، توسط روزنبلات در سال ۱۹۶۲ بنیان گذاری شدند که این نوع شبکه ها، پرسپترون نامیده شدند [۲۴-۲۶]. شبکه های عصبی مصنوعی نوعی مدل آماری است که بر اساس کارکرد مغز انسان طراحی شده است. این نوع مدل می تواند ورود پهای معینی را دریافت کند و طی یک سری پردازش های موجود در مدل، نتیجه مطلوب را ارائه دهد. شبکه های عصبی از واحدهای ساده ای به نام نورون ساخته می شوند و سلول هایی نظیر آنچه که در مغز انسان وجود دارد را ارائه می دهند. در یک شبکه، نورون ها بوسیله اتصالات وزنی به یکدیگر متصل می شوند. از طریق تنظیم این وزن ها، فرآیند آموزش درون شبکه بدست می آید. با توجه به شکل ۳ شبکه های عصبی از مجموعه لایه هایی تشکیل می شود که لایه اول شامل ورودی ها و لایه آخر شامل خروجی ها می باشد. لایه های نهان نیز بین لایه های ورودی و خروجی قرار می گیرند. شبکه های عصبی براساس نوع فیزیک مسئله می توانند تک لایه یا چند لایه باشند. فرآیند آنالیز داده ها با ورود پارامترهای خوراک به لایه اول نورون ها آغاز می گردد و سپس داده ها برای تنظیمات بیشتر به نورون های لایه دوم انتشار می یابند. سپس نتایج به لایه بعدی انتقال می گردد و این فرآیند ادامه می یابد تا به

لایه داده های خروجی برسد. در اتصال بین لایه ای، دو نوع عمده از اتصالات بین نورون های شبکه وجود دارند که عبارتند از تغذیه رو به جلو و تغذیه رو به عقب. در شبکه تغذیه رو به جلو، سیگنال ها تنها در یک جهت از لایه ورودی به سمت لایه های نهان و در نهایت لایه خروجی جریان می یابند. در شبکه تغذیه رو به عقب، سیگنال ها می توانند در نورون های یک لایه یکسان یا در لایه های قبلی جریان می یابند. هدف شبکه های عصبی یادگیری براساس اتصالات منطقی بین الگوهای پارامترهای ورودی و خروجی، آنالیز و یا یافتن ساختار الگوهای پارامترهای ورودی می باشد. با فراهم کردن شبکه های عصبی با داده های موجود، شبکه آموزش دیده از طریق اصلاح وزن های اتصالی بین نورون ها به دست می آید. از نتایج بدست آمده می توان در شرایط مختلف استفاده نمود، بطور مثال در یک نیروگاه هیبرید (گازی و خورشیدی) در صورتی که توان تولیدی نیروگاه خورشیدی را بتوان بخوبی تخمین و پیش بینی نمود، می توان اعمال کنترلی دقیق تر جهت بهینه سازی مصرف سوخت و تولید توان ثابت کل نیروگاه را بدست آورد.




شکل ۳- نمونه شبکه عصبی [۱۶]

۳- مدل سازی پنل های فتوولتایی ۲/۵ کیلووات

سایت خورشیدی توسط شبکه های عصبی

به طور کلی مدل سازی یکی از ابزارهای مناسب برای تصمیم گیری و پیش بینی پدیده های محیط زیستی و طبیعی می باشد که اغلب به صورت مدل های مفهومی با روابط ریاضی بیان می شوند. تبدیل یک مفهوم آماری به زبان ریاضی، نوعی از مدل سازی است. از طریق مدل سازی می توان شرایط و موقعیت های خاص را به صورت مجازی ایجاد و آن را مورد آزمون قرار داده و تحلیل کرد.

دمای بهینه طراحی پنل ۲۵ درجه سلسیوس می باشد محدوده دمای اندازه گیری شده پنل های سایت خورشیدی بین ۰ تا ۷۰ درجه سلسیوس متغیر است. تولید توان پنل های فتوولتایی به دمای محیط بستگی دارد. هرچه این دما بیشتر شود باعث کاهش بازده پنل (توان تولیدی) می شود. این افزایش دما بر روی پنل های مونوکریستال اثر بیشتری گذاشته و حدود ۸ درصد کاهش بازده بیشتری نسبت به پلی کریستال دارد [۱]. با توجه به توضیحات داده شده و تحقیقات انجام گرفته شده در این زمینه، دمای محیط و میزان تابش خورشیدی دو پارامتر اصلی اثر گذار بر روی توان تولیدی پنل های فتوولتایی می باشد. در این تحقیق ۹ مدل با ورودی و خروجی های متعدد در نظر گرفته شده است در جدول ۱ این مدل ها نشان داده شده اند. در اینجا T ، دمای پنل و R ، تابش خورشید بعنوان داده های ورودی مساله و خروجی ها؛ شامل W_p ، توان تولیدی پلی کریستال و W_m ، توان تولیدی مونوکریستال می باشد.



شکل ۵- الگوریتم شبکه عصبی

۳-۱- شاخص‌های آماری

برای ارزیابی دقت کارایی مدل‌های توسعه یافته و بررسی روند عملکرد در مدل‌ها، تجزیه و تحلیل آماری شامل خطای مجذور میانگین مربعات خطا^۴، میانگین خطای تقریبی^۵ و ضریب همبستگی^۶ انجام شده است. میانگین مربعات خطا، اطلاعاتی در مورد عملکرد کوتاه مدت ارائه می‌دهد که یک اندازه از تغییرات تخمین زده شده در اطراف داده‌های اندازه‌گیری شده است. هر چه میانگین مربعات خطا پایین‌تر باشد، تخمین دقیق‌تر است. میانگین خطای تقریبی، نشانه‌ای از انحراف میانگین مقادیر برآورد شده از داده‌های مربوط به اندازه‌گیری است و می‌تواند اطلاعاتی در مورد عملکرد بلند مدت مدل ارائه دهد. میانگین خطای تقریبی پایین‌تر و ضریب همبستگی بیشتر مناسب‌تر می‌باشد. هرچه ضریب همبستگی بیشتر باشد نشان دهنده میزان تطابق خروجی مدل با هدف^۷ است و اگر برابر با یک باشد گویای این است که خروجی سیستم با هدف برابر می‌باشد. جاکویدز [۲۸] نشان داد استفاده از شاخص‌های میانگین مربعات خطا، میانگین خطای تقریبی تنها باعث اشتباه در مدل می‌شود. بنابراین در کنار این دو شاخص آزمون تی^۸ توصیه می‌شود، آزمون تی معیاری است که تفاوت واقعی بین دو شاخص را در مقایسه با تغییرات داده‌ها مقایسه می‌کند. به عبارت دیگر آزمون تی نشان دهنده اهمیت اختلاف شاخص‌ها با استفاده از متوسط خطاهای ریشه میانگین مربعات خطا و خطای متوسط میانگین خطای تقریبی است. روابط شاخص‌های گفته شده به صورت معادلات زیر می‌باشد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (1)$$

⁴ Root Mean Square Error (RMSE)

⁵ Mean Bias Error (MBE)

⁶ Coefficient of determination (R^2)


⁷ Target

⁸ T-Test

جدول ۱- انواع مدل‌ها با ورودی و خروجی‌های در نظر گرفته شده

مدل‌ها	ورودی‌ها	خروجی‌ها
مدل ۱	تابش	توان مونو کریستال
مدل ۲	تابش	توان پلی کریستال
مدل ۳	تابش	توان مونو و توان پلی کریستال
مدل ۴	دما	توان مونو کریستال
مدل ۵	دما	توان پلی کریستال
مدل ۶	دما	توان مونو و توان پلی کریستال
مدل ۷	دما و تابش	توان مونو کریستال
مدل ۸	دما و تابش	توان پلی کریستال
مدل ۹	دما و تابش	توان مونو و توان پلی کریستال

از مهمترین موارد مورد بررسی به دست آوردن بهترین مدل انجام آنالیز حساسیت نسبت به پارامترهای مختلف در آن مدل می‌باشد. مدل شبکه عصبی نیز از این فرایند مستثنی نمی‌باشد. در ادامه نتایج آنالیز حساسیت مدل شبکه عصبی به دست آمده بر روی نیروگاه ۲/۵ کیلو وات دانشگاه ولی عصر (عج) رفسنجان نمایش داده شده است. جهت انجام آنالیز حساسیت باید تمامی شرایط یکسان در نظر گرفته شود. این شرایط عبارتند از تعداد لایه‌ها و نرون‌های هر لایه و نوع توابع انتقال شبکه عصبی می‌باشد. انتخاب تابع انتقال تاثیر به سزایی بر دقت خروجی شبکه عصبی می‌گذارد. معمولاً سه تابع انتقال اصلی برای مدل-سازی شبکه عصبی وجود دارد که شامل توابع سیگموید تانژانت^۱، سیگموید لگاریتمی^۲ و سیگموید خطی^۳ می‌باشند (شکل ۴) [۲۷]. برای تعیین بهترین ترکیب از توابع انتقال در شبکه با یک یا دو لایه نهان، توابع انتقال مختلفی برای توسعه شبکه استفاده می‌شود. بررسی نتایج آنالیز حساسیت توسط شاخص‌های آماری صورت می‌گیرد که در ادامه توضیح داده شده است. شکل ۵ الگوریتم شبکه عصبی را نشان می‌دهد.





شکل ۴- توابع انتقالی شبکه عصبی



¹ Tangent sigmoid (Tansig)

² Log sigmoid (Logsig)

³ Purelin sigmoid (Purelin)



شکل ۶- نتایج حاصل از مدل ۹ برای روز ۲۰۱۶/۱۱/۲۱



شکل ۷- نتایج حاصل از مدل ۴ برای روز ۲۰۱۸/۰۸/۲۰

شکل ۸ آنالیز حساسیت را با توجه به شاخص‌های آماری مورد مطالعه برای مدل‌های شماره ۱ تا ۳، که ورودی هر سه مدل میزان تابش خورشیدی می‌باشد اما خروجی آنها به ترتیب توان پنل مونو کریستال، پنل پلی کریستال و هردو توان باهم می‌باشد، را نشان می‌دهد. همانطور که در شکل مشخص است شاخص خطای تقریبی و

$$MBE = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad (2)$$

$$t\text{-test} = \frac{\sqrt{(n-1)MBE^2}}{\sqrt{RMSE^2 - MBE^2}} \quad (3)$$

در معادلات فوق؛ P_i مقدار پیش‌بینی شده، O_i مقدار اندازه‌گیری شده و n تعداد مشاهدات می‌باشد. هرچه مقدار میانگین مربعات خطا کمتر باشد، مدل از دقت بیشتری برخوردار است. اگر مقدار میانگین خطای تقریبی مثبت باشد، یعنی مقدار پیش‌بینی شده از مقدار اندازه‌گیری شده بیشتر و اگر مقدار میانگین خطای تقریبی منفی باشد، یعنی مقدار اندازه‌گیری شده از مقدار پیش‌بینی شده کمتر است. جهت انجام شبیه‌سازی از داده‌های یکساله نیروگاه خورشیدی فتولتاییک دانشگاه ولی عصر (عج) رفسنجان استفاده شده است این داده‌ها در بازه زمانی ۵ دقیقه ذخیره شده‌اند از دو سوم کل داده‌ها یعنی حدود ۷۰ درصد برای آموزش، ۱۵ درصد برای صحت‌سنجی و ۱۵ درصد برای آزمون انتخاب شده است.

۴- نتایج

با توجه به اینکه برای تعیین بهترین ترکیب از توابع انتقال در شبکه با یک، دو یا سه لایه نهان، توابع انتقال مختلفی برای توسعه شبکه استفاده می‌شود و تعیین تعداد لایه‌های نهان جهت ایجاد یک شبکه با کمترین خطا در پیش‌بینی خروجی‌های مور دنظر، امری ضروری است. معمولاً برای تعیین تعداد بهینه لایه‌های نهان از رویه خطا و آزمایش استفاده می‌شود و بنابراین، ساختاری با کمترین تعداد لایه‌های نهان با درجه خطای قابل قبول انتخاب می‌گردد. هرچه تعداد لایه‌های نهان یک شبکه کمتر باشد، زمان کمتری برای آموزش شبکه مورد نیاز است. همچنین تعداد نرو-های موجود در لایه‌های نهان تأثیر بسزایی در عملکرد شبکه عصبی خواهد گذاشت. استفاده از تعداد نرون کم، مانع از یادگیری دقیق اغلب الگوهای موجود توسط شبکه عصبی می‌شود. از سویی دیگر، وجود تعداد بالای نرون‌ها منجر به حفظ کردن الگوها شده و در نتیجه مانع از یادگیری تشخیص ویژگی‌های اساسی آنها توسط شبکه عصبی می‌گردد. بنابراین ۹ مدل با تعداد لایه‌های نهان متفاوت و تعداد نرون‌های مختلف و ترکیب‌های مختلف توابع انتقالی با ورودی و خروجی‌های مختلف انتخاب گردید که در ادامه نتایج بررسی این مدل‌ها ارائه می‌گردد.

در شکل ۶ نتایج حاصل از مدل انتخاب شده (مدل ۹) در روز بیست و یکم نوامبر سال ۲۰۱۶ برای توان پنل‌های پلی کریستال و مونو کریستال نشان داده شده است. همچنین شکل ۷ نیز مقایسه بین نتایج مدل‌سازی و داده‌های اندازه‌گیری شده در روز بیستم آگوست سال ۲۰۱۸ را نشان می‌دهد همانطور که از دو شکل هم مشخص است نتایج این روزها برای پنل‌های مونو کریستال و پلی کریستال بیانگر مدل‌سازی مناسب سیستم توسط شبکه عصبی می‌باشد.

تجربی نیز نتیجه بدست آمده قابل پیش بینی می باشد. بطور مثال در صورتی که دمای پنل در در تابستان ۶۰ درجه سلسیوس باشد ولی بطور لحظه ای یک ابر یا گرد و غبار جو تابش خورشید را بگیرد، توان تولیدی کاهش شدیدی می یابد.

در ادامه نتایج شبیه سازی برای مدل دو لایه {۵ ۵} که در هر لایه ۵ نرون می باشد و از هر سه تابع انتقالی استفاده شده است در جدول ۳ نشان داده شده است. در اینجا هم همانطور که از نتایج مشخص است مدل هایی که ورودی آنها فقط دما می باشد نتایج ضعیف تری را دارند و مدل های با ورودی تابش (مدل های ۱ تا ۳) نتایج بهتری از خود بروز کرده اند. در جدول ۴ این نتایج برای سه لایه {۱۰ ۱۰ ۱۰} که دارای ده نرون در هر لایه است و از هر سه تابع انتقالی استفاده شده است نشان داده شده است. در اینجا هم همانطور که از نتایج مشخص است مدل هایی که ورودی آنها فقط دما می باشد نتایج ضعیف تری را دارند و ورودی تابش نتایج بهتری از خود بروز کرده اند. با توجه به نتایج شاخص های آماری، مدل شماره ۹ که دارای دو ورودی دمای پنل و تابش خورشید می باشد و همزمان دارای دو خروجی توان پنل های مونوکریستال و پلی کریستال می باشند، جهت تحقیقات بیشتر انتخاب گردید.


با توجه به توضیحات داده شده برای انتخاب مدل ۹، در جدول ۵ نتایج حاصل از این مدل (۲ ورودی و ۲ خروجی) برای تعداد نرون ها و توابع مختلف نشان داده شده است. همانطور که از نتایج مشخص است مدل با سه لایه نهان و ده نرون در هر لایه {۱۰ ۱۰ ۱۰} و توابع لگاریتم، تانژانت و خطی نتایج بهتری داشته است که باعث گردید این مدل برای پیش بینی توان تولیدی سیستم فتوولتایی انتخاب گردد. ارتباط بین مقادیر واقعی و با مقادیر پیش بینی شده توسط شبکه عصبی در شکل ۱۰ نشان داده شده است. در این شکل ها داده های آموزش اعتبارسنجی و آزمون نشان داده شده اند. همانطور که از نتایج جدول ۵ و شکل ۱۰ مشخص است نزدیک بودن شیب عبوری به عدد ۱ و مقدار عرض از مبدا، نشان دهنده کارایی خوب شبکه عصبی طراحی شده می باشد و می توان در موقع نیاز با دقت خوبی از آن استفاده نمود. شکل ۱۱ نمودار همگرایی شبکه عصبی برای مدل سه لایه {۱۰ ۱۰ ۱۰} و توابع انتقالی را نشان می دهد. همانطور که از شکل مشخص است سیستم در تکرار ۱۹ همگرا شده است.

در مجموع می توان گفت، همانطور که از نتایج جدول های ۲ تا ۵ مشخص است مدل هایی که تابش خورشیدی یکی از ورودی های آنها باشد بخوبی توانسته اند توان تولیدی را تخمین بزنند. در مدل های ۱ تا ۳ تابش خورشید تنها ورودی می باشد و در مقایسه این سه مدل، مدل ۱ بهتر از بقیه می تواند توان خروجی را یعنی توان مونوکریستال را تخمین بزند که این بدلیل ساختار این نوع پنل و بازده بیستر آن نسبت به پنل پلی کریستال بر می گردد. نتایج نشان می دهد که هرچه تعداد نرون در هر لایه و تعداد لایه ها نیز تعداد ورودی های شبکه عصبی بیشتر باشد خروجی را بهتر و دقیق تر می تواند تخمین و پیش بینی نماید، همانگونه که در جدول ۵ مشخص است هرچه تعداد نرون ها و لایه ها بیشتر باشد نتایج مدلسازی بهتر می باشد.


۵- جمع بندی و نتیجه گیری

در این مقاله با استفاده از داده های یک ساله سایت خورشیدی

ضریب تعیین برای توان پلی کریستال نسبت به مونو کریستال و مجموع بیشتر می باشد. همچنین شاخص خطای میانگین مربعات و آزمون تی برای مدل شماره ۳ که خروجی آن توان مونوکریستال و پلی کریستال باهم می باشد بیشتر است.



شکل ۸- آنالیز حساسیت برای مدل های ۱، ۲ و ۳ با ورودی یکسان و خروجی متفاوت



شکل ۹- آنالیز حساسیت برای مدل های ۱، ۴ و ۷ با خروجی یکسان و ورودی متفاوت

شکل ۹ آنالیز حساسیت را با توجه به شاخص های آماری مورد مطالعه برای مدل های شماره ۱، ۴ و ۷، که خروجی هر سه مدل توان مونوکریستال می باشد اما ورودی آنها به ترتیب تابش خورشیدی، دمای محیط و دما و تابش با هم می باشد، را نشان می دهد. همانطور که در شکل مشخص است شاخص خطای میانگین مربعات و خطای تقریبی برای ورودی دما نسبت به ورودی تابش و دما و تابش باهم بیشتر اما شاخص ضریب تعیین و آزمون تی کمتر می باشد.

جدول ۲ نتایج شبیه سازی برای مدل تک لایه که دارای پنج نرون {۵} و از توابع انتقالی خطی و تانژانت استفاده شده است را نشان می دهد. در این جداول برای هر مدل، چندین شبیه سازی انجام شده است و نتایج شبیه سازی با تعداد کمتر انتخاب و گزارش شده است. همانطور که از نتایج مشخص است مدل های ۴، ۵ و ۶ که ورودی آنها فقط دما می باشد نتایج ضعیف تری را دارند. همانطور که از نتایج مشخص است، مدل هایی که ورودی آنها فقط دما (مدل های ۴، ۵ و ۶) می باشد، به تنهایی قادر نیستند که توان خروجی را پیش بینی کنند و از لحاظ

دانشگاه ولی عصر(عج) رفسنجان که شامل پنل‌های مونو و پلی کریستال نصب شده در نیروگاه ۲/۵ kW است، مدل‌سازی شبکه‌های عصبی سیستم‌های فتوولتایی ارائه شده است. در این مقاله هدف به دست آوردن مدلی بهینه برای پنل‌های موردنظر در این شرایط آب هوایی جهت تخمین توان تولیدی از آن‌ها می‌باشد. در اینجا ۹ مدل متفاوت بررسی گردید. در این مدل‌ها؛ ورودی‌ها، دمای پنل و تابش مستقیم خورشید و خروجی‌ها توان تولیدی پنل‌های مونوکریستال و

پلی کریستال می‌باشند. آنالیز حساسیت برای انواع ورودی و خروجی و نیز برای تعداد مختلف نرون و توابع مختلف نیز بررسی گردید. نتایج برای یک روز نیز مقایسه گردید. نتایج حاصله گویای مدل‌سازی دقیق پنل‌ها توسط سیستم‌های مورد استفاده در این تحقیق می‌باشد. در نهایت بهترین مدل از ۹ مدل ارائه شده مدل با ورودی دما و تابش و خروجی پنل مونوکریستال و پلی-کریستال می‌باشد.

جدول ۲- نتایج شبیه سازی برای تک لایه با ۵ نرون {۵} برای ۹ مدل در نظر گرفته شده

مدل	تکرار	ضریب همبستگی				میانگین مربعات خطا	میانگین خطای تقریبی	آزمون تی
		آموزش	اعتبارسنجی	آزمون	میانگین			
مدل ۱	۳۸	۰/۹۵۴۴۹	۰/۹۵۷۶۳	۰/۹۵۹۱۸	۰/۹۵۵۵۶	۸۷/۱۲۳	-۰/۴۷۹۷	۰/۴۳۷۹
مدل ۲	۱۴	۰/۹۲۰۴۹	۰/۹۱۵۸۹	۰/۹۳۱۶	۰/۹۲۰۰۲	۱۲۱/۶۴۵۶	-۰/۷۶۴۴	۰/۴۹۹۸
مدل ۳	۱۵۱	۰/۹۳۸۳۲	۰/۹۳۶۳۷	۰/۹۳۳۸۸	۰/۹۳۷۳۴	۱۰۸/۲۶۴۱	-۱۰/۱۷۷۷	۷/۵۱۰۳
مدل ۴	۱۸	۰/۵۵۳۷۵	۰/۵۵۲۲۵	۰/۵۶۹۱	۰/۵۵۵۸۴	۲۴۵/۶۶۹۹	-۱/۹۰۸۷	۰/۶۱۷۷
مدل ۵	۲۶	۰/۶۱۲۸۴	۰/۵۹۹۹	۰/۶۰۰۳۷	۰/۶۰۰۸۸	۲۴۶/۵۹۹۲	-۰/۵۹۶۹	۰/۱۹۲۵
مدل ۶	۸	۰/۵۷۸۱	۰/۶۰۵۵۴	۰/۵۹۷۵۶	۰/۵۸۵۳	۲۶۱/۴۰۹۴	-۸/۹۴۴۷	۲/۲۷۳۱
مدل ۷	۹	۰/۹۵۹۰۲	۰/۹۵۸۵۴	۰/۹۶۰۶۲	۰/۹۵۹۱۴	۸۳/۶۳۵۷	۱/۷۹۶۸	۱/۷۰۹۱
مدل ۸	۳۷	۰/۹۲۷۶۸	۰/۹۲۸۲	۰/۹۳۳۸۱	۰/۹۲۸۶۵	۱۱۵/۳۲۶۸	۱/۴۹۹۲	۱/۰۳۴
مدل ۹	۵۵	۰/۹۴۲۹۱	۰/۹۴۵۴۳	۰/۹۴۲۲۴	۰/۹۴۳۱۸	۱۰۳/۷۲۱۲	-۱۱/۵۹۲۹	۸/۹۳۹۷

جدول ۳- نتایج شبیه سازی برای دو لایه با ۵ نرون در هر لایه {۵ ۵}


مدل	تکرار	ضریب همبستگی				میانگین مربعات خطا	میانگین خطای تقریبی	آزمون تی
		آموزش	اعتبارسنجی	آزمون	میانگین			
مدل ۱	۵۰	۰/۹۴۹۷۶	۰/۹۴۳۳۶	۰/۹۳۸۰۲	۰/۹۴۷۰۲	۹۴/۹۳۰۱	۱/۱۱۲	۰/۹۳۱۸
مدل ۲	۷۲	۰/۹۱۹۵۵	۰/۹۲۱۲۶	۰/۹۳۱۸۸	۰/۹۲۰۱۵	۱۲۱/۷۱۴۱	-۰/۵۰۰۸	۰/۳۲۷۳
مدل ۳	۳۶	۰/۹۳۵۸۸	۰/۹۴۱۲۸	۰/۹۳۹۲	۰/۹۳۷۱۸	۱۰۸/۴۷۸۵	-۱۲/۰۱۹۶	۸/۸۶۷۳
مدل ۴	۶	۰/۵۵۶۳۵	۰/۵۳۳۸۸	۰/۵۶۹۱۴	۰/۵۵۵۰۹	۲۴۵/۸۱۴۲	-۰/۵۱۳۹	۰/۱۶۶۳
مدل ۵	۲۸	۰/۶۱۰۲	۰/۵۹۸۰۲	۰/۶۰۰۸۳	۰/۶۰۰۸۱۹	۲۴۶/۷۵۸۸	-۲/۸۹۸۸	۰/۹۳۴۴
مدل ۶	۸۶	۰/۵۹۰۸۹	۰/۵۴۵۳	۰/۶۰۵۹۳	۰/۵۸۶۹۷	۲۶۰/۷۶۶۸	-۱۲/۶۶۶۴	۳/۸۶۷۹
مدل ۷	۱۳	۰/۹۶۰۲۷	۰/۹۶۵۹۱	۰/۹۵۹۸۱	۰/۹۶۱۰۸	۸۱/۶۴۰۶	-۰/۰۵۲۸	۰/۰۵۱۴
مدل ۸	۱۱	۰/۹۳۲۸۲	۰/۹۲۰۵۳	۰/۹۲۲۵۱	۰/۹۲۹۴۲	۱۱۴/۷۰۵۵	-۰/۰۳۸۱	۰/۰۲۶۴
مدل ۹	۲۷	۰/۹۴۲۴۶	۰/۹۴۹۲۳	۰/۹۴۲۵	۰/۹۴۳۵۱	۱۰۳/۲۶۵۸	-۱۲/۷۱۵۲	۹/۸۶۸۵

جدول ۴- نتایج شبیه سازی برای سه لایه با ده نرون در هر لایه {۱۰ ۱۰ ۱۰}


مدل	تکرار	ضریب همبستگی				میانگین مربعات خطا	میانگین خطای تقریبی	آزمون t
		آموزش	اعتبارسنجی	آزمون	میانگین			
مدل ۱	۵۲	۰/۹۵۵۵۸	۰/۹۵۶۴۹	۰/۹۵۶۱۵	۰/۹۵۵۷۸	۸۶/۹۱۶۵	۱/۳۰۰۱	۱/۱۸۹۸
مدل ۲	۲۵	۰/۹۱۹۸۶	۰/۹۱۷۰۷	۰/۹۲۵	۰/۹۲۰۲۲	۱۲۱/۶۸۰۱	-۰/۹۴۹۳	۰/۶۲۰۶
مدل ۳	۲۵	۰/۹۳۵۶۸	۰/۹۴۳۶۲	۰/۹۳۷۷۵	۰/۹۳۷۳۳	۱۰۸/۵۲۹۲	-۱۱/۷۰۷۸	۸/۶۳۰۵
مدل ۴	۶	۰/۵۵۹۱۱	۰/۵۵۲۲۸	۰/۵۵۵۸۴	۰/۵۵۷۴۸	۲۴۵/۳۴۶۹	۱/۹۱۲۳	۰/۶۱۹۹
مدل ۵	۳۱	۰/۶۰۷۸۶	۰/۶۱۵۶۴	۰/۶۲۳۲۱	۰/۶۱۱۲۱	۲۴۶/۰۵۶۱	-۳/۶۹۸۵	۱/۱۹۵۷
مدل ۶	۹	۰/۵۹۷۳۸	۰/۵۷۵۱۹	۰/۵۵۰۷۳	۰/۵۸۷۱۲	۲۶۰/۵۵۵۲	-۱۱/۲۶۴۶	۳/۴۴۱۸
مدل ۷	۱۰	۰/۹۶۲۱	۰/۹۵۱۲۸	۰/۹۶۳۶	۰/۹۶۰۷۲	۸۲/۰۱۰۱	-۰/۴۳۶۱	۰/۴۲۳
مدل ۸	۳۴	۰/۹۳۴۵۴	۰/۹۳۲۹	۰/۹۳۴۰۴	۰/۹۳۴۲	۱۱۰/۹۰۷	-۱/۶۲۳۸	۱/۱۶۴۶
مدل ۹	۱۹	۰/۹۷۷۶	۰/۹۷۲۴۵	۰/۹۷۱۳۸	۰/۹۷۵۹۹	۱۰۰/۰۶۸۴	-۱۵/۹۷۵۱	۱۲/۸۶۲۳

جدول ۵- نتایج حاصل از مدل شماره ۹ برای تعداد لایه‌ها، نرون ها و توابع مختلف

مدل	توابع	تکرار	ضریب همبستگی				میانگین مربعات خطا	میانگین خطای تقریبی	آزمون تی
			آموزش	اعتبارسنجی	آزمون	میانگین			
{۵}	خطی، تانژانتی	۵۵	۰/۹۴۲۹۱	۰/۹۴۵۴۳	۰/۹۴۲۳۴	۰/۹۴۳۱۸	۱۰۳/۹۷۱۲	-۱۱/۵۹۳۹	۸/۹۳۹۷
{۵ ۵}	خطی، تانژانتی، لگاریتمی	۳۷	۰/۹۴۲۴۶	۰/۹۴۹۲۳	۰/۹۴۲۵	۰/۹۴۳۵۱	۱۰۳/۲۶۵۸	-۱۲/۷۱۵۲	۹/۸۶۸۵
{۵ ۵ ۵}	خطی، خطی، تانژانتی، لگاریتمی	۵۲	۰/۹۴۰۸۲	۰/۹۵۱۶۹	۰/۹۵۰۲۹	۰/۹۴۳۹۶	۱۰۳/۰۶۸۳	-۱۲/۹۶۴۷	۱۰/۰۸۴۸
{۱۰}	خطی، تانژانتی	۲۰	۰/۹۴۶۳۹	۰/۹۴۱۱۳	۰/۹۴۴۴۳	۰/۹۴۵۲۸	۱۰۴/۳۵۲	۱۰۰/۱۸۵۱	۹/۷۱۴۳
{۱۰ ۱۰}	خطی، تانژانتی، لگاریتمی	۳۵	۰/۹۴۹۴۲	۰/۹۳۸۰۸	۰/۹۴۷۲۵	۰/۹۴۷۴۳	۹۷/۹۲۰۷	-۱۱/۳۲۱	۹/۱۷۴۷
{۱۰ ۱۰ ۱۰}	خطی، خطی، تانژانتی، لگاریتمی	۱۹	۰/۹۷۷۶	۰/۹۷۲۴۵	۰/۹۷۱۸۳	۰/۹۷۵۹۹	۱۰۰/۰۶۸۴	-۱۵/۹۷۵۱	۱۲/۸۶۲۳



شکل ۱۰- ارتباط بین مقادیر واقعی و با مقادیر پیش بینی شده توسط شبکه عصبی



شکل ۱۱- نمودار همگرایی شبکه عصبی برای مدل سه لایه {۱۰ ۱۰ ۱۰} و توابعی خطی، تانژانتی و لگاریتمی

- [15] Mandal P., Madhira S. T. S., Meng J., & Pineda R. L. Forecasting power output of solar photovoltaic system using wavelet transform and artificial intelligence techniques. *Procedia Computer Science*, Vol. 12, pp.332-337, 2012.
- [16] Saberian A., Hizam H., Radzi M. A. M., Ab Kadir M. Z. A., and Mirzaei M. Modelling and prediction of photovoltaic power output using artificial neural networks. *International journal of Photoenergy*, Vol.20, No 14, pp.1-12, 2014.
- [17] Hadi R. S., and Abdulateef O. F. Modeling and Prediction of Photovoltaic Power Output Using Artificial Neural Networks Considering Ambient Conditions, *Association of Arab Universities Journal of Engineering Sciences*, Vol. 25, Vol. 5, pp. 623-638, 2018.
- [18] Nespoli A., Ogliari E., Leva S., Massi Pavan A., Mellit A., Lughì V., & Dolara A. Day-ahead photovoltaic forecasting: A comparison of the most effective techniques. *Energies*, Vol. 12, No. 9, pp. 1621- 1632, 2019.
- [19] Moravaj Z., Azarakhsh J., Modeling Impact Energy of Ranked Steels Using Artificial Neural Networks, *Journal of Modeling in Engineering, Semnan University*, Vol. 13, No. 41, pp. 137-146, 2014.
- [20] Firouznia R., Amjadi N., Short-term load forecast using load time series and neural network analysis, *Journal of Modeling in Engineering, Semnan University*, Vol. 2, No. 16, pp. 23-32, 2008.
- [21] Mellit A., Saglam S., Kalogirou S. A., Artificial neural network-based model for estimating the produced power of a photovoltaic module, *Renewable Energy*, Vol. 60, pp. 71–78, 2013.
- [22] Almonacid F., Rus C., Hontoria L., Fuentes M., and Nofuentes G., Characterisation of Si-crystalline photovoltaic modules by artificial neural networks, *Renewable Energy*, Vol.34, No. 4, pp. 941–949, 2009.
- [23] Monteiro R. V., Guimarães G. C., Moura F. A., Albertini M. R., and Albertini M. K., Estimating photovoltaic power generation: Performance analysis of artificial neural networks, Support Vector Machine and Kalman filter, *Electric Power Systems Research*, Vol. 143, pp. 643-656, 2017.
- [24] Zamani Mohiabadi M., The instantaneous prediction of the global solar radiation in the Rafsanjan city, *Iranian journal of energy*, Vol. 16, No. 4, pp. 15-31, 2012.
- [25] Menhaj M. B., *Fundamentals of Neural Networks*, Amirkabir University, pp.37-40, 2013.
- [26] Zamani Mohiabadi M., and Mirzaei M., Comparison of two intelligent models to estimate the instantaneous global solar radiation in semi-arid climate conditions: Application in Iran, *Journal of Earth System Science*, Vol. 126, No. 5, pp. 75-88, 2017
- [27] Agatonovic-Kustrin S., and Beresford R. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of pharmaceutical and biomedical analysis*, Vol. 22, No. 5, pp.717-727, 2000.
- [28] Jacovides C. P. Reply to comment on Statistical procedures for the evaluation of evapotranspiration models, *Agricultural water management*, Vol. 3, pp. 95-97, 1997.
- [1] Mirzaei M., and Zamani Mohiabadi, M., A comparative analysis of long-term field test of monocrystalline and polycrystalline PV power generation in semi-arid climate conditions, *Energy for Sustainable Development*, Vol. 38, pp. 93-101, 2017.
- [2] Shi J., Lee W. J., Liu Y., Yang Y., & Wang P. Forecasting power output of photovoltaic systems based on weather classification and support vector machines. *IEEE Transactions on Industry Applications*, Vol. 48, No. 3, pp.1064-1069, 2012.
- [3] Kostylev V., & Pavlovski A. Solar power forecasting performance – towards industry standards, *1st International Workshop on the Integration of Solar Power into Power Systems, Aarhus, Denmark*, 2011.
- [4] Thomson M., and Infield D. G., Impact of widespread photovoltaics generation on distribution systems, *IET Renewable Power Generation*, Vol. 1, No.1, pp. 33-40, 2007.
- [5] Tan Y. T., and Kirschen D. S., Impact on the power system of a large penetration of photovoltaic generation,” *IEEE Power Engineering Society General Meeting*, pp. 1-8, 2007.
- [6] Aguiar L. M., Pereira B., Lauret P., Díaz F., and David M. Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting, *Renewable Energy*, Vol. 97, pp. 599-610, 2016.
- [7] d'Alessandro V., Di Napoli F., Guerriero P., & Daliento S, An automated high-granularity tool for a fast evaluation of the yield of PV plants accounting for shading effects, *Renewable Energy*, Vol. 83, pp. 294-304, 2015.
- [8] Reindl T., Walsh W., Yanqin Z., & Bieri M. Energy meteorology for accurate forecasting of PV power output on different time horizons. *Energy Procedia*, Vol. 130, pp.130-138, 2017.
- [9] Malvoni M., De Giorgi M. G., & Congedo P. M. Forecasting of PV Power Generation using weather input data-preprocessing techniques. *Energy Procedia*, Vol. 126, pp.651-658, 2017.
- [10] Junior J. G. D. S. F., Oozeki T., Ohtake H., Shimose K. I., Takashima, T., & Ogimoto, K., Forecasting regional photovoltaic power generation-a comparison of strategies to obtain one-day-ahead data, *Energy Procedia*, Vol. 57, pp. 1337-1345, 2014.
- [11] Wang F., Mi Z., Su S., & Zhao H. Short-term solar irradiance forecasting model based on artificial neural network using statistical feature parameters, *Energies*, Vol. 5, No. 5, pp. 1355–1370, 2012.
- [12] Gutierrez-Corea F. V., Manso-Callejo M. A., Moreno-Regidor M. P., and Manrique-Sancho, M. T. Forecasting short-term solar irradiance based on artificial neural networks and data from neighboring meteorological stations, *Solar Energy*, Vol. 134, pp. 119-131, 2016.
- [13] Sivaneasan B., Yu C. Y., & Goh K. P. Solar forecasting using ANN with fuzzy logic pre-processing. *Energy procedia*, Vol. 143, pp. 727-732., 2017.
- [14] Liu L., Liu D., Sun Q., Li H., & Wennersten R. Forecasting power output of photovoltaic system using a BP network method. *Energy Procedia*, Vol. 142, pp. 780-786, 2017.