

# تخمین تابش کلی خورشید در استان کرمانشاه با استفاده از شبکه‌های عصبی مصنوعی

یاسر واثقیان<sup>۱</sup>

تاریخ پذیرش مقاله:

۹۴/۱۲/۲۴

تاریخ دریافت مقاله:

۹۴/۷/۳

## چکیده:

هدف مطالعه حاضر توسعه یک مدل شبکه عصبی مصنوعی (ANN) بر اساس روش رگرسیون غیرخطی چندگانه (MNL) برای تخمین میانگین ماهانه مجموع روزانه تابش کلی خورشید در هر محل از استان کرمانشاه است. برای این منظور، داده‌های هواشناسی ۲۳ ایستگاه در استان کرمانشاه در طول سالهای ۱۳۹۲-۱۳۸۷ جمع‌آوری که داده‌های ۱۷ ایستگاه برای آموزش و ۶ ایستگاه برای آزمایش شبکه استفاده شد. در مرحله اول، همه متغیرهای مستقل (عرض جغرافیایی، طول جغرافیایی، ارتفاع، ماه، حداقل درجه حرارت ماهانه در جو، حداکثر درجه حرارت در جو، متوسط درجه حرارت در جو، دمای خاک، رطوبت نسبی، سرعت باد، بارش، فشار اتمسفریک، فشار بخار، کدورت و مدت زمان تابش آفتاب) جمع‌آوری و پس از انتخاب مناسب‌ترین متغیرهای ورودی، با استفاده از این متغیرهای ورودی، نتایج بدست آمده توسط مدل ANN با داده‌های واقعی مقایسه شد و میانگین درصد خطای مطلق (MAPE) در حدود ۳/۹۸ درصد و ضریب همبستگی (R) در حدود ۰/۹۹۶۱ برای مجموعه داده‌های آزمایش به دست آمد که نشان‌دهنده معتبر بودن مدل است.

## کلمات کلیدی:

شبکه‌های عصبی مصنوعی، رگرسیون غیرخطی چندگانه، سری‌های زمانی، تابش کلی خورشید، استان کرمانشاه

## مقدمه

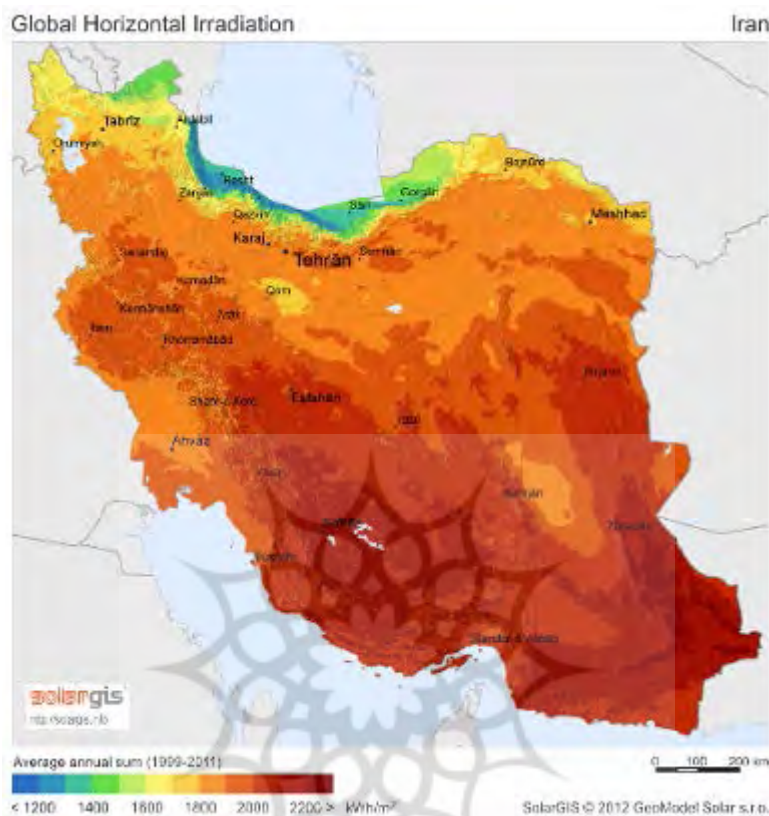
افزایش نگرانی در مورد اثر گازهای گلخانه‌ای<sup>۱</sup> تولیدی بر روی تغییرات آب و هوایی، دولت‌ها و جوامع بین‌المللی را برای رسیدن به توسعه پایدار در اقتصادی که وابستگی کمتری به تولید کربن داشته باشد (چشم‌اندازی که معمولاً جامعه کم کربن<sup>۲</sup> نامیده می‌شود) ترغیب می‌کند. از آنجا که منابع انرژی موجود، منبع اصلی انتشار گازهای گلخانه‌ای می‌باشند، بازسازی سیستم‌های انرژی موجود به منظور تحقق چشم‌انداز LCS ضروری است [۲۷]. برای پرداختن به این نگرانی‌ها تا حدی، جوامع جهانی در حال تلاش برای پیدا کردن و پیاده‌سازی راهبرد فناوری‌های صرفه‌جو در انرژی‌های مختلف و منابع جایگزین انرژی برای بخش‌های مختلف انرژی می‌باشند. در این راستا، توسعه انرژی خورشیدی، علاوه بر اینکه نقش قابل توجهی در پاسخگویی به تقاضای انرژی در آینده دارد، می‌تواند آلودگی‌های زیست‌محیطی را نیز تا حدودی کاهش دهد [۲۷].

مقدار انرژی تابشی خورشید در یک ثانیه بیش از کل انرژی استفاده شده جمعیت جهان از آغاز تاریخ است [۱۹]. منابع سوخت‌های فسیلی محدود هستند و منجر به تغییرات آب و هوایی ناخواسته می‌شوند در حالی که انرژی خورشیدی یکی از پاک‌ترین انواع انرژی است که می‌تواند به عنوان یک جایگزین برای منابع انرژی سوخت‌های فسیلی استفاده شود و منجر به کاهش سرعت گرم شدن کره زمین شود. این عوامل زمینه‌ای مناسب را برای توجه به انرژی خورشیدی بخصوص در مناطق با تابش خورشیدی بالا فراهم کرده است. فناوری‌های انرژی خورشیدی شامل گرمایش خورشیدی، فتوولتائیک خورشیدی، برق حرارتی خورشیدی و ساختار خورشیدی می‌توانند نقش قابل توجهی در حل برخی از مهمترین مشکلاتی که در حال حاضر جهان با آن مواجه است، ایفا کنند [۳۸].

در میان مناطق با پتانسیل انرژی خورشیدی می‌توان به جنوب‌غربی ایالات متحده آمریکا، کشورهای مدیترانه، خاورمیانه و خاور نزدیک، ایران و صحراهای هند، پاکستان، چین و استرالیا اشاره کرد. در بسیاری از نقاط جهان، امکان تولید بین ۱۰۰ تا ۳۰۰ گیگاوات ساعت برق خورشیدی با استفاده از فناوری‌های گرمایش خورشیدی در مساحت یک کیلومتر مربع وجود دارد. این میزان برابر با میزان تولید سالانه برق در برابر متوسط تولید، توسط سوخت‌های متعارف فسیلی، زغال‌سنگ و نیروگاه‌های گازی با ظرفیت ۵۰ مگاوات است. در کمربند خورشیدی جهان، ایران از ۲۸۰۰ ساعت آفتابی در سال برخوردار است و متوسط نرخ عایق‌های خورشیدی کشور ۲۰۰۰ کیلووات ساعت بر مترمربع در سال تخمین زده می‌شود (شکل ۱) [۹].

1) Green House Gas (GHG)

2) Low-Carbon Society (LCS)



شکل (۱) نقشه انرژی خورشیدی ایران [۲۶]

مقدار تابش کلی خورشید<sup>۱</sup> یک پارامتر بسیار مهم در کاربردهای انرژی خورشیدی است [۱۱]. برای استفاده ارزان و موثر از انرژی خورشیدی، دانش کامل در مورد دسترسی و تنوع شدت تابش خورشیدی در زمان و دامنه خاص از اهمیت زیادی برخوردار است [۳۱]. اندازه‌گیری تابش کلی خورشید معمولاً در سایت‌های کمی که شبیه به سایت‌های واقعی ساخته شده‌اند، ممکن است. به طور کلی، مطالعه رفتار تابش خورشید در محل، نیاز به داده‌های طولانی مدت در یک مکان همراه با شبکه‌های تجربی، نیمه تجربی، فیزیکی، عصبی، موجک، فرکتال و غیره دارد [۳۱]. تاکنون مطالعات زیادی در مورد مدل‌های تجربی آنگستروم به منظور برآورد GSR در سطح افقی انجام شده و در این مطالعات، مقادیر مدت زمان نور خورشید اندازه‌گیری شده است [۲,۳,۵,۷,۱۰,۱۱,۳۰]. همچنین چند مدل معمولی برای پیش‌بینی GSR با استفاده از متغیرهای مختلف هواشناسی توسط محققان ارائه شده است [۱,۲۸,۳۱,۳۲]. شبکه‌های عصبی مصنوعی یک ابزار پیش‌بینی قوی برای پیش‌بینی از طریق متغیرهایی است که هیچ رابطه مشخصی بین آنها وجود ندارد. متغیرهای

1) Global Solar Radiation (GSR)

هواشناسی مهمترین پارامترهایی هستند که مقدار تابش خورشیدی در یک ناحیه را نشان می‌دهند [۸]. مطالعات مختلفی در پیش‌بینی تابش خورشید توسط شبکه‌های عصبی مصنوعی وجود دارد.

Al-Hinai و Al-Alawi در سال ۱۹۹۸ از پارامترهای مکان، ماه، متوسط فشار، دما، فشار بخار، رطوبت نسبی، سرعت باد و طول مدت تابش خورشید به عنوان ورودی به شبکه عصبی مصنوعی برای پیش‌بینی GSR در منطقه ماجیز (شمال عمان) استفاده کردند. نتایج نشان داد که ضریب همبستگی بین مقادیر پیش‌بینی شده و اندازه‌گیری شده (R) و میانگین درصد خطای مطلق (MAPE) به ترتیب برابر ۰/۹۳ و ۷/۳۰ درصد است که این مقادیر نشان‌دهنده توانایی شبکه‌های عصبی مصنوعی برای پیش‌بینی GSR در این منطقه از عمان است [۴].

Onat و Togrul در سال ۱۹۹۹ از پارامترهای جغرافیایی و هواشناسی (متوسط تابش فرازمینی ماهانه، نسبت ساعات آفتابی (روشن) به طول روز، درجه حرارت محیط و خاک، رطوبت و سینوس زاویه میل) همراه با روش LR برای پیش‌بینی تابش خورشید در سایت الازبک در ترکیه استفاده کردند [۳۹].

Sozen و همکارانش در سال ۲۰۰۴ پتانسیل انرژی خورشیدی برای ۱۷ سایت در ترکیه را با استفاده از متغیرهای هواشناسی و جغرافیایی (عرض جغرافیایی، طول جغرافیایی، ارتفاع، ماه، میانگین مدت زمان نور خورشید و متوسط درجه حرارت) به عنوان ورودی شبکه‌های عصبی پیش‌بینی کردند. در این مطالعه، داده‌های ۱۱ ایستگاه برای آموزش شبکه عصبی و داده‌های ۶ ایستگاه دیگر برای آزمایش شبکه استفاده شدند. نتایج نشان داد که ضریب همبستگی (R) و میانگین درصد خطای مطلق (MAPE) به ترتیب ۰/۹۹۸۹ و ۶/۷ درصد است [۳۷].

در تحقیقی دیگر، Sozen و همکارانش در سال ۲۰۰۵ پتانسیل انرژی خورشیدی برای ۱۲ سایت در ترکیه را با استفاده از شبکه‌های عصبی مبتنی بر عوامل هواشناسی و جغرافیایی پیش‌بینی کردند. در این مطالعه، از داده‌های ۹ ایستگاه برای آموزش شبکه و از داده‌های ۳ ایستگاه دیگر برای آزمایش شبکه استفاده شد. نتایج بدست آمده نشان داد که ضریب همبستگی (R) و میانگین درصد خطای مطلق (MAPE) به ترتیب ۰/۹۹۷۸ و ۶/۷۸ درصد است [۳۶].

Mohandes و Rehman در سال ۲۰۰۸ از شبکه‌های عصبی مصنوعی به منظور برآورد GSR برای سایت ابها در عربستان سعودی استفاده کردند. در این مطالعه دمای هوا، تعداد روز و رطوبت نسبی به عنوان ورودی به شبکه عصبی در نظر گرفته شد و نتایج نشان داد که میانگین درصد خطای مطلق (MAPE) در حدود ۴/۴۹ درصد است [۳۱].

Azadeh و همکارانش در سال ۲۰۰۹ با استفاده از متغیرهای اقلیمی و هواشناسی از قبیل متوسط حداکثر دما، حداقل دما، رطوبت نسبی، فشار بخار، سرعت باد، طول مدت تابش آفتاب و بارش کل، GSR ماهانه را برای شش سایت در ایران با استفاده از شبکه‌های عصبی پرسپترون چند لایه (MLP) مطالعه کردند. نتایج نشان داد که ضریب همبستگی (R) و میانگین درصد خطای مطلق (MAPE) به ترتیب ۰/۹۴ و ۶/۷۰ درصد است [۸].

Senkal و Kuleli در سال ۲۰۰۹ از پارامترهای جغرافیایی و هواشناسی (عرض جغرافیایی، طول جغرافیایی، ارتفاع، ماه، متوسط تابش منتشر شده و متوسط تابش پرتو خورشیدی) به عنوان ورودی به مدل ANN برای برآورد GSR در ترکیه استفاده کردند. آنها در این مطالعه از داده‌های ۱۲ ایستگاه برای آموزش شبکه و از داده‌های ۳ ایستگاه دیگر برای آزمایش شبکه استفاده کردند. و به این نتیجه رسیدند که شبکه‌های عصبی مصنوعی می‌تواند با دقت قابل قبولی GSR در ترکیه را پیش‌بینی کند [۳۴].

Rahimikhoob در سال ۲۰۱۰ از شبکه‌های عصبی مصنوعی برای برآورد GSR در یک محیط نیمه‌خشک استفاده کرد. در این مطالعه، شبکه‌های عصبی مصنوعی از نوع پرسپترون چند لایه به منظور برآورد GSR به عنوان تابعی از حداکثر و حداقل دمای هوا و تابش فرازمینی آموزش داده شد. داده‌های مورد استفاده در آموزش شبکه از داده‌های ایستگاه اهواز در فاصله زمانی ۲۰۰۱-۱۹۹۴ جمع‌آوری شدند. در این مطالعه همچنین معادلات تجربی هارگریوز و سامانی (HS) نیز برای مقایسه استفاده شد. نتایج این مطالعه نشان داد که روش ANN بهتر از روش HS می‌تواند GSR را پیش‌بینی کند [۲۹].

Hasni و همکارانش در سال ۲۰۱۲ از شبکه‌های عصبی مصنوعی برای برآورد GSR به عنوان تابعی از درجه حرارت هوا و رطوبت نسبی در منطقه جنوب‌غربی الجزایر استفاده کردند. در این مطالعه از داده‌های بین ۲ فوریه تا ۳۱ مه سال ۲۰۱۱ برای آموزش شبکه و همچنین از داده‌های ۶۵۱ ساعت از ژوئن ۲۰۱۱ برای آزمایش شبکه استفاده شد. نتایج بدست آمده نشان داد که شبکه‌های عصبی بخوبی قادر به برآورد GSR است [۱۸].

Landeras و همکارانش در سال ۲۰۱۲ از روش برنامه‌نویسی (GEP)، شبکه‌های عصبی مصنوعی و سیستم فازی عصبی برای مدل‌سازی برآورد تابش خورشیدی ورودی روزانه در منطقه باسک (شمال اسپانیا) استفاده کردند. در این مطالعه، مقایسه بین این روشها بر اساس درجه حرارت کلی خورشیدی بود. همچنین از پارامترهای مقدار موثر خطا (RMSE)، متوسط خطای مطلق (MAE) و ضریب همبستگی ( $R^2$ ) برای ارزیابی این روشها استفاده شد. در نهایت، نتایج نشان داد که روش GEP توانایی بهتری از سایر روشها برای پیش‌بینی GSR بر اساس متغیرهای جوی روزانه دارد [۲۴].

Kaushika و همکارانش در سال ۲۰۱۴ از مدل شبکه عصبی مبتنی بر رویکرد صریح برای پیش‌بینی GSR در هند استفاده کردند. در این مطالعه، مدت زمان تابش آفتاب در ساعت، رطوبت نسبی و میزان بارندگی به عنوان ورودی شبکه در نظر گرفته شدند. همچنین ارزیابی مدل نیز توسط پارامترهای مجذور میانگین مربع خطا (RMSE) و متوسط خطا (MBE) انجام شد. نتایج نشان داد که مقدار RMSE برای ماه‌های مرطوب (ژوئیه، اوت، سپتامبر، اکتبر) نسبتاً بالاتر از ماه‌های خشک (ژانویه، فوریه، مارس، آوریل) است که این امر به علت بادهای موسمی شدید در هند می‌باشد. در این مطالعه همچنین مقایسه‌ای بین نتایج حاصل از مدل ANN با داده‌های ناسا انجام گرفت که نشان‌دهنده دقت خوب مدل شبکه‌های عصبی مصنوعی در پیش‌بینی GSR بود [۲۲].

Amrouche و Pivert در سال ۲۰۱۴ از مدل شبکه‌های عصبی مصنوعی برای پیش‌بینی GSR برای چهار منطقه در فرانسه استفاده کردند. در این مطالعه، نتایج مدل با داده‌های اندازه‌گیری مقایسه شد که نشان داد مدل شبکه‌های عصبی با دقت رضایت‌بخش قادر به برآورد GSR است [۶].

همانطور که بررسی کارهای پیشین نشان می‌دهد، برای برآورد تابش کلی خورشید از پارامترهای مختلف هواشناسی استفاده می‌شود. با این حال، هنوز متغیرهای ورودی مناسب برای تخمین تابش کلی خورشید مطالعه و تعیین نشده است. هدف اصلی از این مطالعه، تعیین متغیرهای مناسب برای برآورد ماهانه متوسط مجموع روزانه تابش کلی خورشید<sup>۱</sup> در هر محل از استان کرمانشاه است. برای نیل این هدف، در مرحله اول، همه متغیرها (ورودی‌ها) مستقل به مدل رگرسیون وارد می‌شوند و سپس، مناسب‌ترین متغیرهای مستقل با استفاده از روش گام به گام رگرسیون غیرخطی چندگانه (MNL) تعیین شده و با استفاده از روش شبکه‌های عصبی مصنوعی تابش کلی خورشید پیش‌بینی می‌شود. در نهایت، جهت اعتبارسنجی نتایج حاصل از شبکه‌های عصبی مصنوعی برای بازه‌های زمانی طولانی مدت، نتایج حاصل از شبکه‌های عصبی مصنوعی با روش سری‌های زمانی مقایسه می‌شود.

## مواد و روش‌ها

### روش رگرسیون غیرخطی چندگانه

روش رگرسیون یکی از روشهای پرکاربرد برای بیان وابستگی یک متغیر پاسخ به چندین متغیر مستقل است. در حالی که رفتار متغیرهای مستقل، مهمتر از تعیین بهترین ترکیب این متغیرها در پیش‌بینی متغیر وابسته است. همچنین روش رگرسیون گام به گام یک ابزار قوی برای انتخاب بهترین ترکیب از متغیرهای مستقل است [۱۴]. رگرسیون گام به گام در واقع یک فرایند انتخاب رو به جلو است که در هر مرحله مجدداً اهمیت همه متغیرهای قبلی را بررسی می‌کند. اگر مجموع مربعات جزئی برای هر متغیر شامل یک مقدار حداقل در مدل نباشند، انتخاب رو به عقب متغیرها ادامه می‌یابد تا زمانی که همه متغیرها شامل یک مقدار حداقل در مدل شوند.

روش رگرسیون شامل مجموعه‌ای از فنون برای تعیین روابط بین متغیرها است [۱۳]. رگرسیون غیرخطی یک شکل از تجزیه و تحلیل رگرسیون است که در آن داده‌های مشاهده‌ای توسط یک تابع که ترکیبی غیرخطی از پارامترهای مدل است، مدل می‌شوند و به یک یا چند متغیر مستقل وابسته است. برخلاف رگرسیون خطی رایج، که محدود به تخمین مدل‌های خطی است، رگرسیون غیرخطی می‌تواند مدل‌های با روابط دلخواه بین متغیرهای مستقل و وابسته را تجزیه و تحلیل کند. حالت کلی رابطه غیرخطی به صورت زیر در نظر گرفته می‌شود:

1) Monthly Mean Daily Sum Global Solar Radiation

$$Y = \beta_0 (X_1^{\beta_1}) (X_2^{\beta_2}) \dots (X_n^{\beta_n}) \quad (1)$$

که در آن 0 تا n پارامترهای معادله برای رابطه غیرخطی می‌باشند [۳۳]. برخی از مشکلات رگرسیون غیرخطی را می‌توان با خطی کردن مناسب برطرف نمود. اگر از معادله (۱)، لگاریتم گرفته شود، یک رابطه خطی به صورت رابطه (۲) حاصل می‌شود:

$$\log(Y) = \log(\beta_0) + \beta_1 \log(X_1) + \beta_2 \log(X_2) + \dots + \beta_n \log(X_n) \quad (2)$$

بنابراین، رگرسیون  $\log(Y)$  نسبت به  $\log(X_1)$ ،  $\log(X_2)$  تا  $\log(X_n)$  برای تخمین پارامترهای 0 تا n استفاده می‌شود [۱۳]. پارامترهای معادله (0 تا n) شبیه به رگرسیون ساده، با به حداقل رساندن مجموع فاصله‌های  $e_{yi}$  نقاط مشاهده شده از مدل بیان شده توسط معادله رگرسیون، ارزیابی می‌شوند [۲۳]:

$$\sum_{i=1}^N e_{yi}^2 = \sum_{i=1}^N (y_i - \beta_0 - \beta_1 X_{1i} - \beta_2 X_{2i} - \dots - \beta_n X_{ni}) \quad (3)$$

### شبکه‌های عصبی مصنوعی<sup>۱</sup>

شبکه‌های عصبی مصنوعی را می‌توان به عنوان یک سامانه پردازش اطلاعات معرفی کرد که دارای ویژگیهای اجرایی مشابه با شبکه‌های عصبی زیست‌شناختی هستند و در حقیقت می‌توان آنها را به نحوی، تعمیم یافته ریاضی زیست‌شناسی عصبی یا قوه درک انسان معرفی کرد. ساختار اصلی شبکه‌های عصبی را نورون‌ها تشکیل می‌دهند. نورون‌ها ریزپردازشگرهایی هستند که هر یک وظیفه ساده‌ای بر عهده دارند. این اجزا، یک تابع ریاضی را بر داده‌های ورودی اعمال می‌کنند و خروجی حاصل از این عمل را نشان می‌دهند. همانند دستگاه عصبی زیستی، نورون‌ها توسط اتصالاتی به هم متصل می‌شوند که سیگنال‌ها در بین آنها انتقال می‌یابند. شدت این اتصالات با تغییر وزن مربوط به آنها تغییر می‌کند. نورون‌ها در قالب لایه‌هایی قرار می‌گیرند که هر یک از این لایه‌ها دارای تعدادی نورون با وظایف خاص خود می‌باشند و در نهایت، نوعی ارتباط بین ورودی‌ها و خروجی‌های مورد نظر ایجاد می‌کنند [۲۵]. شبکه‌های عصبی، با قابلیت جالب توجه آنها در استنتاج معانی از داده‌های پیچیده یا مبهم، می‌توانند برای استخراج الگوها و شناسایی روشهایی که آگاهی از آنها برای انسان و دیگر فنون رایانه‌ای بسیار پیچیده و دشوار است، به کار گرفته شوند.

1) Artificial Neural Network (ANN)

یک شبکه عصبی شامل تعدادی از عناصر پردازش بسیار بهم پیوسته (یا گره) و همچنین یک الگوریتم محاسباتی است که پردازش اطلاعات توسط یک پاسخ پویا از عناصر پردازش آن و اتصالات آنها را به نهادهای خارجی می‌فرستد [۲۱]. همانطور که گفته شد، ساختار اصلی شبکه‌های عصبی را نورون‌ها تشکیل می‌دهند. هر نورون می‌تواند ورودی‌های متعددی داشته باشد در حالی که تنها یک خروجی دارد. ورودی‌های نورون می‌توانند از محرک‌های خارجی و یا از خروجی نورون‌های دیگر باشد [۱۷]. هر نورون مجموع وزن‌های ورودی را محاسبه کرده و آنرا با بایاس  $b$  به شکل یک ورودی خالص  $x$  جمع می‌کند [۱۶].

$$x = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,j}p_j + b \quad (۴)$$

ورودی خالص  $x$  از طریق یک تابع غیرخطی سیگموئید به شکل خروجی خود  $y_j$  تبدیل می‌شود:

$$y_j = \frac{1}{1 + e^{-x}} \quad (۵)$$

سپس خروجی  $y_j$  با خروجی هدف  $t_j$  با استفاده از یک تابع خطا به صورت رابطه (۶) مقایسه می‌شود:

$$\delta_k = (t_j - y_j)y_j(1 - y_j) \quad (۶)$$

برای نورون در لایه پنهان، مقدار خطا توسط رابطه (۷) محاسبه می‌شود [۱۶]:

$$\delta_j = y_j(1 - y_j) \sum_k \delta_k w_k \quad (۷)$$

که در آن،  $w_k$  مقدار خطا در لایه خروجی و  $w_k$  وزن بین لایه پنهان و لایه خروجی است. سپس خطا به سمت عقب از لایه خروجی به لایه ورودی گسترش یافته و وزن‌های اتصال به صورت رابطه (۸) به‌روز می‌شوند [۱۶]:

$$w_{ji}(t+1) = w_{ji}(t) + \eta \delta_j y_j + \alpha (w_{ji}(t) - w_{ji}(t-1)) \quad (۸)$$



که در آن، سرعت یادگیری و فاکتور ممتوم است که اثر تغییرات وزنه‌های پیشین در جهت حرکت را تعیین می‌کند. هر دو این پارامترها ثابت بوده و مقدار آنها در شروع چرخه آموزش مشخص می‌شود و سرعت و پایداری شبکه را تعیین می‌کنند.

قبل از فرایند آموزش شبکه، مجموعه داده‌های ورودی و هدف در بازه ۰/۱ تا ۰/۹ توسط رابطه (۹) نرمالیزه شده و پس از انجام شبیه‌سازی به مقدار اصلی خود برگردانده می‌شوند.

$$X_N = 0.8 \left( \frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) + 0.1 \quad (9)$$

که در آن،  $X_N$  مقدار نرمالیزه شده،  $X$  مقدار اصلی،  $X_{\min}$  کمترین مقدار و  $X_{\max}$  بیشترین مقدار است. به منظور مقایسه بین مدل‌های رگرسیون و شبکه‌های عصبی مصنوعی، درصد میانگین خطای مطلق (MAPE) و ضریب همبستگی (R) برای رسیدن به همگرایی بین مقادیر هدف و خروجی استفاده می‌شود که MAPE به صورت رابطه (۱۰) تعریف می‌شود [۱۲]:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|o_i - t_i|}{o_i} \times 100 \quad (10)$$

که در آن،  $t$  مقدار هدف،  $o$  مقدار خروجی و  $n$  تعداد کل ماه‌هاست.

### روش سری‌های زمانی

یک سری زمانی مجموعه‌ای از مشاهدات درباره یک متغیر است که در نقاط گسسته‌ای از زمان که معمولاً فاصله‌های مساوی دارند، اندازه‌گیری شده و بر حسب زمان مرتب شده‌اند. بنابراین، یک سری زمانی از مشاهده یک پدیده در طول زمان به دست می‌آید. تفاوت سری‌های زمانی و سایر روش‌های مدلسازی در این است که سری‌های زمانی با استفاده از داده‌های قبلی مقادیر آینده را پیش‌بینی می‌کند در حالیکه در دیگر روش‌های مدلسازی اغلب با استفاده از متغیرهای مستقل دیگر سعی به پیش‌بینی متغیر مورد نظر می‌شود. لذا قدرت سری‌های زمانی در پیش‌بینی کمتر است ولی به دلیل اینکه به اطلاعات جانبی کمتری نیاز دارد تمایل به استفاده از آن زیاد می‌باشد.

به منظور ارزیابی و مقایسه عملکرد روش‌های استوکستیک، از اطلاعات سالانه تابش کلی خورشید در استان کرمانشاه در بازه زمانی ۱۳۹۲-۱۳۸۷ استفاده گردید. بررسی‌های عینی آمار منطقه مورد مطالعه نشان می‌دهد که هیچگونه خلأ آماری وجود ندارد و نیازی به بازسازی آمار نیست. سری زمانی مجموعه‌ای از مشاهدات در طول زمان است و در هر سری زمانی، چند ویژگی وجود دارند که عبارتند از: (۱) واحد زمانی ثابت، (۲) مکان ثبت ثابت، (۳) فاصله زمانی ثابت بین

مشاهدات و ۴) کمیت مشاهده‌ای ثابت در تمامی مشاهدات. مهمترین هدف از تجزیه و تحلیل یک سری زمانی، یافتن مدلی است که بتوان براساس مشاهدات موجود، اندازه کمیت را در چند واحد زمانی آینده پیش‌بینی کرد. برای این منظور، مدل‌های متعددی ارائه شده‌اند که از جمله پرکاربردترین‌های آن، AR (خود همبسته)، MA (میانگین متحرک) و ARIMA (خود همبسته- میانگین متحرک) می‌باشند [۱۵].

**حذف مقادیر پرت:** با استفاده از توزیع  $t$  و با حد اطمینان ۹۵ درصد، داده‌های پرت شناسایی شده و مقادیر آنها با یک مقدار حاصل از میانبایی خطی جایگزین می‌شود. هیچیک از این داده‌ها در ارزیابی مدل سری زمانی در مراحل واسنجی و اعتبارسنجی مورد استفاده قرار نمی‌گیرند.

**حذف روند از سری زمانی:** هنگام فرمول‌بندی یک سری زمانی، ممکن است لازم باشد سری زمانی ایستا شود. ایستا کردن به معنی ایجاد نوعی تعادل در نوسانات سری است. روند حذف شده در انتها به سری شبیه‌سازی شده اضافه می‌شود از جمله روندهای موجود می‌توان به روند خطی، روند تناوبی یا نمایی یا توانی از سری زمانی اشاره کرد.

**استانداردسازی:** روشهای مختلفی برای استاندارد کردن داده‌ها وجود دارد از جمله استاندارد کردن به نحوی که میانگین و انحراف معیار داده‌ها، به مقادیر مشخصی تبدیل شوند.

**تحلیل اجزای اصلی:** در پاره‌ای موارد، تعداد ابعاد بردار ورودی به یک تابع زیاد و اجزای مختلف این بردار (ستونها یا متغیرها) بشدت به یکدیگر وابسته هستند. در چنین شرایطی بهتر است که ابعاد بردار ورودی کاهش داده شود.

**مدل خود همبسته (AR (p)):** اساس این مدل بر پایه زنجیره مارکوف در زنجیره زمانی بنا شده است. یک سری زمانی از زنجیره مارکوف تبعیت می‌کند اگر هر داده ثبت شده سری زمانی  $t$  با زمان قبل و یا زمان بعد از خود مرتبط باشد.

**مدل میانگین متحرک (MA (q)):** در این مدل، متغیر در زمان  $t$  از روی مقدار تصادفی همان لحظه به علاوه  $q$  برابر مقدار تصادفی مربوط به زمان‌های قبل از  $t$  برآورد می‌شود.

**مدل خود همبسته- میانگین متحرک (ARIMA (p,q)):** هرگاه دو مدل قبل در یکدیگر ادغام شوند، مدل ARIMA با مرتبه  $p$  و  $q$  تصادفی مربوط به زمان‌های قبل از  $t$  برآورد می‌شود (معادله ۱۱) [۳۵]:

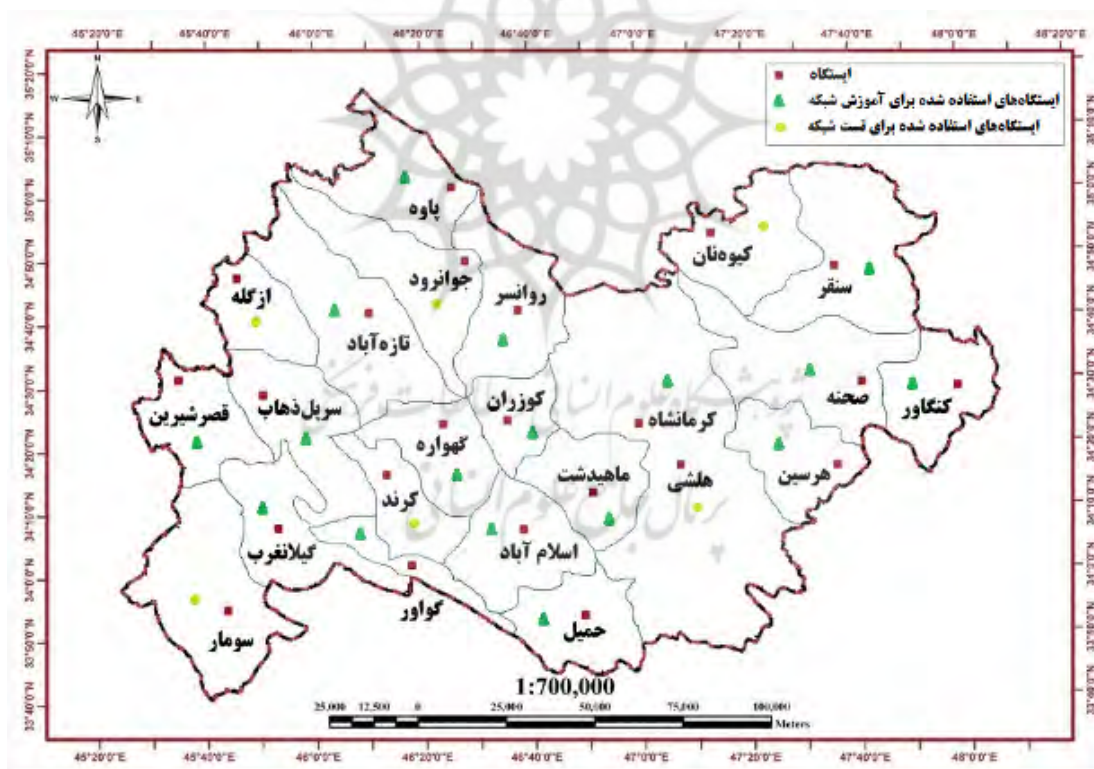
$$Z_t = u + \sum_{i=1}^p (Z_{t-i} - u) - \sum_{i=1}^p \theta_i a_{t-i} + a_t \quad (11)$$

که در آن،  $Z_t$  مقدار پیش‌بینی شده،  $Z_{t-i}$  اطلاعات مربوط به گذشته سری،  $u$  میانگین سری،  $a$  و ضرایب مدل،  $a_{t-i}$  و  $a_t$  به ترتیب اغتشاش در حال و گذشته می‌باشد.

مدل خود همبسته- میانگین متحرک تلفیق شده (ARIMA (p,d,q)): از آنجا که برای استفاده از مدل‌های فوق باید فرایند ایستایی برقرار باشد، باکس و همکارانش در شرایط نایستایی، مدل ARIMA را با در نظر گرفتن مرتبه تفاضلی d ارائه نمودند.

## نتایج و بحث

داده‌های هواشناسی مورد استفاده در این مطالعه از اطلاعات سازمان هواشناسی کشور<sup>۱</sup> در ۲۳ ایستگاه واقع در استان کرمانشاه در طول سالهای ۱۳۸۷-۱۳۹۲ به دست آمده است [۲۰]. موقعیت جغرافیایی این ایستگاه‌ها در شکل (۲) نشان داده است. این ایستگاه‌ها، همانطور که در شکل ۲ نشان داده شده است، تقریباً تمام استان کرمانشاه را پوشش می‌دهند. در بین ایستگاه‌های مطالعه شده از اطلاعات ۱۷ ایستگاه برای آموزش شبکه و از اطلاعات ۶ ایستگاه دیگر برای آزمایش شبکه استفاده شده است. مختصات جغرافیایی ایستگاه‌های مطالعه شده در جدول (۱) ذکر شده است.



شکل (۲) موقعیت جغرافیایی ایستگاه‌های مطالعه شده

1) Iran Meteorological Organization (IMO)

ایستگاه‌های مطالعه شده (استان کرمانشاه) بین عرض جغرافیایی ۳۳ تا ۳۵ درجه شمالی و طول جغرافیایی ۴۵ تا ۴۸ درجه شرقی قرار گرفته‌اند. این ایستگاه‌ها متغیرهای هواشناسی مانند حداقل درجه حرارت ماهانه در جو ( $T_{min}$ )، حداکثر درجه حرارت در جو ( $T_{max}$ )، متوسط درجه حرارت در جو ( $T_{mean}$ )، دمای خاک در عمق ۵ سانتیمتر (ST)، رطوبت نسبی (RH)، سرعت باد (W)، بارش (R)، فشار اتمسفریک (P)، فشار بخار (VP)، کدورت (C)، مدت زمان تابش آفتاب (S) و تابش کلی خورشید (H) در مناطق مختلف در استان کرمانشاه را فراهم می‌کنند.

جدول (۱) پارامترهای جغرافیایی ایستگاه‌های مطالعه شده

شماره	شهر	ایستگاه	عرض جغرافیایی (°N)	طول جغرافیایی (°E)	ارتفاع (m)
۱	هرسین	هرسین	۳۴/۲۷	۴۷/۵۷	۱۵۴۶
۲	صحنه	صحنه	۳۴/۴۷	۴۷/۷۰	۱۳۸۲
۳	کنگاور	کنگاور	۳۴/۵۰	۴۸/۰۰	۱۴۶۸
۴	سنقر و کلیایی	سنقر	۳۴/۷۵	۴۷/۵۸	۱۷۰۰
۵	سنقر و کلیایی	کیوه‌نان <sup>a</sup>	۳۴/۸۲	۴۶/۱۸	۱۹۷۰
۶	کرمانشاه	کرمانشاه	۳۴/۲۱	۴۷/۰۹	۱۳۱۸/۶
۷	کرمانشاه	هلشی <sup>a</sup>	۳۴/۱۰	۴۶/۰۸	۱۴۸۵
۸	کرمانشاه	ماهیدشت	۳۴/۲۷	۴۶/۸۳	۱۳۱۸/۶
۹	کرمانشاه	کوزران	۳۴/۵۰	۴۶/۶۰	۱۳۸۰
۱۰	روانسر	روانسر	۳۴/۷۲	۴۶/۶۵	۱۳۸۰
۱۱	جوانرود	جوانرود <sup>a</sup>	۳۴/۸۱	۴۶/۴۹	۱۳۷۵
۱۲	پاوه	پاوه	۳۵/۰۵	۴۶/۳۵	۱۴۸۵
۱۳	اسلام آباد غرب	اسلام آباد	۳۴/۱۳	۴۶/۴۳	۱۳۴۹
۱۴	اسلام آباد غرب	کرد <sup>a</sup>	۳۴/۲۷	۴۶/۲۵	۱۵۱۵
۱۵	اسلام آباد غرب	حمیل	۳۳/۹۳	۴۶/۷۸	۱۳۲۰
۱۶	اسلام آباد غرب	گهواره	۳۴/۳۵	۴۶/۴۲	۱۵۰۰
۱۷	ثلاث باباجانی	تازه‌آباد	۳۴/۷۵	۴۶/۰۹	۱۲۲۶
۱۸	ثلاث باباجانی	ازگله <sup>a</sup>	۳۴/۸۳	۴۵/۸۵	۶۹۹
۱۹	سرپل‌ذهاب	سرپل‌ذهاب	۳۴/۴۷	۴۵/۸۳	۵۴۵
۲۰	گیلانغرب	گیلانغرب	۳۴/۱۳	۴۵/۹۲	۸۱۶
۲۱	گیلانغرب	گواور	۳۴/۰۲	۴۶/۳۳	۱۴۷۶
۲۲	قصرشیرین	قصرشیرین	۳۴/۵۰	۴۵/۵۸	۳۵۶
۲۳	قصرشیرین	سومار <sup>a</sup>	۳۳/۸۱	۴۵/۶۶	۳۷۲

<sup>a</sup> ایستگاه‌های استفاده شده برای آزمایش شبکه

برای توسعه مدل‌های پیش‌بینی، در مرحله اول، تعداد ۱۶۵۹ داده از کل ایستگاه‌های مطالعه شده جمع‌آوری می‌شود. مجموعه داده‌ها را به دو زیر مجموعه آموزش و آزمایش تقسیم کردیم. مجموعه داده‌های آموزش شامل تعداد ۱۲۴۴ داده

مشاهده شده از ۱۷ ایستگاه می‌باشد که تقریباً ۷۵ درصد از کل داده‌هاست. همچنین مجموعه داده‌های آزمایش شامل تعداد ۴۱۵ داده مشاهده شده از ۶ ایستگاه می‌باشد که تقریباً ۲۵ درصد از کل داده‌هاست. سپس به دلیل بهبود کیفیت آموزش، همه ورودی‌ها و خروجی‌ها مطابق معادله (۹) نرمالیزه می‌شوند. ویژگی‌های آماری مهمی از اطلاعات آب و هوایی ماهانه و مقدار حداقل و حداکثر آنها در جدول (۲) ارائه شده است.

جدول (۲) پارامترهای آماری ماهانه از متغیرهای ورودی و خروجی

ضریب همبستگی با H	X <sub>std</sub>	X <sub>mean</sub>	X <sub>max</sub>	X <sub>min</sub>	متغیرهای ورودی و خروجی
۱/۰۰	۱۳۱/۲۹	۵۳۹/۱۹	۸۸۶/۱۲	۲۰۴/۶۴	تابش کلی خورشید (cal/cm <sup>2</sup> day)
-۰/۲۹	۱/۵۷	۳۴/۴۲	۳۵/۵۰	۳۳/۸۱	عرض جغرافیایی (°)
-۰/۳۴	۲/۶۱	۴۵/۵۳	۴۸/۰۰	۴۵/۵۸	طول جغرافیایی (°)
۰/۱۳	۴۰۲/۹۴	۱۲۶۰/۱۰	۱۹۷۰	۳۵۶	ارتفاع (m)
-۰/۰۵	۳/۴۵	۶/۵۰	۱۲	۱	ماه‌های سال
۰/۵۳	۵/۵۴	۳/۲۷	۲۴/۶۰	-۲۲/۳۰	حداقل درجه حرارت ماهانه در جو (°C)
۰/۶۲	۷/۲۱	۳۳/۷۰	۵۰/۴۰	۱۱/۴۰	حداکثر درجه حرارت در جو (°C)
۰/۶۸	۷/۷۲	۲۵/۱۰	۳۷/۱۰	-۱۳/۷۰	متوسط درجه حرارت در جو (°C)
۰/۷۰	۸/۵۴	۲۰/۸۳	۴۲/۴۰	-۸/۶۰	دمای خاک (°C)
-۰/۵۵	۱۰/۶۱	۷۳/۳۲	۹۸/۴۰	۱۱/۳۰	رطوبت نسبی (%)
۰/۱۱	-/۴۳	۴/۷۰	۱۰/۱۰	-/۳۰	سرعت باد (m/s)
-۰/۳۹	۷۹/۷۲	۷۵/۲۰	۴۹۰/۰۰	۰	بارش (mm)
-۰/۲۷	۵۷/۳۰	۹۳۳/۵۶	۱۰۴۲/۳۰	۸۵۴/۱۰	فشار اتمسفریک (mbar)
۰/۴۴	۳/۴۱	۱۲/۵۰	۳۲/۵۷	۲/۳۲	فشار بخار (mbar)
-۰/۵۹	۲/۱۸	۵/۲۲	۱۰/۵۰	۰	کدورت
۰/۷۵	۴/۲۷	۸/۴۵	۲۵/۰۰	-/۱۰	مدت زمان تابش آفتاب (h)

### نتایج روش رگرسیون غیرخطی چندگانه گام به گام

این مطلب که تابش کلی خورشید به متغیرهای مختلف هواشناسی مرتبط می‌باشد، امری شناخته شده است. بنابراین، تابش ماهانه کلی خورشید (H) در هر منطقه از استان کرمانشاه را می‌توان به عنوان تابعی از عرض جغرافیایی (LT)، طول جغرافیایی (LN)، ارتفاع (A)، ماه‌های سال (M)، حداقل درجه حرارت ماهانه در جو (T<sub>min</sub>)، حداکثر درجه حرارت در جو (T<sub>max</sub>)، متوسط درجه حرارت در جو (T<sub>mean</sub>)، دمای خاک (ST)، رطوبت نسبی (RH)، سرعت باد (W)، بارش (R)، فشار اتمسفریک (P)، فشار بخار (VP)، کدورت (C) و مدت زمان تابش آفتاب (S) بیان کرد. رابطه بین تابش کلی خورشید و متغیرهای مستقل را می‌توان به صورت زیر بیان کرد:

$$H = f(LT, LN, A, M, T_{\min}, T_{\max}, T_{\text{mean}}, ST, RH, W, R, P, VP, C, S) \quad (12)$$

با این حال، یکی از مهم‌ترین مراحل توسعه یک مدل پیش‌بینی رضایت‌بخش، انتخاب مناسب‌ترین متغیرهای مستقل است، زیرا این متغیرها در تعیین ساختار مدل‌های پیش‌بینی، ضرایب وزنی و نتایج حاصل از مدل تأثیرگذار هستند. به همین دلیل، در مرحله اول، همه متغیرهای مستقل به مدل رگرسیون غیرخطی چندگانه ساده (روش رگرسیون "Enter" با استفاده از نرم افزار SPSS) اضافه می‌شوند. جدول (۳) خلاصه‌ای از این روش نشان را می‌دهد. با توجه به این جدول، به نظر می‌رسد روش "Enter" نتایج مناسبی نمی‌دهد، به این دلیل که چهار مقدار مهم، خیلی بالاتر از ۰/۰۵ هستند که این روند در ستون آخر جدول (۳) دیده می‌شود. بنابراین، روش "Enter" را نمی‌توان برای تخمین تابش کلی خورشید به کار برد.

جدول (۳) رگرسیون غیرخطی چندگانه با اسفاده از روش Enter

Sig.	t	ضرایب استاندارد شده	Std. error	ضرایب غیراستاندارد شده	مدل
		$\beta$		$\beta$	
۰/۰۰۳	۴/۳۹۰		۰/۰۲۱	۱/۰۸۶	1-Constant
۰/۰۲۱	۳/۵۹۱	۰/۰۳۲	۰/۰۰۴	۰/۰۳۰	LT
۰/۲۱۵	-۰/۱۷۳	-۰/۰۰۶	۰/۰۰۷	-۰/۰۰۵	LN
۰/۰۰۷	-۴/۰۵۵	-۰/۰۱۴	۰/۰۰۵	-۰/۰۰۹	A
۰/۰۰۰	۱۱/۵۷۸	۰/۱۴۵	۰/۰۱۰	۰/۱۲۰	M
۰/۰۰۹	۱/۶۴۵	۰/۱۸۹	۰/۰۱۱	۰/۲۱۷	$T_{\min}$
۰/۰۰۴	-۱۴/۲۳۳	-۰/۲۷۵	۰/۰۰۳	-۰/۲۵۶	$T_{\max}$
۰/۰۵۱	۵/۷۹۰	۰/۹۲۳	۰/۰۱۴	۱/۰۱۴	$T_{\text{mean}}$
۰/۰۰۰	۷/۴۱۹	۱/۰۰۸	۰/۰۲۳	۰/۹۷۶	ST
۰/۰۲۲	۱۷/۲۸۰	۰/۰۴۱	۰/۰۴۹	۰/۰۳۳	RH
۰/۰۴۰	-۹/۱۰۱	-۰/۱۷۷	۰/۰۰۵	-۰/۲۲۴	W
۰/۰۳۹	۱۹/۰۰۲	۰/۰۵۲	۰/۰۲۶	۰/۰۸۶	R
۰/۱۹۱	-۰/۳۴۲	۰/۱۰۱	۰/۰۱۷	۰/۱۵۰	P
۰/۱۴۰	-۰/۴۱۰	-۰/۰۱۰	۰/۰۰۶	-۰/۰۰۷	VP
۰/۷۰۱	-۰/۱۳۹	-۰/۱۱۲	۰/۰۱۸	-۰/۱۳۹	C
۰/۰۰۰	۲۲/۰۲۱	۰/۷۲۱	۰/۰۸۳	۰/۶۴۹	S

سپس، بمنظور تعیین رابطه بین تابش کلی خورشید و متغیرهای مستقل و همچنین برای تعیین بهترین متغیرهای مستقل، روش رگرسیون گام به گام اعمال می‌شود. مقادیر ضریب همبستگی (R) و سطوح معنادار (P-values) برای ارزیابی عملکرد روش رگرسیون استفاده می‌شود. مقایسه روشهای رگرسیون "Enter" و گام به گام نشان می‌دهد که روش رگرسیون گام به گام دقیق‌تر است. در روش رگرسیون گام به گام، مقادیر مهم بسیار پایین‌تر از ۰/۰۵ به دست می‌آیند. جدول (۴) خلاصه روش رگرسیون گام به گام را نشان می‌دهد.

جدول (۴) نتایج رگرسیون غیرخطی چندگانه با استفاده از روش گام به گام

معادلات	ترکیبات مستقل	مدل
$H = 0.729(S)^{1.17}$	S	MNLR1
$H = 0.819(S)^{1.024} (M)^{-0.101}$	S and M	MNLR2
$H = 1.16(S)^{1.330} (M)^{-0.133} (C)^{0.16}$	S, M and C	MNLR3
$H = 0.99(S)^{1.016} (M)^{-0.939} (C)^{0.192} (ST)^{0.303}$	S, M, C and ST	MNLR4
$H = 1.294(S)^{1.25} (M)^{-0.109} (C)^{0.185} (ST)^{1.502} (T_{mean})^{-1.338}$	S, M, C, ST and $T_{mean}$	MNLR5
$H = 1.311(S)^{0.953} (M)^{-0.106} (C)^{0.165} (ST)^{1.424} (T_{mean})^{-1.214} (A)^{0.06}$	S, M, C, ST, $T_{mean}$ and A	MNLR6
$H = 1.41(S)^{0.92} (M)^{-0.119} (C)^{0.172} (ST)^{1.309} (T_{mean})^{-1.227} (A)^{0.039} (W)^{0.072}$	S, M, C, ST, $T_{mean}$ , A and W	MNLR7
$H = 1.556(S)^{0.901} (M)^{-0.258} (C)^{0.183} (ST)^{1.32} (T_{mean})^{-1.468} (A)^{0.04} (W)^{0.081} (T_{max})^{0.194}$	S, M, C, ST, $T_{mean}$ , A, W and $T_{max}$	MNLR8
$H = 1.57(S)^{0.817} (M)^{-0.266} (C)^{0.194} (ST)^{1.47} (T_{mean})^{-1.318} (A)^{0.051} (W)^{0.067} (T_{max})^{0.152} (T_{min})^{-0.197}$	S, M, C, ST, $T_{mean}$ , A, W, $T_{max}$ and $T_{min}$	MNLR9
$H = 1.46(S)^{0.845} (M)^{-0.134} (C)^{0.179} (ST)^{1.444} (T_{mean})^{-1.408} (A)^{0.04} (W)^{0.077} (T_{max})^{0.173} (T_{min})^{-0.177} (LT)^{-0.019}$	S, M, C, ST, $T_{mean}$ , A, W, $T_{max}$ , $T_{min}$ and LT	MNLR10

با توجه به روش رگرسیون گام به گام، ده مدل MNLR متشکل از ترکیبی از متغیرهای مستقل به دست آمده است و بهترین متغیرهای مستقل عرض جغرافیایی (LT)، ارتفاع (A)، ماه سال (M)، حداقل درجه حرارت ماهانه در جو ( $T_{min}$ )، حداکثر درجه حرارت در جو ( $T_{max}$ )، متوسط درجه حرارت در جو ( $T_{mean}$ )، دمای خاک (ST)، سرعت باد (W)، کدورت (C)، مدت زمان تابش آفتاب (S) انتخاب می‌شوند. و رابطه‌ای بین تابش کلی خورشید و سایر متغیرهای مستقل، طول جغرافیایی (LN)، رطوبت نسبی (RH)، بارش (R)، فشار اتمسفریک (P)، فشار بخار (VP) وجود ندارد. بنابراین، این متغیرها به عنوان متغیرهای مستقل انتخاب نشده و در نتیجه، حذف شدند. در میان ده متغیر مستقل (S, M, C, ST, A, W,  $T_{min}$ ,  $T_{max}$ ,  $T_{mean}$ , LT) و (LT) به نظر می‌رسد که در برآورد تابش کلی خورشید، مدت زمان تابش آفتاب (S) موثرترین پارامتر است. همانطور که نتایج جدول (۴) نشان می‌دهد، برای مدل MNLR1، تنها S به عنوان متغیر مستقل و H به

عنوان متغیر وابسته استفاده شده است. سایر مدل‌های دیگر (MNLR2- MNLR10) با افزودن سایر متغیرهای مستقل (M, C, ST, A, W, T<sub>mean</sub>, T<sub>max</sub>, T<sub>min</sub>, LT) به مدل MNLR1 به دست آمده‌اند.

همه مدل‌های داده شده در جدول (۴) بمنظور مقایسه و ارزیابی عملکرد مدل MNLR آموزش دیده و مورد آزمایش قرار گرفته‌اند. عملکرد مدل‌های MNLR برای مجموعه داده‌های آموزش و آزمایش در جدول (۵) ارائه شده است. با توجه به نتایج بدست آمده، بر اساس مجموعه داده‌های آموزش، MAPE و R به ترتیب در بازه ۷/۷۰-۱۲/۱۲ درصد و ۰/۹۷۳۹-۰/۹۴۱۴ به دست آمده‌اند در حالی که این مقادیر برای مجموعه داده‌های آزمایش به ترتیب برابر ۱۴/۱۹-۷/۱۱ درصد و ۰/۹۸۷۵-۰/۹۵۲۷ به دست آمده‌اند. برای مجموعه داده‌های آزمایش، حداکثر MAPE برای مدل MNLR1 می‌باشد که برابر ۱۴/۱۹ درصد است و بهترین MAPE مربوط به MNLR10 می‌باشد که برابر ۷/۱۱ درصد است. علاوه بر این، حداکثر ضریب همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده برابر ۰/۹۸۷۵ می‌باشد که برای مدل MNLR10 به دست آمده در حالی که حداقل ضریب همبستگی برابر ۰/۹۵۲۷ می‌باشد که برای مدل MNLR1 به دست آمده است.

جدول (۵) عملکرد مدل‌های MNLR

مجموعه داده‌های آموزش		مجموعه داده‌های آزمایش		مدل
R	MAPE (%)	R	MAPE (%)	
۰/۹۴۱۴	۱۲/۱۲	۰/۹۵۲۷	۱۴/۱۹	MNLR1
۰/۹۴۲۳	۱۱/۷۳	۰/۹۵۴۶	۱۳/۳۲	MNLR2
۰/۹۴۷۴	۱۱/۲۴	۰/۹۶۱۲	۱۳/۰۷	MNLR3
۰/۹۵۰۱	۱۰/۵۹	۰/۹۶۶۶	۱۱/۴۶	MNLR4
۰/۹۵۱۲	۱۰/۱۴	۰/۹۷۰۱	۱۰/۹۸	MNLR5
۰/۹۵۵۹	۹/۹۳	۰/۹۷۸۰	۱۰/۱۰	MNLR6
۰/۹۶۰۰	۹/۵۵	۰/۹۷۹۹	۹/۸۷	MNLR7
۰/۹۶۴۵	۹/۲۳	۰/۹۸۲۳	۸/۵۴	MNLR8
۰/۹۷۰۲	۷/۴۹	۰/۹۸۴۶	۷/۳۲	MNLR9
۰/۹۷۳۹	۷/۷۰	۰/۹۸۷۵	۷/۱۱	MNLR10

#### نتایج روش شبکه‌های عصبی مصنوعی

در این بخش، ۱۰ ترکیب از متغیرهای S, M, C, ST, A, W, T<sub>mean</sub>, T<sub>max</sub>, T<sub>min</sub> و LT به عنوان ورودی به مدل شبکه‌های عصبی مصنوعی با استفاده از نرم افزار MATLAB بررسی می‌شوند. همچنین متغیر تابش کلی خورشید (H)



به عنوان هدف شبکه در نظر گرفته شده است. ترکیب ورودی و معادلات بدست آمده از مدل شبکه‌های عصبی مصنوعی در جدول (۶) داده شده و وزن‌های جدول (۶) در جدول (۷) آورده شده است.

جدول ۶) ترکیب‌های ورودی و معادلات بدست آمده از مدل شبکه‌های عصبی مصنوعی

معادلات	ترکیبات مستقل	مدل
$x_i = w_{1i}(S) + w_{2i}$ $y_i = \frac{1}{1 + e^{-x_i}}$ $H = 1.012(y_1) + 0.419(y_2) + 0.404$	S	ANN1
$x_i = w_{1i}(S) + w_{2i}(M) + w_{3i}$ $y_i = \frac{1}{1 + e^{-x_i}}$ $H = 0.824(y_1) + 1.015(y_2) + 1.279$	S and M	ANN2
$x_i = w_{1i}(S) + w_{2i}(M) + w_{3i}(C) + w_{4i}$ $y_i = \frac{1}{1 + e^{-x_i}}$ $H = 1.794(y_1) - 2.294(y_2) + 0.033(y_3) + 0.14$	S, M and C	ANN3
$x_i = w_{1i}(S) + w_{2i}(M) + w_{3i}(C) + w_{4i}(ST) + w_{5i}$ $y_i = \frac{1}{1 + e^{-x_i}}$ $H = -0.376(y_1) - 1.44(y_2) + 1.77(y_3) + 1.683(y_4) - 0.199$	S, M, C and ST	ANN4
$x_i = w_{1i}(S) + w_{2i}(M) + w_{3i}(C) + w_{4i}(ST) + w_{5i}(T_{mean}) + w_{6i}$ $y_i = \frac{1}{1 + e^{-x_i}}$ $H = 4.509(y_1) + 7.081(y_2) - 3.578(y_3) - 0.6411(y_4) - 6.931(y_5) + 1.129$	S, M, C, ST and T <sub>mean</sub>	ANN5
$x_i = w_{1i}(S) + w_{2i}(M) + w_{3i}(C) + w_{4i}(ST) + w_{5i}(T_{mean}) + w_{6i}(A) + w_{7i}$ $y_i = \frac{1}{1 + e^{-x_i}}$ $H = 0.213(y_1) - 5.161(y_2) + 0.079(y_3) + 5.921(y_4) + 2.018(y_5) - 4.486(y_6) + 7.458$	S, M, C, ST, T <sub>mean</sub> and A	ANN6
$x_i = w_{1i}(S) + w_{2i}(M) + w_{3i}(C) + w_{4i}(ST) + w_{5i}(T_{mean}) + w_{6i}(A) + w_{7i}(W) + w_{8i}$ $y_i = \frac{1}{1 + e^{-x_i}}$ $H = 5.715(y_1) + 0.213(y_2) + 1.581(y_3) - 3.92(y_4) - 1.55(y_5) + 0.377(y_6) + 4.46(y_7) + 0.075$	S, M, C, ST, T <sub>mean</sub> , A and W	ANN7

معادلات	ترکیبات مستقل	مدل
$x_i = w_{1i}(S) + w_{2i}(M) + w_{3i}(C) + w_{4i}(ST) + w_{5i}(T_{mean}) + w_{6i}(A) + w_{7i}(W) + w_{8i}(T_{max}) + w_{9i}$ $y_i = \frac{1}{1 + e^{-x_i}}$ $H = -0.528(y_1) + 2.349(y_2) + 3.497(y_3) + 0.21(y_4) + 1.711(y_5) + 4.959(y_6) - 0.02(y_7) + 0.448(y_8) - 1.112$	S, M, C, ST, T <sub>mean</sub> , A, W and T <sub>max</sub>	ANN8
$x_i = w_{1i}(S) + w_{2i}(M) + w_{3i}(C) + w_{4i}(ST) + w_{5i}(T_{mean}) + w_{6i}(A) + w_{7i}(W) + w_{8i}(T_{max}) + w_{9i}(T_{min}) + w_{10i}$ $y_i = \frac{1}{1 + e^{-x_i}}$ $H = 1.396(y_1) + 0.673(y_2) + 0.074(y_3) + 3.99(y_4) - 0.02(y_5) + 5.67(y_6) + 1.37(y_7) + 1.147(y_8) + 0.997(y_9) + 4.077$	S, M, C, ST, T <sub>mean</sub> , A, W, T <sub>max</sub> and T <sub>min</sub>	ANN9
$x_i = w_{1i}(S) + w_{2i}(M) + w_{3i}(C) + w_{4i}(ST) + w_{5i}(T_{mean}) + w_{6i}(A) + w_{7i}(W) + w_{8i}(T_{max}) + w_{9i}(T_{min}) + w_{10i}(LT) + w_{11i}$ $y_i = \frac{1}{1 + e^{-x_i}}$ $H = 0.64(y_1) + 2.292(y_2) + 3.126(y_3) + 0.11(y_4) + 0.774(y_5) - 1.59(y_6) - 2.4(y_7) + 0.349(y_8) + 0.819(y_9) - 6.903(y_{10}) + 1.101$	S, M, C, ST, T <sub>mean</sub> , A, W, T <sub>max</sub> , T <sub>min</sub> and LT	ANN10

جدول (۷) وزنهای جدول ۶

i	W <sub>1i</sub>	W <sub>2i</sub>	W <sub>3i</sub>	W <sub>4i</sub>	W <sub>5i</sub>	W <sub>6i</sub>	W <sub>7i</sub>	W <sub>8i</sub>	W <sub>9i</sub>	W <sub>10i</sub>	W <sub>11i</sub>
ANN1											
1	۲/۲۹	-۰/۷۷	۴/۹۸	-	-	-	-	-	-	-	-
2	۲/۱۱	-۳/۲۴	۴/۵۸	-	-	-	-	-	-	-	-
ANN2											
1	۳/۶۱	۵/۹۳	۱۴/۸۵	-	-	-	-	-	-	-	-
2	۶/۳۸	-۱/۵۱	۰/۵۷	-	-	-	-	-	-	-	-
ANN3											
1	۱۳/۱۶	۴/۱۱	۹/۳۱	۵/۷۷	-	-	-	-	-	-	-
2	-۳/۱۵	۹/۶۲	-۰/۴۶	۱/۱۹	-	-	-	-	-	-	-
3	۲/۷۲	۷/۶۰	-۶/۵۰	۹/۳۷	-	-	-	-	-	-	-
ANN4											
1	۱/۳۸	-۰/۵۳	۷/۵۷	۶/۴۹	-۰/۰۸	-	-	-	-	-	-
2	۱۴/۱۴	۱/۲۵	۵/۳۱	۱۶/۷۹	۳/۴۵	-	-	-	-	-	-
3	۴/۴۳	-۹/۱۴	۱۱/۲۹	۷/۱۱	۲/۰۲	-	-	-	-	-	-
4	-۱/۵۶	۹/۴۷	۲۴/۷۳	-۴/۲۳	۴/۵۵	-	-	-	-	-	-
ANN5											
1	۱۵/۲۳	۷/۲۸	۲/۹۳	۹/۸۵	۴/۳۴	۱۲/۶۷	-	-	-	-	-
2	۱/۰۱	۱۱/۹۳	۶/۴۴	۱۷/۹۱	۷/۵۵	۱/۰۴	-	-	-	-	-
3	-۲/۳۳	۶/۳۳	-۳/۰۲	-۹/۳۱	۹/۲۹	۲/۸۰	-	-	-	-	-
4	۹/۱۶	۷/۳۹	۰/۶۴	۲۱/۶۳	۱/۴۶	۴/۱۱	-	-	-	-	-

i	W <sub>1i</sub>	W <sub>2i</sub>	W <sub>3i</sub>	W <sub>4i</sub>	W <sub>5i</sub>	W <sub>6i</sub>	W <sub>7i</sub>	W <sub>8i</sub>	W <sub>9i</sub>	W <sub>10i</sub>	W <sub>11i</sub>
5	۸/۱۸	-۱/۰۶	۲/۸۱	۱/۶۴	۹/۳۷	۵/۵۱	-	-	-	-	-
ANN6											
1	۳/۰۳	۱۱/۸۶	۹/۱۶	۴/۹۱	۸/۳۹	۱۶/۶۴	۴۱/۷۱	-	-	-	-
2	۷/۷۱	۴/۳۵	-۴/۲۹	۳۷/۲۱	-۰/۳۴	۰/۴۰	۳۲/۸۴	-	-	-	-
3	-۹/۵۵	-۷/۹۳	۱۲/۴۵	۰/۱۶	۱۲/۱۹	۹/۶۵	۱۰/۷۷	-	-	-	-
4	۱۵/۴۳	۲/۴۹	۱/۰۹	۲/۶۵	۵/۲۷	۱۹/۷۵	-۰/۶۴	-	-	-	-
5	۷/۴۳	۴۲/۵۵	۶/۶۳	۱/۳۴	۳/۳۸	۶/۳۵	-۰/۵۵	-	-	-	-
6	-۷/۴۷	۵/۹۳	۱۳/۹۳	-۳۳/۴۳	-۱۱/۵۶	۹/۲۱	۲/۰۳	-	-	-	-
ANN7											
1	۸/۲۷	-۰/۳۴	-۱۹/۱۰	-۷/۸۸	۲/۹۸	۳/۰۲	-۶/۸۳	۲/۵۷	-	-	-
2	۰/۱۹	-۸/۳۴	۴/۲۲	۰/۹۸	۲۷/۵۷	۵/۸۱	۱۳/۵۰	۱/۶۹	-	-	-
3	۵/۴۰	۳/۲۳	-۲/۷۷	۵/۴۵	-۱/۴۰	۱۲/۲۲	۲۱/۰۲	۰/۳۴	-	-	-
4	۹/۳۸	۳۰/۴۱	۲/۰۳	-۴/۱۰	۷/۲۲	-۰/۱۶	-۲/۹۰	۶/۸۱	-	-	-
5	۸/۰۱	-۰/۹۱	-۰/۲۵	۱۵/۳۰	۱۱/۲۱	-۱۲/۵۶	۴/۰۴	۷/۴۶	-	-	-
6	۱/۳۷	۹/۲۲	۱۷/۰۲	۹/۷۱	۳۳/۶۷	۱/۵۸	۲/۲۲	۸/۳۴	-	-	-
7	۹/۴۸	-۲/۰۳	۱/۱۹	۸/۵۸	۷/۰۸	۲۸/۴۷	۹/۲۵	۳/۱۱	-	-	-
ANN8											
1	۰/۹۴	۲۱/۱۶	-۳/۰۰	۱۰/۳۲	۰/۶۷	-۱۶/۸۷	۹/۵۱	۱/۳۲	۹/۶۲	-	-
2	۹/۳۵	۱۸/۵۳	۷/۷۸	۵/۱۵	-۱۳/۴۸	۰/۲۰	۶/۱۰	۱/۲۷	۳/۱۶	-	-
3	۲/۱۳	-۵/۰۸	۹/۶۷	۱/۹۰	۱/۵۹	۶/۴۶	-۰/۵۰	۱۹/۲۲	۰/۶۳	-	-
4	۹/۶۸	۱/۹۲	۳۱/۶۳	۰/۰۴	-۰/۸۰	۹/۳۷	۱۶/۳۵	۱۸/۹۹	-۲/۵۶	-	-
5	-۹/۳۵	۸/۶۱	-۶/۲۸	۰/۹۷	۱۱/۴۵	۷/۲۷	-۰/۵۱	۹/۱۲	۲/۳۰	-	-
6	۹/۹۹	۱/۱۱	-۰/۸۱	۹/۴۶	۲/۳۱	۰/۱۹	۳/۰۲	۵/۲۲	۱/۰۸	-	-
7	۹/۴۳	۳۰/۹۰	۱/۴۷	-۳/۱۲	۷/۹۳	-۰/۰۳	۹/۹۰	-۴/۶۵	۴۷/۲۷	-	-
8	-۱/۵۷	۳/۳۰	۲۱/۱۲	-۵/۳۴	۲/۹۳	-۴/۰۱	۵۲/۸۵	۹/۵۰	۱۲/۹۴	-	-
ANN9											
1	۲/۶۱	۷/۶۶	۱۳/۹۱	۲۵/۳۰	۱۶/۸۴	۵/۷۰	۱/۹۸	۳/۷۲	-۱۷/۳۳	۴/۴۱	-
2	۳۳/۴۹	-۱۲/۱۷	۱/۶۸	۱۰/۱۲	۱۲۱/۲۹	۰/۱۲	۸/۴۸	۴/۱۸	۹/۹۴	۵/۰۲	-
3	۱۲/۲۷	۳۵/۳۲	۷۹/۵۴	۳۱/۳۸	-۵/۳۰	۳/۵۱	۷/۹۲	۱۹/۳۷	۲۱/۷۹	۷/۱۱	-
4	۴/۲۹	۶/۷۳	-۴۱/۷۷	۴/۵۰	-۷/۲۱	۱۶/۰۴	-۰/۱۸	۱/۷۱	۳/۹۹	-۰/۴۸	-
5	۶/۰۱	۹/۲۷	۵/۹۴	۱۱/۱۰	۹/۲۴	-۱/۱۶	-۰/۸۰	۷/۱۴	۴/۰۶	۱۵/۱۹	-
6	۴/۶۴	-۲۷/۴۹	۹/۱۱	۴/۶۸	۹/۷۰	۱/۲۲	۵/۴۹	۳/۹۷	۹/۶۸	۷/۷۵	-
7	۱۱/۳۵	-۰/۲۹	۳/۴۴	۹/۱۴	-۰/۰۱	۷/۷۵	۴/۵۸	-۹/۶۹	۳/۷۱	۳/۱۶	-
8	۱/۵۷	-۳/۸۷	۹/۵۳	-۷/۰۴	۱/۲۲	۳/۴۸	-۰/۱۲	۹/۶۱	۲/۲۷	۹/۹۳	-
9	۲/۷۰	۲۵/۳۹	۱/۶۱	۳/۵۱	۷/۴۵	-۳۵/۲۷	۲۱/۹۱	-۶/۷۴	۴/۰۵	-۱۳/۳۲	-
ANN10											
1	-۰/۶۰	۹/۲۷	۱۲/۵۶	-۴/۶۴	۹/۸۰	۷/۱۱	۳/۰۳	۹/۸۴	۹/۲۹	۷/۶۰	۳/۱۲
2	۸/۹۳	۹/۲۱	۵/۲۱	۳۳/۰۵	۵/۶۴	۴/۴۷	۲/۴۸	۸/۵۲	۴/۹۸	۵/۵۶	۶/۷۰
3	-۶/۸۷	۱/۹۹	-۰/۴۴	۳۱/۹۱	-۲۱/۵۵	-۵/۶۱	۱/۰۱	۹/۶۰	-۰/۴۷	-۱۲/۰۴	-۱۵/۷۷
4	۴/۱۰	۱/۸۲	۳۷/۳۹	۳/۲۵	۱۵/۰۱	۱/۶۹	-۰/۲۲	-۲۲/۲۴	۸/۲۰	-۰/۰۲	۹/۵۹
5	۷/۰۳	-۲/۴۵	۱۵/۲۱	-۷/۸۵	۱/۱۱	۳۱/۶۱	-۱/۹۳	-۹/۰۵	۷/۲۶	-۴/۱۳	۲/۹۴
6	۲/۹۳	۶/۷۰	-۰/۲۱	۵/۹۸	۹/۲۷	۱۱/۴۳	۷/۱۴	۹/۹۱	۷/۳۰	۹/۲۴	۳/۸۹
7	۳۰/۴۱	۱/۶۴	۹/۹۱	۵/۱۳	۳/۲۵	۱/۴۵	۳/۴۵	۹/۱۱	۷/۹۳	-۰/۵۴	۹/۸۹
8	۷/۴۹	-۴/۷۳	۷/۴۰	-۳/۸۴	۱۴/۶۵	-۷/۶۹	-۰/۸۱	۵/۷۱	۹/۲۲	۸/۲۰	۳/۳۳
9	۴/۷۹	۹/۲۳	۶/۰۱	۵/۵۳	-۰/۲۹	۴/۳۲	۹/۳۰	۷/۶۱	-۰/۰۸	۳/۶۲	-۰/۱۷
10	۳/۵۰	۵/۳۹	-۰/۱۲	۴/۱۹	-۲/۳۴	-۱۱/۰۹	-۵/۵۱	-۷/۲۴	۱۷/۸۷	۹/۷۰	۷/۰۹

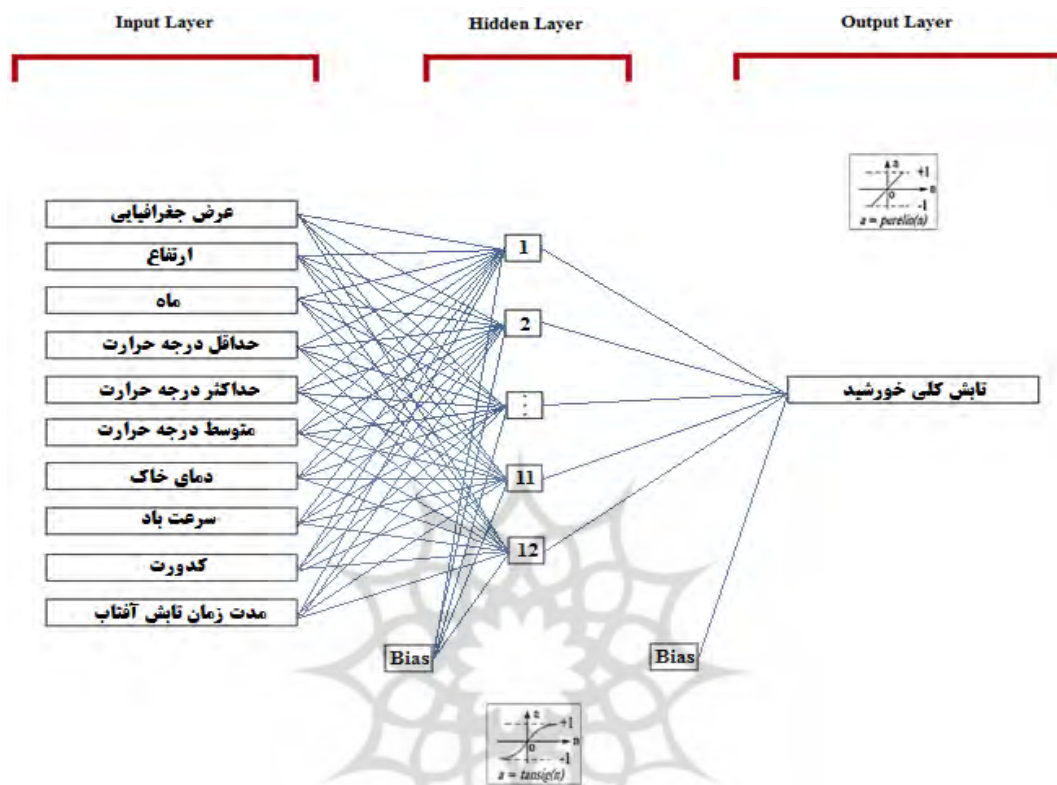
از این معادلات می‌توان برای پیش‌بینی ماهانه متوسط مجموع روزانه تابش کلی خورشید در هر محل از استان کرمانشاه استفاده کرد. همه مدل‌ها به منظور ارزیابی و عملکرد روش شبکه‌های عصبی مصنوعی آموزش دیده و مورد آزمایش قرار گرفته‌اند. عملکرد مدل شبکه‌های عصبی مصنوعی برای مجموعه داده‌های آموزش و آزمایش در جدول (۸) ارائه شده است.

جدول (۸) عملکرد مدل‌های شبکه‌های عصبی مصنوعی

مجموعه داده‌های آموزش		مجموعه داده‌های آموزش		مدل
R	MAPE (%)	R	MAPE (%)	
۰/۹۸۳۶	۷/۷۹	۰/۹۸۱۲	۶/۲۲	ANN1
۰/۹۸۷۰	۷/۵۶	۰/۹۸۴۰	۵/۵۴	ANN2
۰/۹۸۹۱	۶/۲۳	۰/۹۸۹۹	۵/۳۹	ANN3
۰/۹۹۰۱	۶/۰۸	۰/۹۹۱۲	۵/۰۳	ANN4
۰/۹۹۱۲	۵/۴۹	۰/۹۹۲۵	۴/۴۹	ANN5
۰/۹۹۲۰	۵/۱۴	۰/۹۹۳۴	۴/۳۰	ANN6
۰/۹۹۳۷	۴/۷۰	۰/۹۹۲۹	۴/۱۹	ANN7
۰/۹۹۵۰	۴/۲۹	۰/۹۹۵۸	۴/۰۲	ANN8
۰/۹۹۵۲	۴/۰۵	۰/۹۹۶۹	۳/۸۷	ANN9
۰/۹۹۶۱	۳/۹۸	۰/۹۹۷۴	۳/۴۱	ANN10

نتایج حاصل از جدول (۸) نشان می‌دهد که مدل ANN10 بهترین نتیجه را می‌دهد. با توجه به نتایج بدست آمده، براساس مجموعه داده‌های آموزش، MAPE و R به ترتیب در بازه ۶/۲۲-۳/۴۱ درصد و ۰/۹۹۷۴-۰/۹۸۱۲ به دست آمده‌اند در حالی که این مقادیر برای مجموعه داده‌های آزمایش به ترتیب برابر ۷/۷۹-۳/۹۸ درصد و ۰/۹۸۳۶-۰/۹۹۶۱ بدست آمده‌اند. برای مجموعه داده‌های تست، حداکثر MAPE برای مدل ANN1 می‌باشد که برابر ۷/۷۹ درصد است و بهترین MAPE مربوط به ANN10 می‌باشد که برابر ۳/۹۸ درصد است. علاوه بر این، حداکثر ضریب همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده برابر ۰/۹۹۶۱ می‌باشد که برای مدل ANN10 به دست آمده در حالی که حداقل ضریب همبستگی برابر ۰/۹۸۳۶ می‌باشد که برای مدل ANN1 به دست آمده است.

معماری شبکه عصبی مصنوعی برای مدل ANN10 که به عنوان بهترین مدل انتخاب شده است، در شکل (۳) نشان داده شده است.

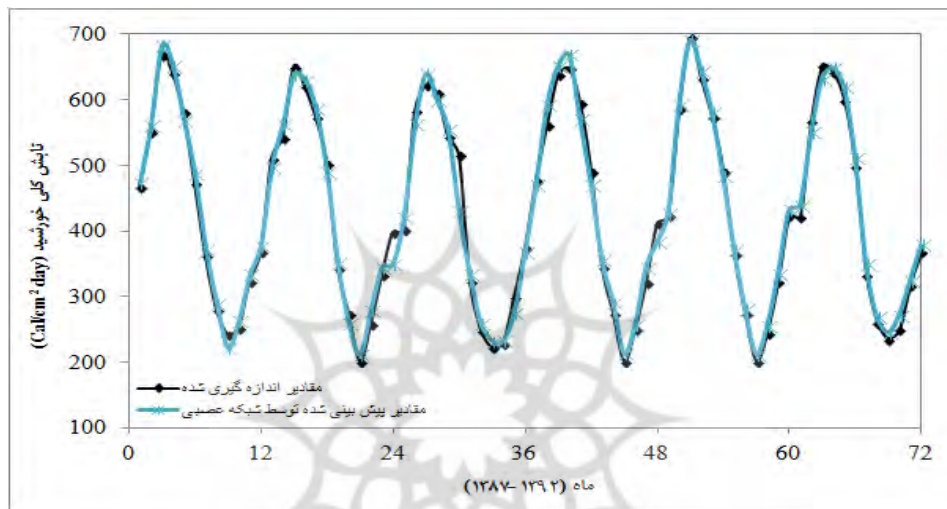


شکل ۳) معماری شبکه عصبی مصنوعی برای مدل ANN10


این مدل یک شبکه پس انتشار خطا<sup>۱</sup> است. به منظور تعیین بهترین معماری شبکه، تعداد بهینه نورون در لایه پنهان با استفاده از روش آزمون و خطا با تغییر تعداد نورون از ۸-۲۰ تعیین شده است. روش آموزش تنظیم ضرایب وزن می‌باشد. در هر مرحله، خروجی شبکه با خروجی مورد نظر مقایسه شده و خطا به دست آمده است. سپس این خطا به سمت عقب از لایه خروجی به لایه ورودی گسترش یافته و وزن‌های اتصال طوری تنظیم می‌شوند که با هر تکرار، خطا کاهش یافته و مدل عصبی نزدیک و نزدیکتر به خروجی مورد نظر شود. در نهایت، روش آموزش یک تابع بین متغیرهای ورودی و خروجی تقریب می‌زند. سپس بردارهای ورودی از مجموعه داده‌های آزمایش به شبکه آموزش دیده ارائه می‌شوند. با استفاده از روش آزمون و خطا با تنظیمات مختلف شبکه، یک شبکه متشکل از یک لایه ورودی با ۱۰ نورون، یک لایه پنهان با ۱۲ نورون و یک لایه خروجی با ۱ نورون به دست می‌آید. حداکثر تعداد اپوک<sup>۲</sup> برابر ۱۲۵ و متوسط مربع خطا برابر  $10^{-5} \times 5$  به دست آمده است. پس از استفاده از الگوریتم‌های آموزش مختلف، الگوریتم یادگیری لوبنبرگ - مارکوارت<sup>۳</sup>

- 1) BackPropagation (BP)
- 2) Epoch
- 3) Levenberg-Marquardt (LM)

انتخاب شده است. همچنین تابع انتقال سیگموئید (Logsig) و تابع انتقال خطی (Purelin) به ترتیب در لایه‌های پنهان و خروجی شبکه استفاده شده است. برای مجموعه داده‌های آزمایش مانند ایستگاه‌های جانرود و سومار نمودار پیش‌بینی شبکه‌های عصبی مصنوعی در برابر مقادیر واقعی برای مدل ANN10 در شکل‌های (۴) و (۵) رسم شده است. همانطور که در این شکلها دیده می‌شود، نتایج پیش‌بینی بسیار نزدیک به مقادیر واقعی هستند.



شکل ۴) مقایسه بین پیش‌بینی مدل ANN10 و نتایج واقعی برای ایستگاه جانرود

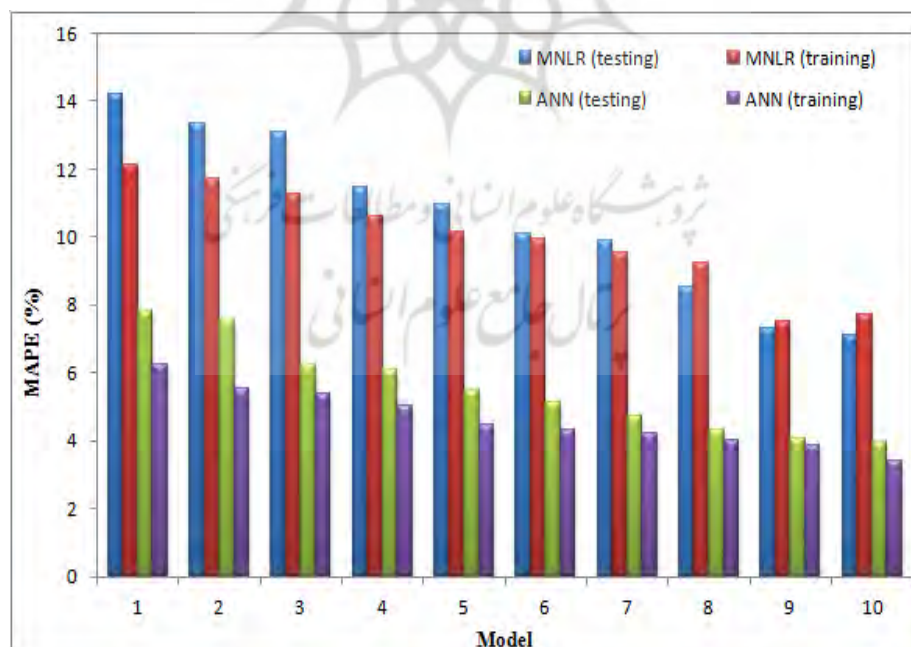


شکل ۵) مقایسه بین پیش‌بینی مدل ANN10 و نتایج واقعی برای ایستگاه سومار

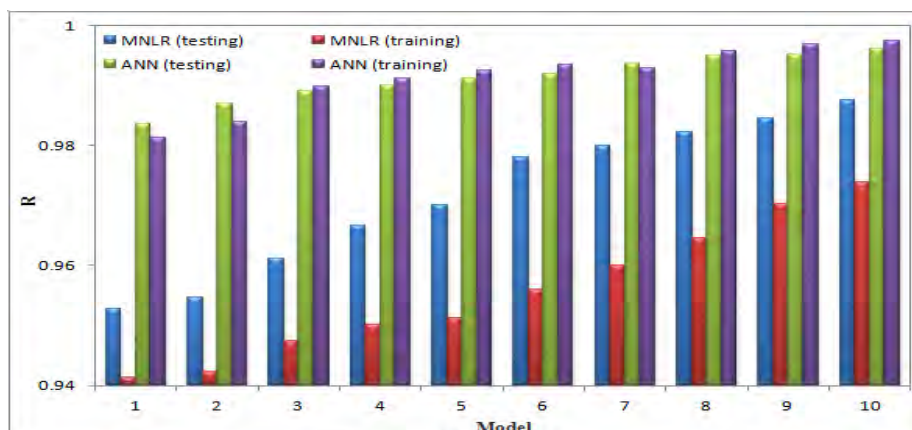
## مقایسه مدل رگرسیون با مدل شبکه‌های عصبی مصنوعی

به منظور مقایسه عملکرد مدل‌های ANN و MNL، مقادیر MAPE و R-value این روشها برای مجموعه داده‌های آموزش و آزمایش در شکل‌های (۶) و (۷) ارائه شده است. مقایسه نتایج حاصل از این روشها و مدل‌های آنها نشان می‌دهد که عملکرد مدل ANN بهتر از مدل MNL است. مقدار MAPE مدل ANN کمتر از مدل MNL است. علاوه بر این، مقدار ضریب همبستگی مدل ANN بالاتر از مدل MNL می‌باشد.

با توجه به نتایج بدست آمده از مدل‌های ANN10، MNL10، مقادیر MAPE و ضریب همبستگی (R) برای تمام ایستگاه‌های مطالعه شده در جدول (۹) ارائه شده است. در مدل شبکه‌های عصبی مصنوعی، براساس مجموعه داده‌های آموزش، مقادیر MAPE و ضریب همبستگی به ترتیب در محدوده ۵/۰۵-۳/۰۲ درصد و ۰/۹۹۹۴-۰/۹۸۲۰ می‌باشد در حالی که محدوده مشابه برای مجموعه داده‌های آزمایش به ترتیب ۵/۹۹-۳/۸۸ درصد و ۰/۹۹۷۰-۰/۹۹۰۵ است. برای مجموعه داده‌های آزمایش، حداکثر MAPE برابر ۵/۹۹ درصد برای ایستگاه ازگله و حداقل MAPE برابر ۳/۸۸ درصد برای ایستگاه کوند به دست آمده است. علاوه بر این، حداکثر و حداقل ضریب همبستگی بین مقادیر پیش‌بینی شده و اندازه‌گیری شده به ترتیب برابر ۰/۹۹۷۰ و ۰/۹۹۰۵ می‌باشد که برای ایستگاه‌های سومار و جوانرود به دست آمده است.



شکل ۶) مقایسه مقدار MAPE برای مدل‌های ANN و MNL



شکل ۷) مقایسه مقدار ضریب همبستگی (R) برای مدل‌های ANN و MNL

جدول ۹) مقادیر MAPE و R برای مدل‌های ANN10 و MNL10

مدل ANN10		مدل MNL10		ایستگاه
R	MAPE (%)	R	MAPE (%)	
۰/۹۹۶۲	۳/۱۳	۰/۹۵۲۳	۱۲/۳۲	هرسین
۰/۹۹۷۷	۴/۶۲	۰/۹۶۱۸	۱۱/۶۵	صحنه
۰/۹۹۴۹	۴/۷۵	۰/۹۷۲۳	۱۵/۲۴	کنگاور
۰/۹۹۷۰	۳/۰۲	۰/۹۹۱۹	۱۳/۷۳	سنقر
۰/۹۹۱۲	۵/۹۵	۰/۹۶۶۵	۱۶/۷۹	کیوه‌نان <sup>a</sup>
۰/۹۹۸۵	۴/۸۴	۰/۹۷۲۹	۱۱/۳۱	کرمانشاه
۰/۹۹۳۸	۴/۳۶	۰/۹۵۱۵	۹/۴۵	هلشی <sup>a</sup>
۰/۹۹۶۱	۳/۲۹	۰/۹۸۳۹	۹/۳۹	ماهیدشت
۰/۹۹۶۰	۳/۱۲	۰/۹۸۴۵	۱۱/۲۹	کوزران
۰/۹۹۲۵	۵/۰۵	۰/۹۸۰۶	۱۲/۰۱	روانسر
۰/۹۹۰۵	۴/۴۵	۰/۹۶۲۶	۸/۱۴	چوانرود <sup>a</sup>
۰/۹۸۲۰	۳/۴۹	۰/۹۹۰۲	۷/۱۲	پاوه
۰/۹۹۶۸	۴/۰۰	۰/۹۷۱۴	۱۲/۲۴	اسلام آباد
۰/۹۹۶۲	۳/۸۸	۰/۹۶۱۳	۸/۴۴	کرد <sup>a</sup>
۰/۹۹۲۴	۳/۳۸	۰/۹۹۲۴	۱۳/۰۹	حمیل
۰/۹۹۴۹	۴/۱۶	۰/۹۸۸۹	۱۱/۲۹	گهواره
۰/۹۹۶۸	۴/۵۵	۰/۹۷۶۲	۹/۶۹	تازه‌آباد
۰/۹۹۵۲	۵/۹۹	۰/۹۵۲۹	۱۲/۴۶	ازگله <sup>a</sup>
۰/۹۸۹۰	۳/۳۲	۰/۹۷۰۷	۱۰/۱۶	سرپل‌ذهاب
۰/۹۹۹۴	۴/۱۶	۰/۹۹۹۱	۱۲/۳۴	گیلانغرب
۰/۹۹۳۹	۴/۰۲	۰/۹۸۵۰	۹/۱۴	گواور
۰/۹۹۷۵	۳/۷۴	۰/۹۶۳۰	۱۱/۹۳	قصرشیرین
۰/۹۹۷۰	۴/۶۶	۰/۹۷۸۵	۸/۱۶	سومار <sup>a</sup>

<sup>a</sup> ایستگاه‌های استفاده شده برای آزمایش شبکه



## نتایج روش سری‌های زمانی

جهت اطمینان از معتبر بودن نتایج حاصل از مدل بدست آمده برای بازه‌های زمانی طولانی مدت، در این مطالعه سری زمانی تغییرات تابش سالانه کلی خورشید در استان کرمانشاه در بازه زمانی ۱۳۸۷-۱۳۹۲ ترسیم گردید و مراحل چهارگانه مدل‌سازی بر روی آن صورت گرفت. سپس نمودارهای خود همبستگی (ACF)<sup>۱</sup> و خود همبستگی جزئی (PACF)<sup>۲</sup> و آزمون بارتلت- لون ایستایی در میانگین و واریانس داده‌ها مورد ارزیابی قرار گرفت. در صورت لزوم، تفاضل مناسب سری برای ایجاد ایستایی و نرمال بودن در سری صورت می‌گیرد. در مرحله دوم، ساختار همبستگی زمانی داده‌های تبدیل شده به وسیله آزمون توابع خود همبستگی و خود همبستگی جزئی تعیین می‌شود (باکس- جینکس). سپس این اطلاعات برای تعیین شکل کلی مدل یک متغیره استفاده می‌شود. در مطالعات مربوط به داده‌های جغرافیایی و هواشناسی، مدلی که دارای دقت بالا می‌باشد مدل ARIMA است. جهت تعیین بهترین ترکیب برای مدل ARIMA از معیارهای AIC<sup>۳</sup> و SBC استفاده می‌شود. مدلی که کمترین مقدار AIC و SBC را داشته باشد بهترین مدل می‌باشد. با توجه به جدول (۱۰)، مناسبترین مدل ARIMA(1,1,1) می‌باشد.

جدول (۱۰) مدل‌های مختلف ARIMA برای پیش‌بینی تابش کلی خورشید در استان کرمانشاه

SBC	AIC	مدل
۱۴۹۴/۱	۱۴۴۶/۴	ARIMA (1,0,0)
۱۳۵۶/۲	۱۳۶۱/۴	ARIMA (1,0,1)
۱۴۲۱/۴	۱۴۱۳/۹	ARIMA (1,1,0)
۱۳۴۷/۶	۱۳۴۳/۲	ARIMA (1,1,1)
۱۴۲۵/۱	۱۵۲۴/۳	ARIMA (2,0,0)
۱۳۷۹/۳	۱۳۶۳/۸	ARIMA (2,0,1)
۱۴۲۶/۵	۱۴۸۳/۶	ARIMA (2,1,0)
۱۴۳۷/۲	۱۳۷۶/۱	ARIMA (2,1,1)
۱۴۲۰/۲	۱۴۱۱/۳	ARIMA (3,0,0)
۱۴۳۷/۲	۱۴۲۶/۴	ARIMA (3,0,1)
۱۴۰۲/۷	۱۳۸۴/۶	ARIMA (3,1,0)
۱۴۲۰/۳	۱۳۸۳/۱	ARIMA (3,1,1)
۱۳۷۶/۱	۱۳۸۸/۶	ARIMA (4,0,0)
۱۴۲۹/۴	۱۳۹۳/۶	ARIMA (4,0,1)
۱۴۳۰/۵	۱۳۷۷/۵	ARIMA (4,1,0)
۱۳۹۸/۴	۱۳۶۹/۳	ARIMA (4,1,1)

- 1) Autocorrelation Function
- 2) Partial Autocorrelation Function
- 3) Akaike Information Criterion

با توجه به آنچه که قبلاً ذکر شده، نتایج پیش‌بینی متغیر تابش کلی خورشید در استان کرمانشاه به صورت گذشته‌نگر در بخشی از دوره تخمین (۱۳۹۲-۱۳۹۰) بر اساس روشهای سری‌های زمانی و شبکه‌های عصبی مصنوعی در جدول (۱۱) ارائه شده است. مقادیر جدول (۱۱) اشاره به این واقعیت دارد که مدل ARIMA از انحراف بیشتری نسبت به مقادیر واقعی برخوردار است. در مقابل، مقادیر پیش‌بینی شده توسط ANN دارای انحراف کمتری نسبت به مقادیر واقعی است. لذا می‌توان نتیجه گرفت که مدل شبکه‌های عصبی مصنوعی ارائه شده در این مطالعه برای بازه‌های زمانی طولانی مدت نیز دارای دقت بالایی است.

جدول (۱۱) مقادیر واقعی و پیش‌بینی شده تابش کلی خورشید در استان کرمانشاه به دو روش ARIMA و ANN در بازه زمانی (۱۳۹۲-۱۳۹۰)

سال	مقدار واقعی تابش کلی خورشید (cal/cm <sup>2</sup> day)	مقدار پیش‌بینی شده توسط ARIMA (1,1,1)	مقدار پیش‌بینی شده توسط ANN
۱۳۹۰	۴۴۱/۲۹	۳۳۴/۵۰	۴۳۲/۷۳
۱۳۹۱	۶۱۹/۶۸	۴۲۰/۱۲	۶۴۵/۲۴
۱۳۹۲	۷۴۹/۴۲	۸۹۸/۴۸	۷۶۱/۱۰
	<b>R</b>	<b>MAPE (%)</b>	
ARIMA(1,1,1)	۰/۸۹۶۷	۱۷/۴۴	
ANN	۰/۹۹۶۹	۴/۴۵	

### نتیجه‌گیری

تعیین تابش کلی خورشید در هر سایت برای بسیاری از برنامه‌های علمی، مهندسی و زیست‌محیطی حائز اهمیت است. در این مطالعه، یک فرمول جدید بر اساس داده‌های جغرافیایی و هواشناسی برای پیش‌بینی ماهانه متوسط مجموع روزانه تابش کلی خورشید در هر محل از استان کرمانشاه توسعه داده شد. به منظور رسیدن به یک مدل موفق، مناسبترین متغیرهای مستقل با استفاده از روشهای رگرسیون چندگانه گام به گام به دست آمد. با توجه به نتایج بدست آمده، میانگین درصد خطای مطلق (MAPE) و ضریب همبستگی (R) برای مقایسه بین تابش کلی خورشید اندازه‌گیری شده و پیش‌بینی شده برای مجموعه داده‌های آزمایش با استفاده از مدل شبکه‌های عصبی مصنوعی بر اساس روشهای رگرسیون غیرخطی چندگانه به ترتیب برابر ۳/۹۸ درصد و ۰/۹۹۶۱ به دست آمد. همچنین با توجه به اینکه روش شبکه‌های عصبی مصنوعی ممکن است برای پیش‌بینی در بازه‌های زمانی طولانی مدت چندان دقیق نباشد، برای صحت‌سنجی در این خصوص از روش سری‌های زمانی برای بازه‌های یکساله (۱۳۹۲-۱۳۹۰) در بازه زمانی مورد مطالعه استفاده شد و نتایج آن صحت مدل شبکه‌های عصبی مصنوعی برای بازه‌های طولانی مدت را نیز تأیید کرد. بنابراین، با استفاده از این مدل و با داشتن

متغیرهای ورودی مورد نیاز، تابش کلی ماهانه خورشید در هر محل از استان کرمانشاه را می‌توان به سرعت و با دقت قابل قبولی پیش‌بینی کرد. علاوه بر این، اگر به دلیل عملکرد نادرست دستگاه‌های اندازه‌گیری نتوان برای چند ماه داده‌ها را به شکل مناسب اندازه‌گیری نمود، با استفاده از مدل موجود می‌توان آنها را پیش‌بینی نمود.

## منابع

- [1] Abdallah, Y.A.G., (1994). "New correlation of global solar radiation with meteorological parameters for Bahrain," *Solar Energy*, Vol. 16, pp. 111–120.
- [2] Aguiar, R., Collares-Pereira, M., (1992). "A time dependent autoregressive, Gaussian model for generating synthetic hourly radiation," *Solar Energy*, Vol. 49, pp. 167–174.
- [3] Akinoglu, B.G., Ecevit, A., (1990). "Construction of a quadratic model using modified Angstrom coefficients to estimate global solar radiation," *Solar Energy*, Vol. 45, pp. 85–92.
- [4] Al-Alawi, S.M., Al-Hinai, H.A., (1998). "An ANN-based approach for predicting global solar radiation in locations with no measurements," *Renewable Energy*, Vol. 14, pp. 199–200.
- [5] Almorox, J., Hontoria, C., (1967). "Global solar estimation using sunshine duration in Spain," *Energy Conversion and Management*, Vol. 11, pp. 170–172.
- [6] Amrouche, B., Pivert, X., (2014). "Artificial neural network based daily local forecasting for global solar radiation," *Applied Energy*, Vol. 130, pp. 333–341.
- [7] Angstrom, A., (1924). "Solar and terrestrial radiation," *Journal of the Royal Meteorological Society*, Vol. 50, pp. 121–126.
- [8] Azadeh, A., Maghsoudi, A., Sohrabkhani, S., (2009). "An integrated artificial neural networks approach for predicting global radiation," *Energy Conversion and Management*, Vol. 50, pp. 1497–1505.
- [9] Bagheri Moghaddam, N., Mousavi, S.M., Nasiri, M., Moallemi, E.A., Yousefdehi, H., (2011). "Wind energy status of Iran: evaluating Iran's technological capability in manufacturing wind," *Renewable and Sustainable Energy Reviews*, Vol. 15, pp. 4200–4211.
- [10] Bahlel, V., Bakhsh, H., Srinivasan, R., (1987). "A correlation for estimation of global solar radiation," *Energy*, Vol. 12, pp. 131–135.
- [11] Bakirci, K., (2009). "Correlations for estimation of daily global solar radiation with hours of bright sunshine in Turkey," *Energy*, Vol. 34, pp. 485–501.

- [12] Bilgili, M., Sahin, B., (2010a). "Prediction of long-term monthly temperature and rainfall in Turkey," *Energy Sources*, Vol. 32, pp. 60–71.
- [13] Cankaya, S., (2009). "A comparative study of some estimation methods for parameters and effects of outliers in simple regression model for research on small ruminants," *Tropical Animal Health and Production*, Vol. 41, pp. 35–41.
- [14] Cevik, A., (2007). "Unified formulation for web crippling strength of cold-formed steel sheeting using stepwise regression," *Journal of Constructional Steel Research*, Vol. 63, pp. 1305–1316.
- [15] Chatfield, C., (2003). "The Analysis Of Time Series An Introduction," 6<sup>th</sup> Edition, CRC Press, UK.
- [16] Elminir, H.K., Azzam, Y.A., Younes, F.I., (2007). "Prediction of hourly and daily diffuse fraction using neural network, as compared to linear regression models," *Energy*, Vol. 32, pp. 1513–1523.
- [17] Gencoglu, M.T., Cebeci, M., (2009). "Investigation of pollution flashover on high voltage insulators using artificial neural network," *Expert Systems with Applications*, Vol. 36, pp. 7338–7345.
- [18] Hasni, A., Sehli, A., Draoui, B., Bassou, A., Amieur, B., (2012). "Estimating Global Solar Radiation Using Artificial Neural Network and Climate Data in the South-western Region of Algeria," *Energy Procedia*, Vol. 18, pp. 531-537.
- [19] Hosseini, S.E., Wahid, M.A., (2013). "Feasibility study of biogas production and utilization as a source of renewable energy in Malaysia," *Renewable and Sustainable Energy Reviews*, Vol. 19, pp. 454–462.
- [20] Iran Meteorological Organization, <http://irimo.ir>.
- [21] Jung, J.R., Yum, B.J., (2011). "Artificial neural network based approach for dynamic parameter design," *Expert Systems with Applications*, Vol. 38, pp. 504–510.
- [22] Kaushika, N.D., Tomar<sup>1</sup>, R.K., Kaushik, S.C., (2014). "Artificial neural network model based on interrelationship of direct, diffuse and global solar radiations," *Solar Energy*, Vol. 103, pp. 327–342.
- [23] Kisi, Ö., (2009). "Modeling monthly evaporation using two different neural computing techniques," *Irrigation Science*, Vol. 27, pp. 417–430.
- [24] Landeras, G., López, J., Kisi, O., Shiri, J., (2012). "Comparison of Gene Expression Programming with neuro-fuzzy and neural network computing techniques in estimating daily

- incoming solar radiation in the Basque Country (Northern Spain),” *Energy Conversion and Management*, Vol. 62, pp. 1-13.
- [25] Lu, W., (2000). “Neural Network Model for Distribution Bucking Behavior of Cold Formed Steel Compression Member,” Helsinki University of Technology of Steel Structures, Publication 16.
- [26] Maps of Global horizontal irradiation, SolarGIS© 2013 Geo Model Solar s.r.o, Available from: <http://solargis.info/doc/71>.
- [27] Nakata, T., Silva, D., Rodionov, M., (2011). “Application of energy system models for designing low-carbon society,” *Progress in Energy and Combustion Science*, Vol. 37, pp. 462–502.
- [28] Prieto, J.I., Martines-Garcia, J.C., Garcia, D., (2009). “Correlation between global solar irradiation and air temperature in Asturias, Spain,” *Solar Energy*, Vol. 83, pp. 1076-1085.
- [29] Rahimikhoob, A., (2010). “Estimating global solar radiation using artificial neural network and air temperature data in a semi-arid environment,” *Renewable Energy*, Vol. 35, pp. 2131-2135.
- [30] Rehman, S., (1998). “Solar radiation over Saudi Arabia and comparison with empirical models,” *Energy*, Vol. 23, pp. 1077–1082.
- [31] Rehman, S., Mohandes, M., (2008). “Artificial neural network estimation of global solar radiation using air temperature and relative humidity,” *Energy Policy*, Vol. 63, pp. 571–576.
- [32] Robaa, S.M., (2009). “Validation of existing models for estimating global solar radiation over Egypt,” *Energy Conversion and Management*, Vol. 50, pp. 184–193.
- [33] Sangun, L., Cankaya, S., Kayaalp, G. T., Akar, M., (2009). “Use of factor analysis scores in multiple regression model for estimation of body weight from some body measurements in Lizardfish,” *Journal of Animal and Veterinary Advances*, Vol. 8, pp. 47–50.
- [34] Senkal, O., Kuleli, T. (2009). “Estimation of solar radiation over Turkey using artificial neural network and satellite data,” *Applied Energy*, Vol. 86, pp. 1222–1228.
- [35] Shumway, R.H., Stoffer, D.S., (2011). “Time Series Analysis and Its Applications: With R Examples,” 3<sup>th</sup> Edition, Springer, New York, USA.
- [36] Sozen, A., Arcaklioglu, E., Ozalpa, M., Caglar, N., (2005). “Forecasting based on neural network approach of solar potential in Turkey,” *Renewable Energy*, Vol. 30, pp. 1075–1090.
- [37] Sozen, A., Arcaklioglu, E., Ozalpa, M., Kanitc, E.G., (2004). “Use of artificial neural networks for mapping of solar potential in Turkey,” *Applied Energy*, Vol. 77, pp. 273–286.

- [38] Tabatabaei, M., Tohidfar, M., Jouzani, G.S., Safarnejad, M., Pazouki, M., (2011). "Biodiesel production from genetically engineered microalgae: future of bioenergy in Iran," Renewable and Sustainable Energy Reviews, Vol.15, pp. 1918–1927.
- [39] Togrul, I.T., Onat, E. (1999). "A study for estimating the solar radiation in Elazığ using geographical and meteorological data," Energy Conversion and Management, Vol. 40, pp. 1577–1584.

