

Performance evaluation of Neural Network and Multivariate Regression Methods for Estimation of Total Solar Radiation at several stations in Arid and Semi-arid Climates

SEDIGHEH AVAZPOUR^{1,2}, BAHRAM BAKHTIARI^{2*}, KOUROSH QADERI²

1. Member of Young Researchers Society, Water Engineering Department, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran

2. Department of Water Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran

(Received: March. 11, 2019- Revised: Apr. 24, 2019- Accepted: Apr. 27, 2019)

ABSTRACT

In this study, the capability of multi-layer perceptron (MLP) and multivariate linear regression methods were evaluated to estimate the total solar radiation. For this purpose, the daily weather data of 25 years (1992-2017) including maximum temperature, mean temperature, relative humidity, sunshine hours and solar radiation were used in the five synoptic stations (Bandarabbas, Zanjan, Shiraz, Kerman and Mashhad). The inputs used in the models included various combinations of these variables, and the output was the solar radiation. To evaluate the performance of these models, Determination of Coefficient (R²), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE) and Index of Agreement (IA) were used. In order to train the structure of the ANN, two Bayesian-regularization (Br) and Levenberg-Marquardt (LM) algorithms were compared. Moreover, the training and validation processes were performed. The results of regression model showed that all the input variables are effective on the solar radiation estimation at Bandarabbas, Zanjan and Shiraz, but the effect of relative humidity on radiation at Kerman and Mashhad stations was low. The ANN application with two algorithms showed that Bandarabbas and Kerman stations using the Br algorithm and Zanjan, Shiraz and Mashhad using the LM algorithm give a good result. The lowest values of RMSE, MAE and the highest value of IA and R² related to Kerman station were 2.799, 0.94, 0.954 and 0.838, respectively. As a main result, the comparison between computation and observation data showed that the ANN model gives better results than the linear regression model for estimation of radiation.

Keywords: Forward back propagation, Solar Radiation, Radiation Modeling, Linear Correlation

بررسی کارایی روش‌های شبکه عصبی و رگرسیون چند متغیره در برآورد تابش کل خورشیدی در چند ایستگاه معرف اقلیم‌های خشک و نیمه‌خشک

صدیقه عوض‌پور^{۱،۲}، بهرام بختیاری^{۳*}، کوروش قادری^۲

۱. عضو انجمن پژوهشگران جوان، بخش مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران

۲. بخش مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران

(تاریخ دریافت: ۱۳۹۷/۱۲/۲۰ - تاریخ بازنگری: ۱۳۹۸/۲/۴ - تاریخ تصویب: ۱۳۹۸/۲/۷)

چکیده

در این مطالعه قابلیت روش‌های پرسپترون چند لایه (MLP) و رگرسیون خطی چند متغیره در برآورد شدت تابش کل خورشیدی مورد بررسی قرار گرفت. به این منظور از داده‌های روزانه ۲۵ ساله (۱۹۹۲-۲۰۱۷) شامل دمای حداکثر، میانگین دما، میانگین رطوبت نسبی، ساعات آفتابی و شدت تابش خورشیدی در پنج ایستگاه همدیدی بندرعباس، زنجان، شیراز، کرمان و مشهد استفاده شد. ورودی‌های بکار رفته در مدل‌ها شامل ترکیبات مختلفی از این متغیرها بودند. جهت بررسی عملکرد مدل‌ها از آماره‌های ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، میانگین مطلق خطا (MAE) و شاخص توافق (IA) استفاده شد. برای آموزش ساختار شبکه عصبی دو الگوریتم تنظیم بیزی (Br) و لونیگ-مارکوات (LM) مورد مقایسه قرار گرفتند. علاوه بر این، فرآیندهای آموزش و اعتبارسنجی بر روی داده‌ها انجام شد. نتایج مدل رگرسیون نشان داد که تمامی متغیرهای ورودی در ایستگاه‌های بندرعباس، زنجان و شیراز بر تابش تأثیرگذارند، اما تأثیرگذاری رطوبت نسبی بر مقدار تابش در ایستگاه‌های کرمان و مشهد اندک بود. کاربرد ANN با دو الگوریتم نشان داد که ایستگاه‌های بندرعباس و کرمان با الگوریتم Br و ایستگاه‌های زنجان، شیراز و مشهد با الگوریتم LM نتایج بهتری به دست می‌دهند. با توجه به نتایج به دست آمده، کمترین مقادیر MAE، RMSE و بیشترین مقادیر IA و R^2 مربوط به ایستگاه کرمان با اقلیم خشک سردسیر به ترتیب ۰/۲۷۹۹، ۱/۹۴، ۰/۹۵۴ و ۰/۸۳۸ می‌باشد. در یک نتیجه‌گیری کلی می‌توان گفت که کارایی مدل شبکه عصبی در برآورد تابش خورشیدی نسبت به مدل رگرسیون خطی چند متغیره در مقایسه با داده‌های مشاهداتی بهتر بوده است.

واژه‌های کلیدی: الگوریتم پس انتشار، تابش کل خورشیدی، مدل‌سازی تابش، همبستگی خطی

مقدمه

کشور به دستگاه تابش‌سنج مجهز نیستند. اما، در اغلب این ایستگاه‌ها تعداد ساعات آفتابی (n) به طور روزانه اندازه‌گیری می‌شود. در مطالعات مربوط به برآورد شدت تابش خورشید نمی‌توان تمام عناصر مؤثر را در معادلات وارد نمود؛ در نتیجه برای تخمین مقدار شدت تابش خورشید توسط معادلات تجربی و نیمه تجربی تنها از تعداد محدودی از متغیرهای اقلیمی استفاده می‌شود. در سال‌های اخیر پژوهشگران مطالعات خود را بر مبنای استفاده از روش‌های داده‌محور، محاسبات نرم و مشتقات روش‌های شبکه عصبی مصنوعی (ANN)^۲ در برآورد متغیرهای هواشناسی معطوف داشته‌اند. نتایج این مطالعات نشان داده است که استفاده از این روش‌ها دارای مزایا و معایبی می‌باشد. مهم‌ترین مزیت ANN تشریح و آشکارسازی روابط پیچیده، حساس نبودن شبکه به وجود خطا در آمار و اطلاعات در ANN دسترس، مقاوم بودن،

شدت تابش خورشیدی (R_s) یکی از مهم‌ترین متغیرهای هواشناسی مؤثر در برآورد تبخیر تعرق و نیاز آبی گیاهان محسوب می‌شود و منشأ انرژی برای تمامی تحولاتی است که در جو و سطح زمین صورت می‌گیرند. این متغیر در معادلات ترکیبی، تعیین نیاز آبی گیاهان به ویژه دسته معادلات پنمن مانیتث به صورت جزء تابش ظاهر می‌شود (Allen, 1998). از سوی دیگر شدت تابش خورشید در معادلات تجربی برآورد تبخیر تعرق که مبتنی بر تابش بوده (نظیر معادله‌های ماکینگ، جنسن-هیز و تورک) کاربرد وسیعی دارد (Makkink, 1957; Jensen and Haise, 1963; Turc, 1961). اندازه‌گیری شدت تابش خورشید، اگرچه در ایران دارای سابقه نسبتاً طولانی است ولی به دلیل هزینه بالای وسایل اندازه‌گیری، بسیاری از ایستگاه‌های موجود در

معادلات تجربی نتایج بهتری به دست می‌دهند (Ghabaei Sough et al., 2012). از طرفی نتایج بسیاری از تحقیقات در سایر نقاط دنیا نشان داده است که روش ANN نسبت به مدل‌های تجربی عملکرد بهتری داشته‌اند. به طور مثال در عربستان سعودی شش مدل مبتنی بر ANN برای برآورد تابش خورشیدی ارزیابی شد. ترکیب مختلفی از متغیرهای ورودی استفاده گردید و نتایج نشان داد که دقت مدل بستگی به مدت زمان تابش و دمای هوا دارد (Benghanem et al., 2009). در کشور هندوستان نیز مدل ANN مبتنی بر پرسپترون چندلایه (MLP)^۴ برای مدل‌سازی شدت تابش خورشیدی استفاده شد و بهترین مدل با شاخص آماری MAPE برابر ۶/۸۹٪ گزارش شد (Yadav et al., 2014; Yadav and Chandel, 2015). مقایسه روش‌های مبتنی بر ANN و رگرسیون خطی در برآورد شدت تابش خورشیدی نیز در کشور-هایی نظیر آرژانتین (Jimenez et al., 2016)، مراکش (Nait Mensour et al., 2017) و مالزی (Olalekan et al., 2018) گویای برتری عملکرد روش ANN در این مناطق بود.

از یک سو با توجه به اینکه در بسیاری از ایستگاه‌های هواشناسی، امکان اندازه‌گیری دقیق شدت تابش خورشید وجود ندارد و از سوی دیگر لازم است تا متغیرهای هواشناسی کمتری در معادلات مورد استفاده قرار گیرد، لذا ضروری است تا روابط غیرخطی موجود بین متغیرهای هواشناسی مؤثر بر شدت تابش خورشیدی بررسی شود. از آنجایی که پیشینه تحقیقات در ایران نشان داد که بیشتر پژوهش‌ها مبتنی بر استفاده از مدل‌های تجربی می‌باشند و نظر به کم بودن تعداد ایستگاه‌های تابش‌سنجی در ایران ضروری است که کارایی روش‌های محاسبات نرم در برآورد شدت تابش خورشیدی ارزیابی شود. به عبارت دیگر لزوم استفاده از روش‌های برآورد شدت تابش خورشید از یک طرف و محدودیت روش‌های موجود به علت نیاز به داده‌های وسیع از طرف دیگر، لزوم استفاده از روش‌های محاسبات نرم را نشان می‌دهد. در این مطالعه تلاش گردید تا دقت روش‌های رگرسیون چند متغیره و ANN جهت برآورد R_s با یکدیگر مقایسه شوند. موارد زیر به طور خاص جهت نوآوری این مطالعه مورد توجه قرار گرفته است: الف) در زمینه کاربرد محاسبات نرم در مبحث تابش خورشیدی تا کنون مقایسه‌ای بین الگوریتم‌های آموزش مختلف و انتخاب مناسب‌ترین آن‌ها در ایستگاه‌های مختلف در ایران به انجام نرسیده است. ب) همچنین در مقالات بسیار اندکی (Izadifar and Elshorbagy, 2010) تأثیر تعداد نرون‌های لایه پنهان در عملکرد شبکه مورد بررسی قرار گرفته که در این مقاله

پردازش موازی و حافظه گسترده می‌باشد. همچنین ANN به دلیل پردازش‌های موازی، از سرعت پردازش بالایی برخوردار است (Jang and roger, 2003; AL-Fatlawi et al, 2015). با وجود برتری‌هایی که شبکه‌های عصبی نسبت به روش‌های تجربی و نیمه تجربی دارند، معایبی نیز دارند از جمله دقت نتایج بستگی زیادی به اندازه مجموعه آموزش دارد. آموزش شبکه ممکن است مشکل و یا حتی غیر ممکن باشد (yan et al., 2014). در ایران مطالعاتی درباره کاربرد مدل‌های تجربی و مدل‌های هوش مصنوعی و به خصوص ANN برای تخمین دقیق‌تر شدت تابش خورشید در برخی از ایستگاه‌های منطبق بر این پژوهش صورت گرفته است. در مطالعه‌ای متشکل از شش ایستگاه سینوپتیک در ایران برخی از روش‌های تجربی برآورد شدت تابش خورشید مورد بررسی قرار گرفت. نتایج حاکی از عملکرد بهتر مدل ریچاردسون در ایستگاه‌های کرمان و زنجان بود (Ghahreman and Bakhtiari, 2009). در کرج و شیراز برای تخمین شدت تابش کل خورشیدی روزانه از دو روش ANN و مدل‌های رگرسیون با در نظر گرفتن متغیرهای هواشناسی استفاده شد. نتایج نشان داد که دقت روش ANN نسبت به مدل‌های رگرسیونی بیشتر بوده است (Bayat and Mirlatifi, 2010). در کرمان برای پیش‌بینی میانگین مقدار کل تابش خورشید روزانه از یک رابطه رگرسیون خطی با تأثیر دادن هفت پارامتر جغرافیایی و هواشناسی استفاده گردید و نتایج، دقت شبکه عصبی را نسبت به روابط رگرسیونی نشان داد (Saffaripour and Mehrabian, 2010). مطالعاتی نیز بر مبنای داده‌های تابش‌سنجی ایستگاه سینوپتیک تهران به انجام رسیده است. در این ایستگاه در مقیاس‌های زمانی مختلف، تأثیر متغیر-های هواشناسی بر مقادیر روزانه تابش کل دریافتی از خورشید در سطح زمین مورد بررسی قرار گرفت. رابطه آنگستروم به عنوان مناسب‌ترین مدل برگزیده شد (Agha Shariatmadari et al., 2012). همچنین براساس آمار همین ایستگاه و با استفاده از روش‌های ANN، مقدار شدت تابش خورشید پیش‌بینی گردید. نتایج نشان داد شبکه عصبی توانایی پیش‌بینی مناسبی در برآورد تابش در این ناحیه دارد (Ramedani et al., 2013). در مطالعه‌ای دیگر برای تخمین شدت تابش خورشید روزانه از روش‌های ANN استفاده شد و در این راستا از سه الگوریتم آموزشی لوبنبرگ-مارکوارت (LM)^۱، الگوریتم کاهشی شیب مقیاس شده (SCG)^۲ و رگرسیون خطی محلی (LLR)^۳ و هشت معادله تجربی واسنجی‌شده مبتنی بر متغیرهای هواشناسی استفاده گردید. نتایج نشان داد که الگوریتم‌های مبتنی بر ANN نسبت به

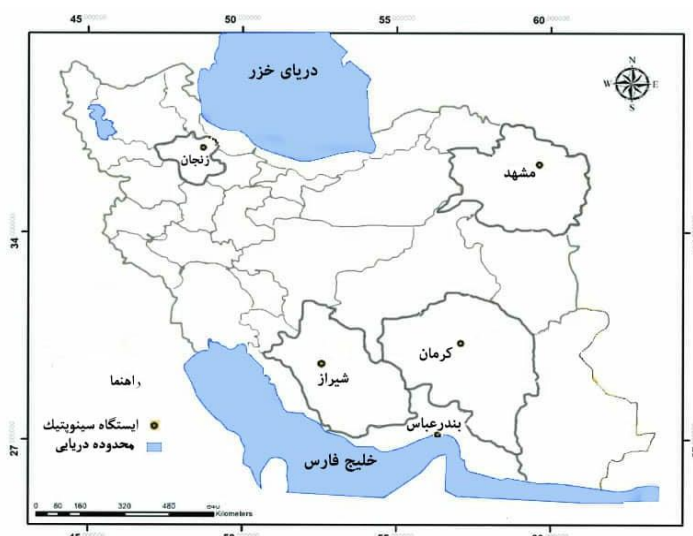
سنجی روش‌های ANN در برآورد R_s در ایستگاه‌های مورد مطالعه.

مواد و روش‌ها

داده‌ها و مناطق مورد مطالعه

در این مطالعه، پنج ایستگاه همدیدی کرمان، بندرعباس، مشهد، شیراز و زنجان به عنوان چند نمونه اقلیمی مختلف انتخاب شدند (شکل ۱). انتخاب این اقلیم‌ها براساس طبقه‌بندی اقلیمی دومارتن گسترش یافته از اقلیم خشک سردسیر تا اقلیم نیمه‌خشک معتدل بوده است (Rahimi et al., 2013). در جدول (۱) ویژگی‌های جغرافیایی و اقلیمی ایستگاه‌های مورد مطالعه آورده شده است. داده‌های مورد استفاده در این مطالعه، متغیرهای T_{max} ، T_{mean} ، RH_{mean} و n به عنوان ورودی و R_s به عنوان خروجی مدل‌ها، در مقیاس زمانی روزانه از ایستگاه‌های مطالعاتی طی دوره آماری ۲۰۱۷-۱۹۹۲ (۲۵ سال) از سازمان هواشناسی کشور (۱۳۹۶، IRIMO) اخذ گردیدند. جدول (۲) میانگین‌های اقلیمی متغیرهای مورد استفاده طی این دوره آماری را نشان می‌دهد. همچنین سری زمانی داده‌های روزانه مشاهداتی در ایستگاه‌های مورد مطالعه در شکل (۲) نشان داده شده است.

این موضوع نیز مورد توجه قرار گرفت. اساساً، انتخاب مناسب و قابل توجه متغیرهای ورودی برای ارزیابی R_s به منظور دقت بیشتر و کمبود پیچیدگی در مدل از اهمیت زیادی برخوردار است. لذا سعی شد که ارزیابی شدت تابش خورشید، با استفاده از کمترین متغیرهای ورودی قابل اندازه‌گیری صورت گیرد. علت این عمل، یکی جلوگیری از وارد شدن مجموع خطاهای ناشی از ابزار اندازه‌گیری متغیرهای ورودی است که در ارزیابی شدت تابش خورشید استفاده می‌گردند و دیگری افزایش سرعت عملکرد شبکه در مراحل آموزش و یادگیری است. جهت دستیابی به این هدف، اهداف زیر در این مطالعه دنبال می‌شوند: (۱) ارائه رابطه رگرسیون خطی چند متغیره بین شدت تابش خورشیدی به عنوان متغیر وابسته و سایر متغیرهای هواشناسی به عنوان متغیرهای مستقل و تعیین ضرایب معادله برای ایستگاه‌های همدیدی مورد مطالعه، (۲) بررسی تأثیر متغیرهای ورودی حداکثر دمای هوا (T_{max})، میانگین دمای هوا (T_{mean})، میانگین رطوبت نسبی (RH_{mean}) و ساعات آفتابی (n) در مدل‌سازی شدت تابش خورشید براساس روش ANN، (۳) انتخاب ساختار مناسب شبکه ANN براساس ترکیبات مختلف متغیرهای ورودی، (۴) واسنجی و صحت



شکل ۱. موقعیت جغرافیایی ایستگاه‌های مورد مطالعه بر نقشه ایران

جدول ۱. مشخصات جغرافیایی و اقلیمی ایستگاه‌های همدیدی مورد مطالعه طی سال‌های ۲۰۱۷-۱۹۹۲

ایستگاه	طول جغرافیایی (°E)	عرض جغرافیایی (°N)	ارتفاع از سطح دریا (m)	میانگین دمای سالانه (°C)	میانگین تابش کل خورشیدی ($MJ m^{-2} d^{-1}$)	اقلیم
کرمان	۵۷/۰۸	۳۰/۲۸	۱۷۵۳	۱۵/۸	۲۱/۴	خشک سردسیر
بندرعباس	۵۶/۲۷	۲۷/۱۸	۹/۸	۲۶/۵	۱۹/۳	خشک گرمسیر
زنجان	۴۸/۵۰	۳۶/۶۸	۱۶۳۸	۹/۵	۱۵/۷	نیمه‌خشک فراسرد
مشهد	۵۹/۵۷	۳۶/۳۰	۱۰۵۰	۱۵/۷	۱۷/۹	نیمه‌خشک سردسیر
شیراز	۵۲/۵۴	۲۹/۶۱	۱۴۸۰	۱۸	۲۰/۵	نیمه‌خشک معتدل

جدول ۲. میانگین متغیرهای هواشناسی مورد استفاده در ایستگاه های همدیدی مطالعاتی

ایستگاه	متغیر	بیشینه	کمینه	میانگین	انحراف معیار
بندرعباس	T _{max} (°C)	۴۷/۶	۱۲/۸	۲۳/۴	۵/۹
	T _{mean} (°C)	۳۹/۶	۱۰/۶	۲۷/۲	۶/۲
	RH _{mean} (%)	۹۸/۵	۴/۵	۶۳/۰	۱۲/۲
	n (h)	۱۲/۴	۰/۰	۸/۷	۲/۴
	R _S (MJ m ⁻² d ⁻¹)	۳۹/۹	۱/۰	۱۹/۳	۵/۸
زنجان	T _{ma} (°C)	۴۰/۵	-۱۱/۲	۱۸/۸	۱۰/۶
	T _{mea} (°C)	۳۰/۵	-۱۸/۶	۱۱/۴	۹/۴
	RH _{mean} (%)	۹۵/۵	۱۶	۵۴/۳	۱۴/۷
	n (h)	۱۳/۹	۰	۸/۰	۳/۷
	R _S (MJ m ⁻² d ⁻¹)	۳۸/۵۹	۱	۱۵/۷	۸/۶
شیراز	T _{ma} (°C)	۴۲/۴	۳/۴	۲۶/۷	۹/۳
	T _{mea} (°C)	۳۴/۷	-۱/۱	۱۹/۱	۸/۹
	RH _{mean} (%)	۹۸	۹/۵	۳۸/۹	۱۶/۳
	n (h)	۱۳/۳	۰	۹/۲	۲/۸
	R _S (MJ m ⁻² d ⁻¹)	۳۹/۵۴	۱/۳	۲۰/۵	۶/۵
کرمان	T _{ma} (°C)	۴۲	-۴/۰	۲۵/۹	۸/۸
	T _{mea} (°C)	۳۳/۴	-۹/۳	۱۷/۳	۸/۷
	RH _{mean} (%)	۹۸/۰	۶/۵	۳۳/۰	۱۷/۱
	n (h)	۱۳/۵	۰/۰	۹/۳	۳/۰
	R _S (MJ m ⁻² d ⁻¹)	۳۹/۴	۱/۴	۲۱/۴	۶/۹
مشهد	T _{max} (°C)	۴۳/۴	-۱۰/۴	۲۲/۶	۱۰/۵
	T _{mea} (°C)	۳۴/۷	-۱۴/۶	۱۵/۷	۹/۸
	RH _{mean} (%)	۱۰۰	۱۰	۴۹/۶	۲۰/۷
	n (h)	۱۴	۰	۸/۲	۳/۹
	R _S (MJ m ⁻² d ⁻¹)	۳۹/۹	۱/۰	۱۷/۹	۷/۹

کار گرفته شد. این نرم افزار امکان طراحی، ساخت، یادگیری و ارزیابی شبکه های عصبی مصنوعی را در اختیار می دهد و در برگیرنده شبکه های متفاوت با قوانین یادگیری مختلف می باشد. قبل از انجام مدل ANN به علت اینکه متغیرهای نامبرده در برآورد R_S ابعاد مختلفی و دامنه تغییرات متفاوتی دارند، عمل نرمال سازی بر روی داده های خام انجام گرفته تا سرعت آزمایش و دقت شبکه افزایش یابد. به این منظور داده ها با استفاده از رابطه (۱) نرمال می شوند. داده ها در مجموعه جدیدی تبدیل می شوند که در آن همه مقادیر بین ۰/۱ و ۰/۹ هستند (DehghaniSanij et al., 2004).

$$X_i = 0.8 \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) + 0.1 \quad (\text{رابطه ۱})$$

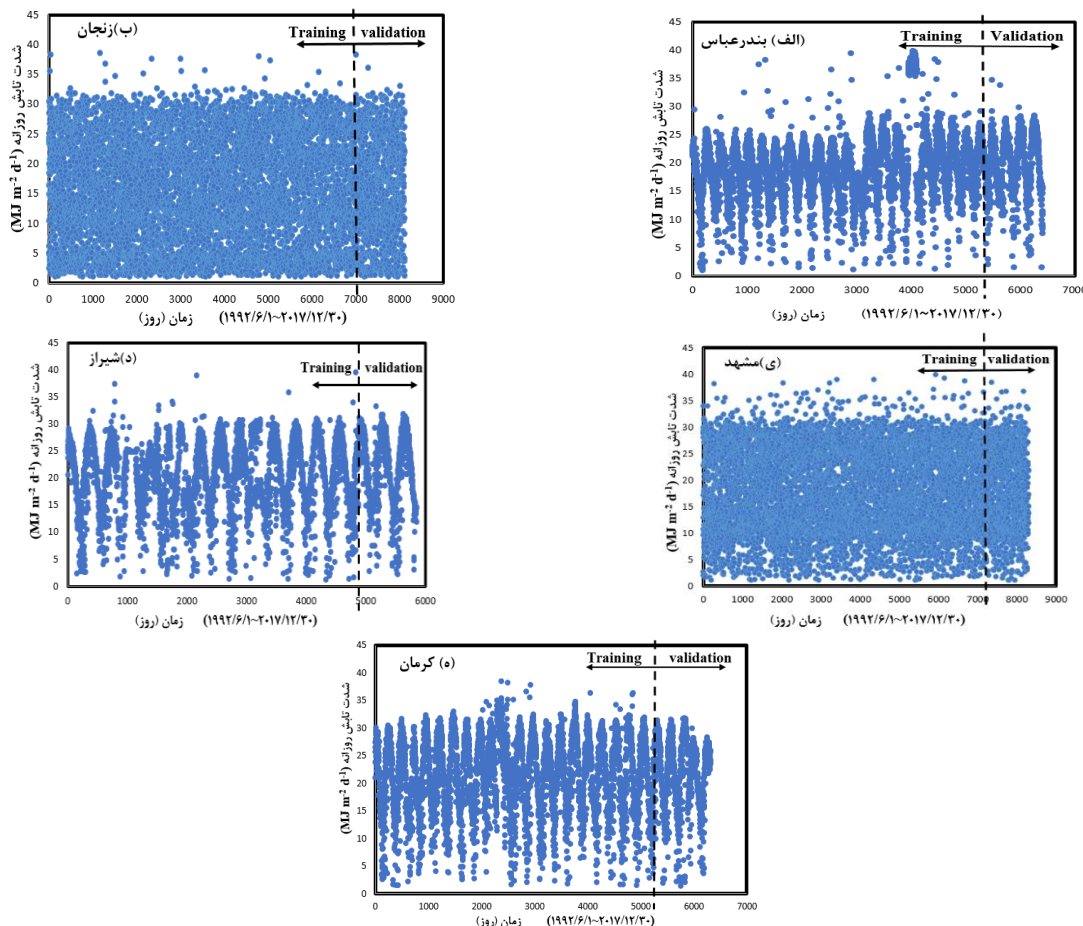
که در آن X_i مقدار نرمال شده، X مقدار هر یک از داده ها، X_{min} کمترین مقدار داده ها و X_{max} بیشترین مقدار داده ها است. برای انجام مراحل آموزش و اعتبارسنجی مدل، داده ها به دو قسمت تقسیم شدند. سری داده ها از تاریخ ۱۹۹۲/۶/۱ تا ۲۰۱۴/۹/۲۳ برای مرحله آموزش و از تاریخ ۲۰۱۴/۹/۲۴ تا ۲۰۱۷/۱۲/۳۰ برای مرحله اعتبارسنجی مورد استفاده قرار

نایبوستگی و عدم کیفیت داده ها مسئله ای است که ممکن است در طی یک دوره در سری زمانی داده های مورد استفاده وجود داشته باشد. لذا به منظور کنترل کیفیت داده های اندازه گیری شده، از الگوریتم کنترل کیفیت ارائه شده توسط Moradi (2009) استفاده شد. براساس الگوریتم ارائه شده، داده های R_S با سه شرط مقایسه گردیدند و تنها داده هایی که در هر سه مرحله صحت آنها تأیید گردید برای مدل سازی و ادامه کار انتخاب شدند. با توجه به عملکرد کنترل کیفیت داده ها در ایستگاه های مورد مطالعه، تعداد ۶/۸٪ داده ها در ایستگاه بندرعباس، ۱۷/۳۹٪ در ایستگاه زنجان، ۸/۱۸٪ در ایستگاه شیراز، ۱۹/۶٪ در ایستگاه مشهد و ۲۸/۶۳٪ در کرمان حذف شدند.

به منظور تحلیل مدل های رگرسیون خطی از نرم افزارهای SPSS (version 24) و Excel (versio 16) در این مطالعه استفاده شد. همچنین برای مدل سازی شدت تابش خورشید با استفاده از ANN از دو الگوریتم آموزش تنظیم بیزی (Br) و لوبنرگ مارکوات (LM) استفاده شد. برای اعمال این عملکردها بر روی مدل، نرم افزار (Matlab (version 9.3.0.713579, R2017b) به

می‌باشد، در این مطالعه از ۱۵ ترکیب مختلف متغیرهای ورودی برای برآورد R_s استفاده شد (جدول ۳). این ترکیبات شامل مدل‌های M_1 تا M_4 به صورت تک متغیره، مدل‌های M_5 تا M_{10} به صورت دومتغیره و مدل‌های M_{11} تا M_{14} به صورت سه متغیره و M_{15} به صورت چهار متغیره می‌باشد.

گرفتند. کل داده‌های ورودی برای ایستگاه کرمان، بندرعباس، زنجان، شیراز و مشهد به ترتیب برابر با ۶۰۷۵، ۸۵۲۷، ۶۷۱۴، ۵۱۵۱، ۶۶۶۸ بود که ۷۵٪ داده‌ها در مرحله آموزش و ۲۵٪ در مرحله اعتبارسنجی مورد استفاده قرار گرفت. برای انجام مدل‌سازی در ANN نیاز به ورودی‌های مناسب



شکل ۲. سری زمانی داده‌های خام شدت تابش روزانه مشاهداتی ($MJ m^{-2} d^{-1}$) در ایستگاه‌های مطالعاتی


مدل‌سازی تابش خورشیدی با استفاده از روش‌های شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری و با استفاده از پردازشگرهای ساده به نام نرون تلاش می‌کند با شناخت روابط ذاتی میان داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. در شبکه‌های عصبی مصنوعی سعی بر این است که ساختار بیولوژیکی مغز انسان و شبکه بدن طراحی شود تا همانند آن قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد. متغیرهای زیادی در یک مدل ANN، از جمله ورودی، تعداد لایه‌ها و نرون‌ها، الگوریتم آموزش، عملکرد انتقال وجود دارد. هرگونه تغییر در آن‌ها می‌تواند یک مدل ANN جدید ایجاد کند. بنابراین لازم است قوانین مناسب برای مقایسه مدل‌های ANN

جدول ۳. ترکیب‌های مختلف مدل‌های مورد استفاده در روش شبکه عصبی

خروجی	مصنوعی	
	ساختار ورودی	علامت اختصاری مدل
R_s	T_{max}	M1
R_s	T_{mean}	M2
R_s	RH_{mean}	M3
R_s	n	M4
R_s	n, RH_{mean}	M5
R_s	n, T_{mean}	M6
R_s	n, T_{max}	M7
R_s	T_{max}, T_{mean}	M8
R_s	T_{max}, RH_{mean}	M9
R_s	T_{mean}, RH_{mean}	M10
R_s	$T_{max}, T_{mean}, RH_{mean}$	M11
R_s	T_{max}, n, RH_{mean}	M12
R_s	T_{mean}, RH_{mean}, n	M13
R_s	T_{max}, T_{mean}, n	M14
R_s	$RH_{mean}, T_{max}, T_{mean}, n$	M15

(Nielsen, 1987). شبکه FFBP دارای یک لایه ورودی، یک یا چند لایه مخفی و یک لایه خروجی است (شکل ۳). پارامترهای ورودی در لایه اول و پارامتر خروجی (هدف) در لایه سوم قرار می گیرند. یک ساختار شبکه ای از تعدادی عناصر مرتبط به هم به نام نرون تشکیل شده است که هر نرون دارای ورودی ها و خروجی هایی است و یک عمل نسبتاً ساده و محلی^۲ را انجام می دهد. ANN عموماً عملکرد خود را طی یک مرحله یادگیری^۳ فرا می گیرد.



شکل ۳. معماری یک شبکه عصبی مصنوعی (ANN) جهت برآورد شدت تابش خورشید با توجه به متغیرهای ورودی هواشناسی

مدل سازی تابش خورشیدی با استفاده از رگرسیون خطی چند متغیره

تحلیل رگرسیونی، پرکاربردترین روش در بین تکنیک های آماری است که برای بررسی و مدل سازی ارتباط بین متغیرها به کار می رود. رگرسیون چند متغیره خطی روشی است برای تحلیل مشارکت جمعی و فردی دو یا چند متغیر مستقل در تغییرات یک متغیر وابسته است. بنابراین تحلیل رگرسیونی با به دست آوردن یک مدل در پیش بینی متغیرهای وابسته مختلف از جمله پارامترهای اقلیمی و هیدرولوژیکی، نقش بارزی ایفا می کند (Tabari et al., 2013). کاربرد مدل های رگرسیونی برای برآورد متغیرهای مختلف توسط پژوهشگران بسیاری مورد استفاده قرار گرفته است (Razi and Athappilly, 2005; Yang et al., 2003). از آنجایی که این روش ها به خوبی می توانند تأثیر یک متغیر مستقل را بر متغیر وابسته نشان دهند، سعی گردید با استفاده از معادله رگرسیونی چند متغیره نیز، ارتباط بین تابش خورشیدی با متغیرهای هواشناسی در هر ایستگاه مورد بررسی قرار گیرد. رگرسیون، یک معادله را که فاصله بین خط برازش شده و همه نقاط داده شده را به حداقل برساند، ارائه می کند. معادله کلی رگرسیون چند متغیره به صورت رابطه (۴) بیان می شود.

$$R_s = C_1(T_{mean}) + C_2(T_{max}) + C_3(RH_{mean}) + C_4(n) + C_5 \quad (\text{رابطه ۴})$$

که در آن، R_s شدت تابش خورشید ($MJ \ m^{-2} \ d^{-1}$)، T_{mean}

مورد نیاز باشد. اولین چیزی که باید در نظر گرفت خروجی یک مدل ANN است. مورد دوم که باید در نظر گرفته شود، ورودی یک مدل ANN است. پارامتر ورودی بیشتر بدان معنی است که مدل نیاز به پیش نیازهای بیشتری برای اجرا دارد. از لحاظ تطابق، یک مدل ANN معمولاً شامل لایه ورودی، لایه پنهان و لایه خروجی است. اندازه یک لایه پنهان عموماً به طور تجربی به دست می آید. برای یک شبکه عصبی با اندازه معقول تعداد نرون های مخفی با یک نسبت کوچکی از تعداد ورودی ها انتخاب می گردد. اگر شبکه به جواب مطلوب همگرا نگردد تعداد نرون های لایه مخفی را افزایش می دهند و اگر شبکه همگرا گردید و از قدرت تعمیم خوبی هم برخوردار بود در صورت امکان تعداد نرون های مخفی کمتری را مورد آزمایش قرار می دهند (Menhaj, 2006). روند عملکرد عمدتاً شامل دو مرحله آموزش و آزمون می باشد. در بخش آموزش، ANN اطلاعات یادگیری و ذخیره می سازی پایگاه داده موجود را ذخیره می کند. در بخش آزمون، ANN اطلاعاتی را برای تولید داده های خروجی براساس پایگاه داده ورودی فرامی خواند. واحدهای محاسبه ANN، نرون ها را در لایه ها متصل می کنند. محاسبات نرون به زبان ریاضی در روابط (۲) و (۳) بیان می شود.

$$y = g\left(\sum_{i=1}^n W_i X_i\right) \quad (\text{رابطه ۲})$$

که در آن، X_i متغیر ورودی، W_i وزن X_i است، $g(\cdot)$ تابع انتقال می باشد. تابع انتقال می تواند خطی، سیگموئید و هایپربولیک باشد.

$$y = f(X, W) \quad (\text{رابطه ۳})$$

که در آن، X نشان دهنده بردار ورودی، Y نشان دهنده بردار خروجی، W نشان دهنده بردار وزن های اتصال و $f(\cdot)$ نشان دهنده رابطه عملکردی بردار ورودی و بردار خروجی است. در مرحله آموزش، با پایگاه داده موجود، ANN برای تنظیم وزن ها در نظم و کاهش اختلاف ورودی و مشاهدات ادامه می دهد. سپس وزن های تعیین شده را می توان برای برآورد با ورودی های جدید استفاده کرد. در ANN که برای برآورد تابش خورشیدی طراحی شده است، ورودی ها معمولاً متغیرهای هواشناسی و جغرافیایی هستند. در حالی که خروجی ها مقادیر تابش خورشیدی در زمان های مختلف است. پژوهش های صورت گرفته نشان می دهد که MLP پیش خور با قانون یادگیری پس انتشار خطا^۱ (FFBP)، ساده ترین و پرکاربردترین نوع شبکه عصبی است که در خصوص تخمین پارامترهای مجهول مناسب ارزیابی شده است (Hecht-

شده برای محاسبه خطای پیش‌بینی مدل است که مقدار آن بین صفر و یک می‌باشد. مقدار یک بیانگر بیشترین توافق و صفر نشان‌دهنده عدم وجود توافق است. این شاخص نیز به دلیل استفاده از مربع اختلافات به شدت به مقادیر حدی حساس است (Willmott, 1982).

نتایج و بحث

نتایج آزمون رگرسیون گام به گام پیش‌رونده جهت انتخاب متغیرهای مناسب ورودی به مدل

برای شناخت مهم‌ترین متغیرهای هواشناسی مؤثر بر مقدار شدت تابش خورشیدی، مقدار ضریب همبستگی بین شدت تابش خورشیدی با هر یک از متغیرهای هواشناسی به تفکیک ایستگاه‌های بندرعباس، زنجان، شیراز، کرمان و مشهد محاسبه شد. به منظور ارزیابی میزان همبستگی بین متغیرها از ضریب همبستگی پیرسون استفاده شد. ضریب همبستگی پیرسون رایج‌ترین همبستگی مورد استفاده است. این ضریب میزان همبستگی بین دو متغیر تصادفی را می‌سنجد. مقدار این همبستگی بین ۱- تا ۱ تغییر می‌کند که مقدار ۱ به معنای همبستگی کامل مثبت یا مستقیم، صفر به معنای عدم همبستگی و ۱- به معنای همبستگی کامل منفی یا معکوس است.

بسته به تعداد داده‌های آماری و درجه آزادی معمولاً همبستگی بالای ۰/۶، همبستگی معنی‌دار بین پدیده‌های طبیعی محسوب می‌شوند. با توجه به همبستگی بالای داده‌های تابش خورشیدی با ساعات آفتابی در ایستگاه کرمان و با حداکثر دما در ایستگاه بندرعباس و با میانگین دما در ایستگاه‌های شیراز، مشهد و زنجان از متغیرهای هواشناسی دیگر به عنوان متغیرهای کمکی جهت آموزش شبکه عصبی استفاده شد. میزان ارتباط بین این متغیرها با استفاده از نتایج به دست آمده از آزمون پیرسون نشانگر ارتباط معنی‌دار بین متغیرها در سطح اطمینان ۹۹ درصد می‌باشد. به عنوان نمونه میزان همبستگی بین متغیرهای هواشناسی و تابش خورشیدی در دو ایستگاه کرمان و بندرعباس در جدول‌های (۴ و ۵) ارائه شده است.

میانگین دما T_{max} ($^{\circ}C$)، حداکثر دما RH_{mean} ($^{\circ}C$)، میانگین رطوبت نسبی (%)، n ساعات آفتابی (hr) و C_1 ، C_2 ، C_3 ، C_4 و C_5 پارامترهای مدل هستند.

معیارهای ارزیابی عملکرد مدل‌ها

تناسب مقادیر حاصل از یک مدل با مقادیر مشاهده شده (که از آن با عنوان ارزیابی یا اعتبارسنجی مدل یاد می‌شود)، معمولاً توسط مقایسه‌های دوگانه بین مقادیر شبیه‌سازی شده با مقادیر مشاهده شده صورت می‌گیرد. شاخص‌های مختلفی برای کارایی مدل‌ها و اعتبارسنجی آن‌ها وجود دارد که می‌توان از معیارهای ضریب تعیین (R^2)^۱، مجذور میانگین مربعات خطا (RMSE)^۲، میانگین مطلق خطا (MAE)^۳ و شاخص توافق (IA)^۴ نام برد. R^2 نشان‌دهنده این است که چه مقدار از تغییرات متغیر وابسته تحت تأثیر متغیر مستقل مربوطه بوده و مابقی تغییرات متغیر وابسته، مربوط به سایر عوامل می‌باشد. این شاخص اگرچه دارای محدودیت‌هایی در زمینه بیان عملکرد مدل می‌باشد اما درجه همبستگی میان مقادیر مشاهده شده و پیش‌بینی شده را نشان می‌دهد (Legates and Mc Cabe, 1999). ضریب تعیین بین صفر تا یک تغییر می‌کند. مقدار صفر نشان می‌دهد که مدل هیچ یک از تغییرپذیری داده‌های پاسخ در اطراف میانگین آن را تعیین نمی‌کند. اما مقدار یک نشان می‌دهد که تمام مقادیر مشاهده شده با مقادیر برازش شده یکسان خواهند بود و همه نقاط داده‌ها بر روی خط برازش شده قرار خواهند گرفت. RMSE، تفاوت میان مقدار پیش‌بینی شده توسط مدل و مقدار واقعی را نشان می‌دهد و یک ابزار خوب برای مقایسه خطاهای پیش‌بینی توسط یک مجموعه داده است. این شاخص خطای پیش‌بینی را به وسیله وزن دهی به خطاهای بیش‌ازحد بزرگ مورد محاسبه قرار می‌دهد (Rezaei and Meybodi, 2006). MAE، شاخصی است که در حالت ایده آل باید صفر باشد. مقادیر مثبت و منفی این شاخص به ترتیب نشان‌دهنده بیش برآورد و کم برآورد مدل می‌باشند. این پارامتر معرف دقت روش و مقدار متوسط خطا است (Rezaei and Meybodi, 2006). IA، نیز یکی از شاخص‌های استاندارد

جدول ۴. مقادیر ضریب همبستگی ساده (دو به دو) پارامترهای هواشناسی ایستگاه کرمان

پارامتر	حداکثر دما	میانگین دما	ساعات آفتابی	میانگین رطوبت نسبی	تابش
تابش	**/۷۵۴	**/۷۴۰	**/۷۶۷	**/۶۸۷	۱
میانگین رطوبت نسبی	**/۷۸۲	**/۷۱۲	**/۶۶۷	۱	
ساعات آفتابی	**/۵۵۶	**/۴۷۵	۱		
میانگین دما	**/۹۷۴	۱			
حداکثر دما	۱				

** معنی‌داری در سطح اطمینان ۹۹ درصد

جدول ۵. مقادیر ضریب همبستگی ساده (دو به دو) پارامترهای هواشناسی ایستگاه بندرعباس

پارامتر	حداکثر دما	میانگین دما	ساعات آفتابی	میانگین رطوبت نسبی	تابش
تابش	**۰/۶۰۴	**۰/۶۰۰	**۰/۵۱۲	**۰/۰۹۳	۱
میانگین رطوبت نسبی	**۰/۱۴۷	**۰/۰۴۰	**۰/۲۵۸	۱	
ساعات آفتابی	**۰/۴۰۶	**۰/۳۱۳	۱		
میانگین دما	**۰/۹۶۲	۱			
حداکثر دما	۱				

** معنی داری در سطح اطمینان ۹۹ درصد

نتایج کاربرد مدل رگرسیون چند متغیره

جدول (۶) ضرایب و شاخص های ارزیابی عملکرد مدل رگرسیون (رابطه ۴) را در ایستگاه های مورد مطالعه نشان می دهد. با توجه به اینکه در این بررسی، سطح معنی داری (α) برابر با ۰/۰۵ در نظر گرفته شده است، اگر $P\text{-Value} \leq 0.05$ باشد، فرضیه صفر رد می شود (یعنی متغیر مستقل مربوطه بر تغییرات تابش خورشیدی تأثیر دارد) و اگر $P\text{-Value} > 0.05$ فرضیه صفر پذیرفته می شود (یعنی متغیر مستقل مربوطه تأثیری بر تغییرات تابش خورشیدی ندارد). از آنجاییکه مقدار P-Value برای ضرایب T_{mean} ، T_{max} ، RH_{mean} و n در ایستگاه های بندرعباس، زنجان و شیراز برابر با ۰/۰۰۰ به دست آمده است، لذا می توان گفت که این متغیرها بر تغییرات تابش خورشیدی در این ایستگاه ها تأثیرگذارتر بوده اند.

از طرفی مقدار P-Value برای متغیر RH_{mean} به ترتیب در ایستگاه های کرمان و مشهد برابر با ۰/۶۲۵ و ۰/۸۸۷ به دست آمد که این امر نمایانگر تأثیر ناچیز این متغیر بر مقدار تابش در ایستگاه ها می باشد.

نتایج حاصل از آماره R^2 نشان می دهد که این مقدار در ایستگاه های زنجان و کرمان به ترتیب برابر با ۰/۷۸۵ و ۰/۷۳۸ بوده که نسبت به سایر ایستگاه های مورد بررسی دارای مقادیر بالاتری می باشند. این موضوع در مورد آماره IA نیز صادق می باشد. مقادیر RMSE به طور تقریبی در کلیه ایستگاه ها، نزدیک به هم بوده و از مقدار ۳/۰۴۵ در ایستگاه بندرعباس تا مقدار ۴/۱۸۲ مگاژول بر مترمربع بر روز در ایستگاه مشهد متغیر بوده است.

جدول ۶. ضرایب مدل رگرسیون چند متغیره مورد استفاده جهت برآورد تابش کل خورشیدی و آماره های ارزیابی عملکرد

ایستگاه	C ₁	C ₂	C ₃	C ₄	C ₅	R ²	RMSE (MJm ⁻² d ⁻¹)	MAE (%)	IA
بندرعباس	۰/۷۷۴	-۰/۳۸۲	-۰/۰۴۱	۱/۰۰۲	۴/۲۳۹	۰/۶۳۸	۳/۰۴۵	۲/۳۳	۰/۸۶۱
زنجان	۰/۴۷۹	-۰/۲۱۴	۰/۰۳۳	۱/۲۶۲	۲/۳۹۴	۰/۷۸۵	۴/۱۵۱	۳/۲۲	۰/۹۰۷
شیراز	۰/۷۸۱	-۰/۴۵۷	-۰/۰۲۷	۱/۰۶۰	۹/۰۰۳	۰/۶۸۲	۳/۶۳۹	۲/۵۹	۰/۸۹۱
کرمان	۰/۷۰۳	-۰/۳۳۵	-۰/۰۰۷	۱/۲۹۱	۶/۱۸۳	۰/۷۳۸	۳/۱۸۴	۲/۴۶	۰/۹۱۸
مشهد	۰/۷۶۹	-۰/۴۴۴	-۰/۰۰۰	۱/۰۱۳	۷/۵۲۹	۰/۶۸۰	۴/۱۸۲	۲/۹۲	۰/۸۹۲

ترکیبات متفاوت مدل ANN و اجرای مدل

در جدول (۷) برای هر ایستگاه همدیدی سه نمونه از بهترین ترکیب های به دست آمده به همراه آماره های ارزیابی مدل ها در دو مرحله آموزش و اعتبارسنجی ارائه شده است. در بین ترکیبات انتخاب شده M_{15} برای همه ایستگاه های مورد مطالعه بهترین ترکیب می باشد. البته همانگونه که در جدول (۷) مشخص است سایر مدل ها نیز با کمی چشم پوشی از اختلافات، قابل بررسی و استفاده می باشند. بنابراین در این مطالعه متغیرهای T_{mean} ، T_{max} ، RH_{mean} و n به عنوان متغیرهای ورودی در برآورد R_s به عنوان خروجی استفاده شدند. طبق جدول (۷) تفاوت مقادیر حداکثر و حداقل مشاهداتی و محاسباتی در ایستگاه همدیدی کرمان نسبت

به سایر ایستگاه ها کمتر می باشد که برابر با ۱/۳۸ است. ایستگاه کرمان با اقلیم خشک سردسیر دارای مقادیر کم RMSE و MAE در مرحله آموزش (به ترتیب ۲/۸۷۸ و ۱/۹۵) می باشد و همچنین بیشترین مقدار R^2 و IA (به ترتیب ۰/۸۳۱ و ۰/۹۵۱) می باشد. در ایستگاه های بندرعباس، زنجان، شیراز و مشهد اختلاف حداکثر و حداقل شدت تابش خورشیدی به ترتیب برابر با ۲/۵۴، ۲/۰۶، ۱/۴ و ۱/۶۶ می باشد.

تحلیل عملکرد دو الگوریتم آموزش

برای استخراج ساختار بهینه شبکه عصبی مورد استفاده در ایستگاه های سینوپتیک مورد مطالعه، تأثیر تعداد نرون های لایه پنهان و نوع آموزش مورد بررسی قرار گرفت. در شکل (۴) نتایج

و اعتبارسنجی استفاده گردید. در نهایت ANN با قانون آموزش و LM و Br به دلیل خطای کمتر به عنوان الگوریتم‌های بهینه شبکه با توابع محرک و تعداد نرون‌های مختلف در لایه میانی مورد استفاده قرار گرفت. مقادیر خروجی از هر شبکه با مقادیر مشاهده‌ای متناظر آن مقایسه شد و جزئیات آن براساس آماره‌های ارزیابی عملکرد مورد بررسی قرار گرفت. نتایج ساختارهای بهینه شبکه عصبی مصنوعی در برآورد مقدار R_s به تفکیک هر ایستگاه در جدول (۸) ارائه شده است.

مقایسه نتایج اجرای آرایش‌های مختلف شبکه عصبی، با معیارهای خطاسنجی نشان می‌دهد، این مدل توانمندی پیش-بینی تابش خورشیدی را دارا است. همانگونه که در جدول (۸) مشاهده می‌شود بهترین مدل ANN با آرایش (۴-۱۲-۱) و با تابع تانژانت سیگموئید و با الگوریتم Br در ایستگاه کرمان می‌باشد. با توجه به نتایج به دست آمده برای شبکه‌ها کمترین مقادیر RMSE، MAE و بیشترین مقدار IA و R^2 مربوط به ایستگاه کرمان با اقلیم خشک سردسیر به ترتیب ۲/۷۹۹، ۱/۹۴، ۰/۹۵۴ و ۰/۸۳۸ می‌باشد. بنابراین شبکه با این ساختار با ورودی‌های T_{mean} ، T_{max} و RH و همچنین با یک لایه پنهان بهترین شبکه برای مدل‌سازی تابش خورشید برای ایستگاه‌های مورد مطالعه می‌باشد.

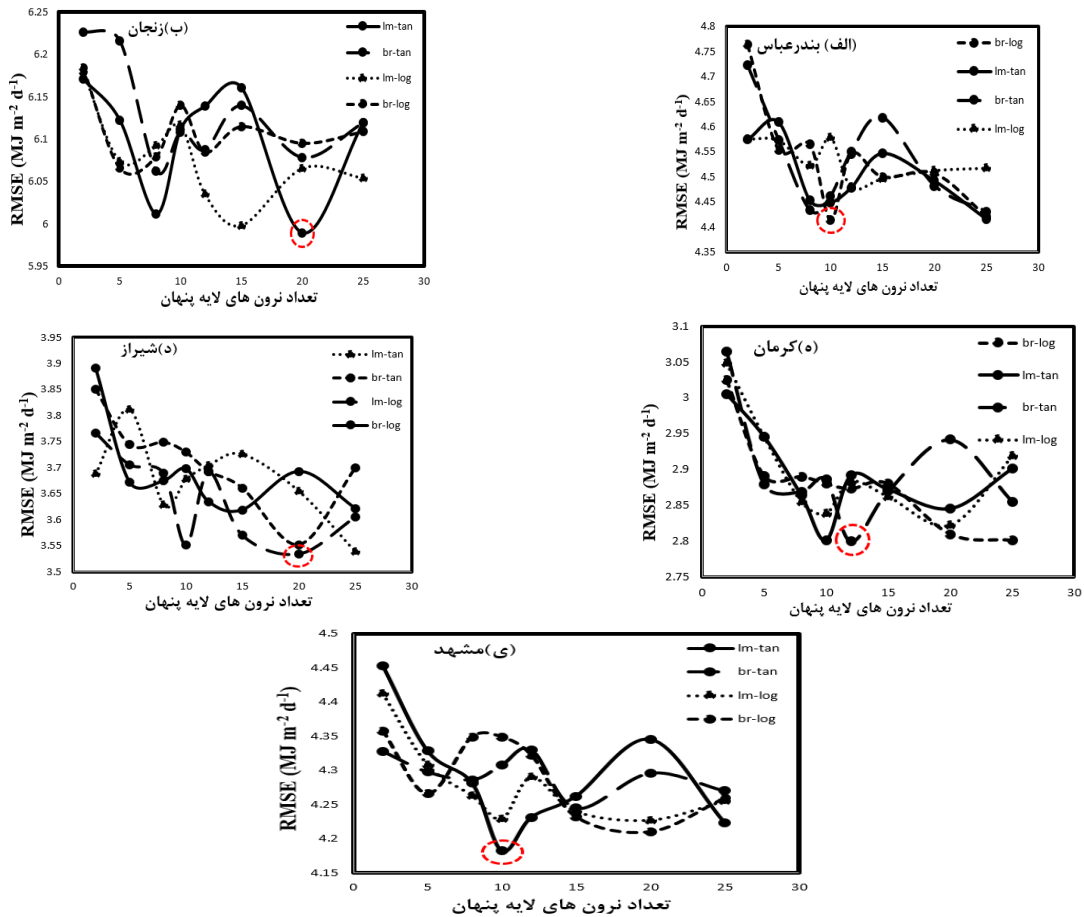
تأثیر دو الگوریتم آموزش LM و Br در مرحله آموزش ارائه شده است. با توجه به نتایج به دست آمده در ایستگاه سینوپتیک بندرعباس در الگوریتم Br و با تابع محرک تانژانت سیگموئید مقدار RMSE در تعداد نرون ۱۰ دارای مقدار بهینه می‌باشد. در ایستگاه زنجان، الگوریتم LM با تابع تانژانت سیگموئید در تعداد نرون ۲۰ دارای مقدار بهینه می‌باشد. در ایستگاه زاهدان در الگوریتم Br و با تابع تانژانت سیگموئید با تعداد نرون ۲۵ دارای مقدار بهینه می‌باشد. در ایستگاه شیراز در الگوریتم LM و با تابع محرک لوگ سیگموئید در تعداد نرون ۲۰ دارای مقدار بهینه می‌باشد. در ایستگاه کرمان در الگوریتم Br و با تابع محرک تانژانت سیگموئید در تعداد نرون ۱۲ مقدار بهینه را دارا می‌باشد. در ایستگاه سینوپتیک مشهد در الگوریتم LM با تابع انتقال تانژانت سیگموئید با تعداد نرون ۱۰ دارای مقدار بهینه می‌باشد. با توجه به نتایج به دست آمده کمترین مقدار RMSE در ایستگاه کرمان با مقدار ۲/۷۹۹ می‌باشد.

نتایج اجرای شبکه ANN

جهت دستیابی به بهترین مدل شبکه عصبی مصنوعی، مدل‌ها و توابع متفاوت با آرایش نرون‌های مختلفی آزمایش شدند. به منظور ارزیابی و مقایسه عملکرد شبکه‌ها با یکدیگر از داده‌های آموزش

جدول ۷. بهترین ترکیب‌های مدل‌های مورد استفاده با ساختار متفاوت در هر ایستگاه سینوپتیک مورد مطالعه

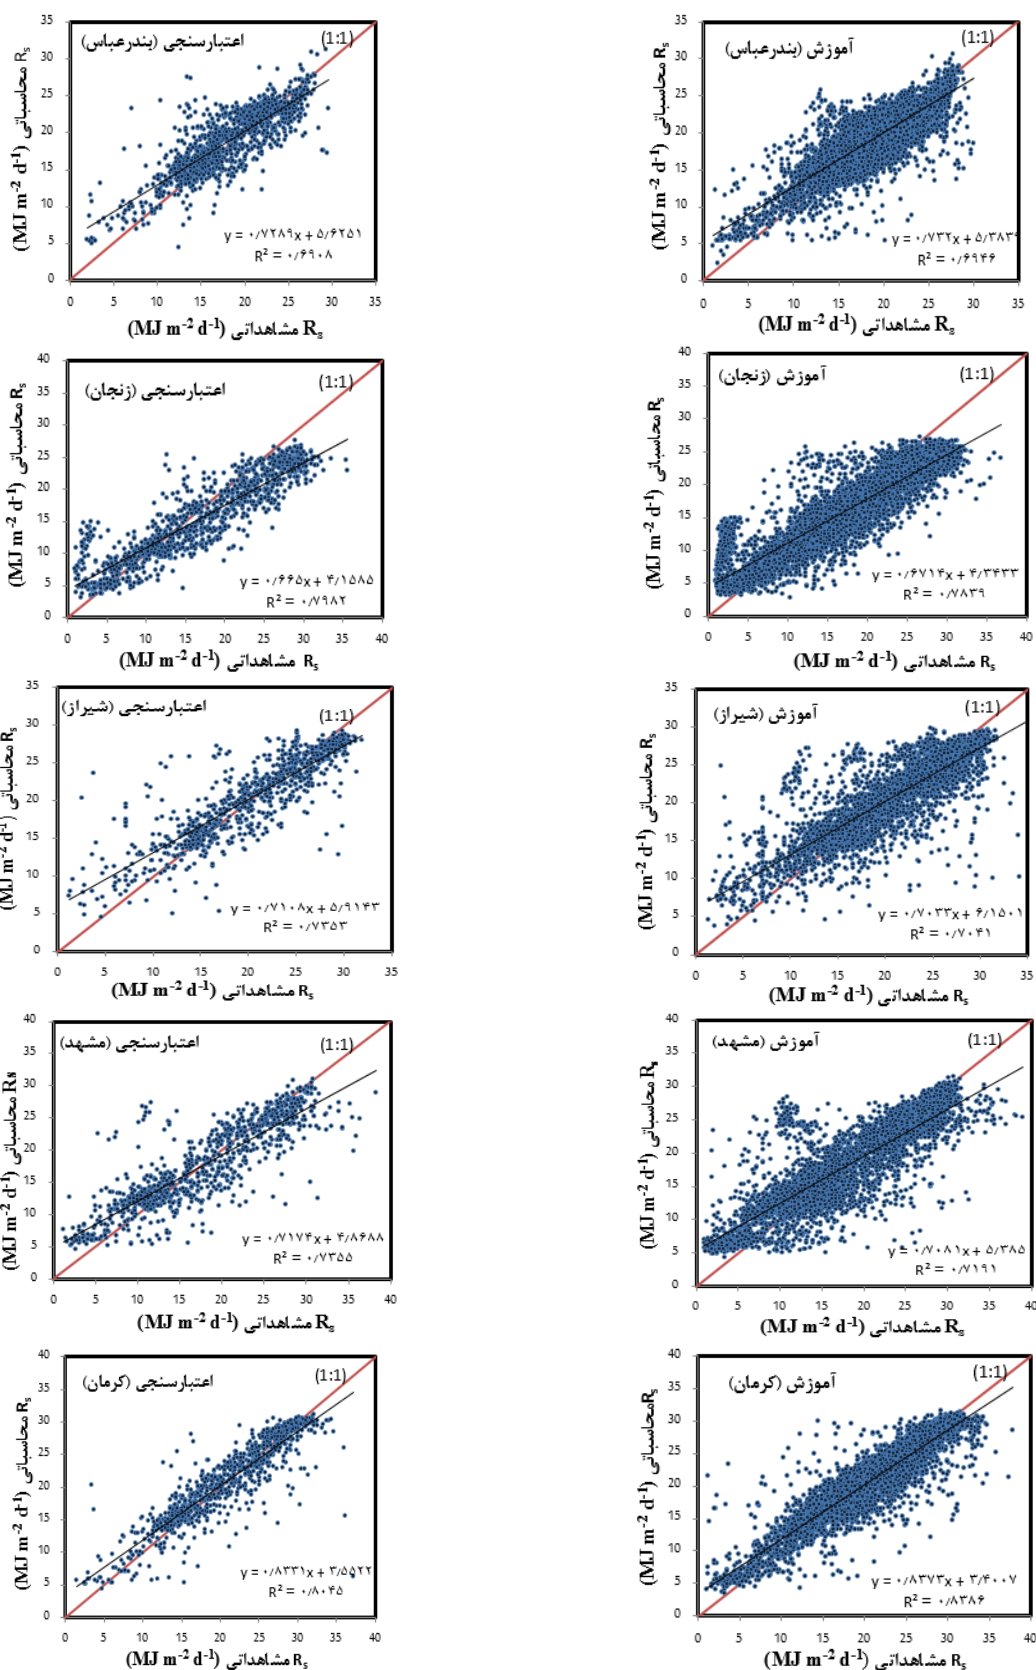
اعتبارسنجی						آموزش				مدل	ایستگاه
Max.	Min.	IA	MAE (%)	RMSE (MJ m ⁻² d ⁻¹)	R ²	IA	MAE (%)	RMSE (MJ m ⁻² d ⁻¹)	R ²		
۳۹/۸۴	۱/۰۷										مشاهداتی
۲۶/۵۲	۴/۶۰	۰/۸۲۲	۲/۵۸	۴/۱۶۶	۰/۴۶۸	۰/۸۱۰	۲/۷۰	۴/۵۳۵	۰/۵۰۵	M ₁₂	بندرعباس
۲۵/۹۰	۳/۳۲	۰/۸۱۹	۲/۵۹	۴/۳۹۷	۰/۴۶۲	۰/۵۰۸	۲/۶۷	۴/۵۵۲	۰/۵۰۸	M ₁₄	
۲۶/۷۴	۳/۶۱	۰/۸۲۳	۲/۶۰۸	۴/۱۱۸	۰/۵۰۱	۰/۸۲۷	۲/۵۵	۴/۰۱۰	۰/۵۳۱	M ₁₅	
۳۸/۵۹	۱/۰۰										مشاهداتی
۳۱/۹۶	۳/۴۴	۰/۸۸۶	۳/۵۶۲	۴/۶۲۸	۰/۷۰۷	۰/۸۹۸	۳/۳۸	۴/۵۳۸	۰/۷۴۰	M ₁₂	زنجان
۲۶/۱۳	۳/۹۷	۰/۸۸۸	۳/۴۷۹	۴/۶۷۶	۰/۷۱۲	۰/۸۹۶	۳/۳۷	۴/۵۳۰	۰/۷۳۷	M ₁₃	
۲۷/۰۶	۳/۰۶	۰/۸۸۹	۳/۴۵۰	۴/۷۱۸	۰/۷۲۲	۰/۹۲۶	۳/۰۹	۴/۰۷۹	۰/۷۵۲	M ₁₅	
۳۹/۵۴	۳/۱۰										مشاهداتی
۳۰/۵۹	۵/۶۸	۰/۸۸۰	۲/۶۶	۴/۰۰۲	۰/۶۳۶	۰/۹۰۱	۲/۴۹	۳/۶۴۰	۰/۶۸۹	M ₁₂	شیراز
۲۹/۴۸	۵/۹۷	۰/۹۰۱	۲/۴۷	۳/۷۷۵	۰/۶۸۳	۰/۹۰۴	۲/۴۲	۳/۶۳۳	۰/۶۹۱	M ₁₄	
۳۰/۴۰	۴/۵۰	۰/۸۹۲	۲/۶۴	۴/۰۲۴	۰/۷۰۰	۰/۹۰۷	۲/۴۸	۳/۵۰۳	۰/۷۰۶	M ₁₅	
۳۸/۷۶	۱/۳۹										مشاهداتی
۳۲/۵۸	۴/۳۲	۰/۹۳۸	۲/۱۵	۳/۲۵۲	۰/۷۹۰	۰/۹۴۲	۲/۰۷	۲/۹۹۹	۰/۸۰۰	M ₁₃	کرمان
۳۲/۶۱	۴/۹۶	۰/۹۳۹	۲/۱۱	۳/۱۵۵	۰/۸۰۲	۰/۹۴۴	۲/۰۰	۲/۹۶۵	۰/۸۰۶	M ₁₄	
۳۲/۵۴	۲/۷۷	۰/۹۴۷	۲/۰۲	۳/۱۵۶	۰/۸۱۷	۰/۹۵۱	۱/۹۵	۲/۸۷۸	۰/۸۳۱	M ₁₅	
۳۹/۹۴	۱/۰۲										مشاهداتی
۳۰/۸۱	۴/۷۷	۰/۹۰۲	۳/۰۷	۴/۳۸۳	۰/۶۸۱	۰/۹۰۳	۳/۰۸	۴/۳۸۱	۰/۶۹۱	M ₁₃	مشهد
۳۰/۱۱	۳/۷۲	۰/۹۰۳	۳/۰۶	۴/۳۸۱	۰/۶۹۶	۰/۹۰۸	۳/۰۵	۴/۳۲۱	۰/۷۰۲	M ₁₄	
۳۲/۰۲	۲/۶۸	۰/۸۹۶	۳/۰۷	۴/۴۳۰	۰/۶۶۸	۰/۹۱۳	۲/۹۵	۴/۲۱۷	۰/۷۱۶	M ₁₅	



شکل ۴. تأثیر تعداد نرون های لایه پنهان در عملکرد شبکه با استفاده از آماره RMSE برای دو الگوریتم آموزش LM و الگوریتم آموزش Br در ایستگاه های مطالعاتی

جدول ۸. مقایسه دو الگوریتم آموزش شبکه عصبی با تعداد نرون های مختلف در ایستگاه های همدیدی مورد مطالعه

ایستگاه	آرایش شبکه	الگوریتم آموزش	تابع محرک	آموزش		اعتبارسنجی	
				IA	MAE (%)	RMSE (MJ m ⁻² d ⁻¹)	R ²
بندرعباس	(۴-۱۰-۱)	LM	tansig	۰/۸۹۲	۲/۲۲۱	۴/۴۴۸	۰/۵۹۴
	(۴-۱۲-۱)	LM	logsig	۰/۸۹۶	۲/۱۵۱	۴/۹۶۶	۰/۶۴۵
	(۴-۲۵-۱)	Br	tansig	۰/۹۰۶	۲/۱۳۵	۴/۴۳۰	۰/۶۹۳
	(۴-۱۰-۱)	Br	logsig	۰/۹۰۶	۲/۱۱۰	۴/۴۱۳	۰/۶۹۴
زنجان	(۴-۲۰-۱)	LM	tansig	۰/۹۱۵	۳/۱۳۱	۵/۹۸۹	۰/۷۸۳
	(۴-۱۵-۱)	LM	logsig	۰/۹۰۰	۳/۳۰۳	۵/۹۹۷	۰/۷۴۴
	(۴-۸-۱)	Br	tansig	۰/۹۰۴	۳/۲۷۳	۶/۰۶۲	۰/۷۶۳
	(۴-۵-۱)	Br	logsig	۰/۸۹۷	۳/۳۶۱	۶/۰۶۶	۰/۷۵۴
شیراز	(۴-۵-۱)	LM	tansig	۰/۸۹۳	۲/۵۹۳	۳/۸۲۲	۰/۶۶۲
	(۴-۲۰-۱)	LM	logsig	۰/۹۰۸	۲/۴۰۹	۳/۵۳۴	۰/۷۰۴
	(۴-۲۰-۱)	Br	tansig	۰/۹۰۹	۲/۳۹۵	۳/۵۵۱	۰/۷۰۱
	(۴-۱۵-۱)	Br	logsig	۰/۹۰۴	۲/۴۵۲	۳/۶۱۸	۰/۶۹۵
کرمان	(۴-۱۰-۱)	LM	tansig	۰/۹۵۴	۱/۹۴۵	۲/۸۰۱	۰/۸۳۵
	(۴-۲۰-۱)	LM	logsig	۰/۹۵۴	۱/۹۱۳	۲/۸۲۱	۰/۸۲۹
	(۴-۱۲-۱)	Br	tansig	۰/۹۵۴	۱/۹۴۴	۲/۷۹۹	۰/۸۳۸
	(۴-۲۵-۱)	Br	logsig	۰/۹۴۶	۱/۹۸۲	۳/۰۲۷	۰/۸۲۱
مشهد	(۴-۱۰-۱)	LM	tansig	۰/۹۱۶	۲/۹۰۸	۴/۱۸۲	۰/۷۱۹
	(۴-۱۰-۱)	LM	logsig	۰/۹۱۲	۲/۹۶۵	۴/۲۲۸	۰/۷۱۴
	(۴-۱۵-۱)	Br	tansig	۰/۹۱۲	۲/۹۵۶	۴/۲۴۴	۰/۷۱۲
	(۴-۲۰-۱)	Br	logsig	۰/۹۱۵	۲/۹۳۷	۴/۲۱۰	۰/۷۱۵



شکل ۵. همبستگی بین شدت تابش محاسباتی با روش ANN و مقادیر مشاهداتی در دو مرحله آموزش و اعتبارسنجی در مدل M15

شکل دیده می‌شود، نزدیک بودن شیب خط رگرسیون به خط نیمساز و کم بودن مقدار عرض از مبدأ بیانگر برتری نتایج مدل در ANN در تخمین مقدار R_s می‌باشد. نتایج خروجی‌های مدل‌های

همبستگی بین مقادیر R_s برآورد شده با ANN و مقادیر مشاهده‌ای هر ایستگاه به تفکیک دو مرحله آموزش و اعتبارسنجی، در شکل (۵) نشان داده شده است. همانگونه که در

ساعات آفتابی) به عنوان ورودی مدل‌ها مورد توجه قرار گرفت. ترکیبات مختلفی از این ورودی‌ها به صورت تک متغیره تا چهار متغیره به عنوان مدل‌های انتخابی در قالب مدل شبکه عصبی مورد بررسی قرار گرفتند. نتایج این مطالعات نشان داد که با توجه به موقعیت جغرافیایی ایستگاه‌های مورد بررسی، شاید بتوان گفت که سه ایستگاه بندرعباس، زنجان و شیراز بیشتر تحت تأثیرات رطوبت نسبی حاصل از جریانات مدیترانه‌ای و سودانی ورودی از سمت غرب و جنوب غرب کشور بوده‌اند و لذا تحلیل‌های آماری هم نشان داده است که تأثیر این متغیر بر شدت تابش خورشیدی و حتی مقدار ابرناکی در این ایستگاه‌ها بیشتر بوده است. تأثیرگذاری این عامل در ایستگاه‌های کرمان و مشهد ناچیز بوده است. همچنین استفاده از روش رگرسیون چند متغیره در مدل‌سازی تابش خورشیدی به اندازه مدل‌های ANN، دقت قابل قبولی ندارد. به طوری که کمترین مقدار R^2 در ایستگاه مشهد با اقلیم نیمه‌خشک سردسیر ($R^2=0/680$) و بیشترین مقدار در ایستگاه زنجان با اقلیم نیمه‌خشک فراسرد ($R^2=0/785$) مشاهده شد. از سوی دیگر ترکیب ورودی‌های مختلف در مدل ANN با دو الگوریتم لوببرگ-مارکوات و تنظیم بیزی و دو تابع تانژانت سیگموئید و لوگ سیگموئید آموزش دیدند. تحلیل‌های آماری و شاخص‌های ارزیابی نشان داد که در ایستگاه‌های مشهد، شیراز و زنجان داده‌ها با الگوریتم LM و در ایستگاه‌های کرمان و بندرعباس با الگوریتم Br بهتر آموزش دیدند. براساس تابع محرک، ایستگاه‌های مشهد، زنجان و کرمان با تابع تانژانت سیگموئید و ایستگاه‌های بندرعباس و شیراز با تابع محرک لوگ سیگموئید عملکرد بهتری داشته‌اند. مقادیر آماره‌های ارزیابی عملکرد مدل‌ها در دو روش رگرسیون خطی و ANN حاکی از کارایی بهتر روش ANN در برآورد تابش خورشیدی در کلیه اقلیم‌های مطالعاتی بود. نتایج این پژوهش قابل مقایسه با نتایج (Jimenez et al. (2016)، Kumar et al. (2015) و بیات و میرلطیفی (۱۳۸۸) می‌باشد که تمامی این مطالعات برتری روش ANN را در پیش‌بینی شدت تابش خورشیدی کل نسبت به سایر روش‌های تجربی و رگرسیون تأیید کرده‌اند. این روش در برآورد مقدار تابش کل خورشیدی به ویژه در ایستگاه‌هایی که فاقد دستگاه تابش‌سنج هستند و یا در اقلیم‌هایی که میزان ابرناکی آن‌ها زیاد است، پیشنهاد می‌شود. در مقاله بعدی نویسندگان عملکرد تکنیک‌های شبکه عصبی مصنوعی، سیستم استنتاج فازی و ماشین بردار پشتیبان در مقایسه با چند معادله تجربی برآورد تابش خورشیدی روزانه را مورد ارزیابی قرار خواهند داد.

سپاسگزاری

این پژوهش مستخرج از قسمتی از پایان‌نامه دوره کارشناسی

M12، M13، M14 و M15 به عنوان بهترین ترکیب‌های مدل‌های مورد استفاده (جدول ۸) از نظر برآورد مقدار کمی تابش خورشید در ایستگاه‌های مختلف در مقایسه با خط نیمساز (۱:۱) نیز نشان داد که در ایستگاه بندرعباس در هر دو مرحله آموزش و اعتبارسنجی در مدل‌های M12 و M14، مقادیر R_s محاسباتی کمتر از ۲۰ مگاژول بر مترمربع بر روز دارای بیش برآورد می‌باشد. در این ایستگاه مقادیر حاصله از مدل M15 نشانگر بیش برآوردی تابش خورشیدی در مقادیر کمتر از ۲۰ مگاژول بر مترمربع بر روز در مرحله اعتبارسنجی و کمتر از ۱۷ مگاژول بر مترمربع بر روز در مرحله آموزش بوده است (شکل ۵). این موضوع در مورد ایستگاه زنجان در مراحل آموزش و اعتبارسنجی حاکی از آن است که مقادیر محاسباتی حاصل از مدل‌های M12 و M13 در مقادیر کمتر از ۱۴ مگاژول بر مترمربع بر روز بیش برآورد می‌باشد. در مدل M15 مقادیر بیش برآوردی کمتر از ۱۲ و ۱۴ مگاژول بر مترمربع بر روز به ترتیب در مراحل آموزش و اعتبارسنجی به دست آمده است. در ایستگاه شیراز نیز مقادیر برآوردی حاصل از مدل M12 در مراحل آموزش و اعتبارسنجی به ترتیب در مقادیر کمتر از ۱۸ و ۲۲ مگاژول بر مترمربع بر روز دارای بیش برآورد بوده است. در مدل M14، مقادیر بیش برآوردی در مرحله آموزش در مقادیر کمتر از ۲۰ مگاژول بر مترمربع بر روز به دست آمد. اما در مرحله اعتبارسنجی، این موضوع مشابه مدل M12 بود. در این ایستگاه مقادیر حاصله از مدل M15 نشانگر بیش برآوردی R_s در مقادیر کمتر از ۲۰ در مرحله اعتبارسنجی و کمتر از ۱۸ مگاژول بر مترمربع در مرحله آموزش بوده است (شکل ۵). در ایستگاه مشهد مقادیر محاسبه شده حاصل از هر سه مدل M13، M14 و M15 نشان داد که مقادیر کمتر از ۱۶ در مرحله آموزش و کمتر از ۱۸ مگاژول بر مترمربع بر روز در مرحله اعتبارسنجی دارای بیش برآورد بوده است. به همین ترتیب در ایستگاه کرمان مقادیر محاسبه شده حاصل از هر سه مدل M13، M14 و M15 نشان داد که در مرحله آموزش مقادیر کمتر از ۱۸ و در مرحله اعتبارسنجی، مقادیر کمتر از ۱۹ مگاژول بر مترمربع بر روز بیش برآورد می‌باشند.

نتیجه‌گیری

امروزه برآورد و پیش‌بینی شدت تابش کل خورشیدی با استفاده از مدل‌های ANN توسعه یافته است. این مطالعه با هدف ارزیابی کارایی روش‌های ANN و رگرسیون چند متغیره خطی در برآورد تابش کل خورشیدی در پنج ایستگاه همدیدی ایران با اقلیم‌های متفاوت به انجام رسید. به این منظور تعداد چهار متغیر روزانه (حداکثر دمای هوا، میانگین دمای هوا، میانگین رطوبت نسبی و

منتخب تابش سنجی ایران" در بخش مهندسی آب دانشگاه شهید باهنر کرمان بوده که به این وسیله تشکر می‌شود.

ارشد مهندسی منابع آب تحت عنوان "مدل‌سازی تابش خورشیدی با استفاده از چند مدل داده محور در ایستگاه‌های

REFERENCES

- AL-Fatlawi, A. W. A., Qazi, A., Hussain, F. and Ahmed Khan, W. (2015). The artificial neural network for solar radiation prediction and designing solar systems: a systematic literature review. *Journal of Cleaner Production*, 104, 1-12.
- Allen, R. G., Pereira, L. S., Raes, D. and Smith, M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. FAO, Rome, 300(9), D05109.
- Agha Shariatmadari, Z., Khalili, A., irannezhad, P. and Leyaghat, A. (2012). Calibration and annual variations of Angstrom-Prescott's (a and b) coefficients in different time scales (Case study: Tehran-Shahr Station (Aghdasiyeh). *Journal of Water and Soil*, 25 (4), 905-911. (In Farsi)
- Bayat, k. and Mirlatifi, S. M. (2010). Estimation of daily total solar radiation using artificial neural networks and comparing it with experimental methods at three stations in Shiraz, Karaj and Ramsar. *Journal of Water and Soil Science, Science and Technology of Agriculture and Natural Resources- Isfahan University of Technology*, 16 (61), 1-13. (In Farsi)
- Benghanem, M., Mellit, A. and Alamri, S. N. (2009). ANN-based modelling and estimation of daily global solar radiation data: A case study. *Energy conversion and management*, 50(7), 1644-1655.
- DehghaniSanij, H., Yamamoto, T. and Rasiah, V. (2004). Assessment of evapotranspiration estimation models for use in semi-arid environments. *Agricultural water management*, 64(2), 91-106.
- Ghabaei Sough, M., Mosaedi, A. and Dehghani, A. A. (2012). Solar radiation data and their intelligent modeling based on gamma test with evaluation of calibrated empirical equations. *Journal of Water and Soil Conservation*, 18(4), 158-208. (In Farsi)
- Ghahreman, N. and Bakhtiari, B. (2009). Solar radiation estimation from rainfall and temperature data in arid and semi-arid climates of Iran. *DESERT*, 14(2), 141-150.
- Hecht-Nielsen, R. (1987). Kolmogorov's mapping neural network existence theorem. In *Proceedings of the IEEE International Conference on Neural Networks III*, IEEE Press. 3, 11-14.
- Izadifar, Z. and Elshorbagy, A. (2010). Prediction of hourly actual evapotranspiration using neural networks, genetic programming, and statistical models. *Hydrological Processes*, 24, 3413-3425.
- Jang, J. and Roger, S. (2003). ANFIS: Adaptive-network-based fuzzy inference systems. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.
- Jensen, M. E. and Haise, H. R. (1963). Estimating evapotranspiration from solar radiation. *Journal of the Irrigation and Drainage Division, Proceedings of the American Society of Civil Engineers*, 89, 15-41.
- Jimenez, A. V., Barrionuevo, A., Will, A. and Rodriguez, S. (2016). Neural network for estimating daily global solar radiation using temperature, humidity and pressure as unique climatic input variables. *Smart Grid and Renewable Energy*, 7(3), 94-103.
- Kumar, R., Aggarwal, R. K. and Sharma, J. D. (2015). Comparison of regression and artificial neural network models for estimation of global solar radiations. *Renewable and Sustainable Energy Reviews*, 52, 1294-1299.
- Legates D. R. and Mc Cabe Jr. G. J. (1999). Evaluating the use of goodness-of-fit measures in hydrologic and hydroclimatic model validation. *Water and Resources Research*, 35(1), 233-241.
- Makkink, G. F. (1957). Testing the Penman formula by means of lysimeters. *Journal of the Institution of Water Engineers*, 11(3), 277-288.
- Menhaj, M. B. (2006). *Fundamentals of Neural Networks*. Amirkabir University of Technology. Tehran, 716 P.
- Moradi, I. (2009). Quality control of global solar radiation using sunshine duration hours. *Energy*, 34(1), 1-6.
- Nait Mensour, O., El Ghazzani, B., Hlimi, B. and Ihlal, A. (2017). Modeling of solar energy potential in Souss-Massa area-Morocco, using intelligence Artificial Neural Networks (ANNs). *Energy Procedia*, 139, 778-784.
- Olalekan, S., Abdullahi, M. I. and Olabisi, A. (2018). Modeling of Solar Radiation Using Artificial Neural Network for Renewable Energy Application. *Journal of Applied Physics*, 10(2), 6-12.
- Ramedani, Z., Omid, M. and Keyhani, A. (2013). Modeling solar energy potential in a Tehran province using artificial neural networks. *International Journal of Green Energy*, 10(4), 427-441
- Rahimi, J., Ebrahimpour, M. and Khalili, A. (2013). Spatial changes of extended De Martonne climatic zones affected by climate change in Iran. *Theoretical and applied climatology*, 112(3-4), 409-418.
- Razi, M. A. and Athappilly, K. (2005). A comparative predictive analysis of neural networks (NNs), nonlinear regression and classification and regression tree (CART) models. *Expert Systems with Applications*, 29(1), 65-74.
- Rezaei, A. and Meybodi, A. (2006). *Statistics and Probability*. Isfahan University of Technology, 590 P. (In Farsi)
- Saffari Pour, M. H. and Mehrabian, M. A. (2010).

- Estimation of the total amount of solar radiation in Kerman using geometric, astronomical, geographic and meteorological characteristics. Sharif Scientific and Research Magazine, 51, 3-13. (In Farsi)
- Tabari, H., Grismer, M. E. and Trajkovic, S. (2013). Comparative analysis of 31 reference evapotranspiration methods under humid conditions. Irrigation Science, 31(2), 107-117.
- Turc, L. (1961). Evaluation des besoins en eau d'irrigation, évapotranspiration potentielle. Annual Agronomy, 12, 13-49.
- Willmott, C. J. (1982). Some comments on the evaluation of model performance. Bulletin of the American Meteorological Society, 63(11), 1309-1313.
- Yadav, A. K. and Chandel, S. S. (2015). Solar energy potential assessment of western Himalayan Indian state of Himachal Pradesh using J48 algorithm of WEKA in ANN based prediction model. Renewable Energy, 75, 675-693.
- Yadav, A. K., Malik, H. and Chandel, S. S. (2014). Selection of most relevant input parameters using WEKA for artificial neural network based solar radiation prediction models. Renewable and Sustainable Energy Reviews, 31, 509-519.
- Yan, X., Abbas, D. and Francois, B. (2014). Solar radiation forecasting using Artificial Neural Network for local power reserve. International Conference on Electrical Sciences and Technologies in Maghreb, (CISTEM), Tunis, Tunisia, 1-6.
- Yang, H., Griffiths, P. R. and Tate, J. D. (2003). Comparison of partial least squares regression and multi-layer neural networks for quantification of nonlinear systems and application to gas phase Fourier transform infrared spectra. Analytica Chimica Acta, 489(2), 125-136.