



Estimation of Solar Radiation using Optimized Artificial Neural Network-Genetic Algorithm and Meteorological Parameters

Sajjad Hashemi¹, Saeed Samadianfard^{2✉}, Ali Ashraf Sadraddini³

1. Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran,

Email: hashemisajjad2009@gmail.com

2. Corresponding Author, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran,

Email: s.samadian@tabrizu.ac.ir

3. Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran,

Email: alisadraddini@yahoo.com

Article Info

Article type: Research Article

Article history:

Received: Nov. 30, 2021

Revised: July. 15, 2022

Accepted: July. 30, 2022

Published online: Sep. 23, 2022

Keywords:

Agriculture,
Artificial intelligence,
Efficiency,
Optimization,
Solar energy.

ABSTRACT

Solar radiation is one of the key factors in the fields of agriculture, hydrology and meteorology and plays an essential role in various physical, biological and chemical processes such as snowmelt, evaporation, photosynthesis and crop production. Thus, accurate estimation of this parameter is very important. Accordingly, in this study, the amounts of daily solar radiation were estimated using artificial neural network and artificial neural network-genetic algorithm in six stations of Ardabil province including Ardabil, Bilehsavar, Sareyn, Germe, Meshgin Shahr and Nir. The data used in this research include maximum, minimum and average temperature, relative humidity and wind speed of the mentioned stations in a time period of two years (2017-2018) which are used in eight different combinations as input data of the models. Also, statistical indices of correlation coefficient, root mean square error, Wilmot index, Kling-Gupta efficiency and Taylor diagrams have been used to compare the obtained results. Generally, the obtained results indicated that among the artificial neural networks, the model of Bilehsavar station and among the artificial neural network-genetic algorithms, the model of Ardabil station recorded the most accurate results. Also, MLP-VIII model in Bilehsavar station with a correlation coefficient of 0.856, root mean square error of 0.319 (MJ/m²d), Kling-Gupta efficiency of 0.659 and Wilmot index of 0.893 have the best performance in the utilized models. Therefore, it is recommended to use artificial neural network-genetic algorithm method for estimation of solar radiation.

Cite this article: Hashemi, S., Samadianfard, S., & Sadraddini, A. A. (2022). Estimation of Solar Radiation using Optimized Artificial Neural Network-Genetic Algorithm and Meteorological Parameters. *Iranian Journal of Soil and Water Research*, 53 (7), 1545-1562.

© The Author(s).

Publisher: University of Tehran Press.

DOI: <http://doi.org/10.22059/ijswr.2022.334806.669144>



برآورد تابش خورشیدی با کاربرد شبکه عصبی مصنوعی بهینه‌سازی شده با الگوریتم ژنتیک و استفاده از پارامترهای هواشناسیسجاد هاشمی^۱، سعید صمدیان فرد^۲، علی اشرف صدرالدینی^۳۱. گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران، ایمیل: hashemisajjad2009@gmail.com۲. نویسنده مسئول، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران، ایمیل: s.amadian@tabrizu.ac.ir۳. گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران، ایمیل: alisadraddimi@yahoo.com**چکیده****اطلاعات مقاله**

تابش خورشیدی یکی از عوامل کلیدی در زمینه‌های کشاورزی، هیدرولوژی و هواشناسی است و نقش اساسی در انواع فرآیندهای فیزیکی، بیولوژیکی و شیمیایی از جمله ذوب برف، تبخیر، فتوسنتز گیاه و تولید محصول ایفا می‌کند و برآورد دقیق این پارامتر اهمیت فراوانی دارد. بر این اساس، در این مطالعه مقادیر تابش خورشیدی روزانه با استفاده از مدل‌های مختلف شبکه عصبی مصنوعی و شبکه عصبی مصنوعی بهینه‌سازی شده با الگوریتم ژنتیک در شش ایستگاه استان اردبیل شامل اردبیل، بیله‌سوار، سرعین، گرمی، مشگین شهر و نیر تخمین زده شد. داده‌های استفاده شده در این تحقیق بیشینه، کمینه و میانگین دما، رطوبت نسبی و سرعت باد ایستگاه‌های مذکور در بازه زمانی دو ساله (۲۰۱۷-۲۰۱۸) می‌باشند که در هشت ترکیب مختلف به‌عنوان داده‌های ورودی مدل‌ها به کار گرفته شده‌اند. همچنین از شاخص‌های آماری ضریب همبستگی، جذر میانگین مربعات خطا، شاخص ویلموت، راندمان کلینگ-گاپتا و دیگرام تیلور برای مقایسه نتایج به‌دست‌آمده بهره گرفته شده است. به‌طور کلی نتایج به‌دست‌آمده نشان داد که در روش شبکه عصبی مصنوعی، مدل‌های ایستگاه بیله‌سوار و در روش شبکه عصبی مصنوعی-الگوریتم ژنتیک مدل‌های ایستگاه اردبیل دقیق‌ترین نتایج را ثبت کردند. همچنین مدل MLP-VIII در ایستگاه بیله‌سوار با دارا بودن ضریب همبستگی ۰/۸۵۶، جذر میانگین مربعات خطای ۰/۳۱۹ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۶۵۹ و شاخص ویلموت ۰/۸۹۳ بهترین عملکرد را در بین مدل‌های به کار گرفته شده دارد. در نتیجه، استفاده از شبکه عصبی مصنوعی بهینه‌سازی شده با الگوریتم ژنتیک در برآورد هر چه دقیق‌تر تابش خورشیدی توصیه می‌گردد.

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۰/۹/۹

تاریخ بازنگری: ۱۴۰۱/۴/۲۴

تاریخ پذیرش: ۱۴۰۱/۵/۸

تاریخ انتشار: ۱۴۰۱/۷/۱

واژه‌های کلیدی:

انرژی خورشیدی،

بهینه‌سازی،

راندمان،

کشاورزی،

هوش مصنوعی.

استناد: هاشمی، سجاد؛ صمدیان فرد، سعید؛ صدرالدینی، علی اشرف (۱۴۰۱) برآورد تابش خورشیدی با کاربرد شبکه عصبی مصنوعی بهینه‌سازی شده با الگوریتم ژنتیک و استفاده از پارامترهای هواشناسی. *مجله تحقیقات آب و خاک ایران*، ۵۳ (۷)، ۱۵۶۲-۱۵۴۵.

DOI: <http://doi.org/10.22059/ijswr.2022.334806.669144>

© نویسندگان

ناشر: مؤسسه انتشارات دانشگاه تهران

مقدمه

با توجه به اینکه بخش کشاورزی یکی از بخش‌های مولد و مهم ایران می‌باشد، بررسی تأثیر انرژی خورشیدی بر فرایندهای مرتبط با این بخش مانند فرآیند فتوسنتز در گیاهان و یا تخمین مقدار تبخیر-تعرق اهمیت ویژه‌ای خواهد داشت. همچنین، به علت این که مقدار تبخیر-تعرق به‌وسیله انرژی در دسترس برای تبخیر آب تعیین می‌گردد (Allen et al. 1998) و از آن جایی که $99/8$ درصد انرژی سطح زمین توسط انرژی خورشیدی تأمین می‌گردد، تخمین مقدار تبخیر-تعرق از مهم‌ترین کاربردهای تابش خورشیدی در علوم آبیاری می‌باشد (De Souza et al. 2005). از طرف دیگر، نیروگاه‌های خورشیدی که انرژی خورشید را به برق تبدیل می‌کنند می‌توانند در آینده با مزایای قاطعی که در برابر نیروگاه‌های فسیلی و اتمی دارند، به‌خصوص این که سازگار با محیط زیست می‌باشند، مشکل برق به‌خصوص در دوران اتمام ذخایر نفت و گاز را حل نمایند. از طرفی دیگر، تأسیس و به‌کارگیری نیروگاه‌های خورشیدی آینده‌ای پرثمر و زمینه‌گسترده‌ای را برای کمک به خودکفایی و قطع وابستگی کشور به صادرات نفت فراهم خواهد کرد. به‌طور کلی مزایایی که در استفاده از انرژی خورشیدی نسبت به انرژی‌های غیرقابل تجدید وجود دارند عبارتند از تولید برق بدون مصرف سوخت، عدم احتیاج به آب زیاد، عدم آلودگی محیط زیست، امکان تأمین شبکه‌های کوچک و ناحیه‌ای و استهلاک کم و عمر زیاد. با توجه به موارد فوق، اهمیت انرژی خورشیدی و ضرورت استفاده از این انرژی نامحدود نمایان می‌شود. لذا می‌توان با اندازه‌گیری پارامتر تابش خورشیدی گام مهمی برای استفاده از این انرژی برداشت. با در نظر گرفتن این که به دلایل مختلف (هزینه‌های بالای ایجاد و نگهداری تجهیزات موردنیاز و ...)، پارامتر تابش خورشیدی در اکثر ایستگاه‌های هواشناسی کشورهای در حال توسعه اندازه‌گیری نمی‌شود، از روش‌های مختلفی برای محاسبه و برآورد این پارامتر استفاده می‌شود. در کنار استفاده از روش‌های فیزیکی و معادلات تجربی، محققان از روش‌های آماری و هوش مصنوعی نیز برای مدل‌سازی و پیش‌بینی تابش خورشیدی کمک می‌گیرند. از جمله این تحقیقات می‌توان به پژوهش‌های (Marzo et al. 2017)، (Rao et al. 2018)، (Samadianfar et al. 2019) و (He et al. 2020) اشاره کرد. (Rahimi Khub et al. 2009) از دو روش تجربی هارگریوز - سامانی و آنگستروم که به ترتیب مبتنی بر دمای هوا و ساعات آفتابی هستند و همچنین از دو مدل شبکه عصبی مصنوعی که ورودی‌هایی مشابه با ورودی‌های مدل‌های تجربی داشتند، مقادیر تابش خورشیدی رسیده به زمین در جنوب شرق تهران را برآورد کردند. نتایج بررسی‌ها نشان داد که مدل‌های تجربی فوق و مدل‌های شبکه عصبی عملکرد بهتری در برآورد مقادیر تابش خورشیدی داشتند، لیکن مدل‌های مبتنی بر ساعات آفتابی نسبت به مدل‌های مبتنی بر دمای هوا برتری دارند. (Bagheri Toulabi et al. 2013) روش جدیدی را به‌منظور تخمین متوسط روزانه تابش خورشیدی در ماه بر روی سطح افقی، بر مبنای مدل آنگستروم و با استفاده از الگوریتم زنبورها معرفی کردند. ضرایب تجربی مدل آنگستروم برای چهار منطقه آب و هوایی مختلف ایران در محاسبه شده و مقدار متوسط روزانه تابش کلی خورشید تخمینی با روش پیشنهادی در ماه برای مناطق نمونه ارائه کردند. مقایسه بین نتایج به‌دست آمده از روش پیشنهادی و روش‌های دیگر، قابلیت مدل پیشنهادی را برای پیدا کردن تابش خورشیدی برای هر چهار منطقه نمونه ایران نشان داد. (Zamani Mohiabadi 2013) با استفاده از روش شبکه عصبی، مدلی را جهت پیش‌بینی لحظه‌ای تابش خورشیدی در شهر رفسنجان توسعه داد. با توجه به شاخص‌های آماری حاصل از مقایسه مقادیر به‌دست آمده از مدل طراحی شده با مقادیر اندازه‌گیری شده توسط پیرانومتر برای یک سال، مشخص شد که مدل مذکور با دقت مناسب، عملکرد خوبی را از خود نشان داده است. (Azadeh et al. 2009) توانایی روش شبکه عصبی مصنوعی و معادله آنگستروم - پرسکات را در برآورد تابش خورشیدی ماهانه در شش ایستگاه سینوپتیک ایران، ارزیابی کردند. مقادیر تابش خورشیدی حاصله از مدل‌ها حاکی از برتری روش شبکه عصبی مصنوعی نسبت به معادله آنگستروم - پرسکات به دلیل میانگین درصد خطای کمتر و دقت بیشتر بود. (Jiang 2009) به‌منظور مدل‌سازی میانگین تابش خورشیدی ماهانه در ۸ شهر چین، یک مدل شبکه عصبی مصنوعی را بر اساس الگوی پس‌انتشار خطا ایجاد کرد. وی بر اساس شاخص‌های ارزیابی دقت، به مقایسه نتایج مدل شبکه عصبی مصنوعی و دیگر مدل‌های رگرسیونی با داده‌های اندازه‌گیری شده پرداخت و نشان داد مدل شبکه عصبی مصنوعی نسبت به مدل‌های رگرسیونی بررسی شده، عملکرد موفق‌تری داشته و تطابق بیشتری با مقادیر تابش خورشیدی اندازه‌گیری شده دارد. (Ramedani et al. 2014) از ۴ مدل مختلف بر پایه هوش مصنوعی به منظور پیش‌بینی تابش خورشیدی در استان تهران بهره گرفتند. در این پژوهش، از داده‌های هواشناسی مختلف ایستگاه مورد مطالعه برای توسعه مدل رگرسیون بردار پشتیبان تابع پایه شعاعی (SVR-RBF) و سه مدل رگرسیون بردار پشتیبان چندجمله‌ای (SVR-Poly)، سیستم استنتاج تطبیقی عصبی-فازی (ANFIS) و شبکه عصبی مصنوعی (ANN) استفاده شد و نتایج با یکدیگر مورد مقایسه




قرار گرفت. رضانی و همکاران بیان کردند در مقایسه مدل SVR-RBF با سه مدل مورد مطالعه، این مدل نسبت به مدل SVR-Poly دقت پیش‌بینی بالاتری داشته است. (Khosravi et al. (2018) با استفاده از روش‌های شبکه عصبی پیش‌رو چند لایه (MLFFNN)، شبکه عصبی تابع پایه شعاعی (RBFNN)، رگرسیون بردار پشتیبان (SVR)، سیستم استنتاجی فازی (FIS) و سیستم استنتاجی عصبی-فازی تطبیقی (ANFIS) مقادیر تابش خورشیدی ساعتی را در جزیره ابوموسی پیش‌بینی کردند. در این تحقیق دو نوع داده ورودی برای مدل‌ها به کار برده شد، به طوری که در نوع اول از متغیرهای زمان محلی، دما، فشار، سرعت باد و رطوبت نسبی و در نوع دوم از سری‌های زمانی تابش خورشیدی به‌عنوان ورودی استفاده شد. نتایج نشان داد که برای مدل‌های نوع اول، روش‌های SVR و MLFFNN و برای مدل‌های نوع دوم روش‌های SVR، MLFFNN و ANFIS با بیشترین همبستگی با مقادیر تابش خورشیدی واقعی، بهترین عملکرد را به ثبت رسانند. (Kaba et al. (2018) تئوری یادگیری عمیق را برای برآورد تابش خورشیدی در ۳۴ ایستگاه ترکیه به کار بردند. آن‌ها نتیجه گرفتند مدل مطالعه شده دقت پیش‌بینی مناسبی نسبت به تعداد بسیاری از مطالعات برآورد تابش خورشیدی قبلی دارد. (Feng et al. (2020) مدل ترکیبی ماشین یادگیری گسترده و بهینه‌سازی ازدحام ذرات (PSO-ELM) را برای برآورد تابش خورشیدی روزانه به کار بردند و نتایج را با پنج مدل دیگر شامل ELM، SVM، شبکه‌های عصبی رگرسیونی گسترش‌یافته (GRNN)، M5 و کدگذار خودکار مورد مقایسه قرار دادند و در نهایت بیان کردند که مدل PSO-ELM در مدل‌سازی تابش خورشیدی مؤثر بوده است. (Agbulut et al. (2021) از چهار الگوریتم یادگیری ماشینی مختلف (شامل ماشین بردار پشتیبان، شبکه عصبی مصنوعی، کرنل و نزدیک‌ترین همسایگی (k-NN) و یادگیری عمیق (DL)) برای برآورد تابش خورشیدی روزانه در ترکیه استفاده کردند و نشان دادند که روش ANN بهترین نتایج را دارا بوده و روش‌های DL، SVM و k-NN به ترتیب در رتبه‌های بعدی قرار گرفتند. با بررسی مطالعات انجام گرفته در زمینه تابش خورشیدی، اهمیت این پارامتر در بسیاری از زمینه‌ها از جمله کشاورزی، هیدرولوژی، هواشناسی و ... کاملاً مشخص است. علاوه بر این، طی سال‌های اخیر به‌کارگیری روش‌های هوش مصنوعی در مدل‌سازی تابش خورشیدی مورد توجه محققین قرار گرفته است. لذا هدف از تحقیق حاضر تخمین مقادیر تابش خورشیدی در شش ایستگاه استان اردبیل شامل ایستگاه‌های اردبیل، بیله‌سوار، سرعین، گرمی، مشگین شهر و نیر با استفاده از پارامترهای هواشناسی در الگوهای مختلف به‌عنوان داده‌های ورودی و با به‌کارگیری روش شبکه عصبی مصنوعی بوده و همچنین سعی شده است با استفاده از الگوریتم بهینه‌سازی ژنتیک خطای مدل‌های شبکه عصبی مصنوعی کاهش داده شود. در نهایت مدل‌های برتر در هر ایستگاه و همچنین در مقایسه کلی ایستگاه‌ها مشخص گردیده و معرفی شده‌اند.

مواد و روش‌ها

منطقه مورد مطالعه

استان اردبیل در شمال فلات ایران و شمال غربی کشور ایران قرار گرفته و با استان‌های آذربایجان شرقی، زنجان و گیلان همجوار است. مساحت این استان حدود ۱۷۸۰۰ کیلومتر مربع می‌باشد و از نظر ارتفاعی نیز دارای دامنه نوسان نسبتاً بالایی است، به طوری که پست‌ترین نقطه آن با ارتفاع ۱۰۰ متر در شهر پارس آباد و بیله‌سوار و بلندترین نقطه آن قله سبلان با ارتفاع ۴۸۱۱ متر می‌باشد. استان اردبیل در محور طول جغرافیایی با گسترش (یک درجه و ۳۵ دقیقه)، همراه با عامل ارتفاع دشت‌ها و کوهستان‌های آن در ترکیبی هماهنگ با همجواری دریای خزر بوده و گستردگی زیاد در جهت شمال - جنوب در عرض جغرافیایی (۲ درجه و ۳۱ دقیقه) تنوع آب و هوایی زیادی به استان اردبیل بخشیده است. حدود دو سوم این استان دارای بافت کوهستانی با اختلاف ارتفاع زیاد است و بقیه را مناطق هموار و پست تشکیل می‌دهند. به طوری که شمال این استان (مغان) با ارتفاع کم دارای آب و هوای نسبتاً گرم و مناطق مرکزی و جنوبی دارای آب و هوای کوهستانی سرد می‌باشند. در تحقیق حاضر از داده‌های تابش خورشیدی، بیشینه، کمینه و میانگین دما، رطوبت نسبی و سرعت باد شش ایستگاه هواشناسی استان اردبیل شامل اردبیل، بیله‌سوار، سرعین، گرمی، مشگین شهر و نیر در بازه زمانی ۲ ساله (۲۰۱۸-۲۰۱۷) در مقیاس روزانه استفاده شده است. موقعیت و مشخصات ایستگاه‌های مورد مطالعه به ترتیب در شکل ۱ و جدول ۱ آورده شده است.



شکل ۱- موقعیت جغرافیایی ایستگاه‌های مورد مطالعه

جدول ۱- مشخصات جغرافیایی ایستگاه‌های مورد مطالعه

ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع از سطح دریا
اردبیل	۴۸° ۱۷'	۳۸° ۱۵'	۱۳۵۱
بيله سوار	۴۸° ۲۱'	۳۹° ۲۲'	۸۳
سرعین	۴۸° ۰۴'	۳۸° ۰۹'	۱۶۵۰
گرمی	۴۸° ۰۴'	۳۹° ۰۱'	۸۵۰
مشگین شهر	۴۷° ۴۰'	۳۸° ۲۳'	۱۴۰۰
نیر	۴۷° ۵۹'	۳۸° ۰۲'	۱۴۵۰

شبکه عصبی مصنوعی

ساختار کلی شبکه‌های عصبی مصنوعی از شبکه‌های عصبی بیولوژیکی انسان الهام گرفته شده است و مدل ساده شده‌ای از سیستم عصبی مرکزی می‌باشد. مغز به عنوان یک سیستم پردازش اطلاعات از عناصر اصلی ساختاری به نام نرون تشکیل شده است. اجتماعی از نرون‌های به هم مرتبط، بافت‌هایی که عصب نامیده می‌شوند را می‌سازند، که اطلاعات و پیام‌ها را از یک قسمت بدن به قسمت دیگر بدن منتقل می‌کنند. شبکه‌های عصبی مصنوعی نیز شامل مجموعه‌ای از نرون‌های به هم متصل می‌باشند که به هر مجموعه از این نرون‌ها یک لایه گفته می‌شود (Menhaj, 1998). شبکه‌های عصبی مصنوعی علی‌رغم تنوع، از ساختار مشابهی برخوردار می‌باشند. در اغلب مدل‌های شبکه عصبی مصنوعی، از مدل ریاضی سلول عصبی که نرون یا پرسپترون نامیده می‌شود، استفاده می‌گردد. یک شبکه عصبی معمولاً از سه لایه ورودی، پنهان و خروجی تشکیل شده است (Kuan and White, 1994). لایه ورودی فقط اطلاعات را دریافت کرده و مشابه متغیر مستقل عمل می‌کند. بنابراین تعداد نرون‌های لایه ورودی براساس طبیعت مسئله تعیین می‌شود و بستگی به تعداد متغیرهای مستقل دارد. لایه خروجی نیز همانند متغیر وابسته عمل نموده و تعداد نرون‌های آن بستگی به تعداد متغیر وابسته دارد. اما برخلاف لایه‌های ورودی و خروجی، لایه پنهان (مخفی) هیچ مفهومی را نشان نمی‌دهد و صرفاً یک نتیجه میانی در فرایند محاسبه ارزش خروجی است. یکی از متداول‌ترین شبکه‌های عصبی مورد بهره‌گیری در مطالعات هیدرولوژی و کشاورزی، شبکه عصبی پرسپترون چند لایه است. همانند سایر مدل‌های شبکه عصبی مصنوعی، این شبکه نیز از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه بین آن‌ها که به طور مستقیم به داده‌های ورودی و نتایج خروجی متصل نیستند، تشکیل یافته‌اند که واحدهای لایه ورودی تنها وظیفه توزیع میزان‌های ورودی‌ها به لایه بعد و لایه خروجی نیز پاسخ سیگنال‌های خروجی را ارائه می‌دهد. در این دو لایه شمار نرون‌ها برابر با شمار ورودی‌ها و خروجی‌ها است و لایه یا لایه‌های پنهان وظیفه ارتباط لایه‌های ورودی به لایه‌های خروجی را بر عهده دارند. پیدا کردن تعداد نرون‌های لایه میانی و تحلیل دقیق آن‌ها در کل بسیار پیچیده است و در شبکه عصبی پرسپترون چند لایه الگوریتم مشخصی برای تعیین تعداد لایه‌های پنهان و تعداد نرون‌ها وجود ندارد و این امر اغلب به روش سعی و خطا انجام می‌گیرد. اما با توجه به اینکه تعداد نرون‌های لایه مخفی تابعی از تعداد عناصر برداری ورودی و همچنین بیشینه تعداد نواحی از فضای ورودی که به‌طور خطی از هم جدا پذیرند می‌باشد، می‌توان تعداد نرون‌های

لایه مخفی به طور تجربی به دست آورد. خروجی نرون‌ها توسط معادله (۱) تعریف می‌گردد:

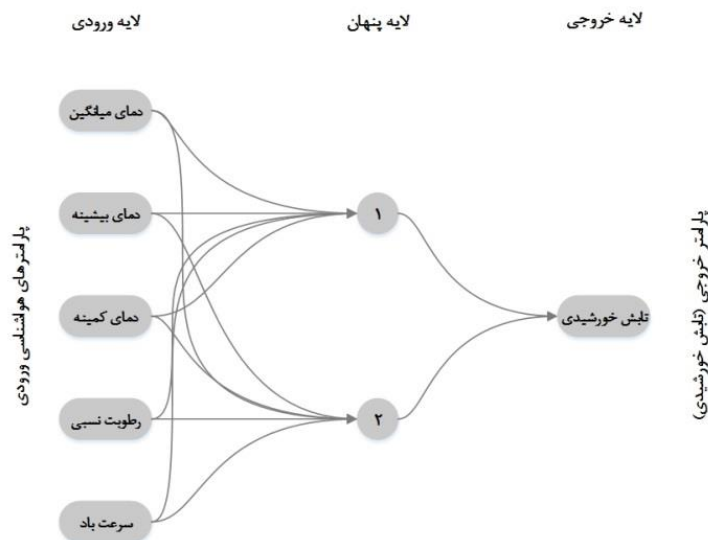
$$a = f \left(b_j + \sum_{i=1}^n p_i w_i \right) \quad \text{رابطه ۱}$$

که در این معادله p و a به ترتیب کمیت‌های ورودی و خروجی می‌باشند. کمیت w میزان تأثیر p روی a را تعیین می‌کند (وزن ارتباطی لایه‌ها). از سوی دیگر نیز مقدار ثابت 1 در جمله b ضرب شده و با مقدار $w \times p$ جمع می‌گردد. حاصل این جمع ورودی خالص n ، برای تابع f خواهد بود.

تابع غیرخطی f که انتقال اعداد از لایه‌ای به لایه دیگر را بر عهده دارد باید به لحاظ ریاضی هموار باشد، که از آن جمله می‌توان به توابع گوسی، سکانت هیپربولیک، سیگموئید و تانژانت هیپربولیک اشاره کرد و از این میان تابع سیگموئید $S(x) = 1/(1 + \exp(-a))$ کاربرد بیشتری در مسائل مهندسی دارد. بنابراین در یک شبکه عصبی با n نرون ورودی، h نرون در لایه میانی و یک نرون خروجی، مقدار خروجی از شبکه عصبی به صورت رابطه ۲ خواهد بود (Samadianfard et al., 2018).

$$Y = S_2 \left(\sum_{j=1}^h w_j \times \left(S_1 \left(b_j + \sum_{i=1}^n w_{i,j} \cdot p_i \right) \right) \right) \quad \text{رابطه ۲}$$

در این پژوهش، با ترکیب لایه‌های ورودی، پنهان و خروجی، از یک ساختار سه لایه‌ای استفاده شده است. پارامترهای مستقل ورودی شامل پارامترهای هواشناسی و متغیر وابسته‌ای که برای خروجی به کار برده شده مقدار تابش خورشیدی در ایستگاه مورد نظر می‌باشد. همچنین از توابع تانژانت سیگموئید و خطی با به‌کارگیری الگوریتم مارکارد لوونبرگ با ۲۰۰ تکرار در لایه‌های ورودی و خروجی استفاده شده است. شکل ۲ نمونه‌ای از ساختار استفاده شده مدل MLP در این مطالعه با استفاده از پارامترهای هواشناسی را نشان می‌دهد.



شکل ۲- ساختار استفاده شده مدل MLP

الگوریتم ژنتیک

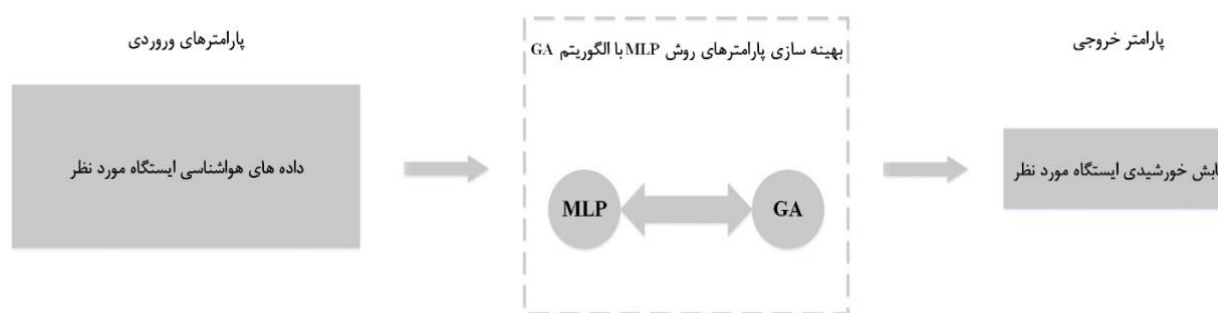
الگوریتم ژنتیک^۱ (GA) یک روش تکاملی با ساختار انتخاب طبیعی است که بر پایه نظریه داروین استوار است که توسط Holland (1992) و Goldberg (1989) توسعه داده شد. الگوریتم‌های ژنتیک اغلب گزینه خوبی برای تکنیک‌های پیش‌بینی بر مبنای رگرسیون هستند. الگوریتم ژنتیک یک فن برنامه‌نویسی است که از تکامل ژنتیکی به‌عنوان یک الگوی حل مسئله استفاده می‌کند. الگوریتم ژنتیک یک فن جستجو در علوم مهندسی برای یافتن راه حل بهینه و مسائل جستجو است. الگوریتم‌های ژنتیک یکی از انواع الگوریتم‌های تکاملی هستند؛ که از علم زیست‌شناسی مثل وراثت، جهش، انتخاب ناگهانی، انتخاب طبیعی و ترکیب الهام گرفته شده است. به‌طور معمول راه‌حل‌ها به صورت اعداد دودویی نشان داده می‌شوند. تکامل از یک مجموعه به‌طور کامل تصادفی از موجودیت‌ها شروع می‌شود و در نسل‌های بعدی تکرار می‌شود و در هر نسل، مناسب‌ترین‌ها انتخاب می‌شوند نه بهترین‌ها. راه‌حل‌های هر مسئله به‌وسیله یک لیست از پارامترها نشان

^۱ Genetic Algorithm

داده می‌شود که به آن‌ها کروموزوم یا ژنوم گفته می‌شود. کروموزوم‌ها به‌طور معمول به‌صورت یک رشته ساده از داده‌ها نمایش داده می‌شوند، البته انواع ساختمان داده‌های دیگر هم می‌توانند مورد استفاده قرار بگیرند. الگوریتم‌های ژنتیک پس از طی چندین مرحله از تولید نسل در نهایت باید بر اساس یک سری شرایط خاصی به اجرای خود خاتمه دهند. تعدادی از شرایط خاتمه الگوریتم‌های ژنتیک عبارتند از: الف) به اندازه تعداد محدود و مشخص عمل تولید نسل را انجام دهد. ب) به اندازه یک زمان ثابت تعریف شده عمل تولید نسل را انجام دهد. ج) یک فرد (فرزند تولید شده) پیدا شود که نتیجه مطلوب را حاصل سازد. د) بیشترین درجه برازندگی فرزندان حاصل شود و یا نتایج بهتری دیگر حاصل نشود. ه) با بازرسی دستی متوقف شود. و) به‌صورت ترکیبی از روش‌های بالا عمل توقف صورت گیرد (Mitchell, 1996).

مدل ترکیبی الگوریتم ژنتیک - شبکه عصبی مصنوعی (GA-MLP)

تعیین تعداد نوروها در لایه‌های پنهان، چرخه آموزش، نرخ یادگیری، مومنتوم، خطای اسیلون و دانه تصادفی محلی یکی از مراحل پیچیده در مدل‌سازی به روش MLP است. برای این منظور از تکنیک ترکیبی GA و MLP برای مدل‌سازی تابش خورشیدی روزانه استفاده شده است. این فرایند با انتخاب یک جمعیت اولیه تصادفی شروع می‌شود که در آن هر فرد تعداد متفاوتی از نوروهای لایه پنهان را تشکیل می‌دهد. سپس، جمعیت نخبه با بهترین افراد انتخاب می‌شوند. این مدل بارها و بارها اجرا می‌شود و برای هر فرد، عملکرد محاسبه شده و نتایج به دست آمده ذخیره می‌شود. در مرحله آخر، اگر معیارهای خاتمه نتایج رضایت‌بخش داشته باشد، فرد با بهترین عملکرد ذخیره می‌شود. در غیر این صورت، این روند همچنان به یافتن جمعیت مناسب با عملکرد جدید ادامه می‌دهد. الگوریتم لونیبرگ-مارگارت بیشتر در مرحله آموزش این فرآیند استفاده می‌شود اما ماهیت تصادفی دارد. با استفاده از GA، مدل در برابر این مشکل محافظت می‌شود و بهترین عملکرد انتقال را برای لایه‌های پنهان و خروجی انتخاب می‌کند. شکل ۳ نمودار مدل ترکیبی GA-MLP را نشان می‌دهد.



شکل ۳- نمای کلی مدل ترکیبی GA-MLP

شاخص‌های ارزیابی دقت

در این پژوهش برای ارزیابی دقت مدل‌ها و مقایسه نسبی نتایج مدل‌های برآوردی با مقادیر اندازه‌گیری شده تابش خورشیدی، از معیارهای آماری، ضریب همبستگی (CC)، جذر میانگین مربعات خطا (RMSE)، شاخص ویلموت (WI) و راندمان کلینگ-گاپتا (KGE) استفاده شد.

$$CC = \frac{\left(\sum_{i=1}^n O_i P_i - \frac{1}{n} \sum_{i=1}^n O_i \sum_{i=1}^n P_i \right)}{\left(\sum_{i=1}^n O_i^2 - \frac{1}{n} \left(\sum_{i=1}^n O_i \right)^2 \right) \left(\sum_{i=1}^n P_i^2 - \frac{1}{n} \left(\sum_{i=1}^n P_i \right)^2 \right)} \quad \text{رابطه ۳}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad \text{رابطه ۴}$$

$$WI = 1 - \left[\frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \right] \quad \text{رابطه ۵}$$

$$KGE = 1 - \sqrt{(R-1)^2 + (\beta-1)^2 + (\gamma-1)^2} \quad \text{رابطه ۶}$$

$$R = \frac{\left[\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P}) \right]}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \quad \text{رابطه ۷}$$

$$\gamma = \frac{CV_P}{CV_O} = \frac{\frac{\sigma_P}{\bar{P}}}{\frac{\sigma_O}{\bar{O}}} \quad \text{رابطه ۸}$$

در روابط ۳ تا ۸، n تعداد داده‌ها، O_i و P_i به ترتیب مقادیر مشاهداتی و پیش‌بینی شده تابش خورشیدی هستند. همچنین σ_P و σ_O به ترتیب انحراف معیار مقادیر مشاهداتی و محاسبه شده با استفاده از روش‌های مورد مطالعه (MLP و GA-MLP) می‌باشند. همچنین، دیاگرام تیلور برای تحلیل دقت روش‌های مورد استفاده در تخمین تابش خورشیدی به کار گرفته شد. دیاگرام تیلور راه‌حلی گرافیکی برای ارزیابی دقت داده‌های پیش‌بینی شده با به تصویر کشیدن همزمان سه پارامتر آماری جذر میانگین مربعات خطا، انحراف معیار و ضریب همبستگی می‌باشد. در دیاگرام تیلور، هر نقطه نشان‌دهنده عملکرد روش متناظر بوده و هر چه نقاط متناظر روش‌ها به نقطه داده‌های مشاهداتی در مختصات قطبی نزدیک‌تر باشد، نشان‌دهنده دقت بالاتر و خطای کمتر آن روش می‌باشد (تیلور، ۲۰۰۱).

یافته‌ها

در پژوهش حاضر، مقادیر تابش خورشیدی روزانه در شش ایستگاه استان اردبیل (ایستگاه‌های اردبیل، بيله‌سوار، سرعین، گرمی، مشگین شهر و نیر) با استفاده از روش‌های شبکه عصبی مصنوعی (MLP) و شبکه عصبی مصنوعی بهینه‌سازی شده با الگوریتم ژنتیک (GA-MLP) تخمین زده شد. بدین منظور، از پارامترهای هواشناسی ایستگاه مورد نظر شامل بیشینه، کمینه و میانگین دما، رطوبت نسبی و سرعت باد به‌عنوان داده‌های ورودی مدل‌ها در هشت سناریو مختلف استفاده شد. لازم به ذکر است که ترکیب‌های مختلف داده‌های ورودی بر اساس ضرایب همبستگی بین پارامتر تابش خورشیدی هر ایستگاه با سایر پارامترهای هواشناسی ایستگاه موردنظر که در جدول ۲ آورده شده است، تعیین گردید (جدول ۳). همچنین در این پژوهش، ۷۰ درصد داده‌ها برای واسنجی مدل‌های مورد مطالعه و ۳۰ درصد باقی مانده برای صحت‌سنجی مدل‌ها به کار گرفته شد و سپس نتایج به‌دست آمده از بخش صحت‌سنجی هر یک از مدل‌ها با استفاده از شاخص‌های آماری ضریب همبستگی، جذر میانگین مربعات خطا، راندمان کلینگ-گاپتا و شاخص ویلموت با مقادیر مشاهداتی تابش خورشیدی مقایسه شد. جدول ۴ نیز مقادیر P-value در سطح معنی‌داری ۹۵ درصد برای پارامترهای هواشناسی مورد استفاده با پارامتر تابش خورشیدی را نشان می‌دهد.

جدول ۲- ضرایب همبستگی بین پارامتر تابش خورشیدی هر ایستگاه با سایر پارامترهای هواشناسی

ایستگاه	حداقل دما	حداکثر دما	دمای میانگین	رطوبت نسبی	سرعت باد	تابش خورشیدی
اردبیل	-۰/۳۳۴	۰/۴۲۸	۰/۴۳۲	-۰/۳۵۲	۰/۰۷۹	۱
بيله‌سوار	-۰/۶۵۸	۰/۸۵۰	۰/۸۰۴	-۰/۸۰۹	۰/۴۱۹	۱
سرعین	۰/۴۳۶	۰/۵۳۳	۰/۵۰۴	-۰/۳۶۱	-۰/۰۶۰	۱
گرمی	۰/۷۳۰	۰/۸۱۹	۰/۸۰۵	-۰/۶۲۹	۰/۴۱۱	۱
مشگین شهر	-۰/۶۸۲	۰/۷۸۸	۰/۷۵۹	-۰/۴۵۲	-۰/۰۰۹	۱
نیر	-۰/۶۰۳	۰/۷۸۰	۰/۷۶۲	-۰/۳۵۷	-۰/۲۳۳	۱

جدول ۳- ترکیب‌های مختلف داده‌های ورودی مدل‌های مورد مطالعه

پارامترهای هواشناسی	شماره الگو
T_m	I
T_{min}, T_{max}	II
T_m, RH	III
T_m, T_{min}, T_{max}	IV
T_{min}, T_{max}, RH	V
T_{min}, T_{max}, RH, WS	VI
$T_m, T_{min}, T_{max}, RH$	VII
$T_m, T_{min}, T_{max}, RH, WS$	VIII

جدول ۴- مقادیر P-value در سطح معنی‌داری ۹۵ درصد برای پارامترهای هواشناسی مورد استفاده با پارامتر تابش خورشیدی

ایستگاه	مقادیر P-value در سطح معنی‌داری ۹۵ درصد			
	دمای میانگین	دمای حداقل	دمای حداکثر	رطوبت نسبی
اردبیل	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۱۸۸
بيله‌سوار	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰
سرعین	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۳۱۹
گرمی	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰
مشگین شهر	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۸۷۸
نیر	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰

با توجه به مقادیر به دست آمده از جدول ۴، بیشتر پارامترها در اکثر ایستگاه‌های مورد مطالعه دارای سطح معنی‌داری ۹۵ درصد با پارامتر تابش خورشیدی می‌باشند. به جز پارامتر سرعت باد که در ایستگاه‌های اردبیل، مشگین شهر و سرعین دارای سطح معنی‌داری ۹۵ درصد نبوده، لذا پارامتر سرعت باد کمتر در ترکیب ورودی مدل‌ها مورد استفاده قرار گرفته است. جدول ۵ مقادیر شاخص‌های ارزیابی دقت مدل‌های به‌کاربرده شده در ایستگاه‌های مورد مطالعه را نشان می‌دهد.

با توجه به نتایج به‌دست آمده (جدول ۵)، در ایستگاه اردبیل مدل MLP-III با ضریب همبستگی ۰/۷۲۴، جذر میانگین مربعات خطای ۰/۳۴۵ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۶۲۷ و شاخص ویلموت ۰/۸۱۴ و با داده‌های ورودی دمای میانگین و رطوبت نسبی، بهترین عملکرد را در بین مدل‌های مختلف روش شبکه عصبی مصنوعی به خود اختصاص داد. در رتبه دوم، مدل MLP-V با دارا بودن ضریب همبستگی ۰/۷۰۳، جذر میانگین مربعات خطای ۰/۳۶۴ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۵۶۹ و شاخص ویلموت ۰/۷۹۶ پس از مدل MLP-III، دارای کمترین مقدار خطا نسبت به سایر مدل‌ها در این روش بود و مدل MLP-VIII دارای ضریب همبستگی ۰/۷۲۷، جذر میانگین مربعات خطای ۰/۴۴۴ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۴۴۹ و شاخص ویلموت ۰/۷۰۸ بود و با به‌کارگیری همه پارامترهای ورودی مورد استفاده، به‌عنوان رتبه سوم از نظر دقت عملکرد مشخص شد. همچنین در این ایستگاه، الگوریتم بهینه‌سازی ژنتیک در ۵ سناریو از ۸ سناریو با کاهش خطا باعث بهبود عملکرد مدل‌های شبکه عصبی مصنوعی شد. به تبع مدل‌های شبکه عصبی مصنوعی، در روش GA-MLP نیز مدل‌های GA-MLP-V، GA-MLP-III، GA-MLP-VIII به ترتیب با ضریب همبستگی ۰/۷۲۴، ۰/۶۷۱ و ۰/۶۴۳، جذر میانگین مربعات خطای ۰/۳۳۵، ۰/۳۵۸ و ۰/۳۷۲ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۵۷۹، ۰/۴۲۶ و ۰/۷۹۴، و شاخص ویلموت ۰/۸۰۷، ۰/۷۹۴ و ۰/۷۲۱ با بیشترین دقت عملکرد، رتبه‌های اول، دوم و سوم را دارا بودند. با توجه به نتایج به‌دست آمده از روش شبکه عصبی مصنوعی در ایستگاه بيله‌سوار (جدول ۵) مدل MLP-VIII دارای ضریب همبستگی ۰/۸۵۶، جذر میانگین مربعات خطای ۰/۳۱۹ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۶۵۹ و شاخص ویلموت ۰/۸۹۳ بوده که بهترین مدل در این روش می‌باشد. مدل MLP-VI با ضریب همبستگی ۰/۸۵۸، جذر میانگین مربعات خطای ۰/۳۳۱ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۶۱۸ و شاخص ویلموت ۰/۸۸۲ و مدل MLP-VII با ضریب همبستگی ۰/۸۳۲، جذر میانگین مربعات خطای ۰/۳۳۶ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۶۴ و شاخص ویلموت ۰/۸۷۸ در رتبه‌های بعدی قرار گرفتند. مدل MLP-I نیز با بیشترین خطا در بین مدل‌های این روش، به‌عنوان ناکارآمدترین مدل ارزیابی شد. در روش شبکه عصبی مصنوعی بهینه‌سازی شده با الگوریتم ژنتیک نیز به جز مدل GA-MLP-III همه مدل‌ها با افزایش خطا همراه بودند. مدل GA-MLP-III با افزایش ضریب همبستگی ۰/۷۸~۰/۷۸۴، کاهش جذر میانگین مربعات خطا ۰/۳۸۷~۰/۳۶۹ (مگاژول بر متر مربع در روز)، افزایش راندمان کلینگ-گاپتا ۰/۵۱۲~۰/۶۳۵ و افزایش شاخص ویلموت ۰/۸۱۲~۰/۸۵ تنها مدل مؤثر در بهبود دقت برآورد مقادیر تابش خورشیدی بود. در ایستگاه سرعین نیز نتایج به‌دست آمده از روش شبکه عصبی مصنوعی (جدول ۵) نشان داد که همه مدل‌ها با خطای نسبتاً زیادی مقدار تابش خورشیدی را برآورد کرده‌اند. با این وجود، مدل MLP-III دارای ضریب همبستگی ۰/۵۱۶، جذر میانگین مربعات خطای ۲/۳۷۶ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۰۵۴ و شاخص ویلموت ۰/۴۳۲ بوده و نسبت به سایر مدل‌ها بهترین عملکرد را داشته است. همچنین بعد از مدل MLP-III، مدل‌های MLP-VI و MLP-II به ترتیب با ضریب همبستگی ۰/۴۹۸ و



جدول ۵- مقادیر شاخص‌های ارزیابی دقت مدل‌های به‌کاربرده شده در ایستگاه‌های مورد مطالعه (مرحله صحت سنجی)

GA-MLP				MLP				سناریو	ایستگاه
WI	KGE	RMSE	CC	WI	KGE	RMSE	CC		
۰/۵۹۴	۰/۲۵۸	۰/۳۹۷	۰/۶۴۸	۰/۶۶۴	۰/۳۵۳	۰/۳۹۶	۰/۶۶۲	I	اردبیل
۰/۶۰۶	۰/۲۷۴	۰/۴۲۴	۰/۴۸۹	۰/۶۶۹	۰/۳۳۹	۰/۲۸۸	۰/۶۱۲	II	
۰/۸۰۷	۰/۵۷	۰/۳۳۵	۰/۷۲۴	۰/۸۱۴	۰/۶۲۷	۰/۳۴۵	۰/۷۲۴	III	
۰/۵۷۱	۰/۲۲۹	۰/۴۱	۰/۵۵۸	۰/۶۹۴	۰/۳۸۶	۰/۴۱۲	۰/۶۹۷	IV	
۰/۷۹۴	۰/۵۷۹	۰/۳۵۸	۰/۶۷۱	۰/۷۹۶	۰/۵۶۹	۰/۳۶۴	۰/۷۰۳	V	
۰/۷۶۶	۰/۵۷۲	۰/۳۹۴	۰/۶۱۹	۰/۶۹۵	۰/۴۳۸	۰/۴۵۹	۰/۷۴۸	VI	
۰/۷۶۵	۰/۵۳۶	۰/۳۷۲	۰/۶۵۹	۰/۶۶۶	۰/۴۲۴	۰/۴۹۶	۰/۷۴۳	VII	
۰/۷۲۱	۰/۴۲۶	۰/۳۷۲	۰/۶۴۳	۰/۷۰۸	۰/۴۴۹	۰/۴۴۴	۰/۷۲۷	VIII	
۰/۶۸۵	۰/۳۵۷	۰/۴۶۳	۰/۶۲۹	۰/۷۰۱	۰/۳۹۲	۰/۴۶	۰/۶۵۲	I	بيله‌سوار
۰/۷۶۶	۰/۴۷۱	۰/۴۲۴	۰/۷۰۸	۰/۸۴۷	۰/۵۸۱	۰/۳۸۴	۰/۸۲۱	II	
۰/۸۵	۰/۶۳۵	۰/۳۶۹	۰/۷۸۴	۰/۸۱۲	۰/۵۱۲	۰/۳۸۷	۰/۷۸	III	
۰/۷۴۴	۰/۴۱۱	۰/۴۱۸	۰/۷۶۶	۰/۸۵۱	۰/۵۷۸	۰/۳۶۷	۰/۸۱۶	IV	
۰/۸۶۴	۰/۶۱۸	۰/۳۴۷	۰/۸۲۲	۰/۸۷۸	۰/۶۰۸	۰/۳۳۵	۰/۸۵۵	V	
۰/۸۸۹	۰/۶۸۸	۰/۳۳۶	۰/۸۳۱	۰/۸۸۲	۰/۶۱۸	۰/۳۳۱	۰/۸۵۸	VI	
۰/۸۶۴	۰/۶۰۱	۰/۳۴۹	۰/۸۲۶	۰/۸۷۸	۰/۶۴	۰/۳۳۶	۰/۸۳۲	VII	
۰/۸۳۶	۰/۵۳۸	۰/۳۶۵	۰/۸۱۸	۰/۸۹۳	۰/۶۵۹	۰/۳۱۹	۰/۸۵۶	VIII	
۰/۲۰۲	-۰/۰۸۴	۲/۳۵۵	۰/۴۴۴	۰/۴۳۳	-۰/۰۲۷	۲/۵۲۵	۰/۴۶۴	I	سرعین
۰/۲۶۱	-۰/۰۲۳	۲/۲۹۸	۰/۴۶۲	۰/۴۰۷	۰/۰۲۳	۲/۳۷۷	۰/۴۷۸	II	
۰/۴۴۷	۰/۱۳۵	۲/۱۸۴	۰/۵۷۴	۰/۴۳۲	۰/۰۵۴	۲/۳۷۶	۰/۵۱۶	III	
۰/۲۶۴	-۰/۰۲۴	۲/۳۰۸	۰/۴۶۳	۰/۴۲۱	۰/۰۰۱	۲/۴۳۹	۰/۴۷۳	IV	
۰/۳۶	۰/۰۵۵	۲/۲۴۹	۰/۵۲۷	۰/۴۵۲	۰/۰۵۳	۲/۴۱۹	۰/۵۱	V	
۰/۳۷۶	۰/۰۶۱	۲/۲۸۵	۰/۵۴۵	۰/۴۳۹	۰/۰۵۴	۲/۳۷۹	۰/۴۹۸	VI	
۰/۴۵۷	۰/۱۱۳	۲/۲۷۴	۰/۵۱۵	۰/۴۳۱	۰/۰۴۴	۲/۳۸۳	۰/۴۹۷	VII	
۰/۳۵	۰/۰۳۹	۲/۳۰۲	۰/۵۵	۰/۴۴۴	۰/۰۴۱	۲/۴۱۶	۰/۴۸۲	VIII	
۰/۶۷۹	۰/۳۲۱	۰/۶۱۱	۰/۷۴۹	۰/۷۴۲	۰/۴۴۵	۰/۵۸۹	۰/۷۴۱	I	گرمی
۰/۶۷۸	۰/۳۲۹	۰/۶۰۶	۰/۷۴	۰/۸۵۳	۰/۶	۰/۴۸۷	۰/۸۰۷	II	
۰/۷۷۱	۰/۴۵۱	۰/۵۵۲	۰/۷۷۲	۰/۸۱۹	۰/۵۵۵	۰/۵۲۸	۰/۷۶۷	III	
۰/۶۹۸	۰/۳۵۲	۰/۵۹۸	۰/۷۳۷	۰/۸۴۸	۰/۵۹۴	۰/۴۸۹	۰/۸۱۵	IV	
۰/۷۹	۰/۴۷۹	۰/۵۳۷	۰/۷۸۳	۰/۸۳۱	۰/۶۵۲	۰/۵۵۱	۰/۷۵۲	V	
۰/۸۱۶	۰/۵۲۶	۰/۵۳۲	۰/۷۶۹	۰/۸۴۸	۰/۵۹۲	۰/۴۹۸	۰/۷۹۳	VI	
۰/۸۲۲	۰/۵۷۲	۰/۵۲۷	۰/۷۷	۰/۸۴۵	۰/۶۱۷	۰/۵۰۹	۰/۷۷۶	VII	
۰/۷۹	۰/۴۹۷	۰/۵۵۱	۰/۷۴۶	۰/۸۴۱	۰/۶۱۸	۰/۵۳۳	۰/۷۵۴	VIII	
۰/۶۲۶	۰/۲۷۹	۰/۵	۰/۶۹۶	۰/۷۰۶	۰/۴۱۷	۰/۴۹۵	۰/۷۰۷	I	مشگین شهر
۰/۷۰۹	۰/۳۷۸	۰/۴۸۴	۰/۶۹۴	۰/۸۱۷	۰/۵۳۸	۰/۴۵۴	۰/۸۳۲	II	
۰/۶۸	۰/۳۳۴	۰/۴۷۱	۰/۷۷۵	۰/۷۲۱	۰/۳۹۱	۰/۵۱	۰/۷۴۵	III	
۰/۶۶۲	۰/۳۰۹	۰/۵۱۹	۰/۷۳۴	۰/۸۳۹	۰/۵۳۹	۰/۳۸۹	۰/۸۲۳	IV	
۰/۷۸۷	۰/۴۹۹	۰/۴۳۱	۰/۸۲۸	۰/۸۷۵	۰/۶۱	۰/۳۶	۰/۸۴۷	V	
۰/۷۸۸	۰/۴۵۳	۰/۴۳	۰/۸۰۲	۰/۸۶۱	۰/۵۷	۰/۳۶۵	۰/۸۴۹	VI	
۰/۷۶۱	۰/۴۲۶	۰/۴۳۲	۰/۸۰۱	۰/۸۵۹	۰/۵۶۸	۰/۳۶۷	۰/۸۴۷	VII	
۰/۷۲۲	۰/۴۰۳	۰/۴۶۳	۰/۷۹۳	۰/۸۶۹	۰/۵۹۷	۰/۳۶۵	۰/۸۴۲	VIII	
۰/۶۱۲	۰/۲۸۳	۰/۴۷۹	۰/۵۶۶	۰/۶۲۹	۰/۴۱۱	۰/۵۹۴	۰/۵۷۷	I	نیر
۰/۵۱۹	۰/۱۸۳	۰/۴۹۴	۰/۵۸	۰/۸۱۲	۰/۵۴۳	۰/۴	۰/۷۶۱	II	
۰/۶۴۷	۰/۳۱۸	۰/۴۶	۰/۶۶۶	۰/۷۴۸	۰/۵۲۲	۰/۴۲	۰/۶۹۷	III	
۰/۶۷۱	۰/۳۵۳	۰/۴۷۱	۰/۶۳۳	۰/۷۷۹	۰/۵۱۶	۰/۴۱۲	۰/۷۴۴	IV	
۰/۷۷۷	۰/۴۸۵	۰/۴۰۸	۰/۷۱۷	۰/۸۰۹	۰/۶۰۶	۰/۴۰۷	۰/۷۷۲	V	
۰/۷۳۵	۰/۴۲۷	۰/۴۳	۰/۷۴۸	۰/۸۳۴	۰/۶۲۹	۰/۳۹۳	۰/۷۳۱	VI	
۰/۶۶۱	۰/۳۲۳	۰/۴۵۲	۰/۶۸۲	۰/۸۳۷	۰/۵۸۹	۰/۳۷۴	۰/۷۶۸	VII	
۰/۶۹۷	۰/۳۷۲	۰/۴۵۳	۰/۷۰۴	۰/۸۱۱	۰/۵۹۴	۰/۴۰۳	۰/۷۲۶	VIII	


۰/۴۷۸، جذر میانگین مربعات خطای ۲/۳۷۹ و ۲/۳۷۷ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۰۵۴ و ۰/۰۲۳ و شاخص ویلموت ۰/۴۳۹ و ۰/۴۰۷ در رتبه‌های بعدی قرار گرفتند. در روش شبکه عصبی مصنوعی بهینه‌سازی شده با الگوریتم ژنتیک، همه مدل‌های GA-MLP باعث افزایش دقت مدل‌های MLP شد، اما همچنان به دلیل مقدار بالای خطا در این مدل‌ها، استفاده از آن‌ها برای پیش‌بینی تابش خورشیدی در ایستگاه سرعین توصیه نمی‌شود.

از مقادیر تابش خورشیدی به دست آمده از روش شبکه عصبی مصنوعی در شهر گرمی (جدول ۵) نتیجه گرفته می‌شود که مدل MLP-II با ضریب همبستگی ۰/۸۰۷، جذر میانگین مربعات خطای ۰/۴۸۷، راندمان کلینگ-گاپتا ۰/۶ و شاخص ویلموت ۰/۸۵۳ بهترین عملکرد را نسبت به سایر مدل‌های این روش داشته و نکته قابل توجه درباره این مدل استفاده از فقط دو پارامتر ورودی (بیشینه و کمینه دما) برای برآورد مقدار تابش خورشیدی است که می‌توان در مواقع کمبود پارامترهای هواشناسی از این مدل با دقت مطلوبی استفاده کرد. مدل‌های MLP-IV و MLP-VI نیز به ترتیب با ضریب همبستگی ۰/۸۱۵ و ۰/۷۹۳، جذر میانگین مربعات خطای ۰/۴۸۹ و ۰/۴۹۸، راندمان کلینگ-گاپتا ۰/۵۹۴ و ۰/۵۹۲ و شاخص ویلموت ۰/۸۴۸ و ۰/۸۴۸ جزو مدل‌های برتر این روش محسوب می‌شوند. مدل MLP-I نیز ضعیف‌ترین مدل این روش با بیشترین خطا بود. در شهر گرمی، تنها مدل کارآمد در بین مدل‌های GA-MLP، مدل GA-MLP-V بود که با افزایش ضریب همبستگی ۰/۷۵۲~۰/۷۸۳ و کاهش جذر میانگین مربعات خطا ۰/۵۵۱~۰/۵۳۷، موجب افزایش دقت مدل MLP-V شد. در ایستگاه مشگین شهر و در روش شبکه عصبی مصنوعی (جدول ۵) مدل MLP-V با دارا بودن ضریب همبستگی ۰/۸۴۷، جذر میانگین مربعات خطای ۰/۳۶ و راندمان کلینگ-گاپتا ۰/۶۱ و شاخص ویلموت ۰/۸۷۵ دقیق‌ترین مدل شناخته شد و پس از آن، مدل MLP-VIII با ضریب همبستگی ۰/۸۴۲، جذر میانگین مربعات خطای ۰/۳۶۵، راندمان کلینگ-گاپتا ۰/۵۹۷ و شاخص ویلموت ۰/۸۶۹ و مدل MLP-VII با داده‌های ورودی بیشینه، کمینه و میانگین دما و رطوبت نسبی و با ضریب همبستگی ۰/۸۴۷، جذر میانگین مربعات خطای ۰/۳۶۷، راندمان کلینگ-گاپتا ۰/۵۶۸ و شاخص ویلموت ۰/۸۵۹، دومین و سومین مدل در این شهر شدند. مدل‌های MLP-III و MLP-I نیز با بیشترین خطا جزو ضعیف‌ترین مدل‌های این روش بودند. در مدل‌های GA-MLP برای ایستگاه مشگین شهر نیز اگرچه سه مدل GA-MLP-V، GA-MLP-VIII و GA-MLP-VII به عنوان مدل‌های برتر روش شبکه عصبی مصنوعی بهینه‌سازی شده با الگوریتم ژنتیک شناخته شدند ولی به طور کلی الگوریتم ژنتیک نتوانست در این شهر باعث بهبود دقت پیش‌بینی مدل‌های شبکه عصبی مصنوعی شود و در اکثر مدل‌ها (به جز یک مدل) باعث افزایش خطای پیش‌بینی شد. از مقادیر به دست آمده از جدول ۵ نتیجه‌گیری می‌شود که در شهر نیر و در روش شبکه عصبی مصنوعی مدل MLP-VII با ضریب همبستگی ۰/۷۶۸، جذر میانگین مربعات خطای ۰/۳۷۴، راندمان کلینگ-گاپتا ۰/۵۸۹ و شاخص ویلموت ۰/۸۳۷ عملکرد بهتری نسبت به سایر مدل‌های این روش داشت. بعد از این مدل، مدل MLP-VI با پارامترهای ورودی بیشینه دما، کمینه دما، رطوبت نسبی و سرعت باد، دارای ضریب همبستگی ۰/۷۳۱، جذر میانگین مربعات خطای ۰/۳۹۳، راندمان کلینگ-گاپتا ۰/۶۲۹ و شاخص ویلموت ۰/۸۳۴ و در رتبه دوم قرار گرفت و مدل MLP-V با دارا بودن ضریب همبستگی ۰/۷۷۲، جذر میانگین مربعات خطای ۰/۴۰۷، راندمان کلینگ-گاپتا ۰/۶۰۶ و شاخص ویلموت ۰/۸۰۹ در رتبه سوم برترین مدل‌های روش MLP قرار گرفت. مدل MLP-I نیز ضعیف‌ترین عملکرد را از خود نشان داد. در مدل ترکیبی الگوریتم ژنتیک-شبکه عصبی مصنوعی نیز مدل GA-MLP-I با کاهش جذر میانگین مربعات خطا ۰/۴۷۹~۰/۵۹۴ عملکرد مدل MLP-I را بهبود بخشید.


بحث

به طور کلی در ایستگاه اردبیل مدل‌های روش شبکه عصبی مصنوعی عملکرد رضایت بخشی در برآورد مقادیر تابش خورشیدی داشتند و الگوریتم ژنتیک نیز باعث بهبود عملکرد ۵ مدل این روش شد. در ایستگاه بيله‌سوار نیز مدل‌های MLP عملکرد قابل قبولی داشتند در حالی که مدل‌های GA-MLP نتوانستند باعث کاهش خطای مدل‌های شبکه عصبی مصنوعی شوند (به جز مدل GA-MLP-III). همچنین در ایستگاه سرعین، در مقایسه با دو ایستگاه دیگر مورد مطالعه، مدل‌های روش MLP مقادیر تابش خورشیدی را با خطای نسبتاً زیادی برآورد کردند ولی در این ایستگاه الگوریتم ژنتیک باعث کاهش خطای همه مدل‌های MLP گردید. در ایستگاه گرمی نتایج به دست آمده حاکی از عملکرد نسبتاً مناسب مدل‌های شبکه عصبی مصنوعی بوده و روش GA-MLP نیز باعث بهبود عملکرد یکی از مدل‌های این ایستگاه گردید. در ایستگاه مشگین شهر نیز مدل‌های MLP نتایج مطلوب با خطای کم را از خود ثبت کردند. در این ایستگاه نیز همانند شهر گرمی، روش ترکیبی الگوریتم ژنتیک-شبکه عصبی مصنوعی باعث افزایش دقت یکی از مدل‌های مورد مطالعه گردید. همچنین در شهر نیر مدل‌های MLP عملکرد قابل قبولی داشتند و می‌توان این مدل‌ها را برای برآورد تابش خورشیدی در شهر نیر به کار گرفت. با

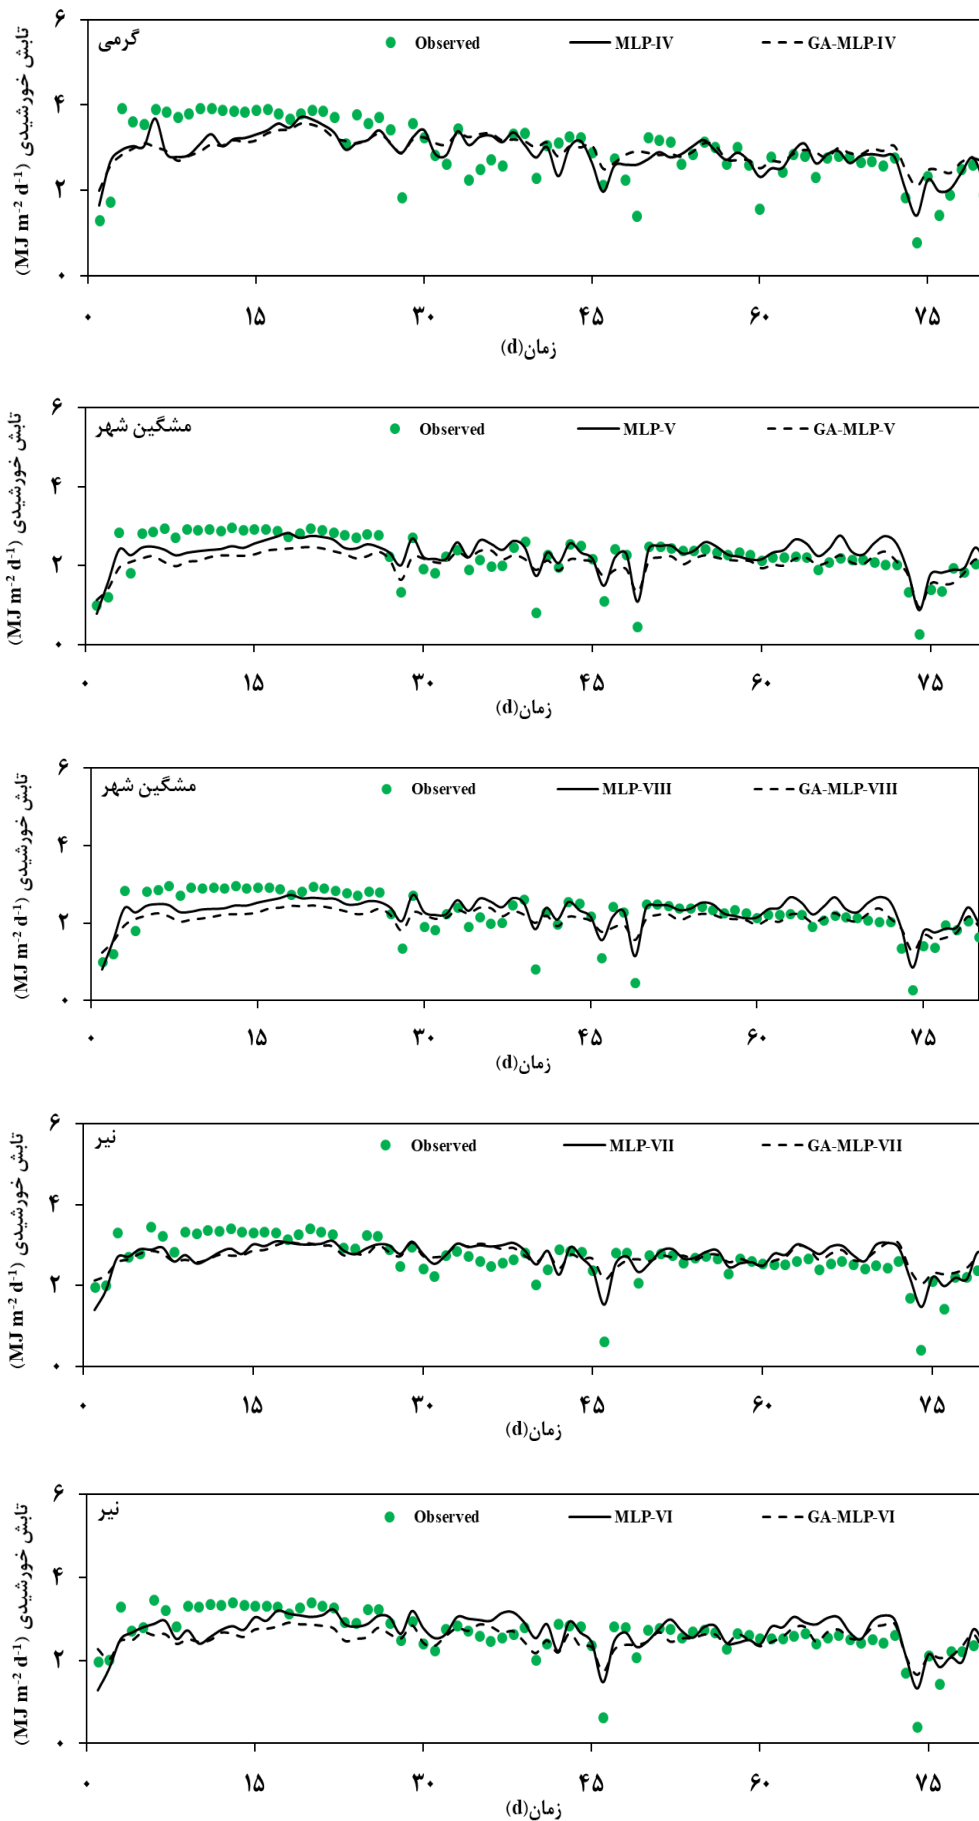
بررسی نتایج ایستگاه‌های مورد مطالعه بر اساس دقت پیش‌بینی تابش خورشیدی در مقایسه با یکدیگر، در روش شبکه عصبی مصنوعی سه ایستگاه بيله‌سوار، مشگین شهر و اردبیل به ترتیب در جایگاه‌های اول تا سوم قرار گرفتند و شهرهای نیر، گرمی و سرعین نیز در رتبه‌های بعدی قرار گرفتند. در روش GA-MLP نیز ایستگاه اردبیل موفق‌ترین عملکرد را دارا بود و ایستگاه‌های بيله‌سوار و نیر نیز نتایج مناسب‌تری نسبت به ایستگاه‌های دیگر داشتند. در مطالعه‌ای مشابه، Landeras et al. (2012) به منظور پیش‌بینی تابش خورشیدی روزانه در ایالت باسک در شمال کشور اسپانیا از تکنیک‌های مختلف شامل شبکه‌های عصبی مصنوعی، برنامه‌ریزی بیان ژن و سیستم استنتاج تطبیقی عصبی - فازی استفاده کردند. در نهایت، یک مدل شبکه عصبی مصنوعی با چهار پارامتر ورودی و ۱۰ نرون در لایه پنهان با بیشترین دقت پیش‌بینی در بین مدل‌های مورد مطالعه، بهترین عملکرد را به خود اختصاص داد. (Yadav and Chandel (2014) با مرور بر مطالعات انجام شده در برآورد تابش خورشیدی با استفاده از روش شبکه عصبی مصنوعی، برتری و دقت بالای این روش را در مقایسه با روش‌های مرسوم نشان دادند. همچنین بیان کردند که دقت مدل‌ها به ترکیب پارامترهای ورودی، الگوریتم یادگیری و ساختار مدل بستگی دارد. (Alsina et al. (2016) مقادیر تابش خورشیدی را با مدل‌های شبکه عصبی مصنوعی در ایتالیا و با ورودی داده‌های هواشناسی تخمین زدند. در این مطالعه مقادیر شاخص میانگین درصد خطای مطلق (MAPE) بین محدوده ۱/۶۷٪ تا ۴/۲۵٪ برای مدل‌ها با نوع و تعداد مختلف پارامترهای ورودی به دست آمد. در ادامه برای بررسی بهتر نتایج به دست آمده، نمودار تغییرات زمانی مقادیر تابش خورشیدی مشاهداتی و پیش‌بینی شده با استفاده از برترین مدل‌های MLP و GA-MLP در ایستگاه‌های مورد مطالعه آورده شده است (شکل ۴). همچنین شکل ۵، نمودارهای پراکنش تابش خورشیدی مشاهداتی و پیش‌بینی شده با استفاده از مدل‌های مذکور را نشان می‌دهد. لازم به ذکر است که باندهای اطمینان در سطح معنی داری ۹۵٪ در نمودارهای پراکنش رسم گردیده‌اند.



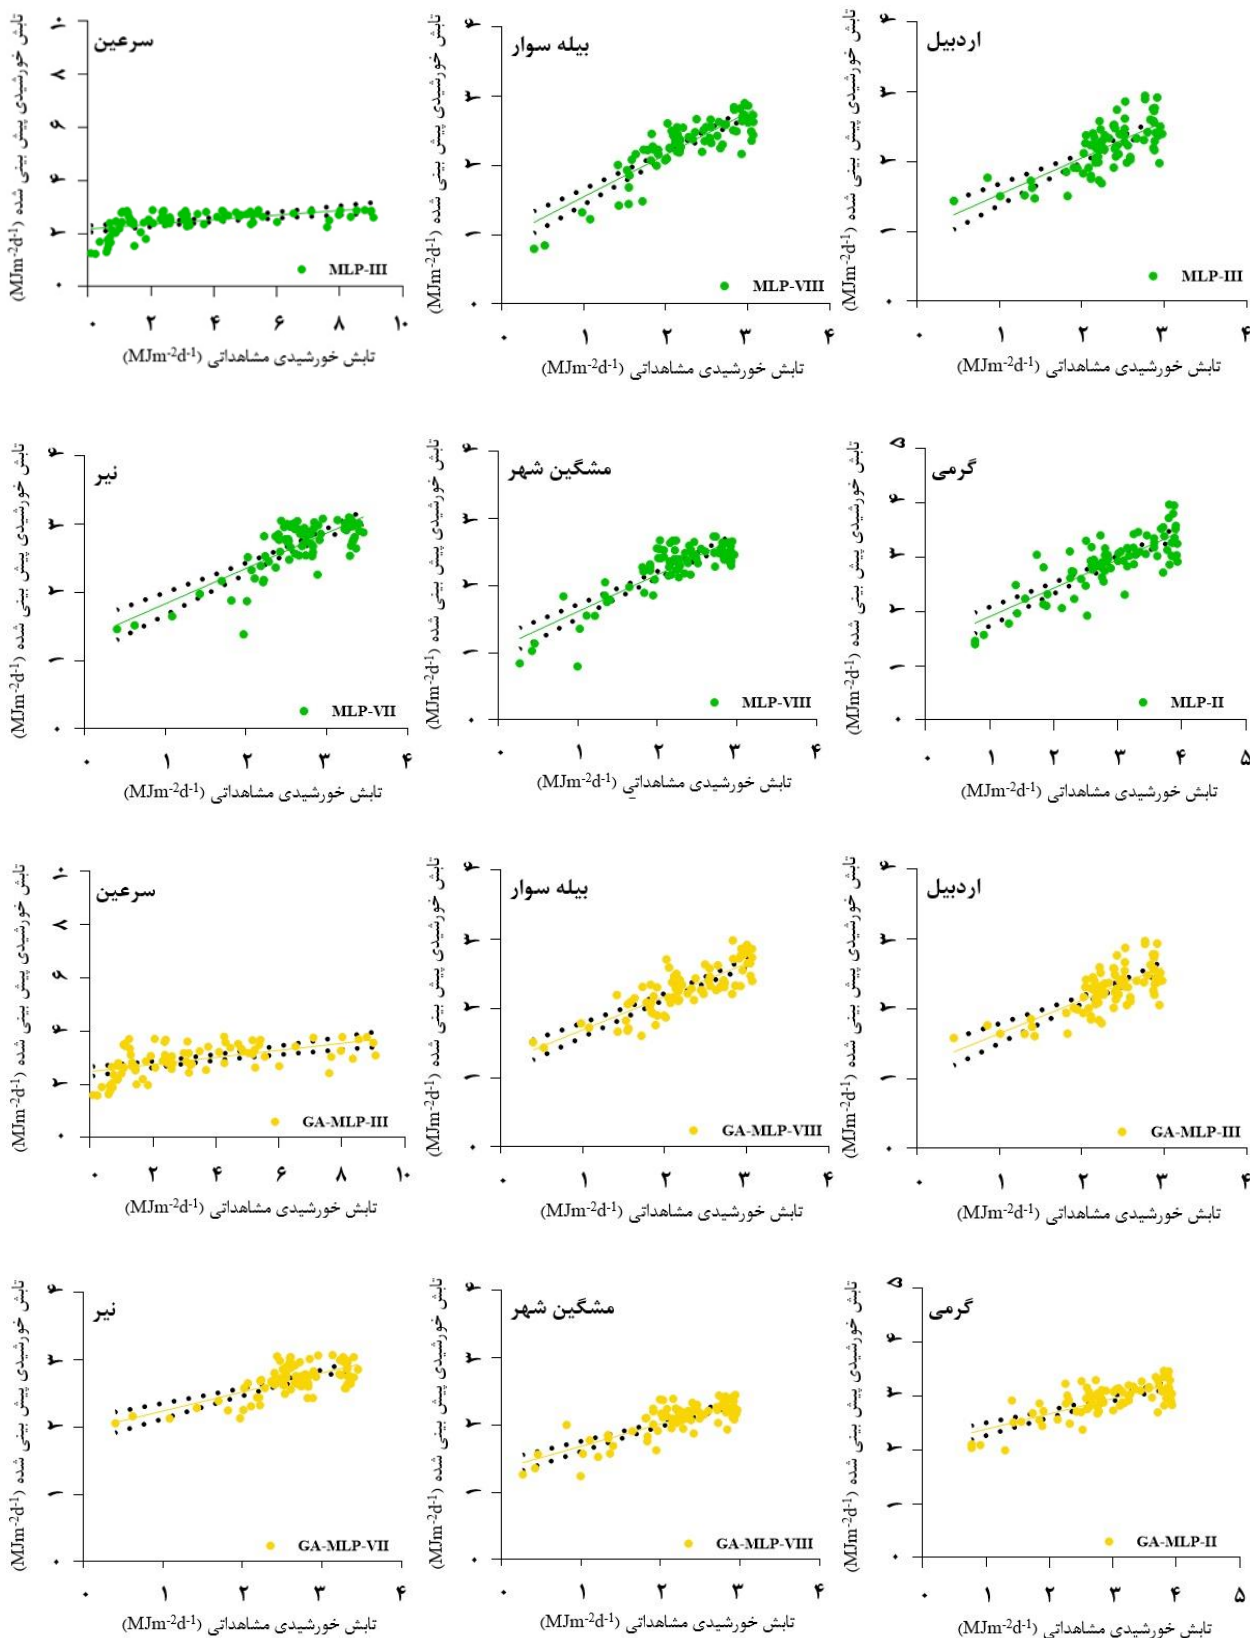
شکل ۴- نمودار تغییرات زمانی مقادیر تابش خورشیدی مشاهداتی و پیش‌بینی شده با استفاده از برترین مدل‌های مورد مطالعه



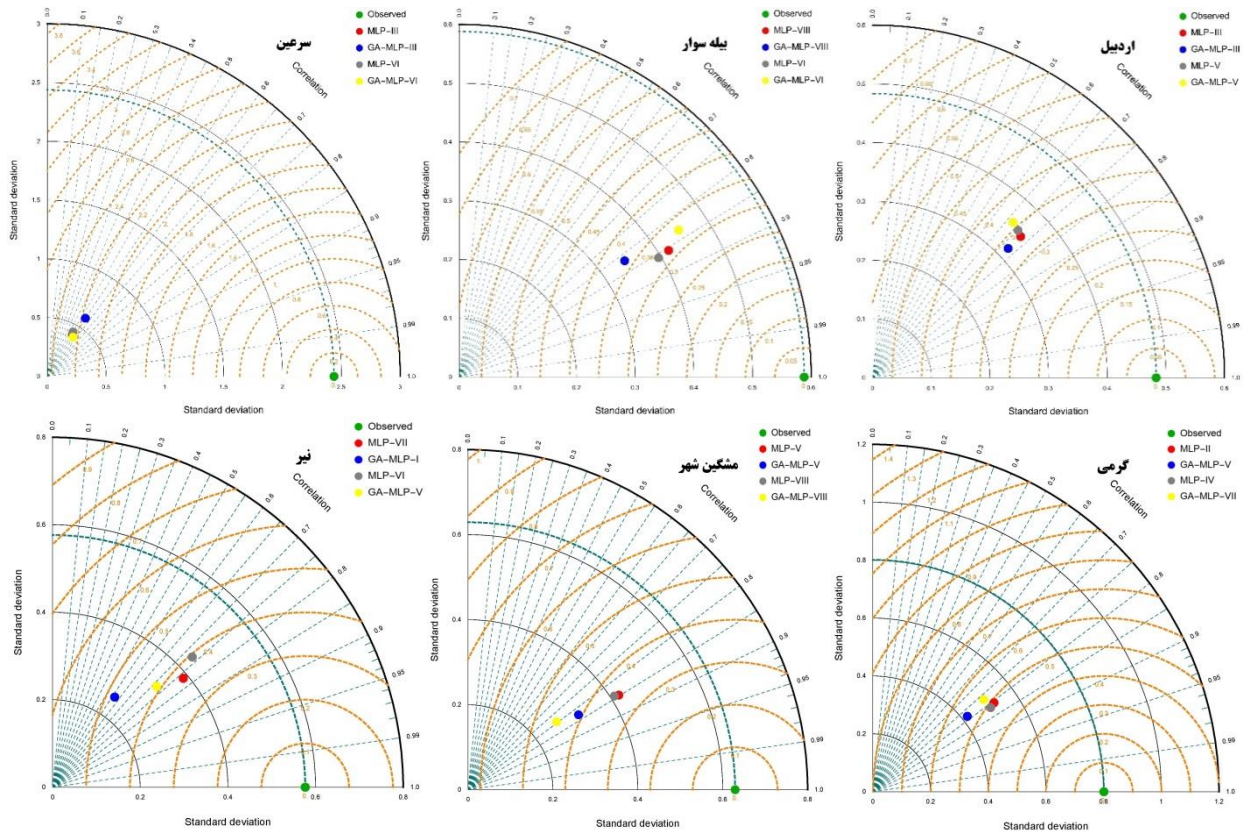
ادامه شکل ۴- نمودار تغییرات زمانی مقادیر تابش خورشیدی مشاهداتی و پیش‌بینی شده با استفاده از برترین مدل‌های مورد مطالعه



ادامه شکل ۴- نمودار تغییرات زمانی مقادیر تابش خورشیدی مشاهداتی و پیش‌بینی شده با استفاده از برترین مدل‌های مورد مطالعه



شکل ۵- نمودارهای پراکنش تابش خورشیدی مشاهداتی و پیش‌بینی شده با استفاده از برترین مدل‌های مورد مطالعه



شکل ۶- دیاگرام تیلور تابش خورشیدی مشاهداتی و پیش‌بینی شده با استفاده از دو سناریو برتر هر ایستگاه

با توجه به نمودارهای تغییرات زمانی مقادیر تابش خورشیدی مشاهداتی و پیش‌بینی شده با استفاده از روش‌های مورد مطالعه (شکل ۴)، روند اشاره شده در مورد مدل‌های برتر نیز قابل نتیجه‌گیری است. با توجه به شکل ۴ در ایستگاه اردبیل مدل‌های MLP-III، MLP-VI، MLP-VIII و GA-MLP-III، GA-MLP-V و GA-MLP-VIII برترین مدل‌ها بودند. در ایستگاه بيله سوار مدل‌های MLP-VI و MLP-VIII کمترین خطا را در هر روش با داده‌های مشاهداتی نشان دادند و مدل‌های GA-MLP نیز هرچند باعث افزایش خطای مدل‌های MLP شدند ولی در بین مدل‌های GA-MLP، مدل برترین مدل شناخته شد. در ایستگاه سرعین همگی مدل‌ها دقت مناسبی از خود نشان ندادند ولی در مقایسه مدل‌ها، چهار مدل MLP-III، MLP-VI، MLP-VIII و GA-MLP-III دقت بالاتری نسبت به سایر مدل‌ها داشتند. در ایستگاه گرمی مدل‌های MLP-II و MLP-IV خطای کمتری نسبت به سایر مدل‌های این ایستگاه داشتند و در ایستگاه مشگین شهر نیز مدل‌های MLP-V و MLP-VIII در بین مدل‌های MLP برآورد نزدیک‌تری را به مقادیر مشاهداتی داشتند و در روش GA-MLP نیز مدل GA-MLP-V جزو مدل‌های دقیق در ایستگاه مشگین شهر بود. همچنین برای شهر نیر مدل‌های MLP-VI و MLP-VIII تطابق بیشتری را با داده‌های مشاهداتی نشان دادند و برترین مدل‌ها در این شهر شناخته شدند. همچنین شکل ۵ نشان می‌دهد که مدل‌های برتر مذکور در هر ایستگاه، با کمترین خطا، دارای پراکنش کمتری حول محور نیم‌ساز هستند و دقت مناسبی در سطح معنی داری ۹۵٪ داشته‌اند. همچنین، دیاگرام تیلور به منظور بررسی و تحلیل مقادیر انحراف معیار، ضریب همبستگی و جذر میانگین مربعات خطا بین داده‌های مشاهداتی و پیش‌بینی شده توسط دو سناریو برتر روش‌های MLP و GA-MLP در هر ایستگاه رسم گردید (شکل ۶). لازم به ذکر است که در دیاگرام تیلور، فاصله شعاعی از نقطه مشاهداتی سبز رنگ، نشان‌دهنده مقدار جذر میانگین مربعات خطای روش‌های مورد مطالعه می‌باشد.

همانطوری که از شکل ۶ مشاهده می‌گردد، مدل GA-MLP-III در ایستگاه‌های اردبیل و سرعین (نقطه آبی) و مدل MLP-VIII در ایستگاه بيله سوار (نقطه قرمز رنگ)، فاصله شعاعی کمتری با داده‌های مشاهداتی (نقطه سبز رنگ) داشته و بنابراین، دقت بالاتری را در تخمین تابش خورشیدی داشته‌اند.

نتیجه گیری

منبع اصلی انرژی کره زمین تابش خورشیدی است که یکی از پرکاربردترین عوامل در مطالعات کشاورزی، هواشناسی، بیلان انرژی در هیدرولوژی، طراحی نیروگاه‌های انرژی خورشیدی و غیره می‌باشد. بنابراین در تحقیق حاضر مقادیر تابش خورشیدی شش ایستگاه هواشناسی استان اردبیل شامل ایستگاه‌های اردبیل، بيله‌سوار، سرعین، گرمی، مشگین شهر و نیر در مقیاس روزانه مدل‌سازی شد. داده‌های استفاده شده در این مطالعه شامل بیشینه، کمینه و میانگین دما، رطوبت نسبی و سرعت باد ایستگاه‌های مورد مطالعه در بازه زمانی دو ساله (۲۰۱۷-۲۰۱۸) بوده که در هشت ترکیب متفاوت به‌عنوان ورودی مدل‌ها مورد استفاده قرار گرفتند. روش‌های مورد استفاده برای ساختن مدل‌ها شامل تکنیک‌های شبکه عصبی مصنوعی و شبکه عصبی مصنوعی-الگوریتم ژنتیک بوده که از الگوریتم ژنتیک برای بهینه‌سازی نتایج مدل‌های روش شبکه عصبی مصنوعی استفاده شد. در نهایت، بررسی کلی نتایج به دست آمده نشان داد که در روش MLP، مدل‌های ایستگاه بيله سوار دقیق‌ترین نتایج را ارائه دادند و در رتبه نخست قرار گرفتند و مدل‌های ایستگاه مشگین شهر و اردبیل نیز در جایگاه‌های دوم و سوم قرار گرفتند. در روش GA-MLP نیز مدل‌های ایستگاه اردبیل، بيله‌سوار و نیر به ترتیب رتبه‌های اول تا سوم را به خود اختصاص دادند. الگوریتم ژنتیک نیز توانست نتایج اکثر مدل‌های ایستگاه‌های اردبیل و سرعین را بهبود بخشد و نتایج مناسب‌تری را ارائه دهد. همچنین مدل MLP-VIII در ایستگاه بيله‌سوار با استفاده از همه پارامترها به‌عنوان داده‌های ورودی و با دارا بودن ضریب همبستگی ۰/۸۵۶، جذر میانگین مربعات خطای ۰/۳۱۹ (مگاژول بر متر مربع در روز)، راندمان کلینگ-گاپتا ۰/۶۵۹ و شاخص ویلموت ۰/۸۹۳ بهترین عملکرد را به ثبت رساند و به‌عنوان برترین مدل در این مطالعه شناخته شد.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

REFERENCES

- Agbulut, U., Gurel, A.E., and Bicen, Y. (2021). Prediction of daily global solar radiation using different machine learning algorithms: Evaluation and comparison. *Renewable and Sustainable Energy Reviews*. 135, 110114.
- Allen, R.G., Pereria, L.S., Raes, D., and Smith, M. (1998). Crop Evapotranspiration: Guidelines for Computing Crop Water Requirements. *FAO Irrigation and Drainage*. Paper. No. 56. 301p.
- Alsina, E. F., Bortolini, M., Gamberi, M., and Regattieri, A. (2016). Artificial neural network optimisation for monthly average daily global solar radiation prediction. *Energy Conversion and Management*. 120, 320-329.
- Azadeh, A., Maghsoudi, A., and Sohrabkhani, S. (2009). An integrated artificial neural networks approach for predicting global radiation. *Energy Conversion and Management*. 50, 1497-1505.
- Bagheri Toulabi, H., Moradi, M. H., and Bagheri Toulabi, S. (2013). A novel method for predicting the total amount of solar radiation on a horizontal surface. *Iranian Journal of Energy*. 16(2), 61-76. (In Persian).
- De Souza, J.L., Nicacio, R.L., and Lima Moura, M.A. (2005). Global solar radiation measurements in Maceio, Brazil. *Agricultural Water Management*. 30, 1203-1220.
- Feng, Y., Hao, W., Li, H., Cui, N., Gong, D., and Gao, L. (2020). Machine learning models to quantify and map daily global solar radiation and photovoltaic power. *Renewable and Sustainable Energy Reviews*. 118, 109393.
- Goldberg, D.E. (1989). Genetic Algorithms in Search, Optimization and Machine Learning. *Addison Wesley Longman Publishing Co., Inc.*
- He, C., Liu, J., Xu, F., Zhang, T., Chen, S., Sun, Z., Zheng, W., Wang, R., He, L., Feng, H., Yu, Q., He, J. (2020). Improving solar radiation estimation in China based on regional optimal combination of meteorological factors with machine learning methods. *Energy Conversion and Management*. 220, 113111.
- Holland, J.H. (1992). Genetic algorithms. *Scientific American*. 267, 66-72.
- Jiang, Y. (2009). Computation of monthly mean daily global solar radiation in China using artificial neural networks and comparison with other empirical models. *Energy*. 34, 1276-1283.
- Kaba, K., Sarıgul, M., Avci, M., and Kandırmaz, H.M. (2018). Estimation of daily global solar radiation using deep learning model. *Energy*. 162, 126-135.
- Khosravi, A., Koury, R.N.N., Machado, L., and Pabon, J.J.G. (2018). Prediction of hourly solar radiation in Abu Musa Island using machine learning algorithms. *Journal of Cleaner Production*. 176, 63-75.
- Kuan, C.M., and White, H. (1994). Artificial neural networks: An econometric perspective. *Econometric*



Reviews. 13, 1-91.

- Landeras, G., López, J.J., Kisi, O., and 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*. 62, 1-13.
- Marzo, A., Trigo-Gonzalez, M., Alonso-Montesinos, J., Martínez-Durban, M., Lopez, G., Ferrada, P., and Batlles, F.J. (2017). Daily global solar radiation estimation in desert areas using daily extreme temperatures and extraterrestrial radiation. *Renewable Energy*. 113, 303-11.
- Menhaj, M. B. (1998). Fundamentals of Neural Networks (Computational Intelligence). (Vol. 1). *Amirkabir University of Technology Press*. (In Persian).
- Mitchell, M. (1996). An introduction to Genetic Algorithms. *MIT Press*, Cambridge, MA.
- Rahimi Khub, A., Behbahani, S. M. R., and Jamshidi, M. (2009). Evaluation of two empirical methods and artificial neural network models for estimating solar radiation reaching the ground - a case study in southeast of Tehran. *Agricultural Science and Technology and Natural Resources, Soil and Water Sciences*. 50, 53-62. (In Persian).
- Ramedani, Z., Omid, M., Keyhani, A., Shamshirband, S., and Khoshnevisan, B. (2014). Potential of radial basis function based support vector regression for global solar radiation prediction. *Renewable and Sustainable Energy Reviews*. 39, 1005-1011.
- Rao, D.V.S., Premalatha, M., and Naveen, C. (2018). Analysis of different combinations of meteorological parameters in predicting the horizontal global solar radiation with ANN approach: A case study. *Renewable and Sustainable Energy Reviews*. 91, 248-258.
- Samadianfard, S., Hashemi, S., and Izadyar, M. (2018). Estimation of daily pan evaporation by using machine learning methods. *Iranian Journal of Irrigation and Drainage*. 12(4), 1004-1015. (In Persian).
- Samadianfard, S., Majnooni-Heris, A., Qasem, S.N., Kisi, O., Shamshirband, S., and Chau, K.W. (2019). Daily global solar radiation modeling using datadriven techniques and empirical equations in a semi-arid climate. *Engineering Applications of Computational Fluid Mechanics*. 13(1), 142-157.
- Taylor, K.E. 2001. Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research. Atmospheres*. 106:7183-7192.
- Yadav, A. K., and Chandel, S. S. (2014). Solar radiation prediction using Artificial Neural Network techniques: A review. *Renewable and Sustainable Energy Reviews*. 33, 772-781.
- Zamani Mohiabadi, M. (2013). Instantaneous prediction of total solar radiation in Rafsanjan city by neural network. *Iranian Journal of Energy*. 16(4), 15-32. (In Persian).