

پیش‌بینی میزان تابش خورشیدی با استفاده از دمای روزانه و شبکه‌های عصبی مصنوعی در اقلیم‌های مختلف آب‌وهوایی

سید ایمان ساعدی¹ - رضا علیمردانی^{2*} - حسین موسی‌زاده³

تاریخ دریافت: 1395/11/17

تاریخ پذیرش: 1396/02/23

چکیده

برآورد میزان تابش خورشیدی در هواشناسی، کشاورزی و سامانه‌های مبتنی بر این منبع انرژی پاک و تجدیدپذیر اهمیت دارد. در این پژوهش از دمای روزانه که در دسترس‌ترین داده هواشناسی است به‌عنوان تنها پارامتر مورد نیاز در اقلیم‌های مختلف، استفاده و با کمک شبکه‌های عصبی مصنوعی مدل‌های پیش‌بینی تابش خورشیدی توسعه داده شد. معیارهای ارزیابی مدل‌ها شامل R ، $RMSE$ و $MAPE$ و نمودارهای پراکندگی مقادیر واقعی و پیش‌بینی شده بود. برای تأمین داده‌های طولانی‌مدت و معتبر، ایالت واشنگتن در شمال‌غربی آمریکا با 19 ایستگاه هواشناسی در اقلیم‌های مختلف، انتخاب شد. ابتدا، یک ایستگاه با بیشترین داده معتبر برای توسعه شبکه‌های عصبی لحاظ شد. برای آن، مدل‌هایی با سه تابع آموزشی لونیبرگ-مارکواریت (LM)، گرادیان توأم مقیاس‌شده (SCG) و تنظیم بیزین (BR) در حالات یک و دولایه پنهان با حداکثر 20 نرون در هر لایه (در مجموع 1260 مدل) توسعه داده شد و شش مدل برتر انتخاب گردید. این مدل‌ها سپس در سایر ایستگاه‌های این ایالت سنجیده شد و در نهایت، دقیق‌ترین و همه‌جانبه‌ترین آنها برای ارزیابی میزان تابش خورشیدی در اقلیم مشهد به‌عنوان نمونه‌ای از اقلیم داخل کشور انتخاب شد. نتایج نشان داد که شبکه‌های عصبی بیزین دقیق‌ترین پاسخ ($0/87 < R < 0/92$ ، $3/54 < RMSE < 4/78 MJm^{-2}$ ، $28/81 < MAPE < 62/75\%$) و الگوریتم SCG با بالاترین سرعت‌های پردازش، کمترین دقت ($0/83 < R < 0/90$ ، $3/91 < RMSE < 5/30 MJm^{-2}$ ، $33/74 < MAPE < 77/28\%$) را در ایالت واشنگتن دارد. بررسی کارایی دقیق‌ترین مدل‌ها (شبکه‌های عصبی بیزین) در ایستگاه هواشناسی مشهد نیز حاکی از توانایی آن بود ($R=0/82$ ، $RMSE=3/92 MJm^{-2}$ ، $MAPE=79/92\%$) که نشان داد به کمک این شبکه‌ها، با کمترین داده‌های هواشناسی می‌توان به برآورد مناسبی از تابش خورشیدی در اقلیم‌های متفاوت دست‌یافت.

واژه‌های کلیدی: تابش جهانی خورشیدی، تنظیم بیزین، دمای روزانه، شبکه عصبی

مقدمه

سمت منابع انرژی جدید مثل انرژی خورشیدی امری اجتناب‌ناپذیر است. این پدیده همچنین در هواشناسی و کشاورزی اهمیت زیادی دارد. فتوسنتز و تبخیر و تعرق دو فرآیند اساسی رشد محصول هستند که هردو ارتباط تنگاتنگی با تابش خورشیدی داشته و لذا داشتن اطلاعات از کمیت و کیفیت آن می‌تواند نقش به‌سزایی در این زمینه داشته‌باشد.

امروزه در حوزه‌های مختلفی از این انرژی پاک استفاده می‌شود که آب‌گرمکن‌های خورشیدی، خوراک‌پزهای خورشیدی، خشک‌کن‌های خورشیدی، پمپ‌های خورشیدی، حصارهای الکتریکی خورشیدی، آب شیرین‌کن‌های خورشیدی و غیره تنها بخشی از آنها می‌باشند. همچنین در زمینه فن‌آوری‌های نوین، استفاده از انرژی خورشیدی در لوله‌های گرمایی، ترموالکتریک، پیل‌های سوختی و نانو، جاذبه‌های فراوانی پیدا کرده‌اند (Layeghi, 2015). در کنار آن، کاربردهای امیدبخش دیگری مثل تراکتور هیبریدی خورشیدی

تابش جهانی خورشیدی⁴ یا به اختصار تابش خورشیدی به مجموع تابش مستقیم، پراکنده شده و بازتابشی خورشیدی اطلاق می‌شود. استفاده از انرژی خورشیدی از جهات مختلف بسیار حائز اهمیت است. انرژی‌های فسیلی مثل نفت و گاز علاوه بر اینکه تجدیدناپذیرند، در آلودگی محیط زیست نیز تأثیرگذارند. لذا گرایش به

1- استادیار، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

2- استاد، گروه مهندسی مکانیک ماشین‌های کشاورزی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران

3- دانشیار، گروه مهندسی مکانیک ماشین‌های کشاورزی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران

(Email: rmardani@ut.ac.ir)

4- Global Solar Radiation
DOI: 10.22067/jam.v8i1.62377

(* - نویسنده مسئول)

(2011). همچنین، شبکه عصبی به‌عنوان روشی قابل اتکا مورد توجه محققین قرار گرفته‌است (Wang *et al.* 2012; Ahmad and Adam, 2013; Mubiru, 2011; Cornaro, 2013; Razafiarison *et al.*, 2011). در یک مطالعه، تلفیقی از سری‌های زمانی و شبکه عصبی مورد استفاده قرار گرفت (Paoli *et al.*, 2009). در این تحقیق داده‌های روزانه تابش جهانی خورشیدی یک ایستگاه هواشناسی اتخاذ و از آن برای پیش‌بینی تابش در سال بعد آن استفاده شد که نتایج ارزیابی حاکی از دقت مناسب این روش بود (21%~ RMSE، $nRMSE \sim 3/59 MJm^2$). همچنین در پژوهشی در کشورمان، از شبکه‌های عصبی برای ارزیابی پتانسیل انرژی خورشیدی در نواحی مرکزی و جنوبی ایران که شامل چند اقلیم آب و هوایی می‌شود استفاده شد (Anjavi *et al.*, 2014). ورودی‌های شبکه عصبی شامل دمای متوسط هوا، ساعات آفتابی و میزان بارندگی بود و در مجموع نتایج قابل قبولی در زمینه پیش‌بینی میزان تابش خورشیدی به‌دست آمد ($R^2 > 0/9697$ ، $RMSE < 14\%$). در پژوهشی مشابه از شش متغیر ورودی شامل میانگین دمای هوا، رطوبت، ساعات آفتابی، تابش خارج از جو، شماره روز سال و درجه حرارت خشک، برای برآورد تابش خورشیدی در اقلیم مشهد با استفاده از شبکه عصبی استفاده شد که دقت خوبی در این زمینه حاصل گردید ($R=0/95$ ، $MAE=1/44$ ، $MSE=4/18$ و $RMSE=2/04$) (Motamed- Shariati *et al.* 2016).

تجهیزات سنجش میزان تابش خورشیدی ممکن است در هر ایستگاهی وجود نداشته باشد. از طرفی مدل‌های پیش‌بینی این پارامتر عموماً وابسته به عوامل ورودی زیادی هستند که خود نیازمند حسگرها و دستگاه‌های سنجش مختلف هستند و غالباً مختص یک یا چند اقلیم خاص بوده و تعمیم‌پذیر نمی‌باشند. لذا، با توجه به ضرورت پیش‌بینی سریع و آسان تابش خورشیدی، هدف از این پژوهش ارائه روشی ساده و کاربردی مبتنی بر شبکه‌های عصبی مصنوعی برای تخمین میزان تابش جهانی خورشیدی است. روشی که وابسته به اقلیمی خاص یا تجهیزات اندازه‌گیری زیاد نباشد و با در اختیار داشتن کمترین و در دسترس‌ترین داده‌های هواشناسی یعنی داده‌های دمای روزانه، حتی در مناطقی با کمترین تجهیزات هواشناسی، قابل استفاده باشد.

مواد و روش‌ها

مشخصات منطقه مورد مطالعه

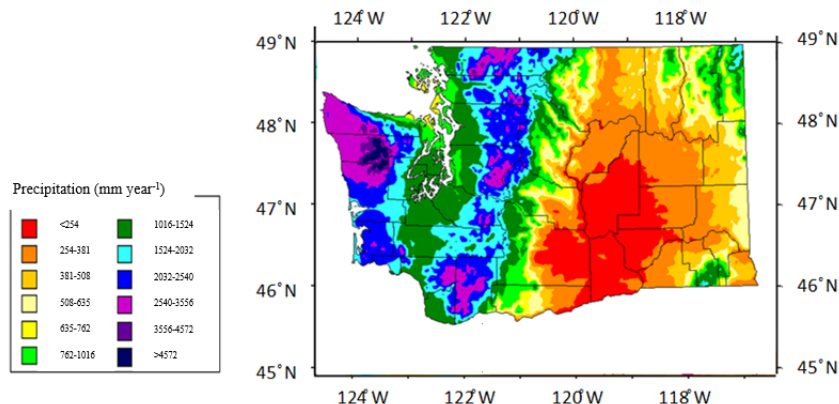
این مطالعه بر روی مناطق مختلف ایالت واشنگتن در شمال غربی آمریکا و در مدت فرصت مطالعاتی در دانشگاه ایالتی واشنگتن انجام شد. این ایالت تنوع اقلیمی بسیار زیادی دارد و از این رو نتایج حاصل از این بررسی قابل تعمیم به شرایط آب و هوایی کشور ایران

(Mousazadeh, 2010)، مرغداری مجهز به سامانه گرمایش هیبریدی خورشیدی (Mirzaee ghale *et al.*, 2014)، گلخانه مجهز به ماژول‌های فتوولتائیک برای تأمین انرژی (Yano, 2014) در این زمینه قابل ذکر می‌باشند. ارائه راهکاری برای پیش‌بینی آسان تابش خورشیدی، علاوه بر کمک به مدیریت بهتر سامانه‌های خورشیدی و مطالعات مرتبط با رشد و توسعه محصولات کشاورزی، این امکان را فراهم می‌آورد تا درک درستی از شرایط متغیر نور خورشید در طول سال - بدون نیاز به انجام آزمون‌های سالانه حاصل آید. داده‌های تابش خورشیدی برای بلند مدت و در تمامی ایستگاه‌های هواشناسی کشور در دسترس نمی‌باشند. علاوه بر این، وجود داده‌های از دست رفته و داده‌های پرت در بسیاری از ایستگاه‌ها امری متداول است.

برای اندازه‌گیری تابش خورشیدی ابزارهای اندازه‌گیری پیشرفته‌ای مورد نیاز است و در این راستا استفاده از مدل‌های ریاضی مبتنی بر متغیرهای هواشناسی برای برآورد این پارامتر در میان محققین مرسوم شده‌است. متغیرهایی مثل مدت تابش آفتاب (Bindi and Miglietta, 2013)، دما و بارش (Gadiwala *et al.*, 2013) (1991) و دما به تنهایی بیشتر مدنظر بوده‌اند. اما پارامتر دما به سبب اندازه‌گیری راحت‌تر و در دسترس‌تر بودن کاربرد بیشتر پیدا کرده‌است. از جمله مدل‌های مبتنی بر دما می‌توان به مدل هارگریوز (Bristow and Hargreaves *et al.*, 1985)، بریستو - کمپیل (Campbell, 1984)، هانت (Hunt *et al.*, 1998)، سامانی (Samani, 2000) و آلن (Allen, 1997) اشاره نمود. محققان متعددی تلاش کرده‌اند تا با ایجاد تغییراتی در این مدل‌ها، آن‌ها را برای اقلیم‌هایی خاص در کشورهای مختلف توسعه داده و در واقع آنها را بومی‌سازی کنند (Li *et al.*, 2013a; Li *et al.*, 2013b; Liu *et al.*, 2009; Li *et al.*, 2014; Namrata *et al.*, 2013; Kim *et al.*, 2014; Almorox *et al.*, 2013; Rivington *et al.*, 2005) در داخل کشور نیز در پژوهشی، تابش جهانی خورشیدی در شش ایستگاه سینوپتیک ایران با ارزیابی هشت مدل مختلف و به‌کارگیری داده‌های دما و بارش بررسی شد (Ghahreman and Bakhtiari, 2009). همچنین در تحقیقی دیگر، مدل‌های مختلفی از تابش جهانی خورشیدی برای مناطق آب و هوایی مختلف بهینه‌سازی شد (Faraji *et al.*, 2015a). علاوه بر این، مدل‌های ریاضی متفاوت برای اقلیم‌های متفاوت کشور (Sabziparvar, 2008) و نیز به‌طور خاص برای آب و هوای بندرعباس (Faraji Mahyari *et al.*, 2015b) توسط محققین توسعه داده و بومی‌سازی شده‌است. این موارد نشان می‌دهند که مدل‌های ریاضی برای شرایط آب و هوایی مختلف کارکرد یکسانی ندارند و هر مدل مختص یک اقلیم است. علاوه بر مدل‌های ریاضی روش‌های دیگری نیز توسط محققین پیاده شده‌است. به‌عنوان مثال با استفاده از تصاویر ماهواره‌ای مدل‌هایی برای تخمین تابش جهانی خورشیدی ارائه شده‌است (Aksoy *et al.*, 2010).

غربی در بیشتر اوقات هوا ابری بوده همراه با مه و باران‌های سبک و تابستان پرتابش‌ترین فصل است. در برخی مناطق این بخش میزان بارندگی سالانه به 4064 میلی‌متر می‌رسد. درحالی‌که در مناطق شرقی بارندگی سالانه تنها حدود 152 میلی‌متر است (شکل 1) (Anonymous, 2015).

می‌باشد. در ایالت واشنگتن، آب و هوا از شرق تا غرب تغییرات قابل توجهی به خود می‌بیند. آب و هوای معتدل و مرطوب در بخش‌های غربی و آب و هوای خنک‌تر و خشک در مناطق شرقی غالب است. متوسط دمای سالانه از 10/6 درجه سلسیوس در سواحل اقیانوس آرام تا 4/4 درجه سلسیوس در مناطق شمال شرقی متغیر است. در مناطق



شکل 1- نقشه پراکنندگی متوسط بارندگی سالانه در ایالت واشنگتن (Anonymous, 2015)

Fig. 1. Washington state precipitation map

شبکه‌های عصبی شامل این سه تابع آموزش به اختصار تحت عنوان LM, SCG و BR شناخته می‌شوند. برای توابع LM و SCG داده‌ها به صورت تصادفی به سه مجموعه تقسیم‌بندی شدند: مجموعه آموزشی (60٪)، ارزیابی (20٪) و آزمایشی (20٪). تابع BR نیازی به مجموعه آزمایشی ندارد (Kia, 2010)، لذا برای آن، 80٪ داده‌ها در مجموعه آموزشی و 20٪ در مجموعه ارزیابی قرار گرفتند. در الگوریتم مقیاس شده یا SCG که یک الگوریتم گرادیان توأم است به دلیل اینکه جستجوی خطی انجام نمی‌شود از مقدار محاسبات در هر تکرار به طور محسوسی کاسته می‌شود (Kia, 2010) که این مسئله سرعت بالای پردازش را به همراه خواهد داشت.

الگوریتم تنظیم بیزین

یکی از روش‌های بهبود عمومیت شبکه‌های عصبی تنظیم نام دارد که معمولاً نتایج مناسبی در بر دارد، چرا که این روش به مجموعه داده‌های معتبرسازی که جدا از مجموعه آموزشی در نظر گرفته می‌شود نیاز ندارد و از تمام داده‌ها استفاده می‌کند (Kia, 2010). برای تنظیم دو روش وجود دارد. اصلاح توابع کارایی و تنظیم خودکار⁴. در تنظیم خودکار از روش بیزین استفاده می‌شود. این روش

برای پوشش شرایط مختلف آب و هوایی در این ایالت، تعداد نوزده ایستگاه هواشناسی در مناطق مختلف وجود دارد که در جدول 1 مشخصات آنها ارائه شده‌است. همچنین، یک اقلیم داخل کشور (مشهد) نیز به منظور بررسی کارایی نتایج در داخل کشور، مورد ارزیابی قرار گرفت. مشهد در طول جغرافیایی 59° 35' E و عرض جغرافیایی 36° 20' N و در ارتفاع 1050 متر از سطح دریا واقع شده‌است. در شهر مشهد میانگین دمای سالانه 12/5 و میانگین بارش سالانه 253/2 میلی‌متر است (Anonymous, 2017).

معماری شبکه عصبی

در این تحقیق از شبکه‌های عصبی پس‌انتشار¹ استفاده شده‌است. روال آموزش تا زمانی ادامه می‌یابد که خطای شبکه روند کاهشی داشته باشد. به این ترتیب از پیش‌برازش شبکه روی مجموعه آموزشی جلوگیری می‌شود. در تمامی شبکه‌ها از تابع تانژانت سیگموئید در لایه‌های میانی و از تابع خطی در لایه خروجی استفاده شده‌است. از نرم‌افزار MATLAB R2015a برای توسعه مدل‌های شبکه عصبی استفاده شد. با بررسی حالات مختلف، در نهایت سه تابع آموزش مختلف مورد ارزیابی قرار گرفتند: لونیبرگ - مارکووارت، الگوریتم گرادیان توأم مقیاس شده² و تنظیم بیزین³. در این تحقیق،

3- Bayesian Regularization
4- Automated Regularization

1- Backpropagation
2- Scaled Conjugate Gradient

می‌کند، ترکیبی از مربع خطاها و وزن‌ها را طبق رابطه (1) حداقل کرده و سپس ترکیب صحیح را به‌گونه‌ای انتخاب می‌کند که شبکه‌ای تولید شود که به‌خوبی عمومیت داشته باشد.

جدول 1- مشخصات ایستگاه‌های هواشناسی مورد مطالعه ایالت واشنگتن (Anonymous, 2015).

Table 1- Specifications of Washington State weather stations

نام ایستگاه Station name	طول جغرافیایی Longitude	عرض جغرافیایی Latitude	ارتفاع از سطح دریا Elevation (m)	میانگین بالاترین دمای روزانه Daily maximum Temp. (°C)	میانگین پایین‌ترین دمای روزانه Daily minimum Temp. (°C)
Bonneville Dam	121.93	45.64	24.38	16.72	8.52
Chamokane	117.73	48.03	594.36	15.27	0.15
Chief Joseph Dam	119.63	47.99	301.75	17.74	4.91
Deer Park	117.43	47.95	662.94	14.16	0.44
Entiat Fish Hatchery	120.32	47.69	314.85	18.65	4.89
Grand Coulee Dam	118.95	47.94	402.33	17.13	6.97
George	119.64	47.04	350.52	17.1	2.79
Goldendale	120.82	45.81	512.06	15.77	1.11
Harrah	120.57	46.38	259.08	18.16	4.05
Kettle Falls	118.12	48.59	408.43	15.81	3.61
Lake Bryan	117.65	46.69	192.02	19.91	6.57
Legrow	118.93	46.2	176.78	18.48	5.87
Liberty Lake	117.08	47.66	587.04	18.11	5.43
Lind	118.73	46.86	449.58	16.62	4.56
Manson	120.12	47.91	601.06	15.57	3.53
Odessa	118.87	47.3	502.92	16.83	2.94
Omak	119.57	48.4	376.42	16.44	3.16
Seven Bays Marina	118.34	47.85	417.57	17.28	5.58
Silcott Island	117.18	46.41	251.46	19.17	7.58

در شبکه‌های عصبی بیزین وزن‌ها به‌صورت متغیرهای تصادفی شناخته می‌شوند و لذا تابع چگالی بر طبق قوانین بیز به شکل رابطه (2) نوشته می‌شوند (Forsee and Hagan, 1997):

$$P(w|D, \alpha, \beta, M) = \frac{P(D|w, \beta, M)P(w|\alpha, M)}{P(D|\alpha, \beta, M)} \quad (2)$$

در رابطه (2)، W بردار وزن‌های شبکه، D داده‌های آموزش و M مدل شبکه عصبی مورد استفاده می‌باشد. در شبکه‌هایی که به روش بیزین تنظیم شده‌اند، شبکه کار محاسبه و آموزش را روی وزن‌های مؤثرتر انجام می‌دهد. این وزن‌ها که پارامترهای مؤثر² نامیده می‌شوند با افزایش اندازه شبکه به یک عدد ثابت همگرا می‌شوند (Burden and Winkler, 2008).

پیش‌پردازش و پس‌پردازش داده‌ها

آموزش شبکه‌های عصبی در صورت اعمال یک‌سری پیش‌پردازش‌ها روی ورودی‌ها و هدف‌ها می‌تواند کارایی بالاتری داشته

به‌طور کلی هدف از مرحله آموزش کاهش مجموع مربعات خطای خروجی مدل و مقدار هدف است که تنظیم بیزین یک عبارت دیگر به آن اضافه می‌کند (Ticknor, 2013)، لذا می‌توان بیان داشت که تنظیم بیزین باعث می‌شود که ریسک بیش‌برازش¹ به حداقل خود برسد:

$$F = \beta ED + Ew \quad (1)$$

در رابطه (1)، F تابع هدف، EW مجموع مربعات وزن‌های شبکه و ED مجموع مربعات خطاها می‌باشد. α و β نیز پارامترهای تابع هدف (پارامترهای تنظیم) هستند (Mackay, 1992).

این الگوریتم زمانی که ورودی‌ها و هدف‌های شبکه در محدوده $[-1, 1]$ مقیاس شده باشند بهترین نتیجه را ارائه می‌دهد (Kia, 2010). هنگام استفاده از این الگوریتم این مسئله خیلی مهم است که اجازه دهیم تا همگرایی مؤثر همه پارامترها اجرا شود. همچنین، زمانی که مجموع مربعات خطاها (ED) و مجموع مربعات وزن‌ها (EW) برای چندین تکرار ثابت باقی بمانند می‌توان گفت الگوریتم همگرا شده و می‌توان آموزش را متوقف نمود.

2- Effective number of parameters

1- Overfitting


در رابطه (3)، $y_{\max} = 1$ و $y_{\min} = -1$ می‌باشد. عکس این فرآیند (پس‌پردازش) روی خروجی‌های تولید شده اعمال می‌شود تا داده‌ها به مقیاس اولیه برای انجام مقایسات تبدیل گردند.

طراحی شبکه‌های عصبی

در این پژوهش پارامترهای حداکثر، حداقل و متوسط دمای روزانه به‌عنوان ورودی، و تابش روزانه خورشیدی به‌عنوان خروجی شبکه‌های عصبی لحاظ گردید (شکل 2). خروجی مدل‌های حاصل با داده‌های واقعی میزان تابش خورشیدی روزانه مقایسه شدند.

باشد. اکثر توابع ایجاد شبکه‌های عصبی به‌صورت خودکار عملیات پیش‌پردازش را روی داده‌های آموزشی انجام می‌دهند. در مورد الگوریتم BR با مقیاس کردن داده‌ها در بازه $[-1, 1]$ نتایج بهتری به‌دست می‌آید. از این رو برای این الگوریتم، نرمال‌سازی با استفاده از تابع mapminmax انجام شده‌است. این تابع داده‌های ورودی و خروجی را به‌گونه‌ای پردازش می‌کند که بازه آنها به $[-1, 1]$ تبدیل شود. از رابطه (3) برای نرمال‌سازی داده‌ها استفاده شده‌است (Rohani et al., 2015):

$$y = \frac{(y_{\max} - y_{\min}) \times (x - x_{\min})}{(x_{\max} - x_{\min})} + y_{\min} \quad (3)$$



شکل 2- ساختار یک شبکه عصبی با سه ورودی، دو لایه پنهان و یک خروجی

Fig. 2. Topology of a neural network with three inputs, two hidden layers, and one output

خورشیدی برای 11254 روز استخراج گردید. بهترین شبکه‌های یک و دو لایه با هریک از توابع آموزشی (در مجموع شش مدل) برای این ایستگاه با بررسی شبکه‌های عصبی ایجاد شده به‌دست آمدند. این مدل‌ها در ابتدا در سایر ایستگاه‌های ایالت واشنگتن ارزیابی شدند تا کارایی و اعتبار آنها مورد بررسی قرار گیرد. سپس، بهترین تابع آموزش در کل ایستگاه‌ها، انتخاب شده و به منظور اثبات کارایی در شرایط اقلیمی مشهد مورد ارزیابی قرار گرفت. در ایستگاه مشهد داده‌های روزانه هواشناسی در طی سال‌های 1992 تا 2014 جمع‌آوری شد که پس از حذف داده‌های گم شده و پرت مشتمل بر 4988 روز بود.

در ابتدا، یکی از ایستگاه‌های ایالت واشنگتن (ایستگاه Lind) با بیشترین داده معتبر هواشناسی که مشتمل بر 32 سال داده‌های روزانه می‌باشد برای توسعه مدل‌های شبکه عصبی در نظر گرفته شد. ابتدا توابع آموزشی LM، BR و SCG با یک لایه پنهان از یک تا 20 نرون متغیر و سپس همین توابع آموزشی با دو لایه پنهان هر کدام از یک تا 20 نرون اعمال شدند. بنابراین قابلیت شبکه عصبی برای پیش‌بینی میزان تابش خورشیدی از روی مقادیر دمای روزانه در ایستگاه Lind با ارزیابی 1260 شبکه عصبی بررسی شد. در این ایستگاه (Lind) پس از حذف داده‌های نامناسب و گم شده، مقادیر حداکثر، حداقل و متوسط دمای روزانه و نیز میزان تابش جهانی

در جدول‌های 2 و 3 مشخصات بهترین شبکه‌های عصبی با یک و دو لایه پنهان و شاخص‌های آماری حاصل از ارزیابی ایستگاه Lind ارائه شده‌است. در تمامی حالت‌ها، حداکثر 1000 تکرار برای فرآیند آموزش شبکه لحاظ گردید. همچنین، نتایج حاصل از ارزیابی ایستگاه Lind با شبکه‌های عصبی یک‌لایه و دو‌لایه در شکل‌های 3 و 4 نشان داده شده‌است.

از بین 1260 شبکه عصبی توسعه داده شده برای ایستگاه Lind، یک شبکه عصبی یک لایه و یک شبکه عصبی دو لایه که بهترین عملکردها را با هریک از توابع آموزش داشتند به‌طور جداگانه در جدول 2 معرفی شده‌اند. اعداد 1 و 2 در کنار نام توابع آموزشی بیان‌گر بهترین شبکه یک و دو لایه آن تابع می‌باشند. همان‌گونه که در این جدول مشاهده می‌شود، شبکه‌های عصبی یک و دو لایه تفاوت معنی‌داری در عملکرد ندارند، در حالت یک لایه، بهترین عملکرد مربوط به تابع BR است که برای آن، تعداد پارامترهای مؤثر 85/3 به‌دست آمد. در رده بعدی دقت، تابع LM و پس از آن SCG قرار می‌گیرد. در بین شبکه‌های دو لایه نیز شرایط مشابه است، به‌طوری‌که تابع BR با تعداد 261 پارامتر مؤثر بهترین دقت را نشان داد که از این منظر با تابع LM تفاوت معنی‌داری نداشت.

معیارهای ارزیابی شبکه عصبی

برای ارزیابی شبکه‌های عصبی ایجاد شده معیارهای مقایسه شامل ضریب همبستگی، ریشه میانگین مربعات خطا (RMSE) و متوسط قدرمطلق درصد خطا (MAPE) مطابق با روابط (4) و (5) استفاده گردید. همچنین معادله رگرسیونی بین مقادیر پیش‌بینی شده توسط مدل و مقادیر واقعی آن بررسی شدند.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (A_t - F_t)^2}{n}} \quad (5)$$

در این رابطه‌ها، A_t مقادیر واقعی، F_t مقادیر پیش‌بینی شده توسط شبکه عصبی و n تعداد نقاط می‌باشد.

نتایج و بحث

ارزیابی شبکه‌های عصبی با یک و دو لایه پنهان برای ایستگاه Lind

جدول 2- مشخصات بهترین شبکه‌های به‌دست آمده یک و دو لایه پنهان برای ایستگاه Lind

Table 2- Properties of the best derived one and two-hidden layer networks for Lind station

تابع آموزش Training function	معماری Architecture	R (all)	R (Training)	R (Validation)	R (test)	RMSE	MAPE
LM1	3-14-1	0.9089	0.9083	0.9046	0.9010	3.81	31.63
BR1	3-20-1	0.9093	0.9098	-	0.9102	3.80	33.73
SCG1	3-9-1	0.8977	0.8947	0.8870	0.8791	4.02	38.92
LM2	3-11-19-1	0.9101	0.9112	0.9081	0.8962	3.78	34.02
BR2	3-20-19-1	0.9143	0.9111	-	0.9086	3.70	34.16
SCG2	3-20-17-1	0.9022	0.8930	0.8940	0.8806	3.94	34.93

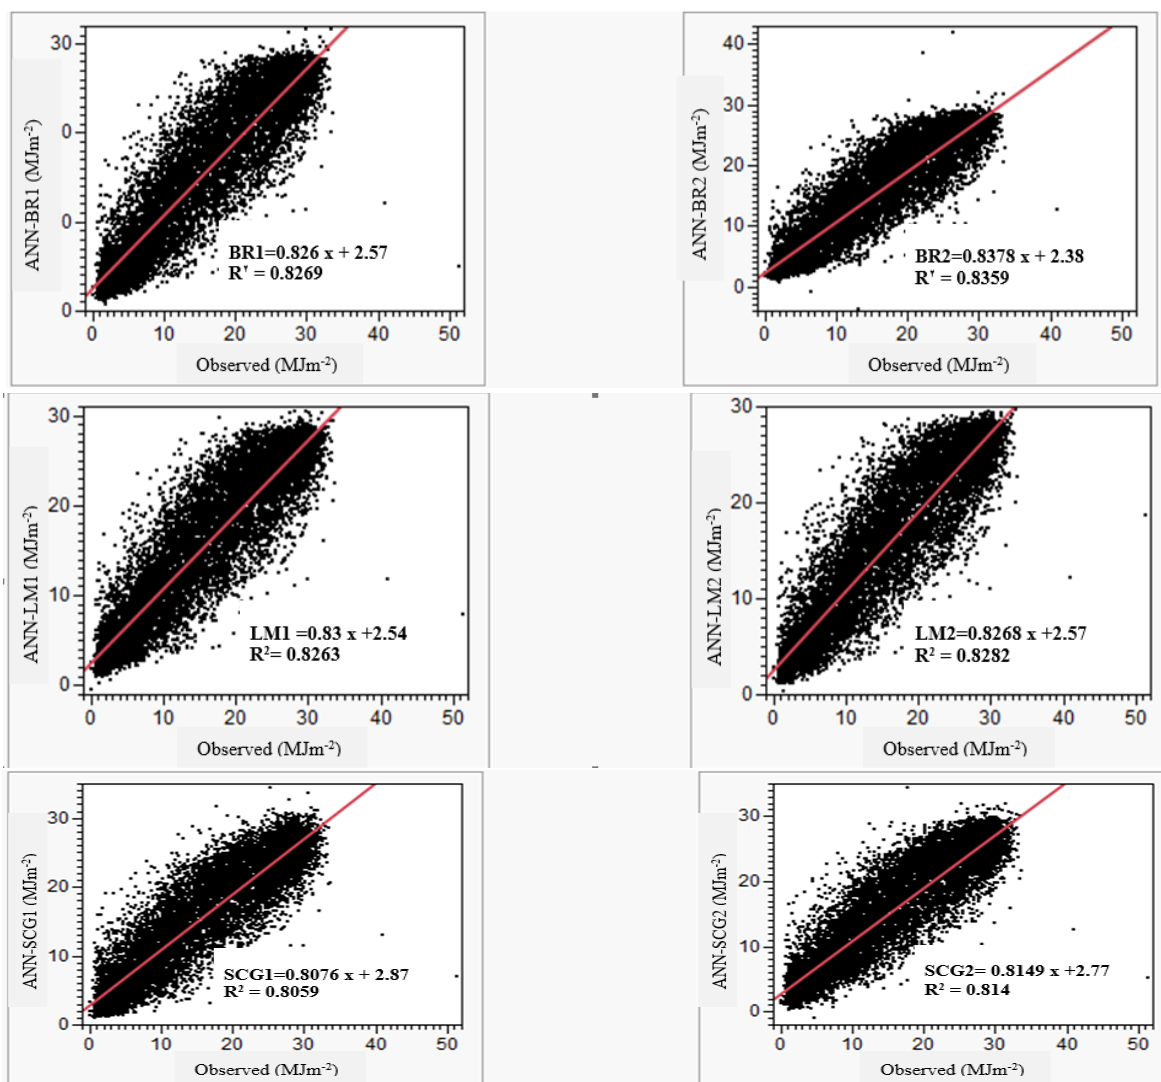
چولگی به سمت راست است. این شاخص برای یک توزیع کاملاً متقارن صفر است (Behboudian, 2015). این شرایط برای تمامی مقادیر پیش‌بینی شده با توجه به چولگی‌های نزدیک‌تر به صفر مشهودتر از مقادیر مشاهده شده‌است. به‌عبارت دیگر، زیاد بودن چولگی در داده‌های مشاهده شده بیانگر تقارن کمتر منحنی توزیع برای آن است. همچنین مشاهده می‌شود که در تمامی موارد کشیدگی دارای مقادیر منفی است، یعنی در تمامی روش‌های مشاهده و پیش‌بینی شده، ارتفاع نمودار تابع توزیع، کوتاه‌تر از توزیع نرمال است. نمودار پراکندگی مقادیر مشاهده شده در برابر مقادیر پیش‌بینی شده توسط بهترین شبکه‌های عصبی یک و دو لایه برای ایستگاه Lind در شکل 3 نشان داده شده‌اند. با توجه به این شکل مشاهده می‌شود که شبکه عصبی دو لایه با تابع آموزش BR بالاترین

جدول 3 مقایسه ویژگی‌های آماری مقادیر مشاهده شده داده‌های هواشناسی و مقادیر پیش‌بینی شده توسط شش شبکه عصبی منتخب را برای ایستگاه Lind نشان می‌دهد. بر طبق آن، شبکه‌های عصبی LM1، BR1 و BR2 نسبت به مقادیر مشاهده شده، کم برآورد¹ و شبکه‌های عصبی LM2، SCG1 و SCG2 نسبت به مقادیر مشاهده شده، بیش برآورد² داشته‌اند. مقادیر چولگی که معیاری از تقارن یا عدم تقارن تابع توزیع می‌باشد برای تمامی مقادیر مشاهده و پیش‌بینی شده به‌جز SCG1 مثبت است که نشان می‌دهد به‌جز SCG1 که در آن، توزیع دارای نامتقارنی با چولگی به سمت چپ است در سایر موارد

- 1- Underestimation
- 2- Overestimation

پردازش بالاتر این تابع در قیاس با دو تابع دیگر است. در مجموع با توجه به جدول 2 و نیز شکل‌های 3 و 4، توابع BR1، LM2، BR2، LM1، SCG1 و SCG2 به‌ترتیب بالاترین دقت‌ها را داشتند. همین‌طور به‌لحاظ سرعت پردازش به‌ترتیب رده‌بندی توابع به‌صورت SCG1، SCG2، LM1، LM2، BR1 و BR2 است.

همبستگی را با داده‌های مشاهده شده دارد. این امر هم به دلیل ضریب تبیین بالاتر و هم به دلیل کوچک‌ترین عرض از مبدأ می‌باشد. همچنین شکل 4 نشان می‌دهد که شبکه عصبی تک‌لایه با تابع آموزش SCG در مجموع، مقادیر کمتری از MSE را تجربه می‌کند که از این منظر تابع آموزش BR در مقادیر بالاتر، تغییر می‌کند. این نکته بدان معناست که تابع آموزش SCG در طول فرآیند آموزش، وزن‌ها و بایاس‌ها را زودتر همگرا می‌کند، که نشان‌دهنده سرعت




شکل 3- نمودار پراکندگی مقادیر مشاهده شده در برابر مقادیر پیش‌بینی شده توسط بهترین شبکه‌های عصبی یک و دو لایه برای ایستگاه Lind
Fig. 3. Scatter plot of the observed vs. predicted solar radiation by the best one and two-hidden layer ANNs for Lind station

جدول 3- ویژگی‌های آماری مقادیر مشاهده شده و پیش‌بینی شده تابش خورشیدی برای ایستگاه Lind
Table 3- Statistical properties of the observed and predicted solar radiation for Lind station

میزان تابش خورشیدی Solar radiation (MJm ⁻²)	ویژگی‌های آماری Statistical properties						
	Ave	sum	std	max	min	kur	ske
Observed	14.79	166396.66	9.13	51.39	0.01	-1.25	0.17
LM1	14.78	166353.76	8.29	31.62	0.68	-1.36	0.02
BR1	14.78	166373.11	8.31	30.88	-0.43	-1.38	0.03
SCG1	14.81	166699.99	8.22	34.43	1.05	-1.34	-0.01
LM2	14.80	166546.12	8.30	29.80	0.29	-1.37	0.03
BR2	14.77	166168.65	8.10	42.74	-3.70	-1.35	0.04
SCG2	14.82	166768.10	8.25	34.33	-0.96	-1.35	0.02

* ave: میانگین، sum: مجموع، std: انحراف معیار، max: بیشینه، min: کمینه، kur: کشیدگی، ske: چولگی



شکل 4- تغییرات MSE برای سه تابع آموزش با تعداد نرون‌های یک تا 20 در شبکه‌های عصبی با یک لایه پنهان برای ایستگاه Lind
Fig. 4. Variation of MSE for the three training functions with one to twenty neurons in one hidden layer-ANNs for Lind station

عصبی مورد استفاده وابسته به شرایط آب و هوایی نیستند. این مسئله به‌خصوص در ارزیابی تابش خورشیدی در مناطق مختلف کشور ایران حائز اهمیت می‌باشد. چون در شرایطی که کمترین داده‌های هواشناسی موجود باشد، تنها با به‌کارگیری داده‌های دمای روزانه می‌توان به برآورد مناسبی از تابش خورشیدی دست یافت. بررسی این موضوع، مدل‌های یک و دولایه مبتنی بر تابع آموزش BR که تقریباً در تمامی شرایط آب و هوایی ایالت واشنگتن بهترین نتیجه را به‌همراه داشت در ایستگاه هواشناسی مشهد به‌عنوان یک نمونه اقلیم داخل کشور، انتخاب و کارایی آن بررسی شد که نتایج آن در جدول 5 نمایش داده شده‌است. همچنین، نمودار پراکندگی مقادیر مشاهده شده در برابر مقادیر پیش‌بینی شده توسط بهترین شبکه‌های عصبی یک و دولایه بیزین برای ایستگاه مشهد در شکل 5 ارائه شده‌است. نتایج نشان می‌دهد که شبکه‌های عصبی بیزین در این اقلیم نیز قادر به برآورد میزان تابش خورشیدی می‌باشند و دقت شبکه‌های یک و دولایه تقریباً مشابه هم است. شکل 6 تغییرات تابش خورشیدی مشاهده شده و پیش‌بینی شده توسط شبکه عصبی BR2 (که تقریباً عملکردی مشابه BR1 داشته است) را در روزهای مختلف سال برای ایستگاه مشهد نشان می‌دهد. همان‌گونه که در این

بررسی کارایی بهترین شبکه‌های عصبی به‌دست آمده در سایر ایستگاه‌ها

این ارزیابی به‌منظور بررسی تعمیم‌پذیری مدل‌های به‌دست آمده در سایر شرایط آب و هوایی می‌باشد. نتایج به‌دست آمده برای ایستگاه‌های دیگر ایالت واشنگتن که در جدول 4 ارائه شده‌است مشابه با نتایج حاصل از ایستگاه Lind است. با توجه به این جدول مشاهده می‌شود که به‌جز یک ایستگاه (Entiat Fish Hatchery) با تعداد داده‌های معتبر کم (724) که در آن، شبکه عصبی LM با دو لایه پنهان عملکرد بهتری داشته‌است، در سایر موارد شبکه عصبی BR با دولایه پنهان (BR2) بهترین نتیجه را نشان داد. شبکه عصبی SCG در رده آخر عملکرد اما با سریعترین زمان پردازش قرار دارد که آن را برای کاربردهای آنلاین مناسب‌تر می‌سازد. در نهایت، شبکه عصبی LM به‌لحاظ دقت و نیز سرعت پردازش، در رده دوم قرار گرفت. بنابراین شبکه عصبی BR2 را می‌توان برای پیش‌بینی تابش خورشیدی با استفاده از داده‌های دما در ایالت واشنگتن توصیه نمود.

نتایج حاصل از جدول 4 نشان می‌دهند که توانایی شبکه‌های

شکل مشاهده می‌شود شبکه‌های عصبی BR روند تغییرات تابش را در روزهای مختلف سال به شکلی مناسب پیش‌بینی کرده‌اند.

جدول 4- نتایج بررسی کارایی بهترین شبکه‌های عصبی برای سایر ایستگاه‌های هواشناسی ایالت واشنگتن

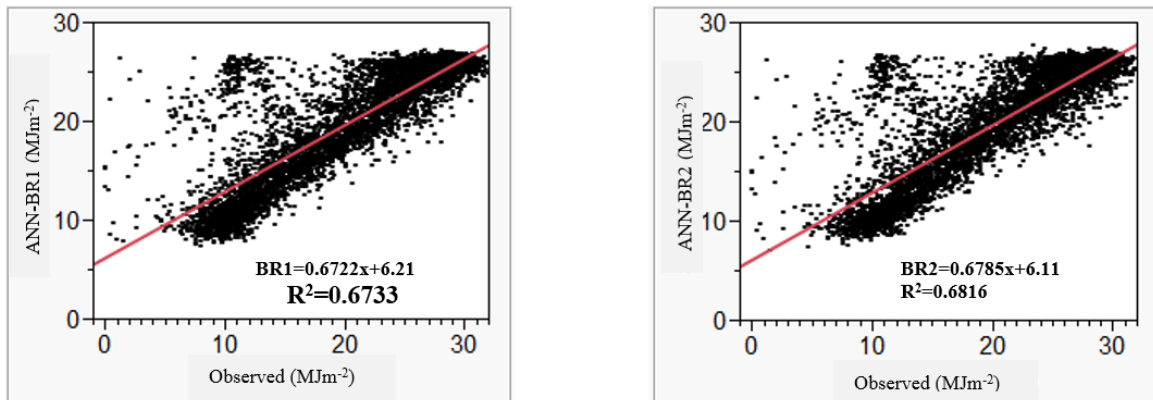
Table 4- Results of the performance of the best ANNs for the remaining Washington State weather stations

نام ایستگاه و تعداد داده معتبر Station name and the # of valid data	تابع آموزش Training function	R	RMSE	MAPE	نام ایستگاه و تعداد داده معتبر Station name and the # of valid data	تابع آموزش Training function	R	RMSE	MAPE
Bonneville Dam (4916)	LM1	0.8929	4.24	67.41	Silcott Island (4926)	LM1	0.8981	4.02	38.79
	BR1	0.8982	4.14	66.55		BR1	0.899	4.00	39.19
	SCG1	0.8703	4.64	77.28		SCG1	0.8885	4.20	42.98
	LM2	0.8976	4.15	65.49		LM2	0.8982	4.02	38.72
	BR2	0.9047	4.01	62.75		BR2	0.909	3.81	36.35
Chamokane (2887)	SCG2	0.8726	4.60	76.89	SCG2	0.8887	4.19	41.76	
	LM1	0.9109	3.79	42.37	LM1	0.9065	3.75	38.14	
	BR1	0.9101	3.81	41.61	BR1	0.9076	3.73	38.03	
	SCG1	0.8938	4.13	50.64	SCG1	0.8774	4.26	42.75	
	LM2	0.9091	3.83	42.19	LM2	0.9078	3.72	37.2	
Chief Joseph Dam (4923)	BR2	0.9152	3.70	40.75	BR2	0.9091	3.70	37.27	
	SCG2	0.885	4.29	46.41	SCG2	0.8976	3.91	40.58	
	LM1	0.9088	3.97	32.75	LM1	0.9013	4.04	34.33	
	BR1	0.9118	3.91	31.43	BR1	0.9024	4.02	33.93	
	SCG1	0.8968	4.21	37.57	SCG1	0.8679	4.63	41.46	
Deer Park (493)	LM2	0.9101	3.95	30.62	LM2	0.9014	4.04	34.01	
	BR2	0.9133	3.88	30.46	BR2	0.9050	3.96	33.04	
	SCG2	0.8955	4.24	36.39	SCG2	0.8875	4.30	38.23	
	LM1	0.8949	4.21	42.91	LM1	0.8888	3.88	31.97	
	BR1	0.9047	3.95	36.45	BR1	0.889	3.88	30.42	
Harrah (10312)	SCG1	0.871	4.56	47.43	SCG1	0.8364	4.68	49.13	
	LM2	0.9152	3.75	31.79	LM2	0.9027	3.64	29.14	
	BR2	0.9242	3.54	32.7	BR2	0.8967	3.75	29.66	
	SCG2	0.8612	4.72	42.66	SCG2	0.8725	4.14	34.42	
	LM1	0.896	4.02	30.73	LM1	0.9073	3.98	35.85	
Liberty Lake (340)	BR1	0.899	3.96	29.96	BR1	0.9096	3.93	36.26	
	SCG1	0.867	4.51	36.94	SCG1	0.892	4.28	39.84	
	LM2	0.8984	3.98	30.07	LM2	0.9048	4.03	36.65	
	BR2	0.905	3.85	28.81	BR2	0.9149	3.82	35.07	
	SCG2	0.8812	4.28	33.74	SCG2	0.8903	4.31	40.55	
Legrow (10445)	LM1	0.8854	4.45	55.06	LM1	0.8796	4.52	46.29	
	BR1	0.8885	4.39	53.86	BR1	0.8817	4.48	43.9	
	SCG1	0.8687	4.73	58.76	SCG1	0.8506	4.99	50.01	
	LM2	0.8698	4.76	49.52	LM2	0.8835	4.45	42.84	
	BR2	0.8916	4.33	50.01	BR2	0.8893	4.34	42.2	
Odessa (11237)	SCG2	0.8694	4.72	55.4	SCG2	0.8698	4.69	48.6	
	LM1	0.8865	4.31	41.52	LM1	0.9128	3.76	38.31	
	BR1	0.8886	4.27	45.19	BR1	0.9136	3.75	37.92	
	SCG1	0.8544	4.84	61.95	SCG1	0.902	3.98	41.87	
	LM2	0.8882	4.27	41.18	LM2	0.9139	3.74	38.76	
Seven Bays Manina (4931)	BR2	0.8925	4.2	37.99	BR2	0.9155	3.71	37.38	
	SCG2	0.8742	4.52	48.38	SCG2	0.9016	3.98	45.68	
	LM1	0.8977	3.99	34.55	LM1	0.8988	4.12	39.29	
	BR1	0.8996	3.96	33.85	BR1	0.8994	4.12	38.94	
	SCG1	0.8653	4.54	41.23	SCG1	0.8784	4.49	45.11	
Mansion (7647)	LM2	0.8989	3.97	33.81	LM2	0.8985	4.12	39.69	
	BR2	0.9027	3.9	33.4	BR2	0.9108	3.88	34.88	
	SCG2	0.8675	4.51	42.43	SCG2	0.8736	4.57	46.09	
	LM1	0.9129	3.84	35.96	LM1	0.8553	5.02	34.81	
	BR1	0.9161	3.78	34.38	BR1	0.8294	5.44	33.34	
Lake Bryan (4839)	SCG1	0.8966	4.17	40.99	SCG1	0.837	5.30	40.83	
	LM2	0.9152	3.79	34.87	LM2	0.8571	4.99	33.3	
	BR2	0.924	3.6	32.02	BR2	0.8696	4.78	31.95	
	SCG2	0.9045	4.02	38.7	SCG2	0.8366	5.30	37.27	


جدول 5- مشخصات بهترین شبکه‌های به‌دست آمده یک و دو لایه پنهان با تابع آموزش BR برای ایستگاه مشهد

Table 5- Properties of the best one and two-hidden layer ANNs with BR training function for Mashhad station

تابع آموزش	معماری	R (all)	R (train g)	R (test)	RM SE	MAP E	تعداد پارامترهای مؤثر
BR1	3-20-1	0.8205	0.8186	0.8326	3.97	78.59	22.2
BR2	3-20-19-1	0.8256	0.8188	0.8628	3.92	79.92	59



شکل 5- نمودار پراکندگی مقادیر مشاهده شده در برابر مقادیر پیش‌بینی شده توسط شبکه‌های عصبی بیزین یک و دو لایه برای ایستگاه مشهد
Fig. 5. Scatter plots of the observed vs. predicted solar radiation by one and two-hidden layer Bayesian neural networks for Mashhad station



شکل 6- تغییرات تابش خورشیدی مشاهده شده در برابر مدل شبکه عصبی BR2 برای ایستگاه مشهد
Fig. 6. Variations of observed vs. predicted solar radiation by two-hidden layer Bayesian neural networks for Mashhad station

نتیجه‌گیری

در این پژوهش، با راهبرد شبکه عصبی و به‌کارگیری سهل‌الوصول‌ترین داده‌های هواشناسی یعنی داده‌های دمای روزانه، مدل‌هایی برای پیش‌بینی میزان تابش جهانی خورشیدی ارائه شد. سه تابع آموزش لونیبرگ-مارکوارت، الگوریتم گرادیان توأم مقیاس شده و تنظیم بیزین در شبکه‌های عصبی یک و دو لایه با حداکثر 20 نرون در هر لایه بررسی شدند. این مدل‌ها بر روی ایالت واشنگتن امریکا که تنوع اقلیمی فراوانی دارد پیاده شده و کارایی آنها ارزیابی شد. از بین آنها، شبکه‌های عصبی بیزین تقریباً در تمامی مناطق این ایالت

در تحقیقات مشابهی که از شبکه‌های عصبی مصنوعی برای پیش‌بینی تابش خورشیدی استفاده شده‌است، پارامترهای ورودی زیادی لحاظ شدند و مدل‌ها مختص یک یا تعداد کمی اقلیم بوده‌است (Motamed-Shariati *et al.*, 2016; Anjavi *et al.*, 2014). اما در پژوهش حاضر تنها از یک پارامتر هواشناسی (دما) به‌عنوان ورودی استفاده شد که برای آن کمترین تجهیزات اندازه‌گیری نیاز است. همچنین، مدل‌های توسعه‌یافته در اینجا به اقلیم وابسته نبوده و تعمیم‌پذیری بیشتری داشتند. لذا، کاربرد این مدل‌ها در مناطقی با کمترین تجهیزات هواشناسی نمود بیشتری دارد.

مناسبی از این پارامتر در اقلیم‌های مختلف کشور دست یافت و از آن در کاربردهای مختلف مثل کشاورزی و نیز توسعه سامانه‌های خورشیدی استفاده نمود.

سیاسگزاری

این طرح با پشتیبانی صندوق حمایت از پژوهشگران و فناوران کشور طی قرارداد شماره 93011269 اجرا شده است که بدین‌وسیله از این نهاد تشکر و قدردانی می‌شود. همچنین، از ایستگاه هواشناسی مشهد برای تأمین داده‌های هواشناسی مورد نیاز تقدیر می‌گردد.

بهترین عملکرد را نشان دادند ($0/87 < R < 0/92$). لذا از آنها برای پیش‌بینی تابش خورشیدی در شرایط داخل کشور و در اقلیم شهر مشهد به‌عنوان نمونه استفاده شد. نتایج نشان داد که در این اقلیم نیز شبکه‌های عصبی بیزین در برآورد تابش خورشیدی با استفاده از داده‌های دمای روزانه کارایی مناسبی دارند ($R=0/82$). برای افزایش دقت مدل‌های پیشنهادی این پژوهش افزودن پارامتر یا پارامترهایی به‌عنوان ورودی شبکه، بسته به امکانات و داده‌های موجود، قابل توصیه است. در مجموع، نتایج این پژوهش بیانگر آن است که در شرایطی که داده‌های تابش خورشیدی و یا تجهیزات پرهزینه مرتبط در دسترس نمی‌باشد با کمترین هزینه و امکانات می‌توان به برآورد

References

- Ahmad, E. A., and E. N. Adam. 2013. Estimate of global solar radiation by using artificial neural network in Qena, Upper Egypt. *Journal of Clean Energy Technologies* 1: 148-150.
- Aksoy, B., S. Ener Rusen, and B. Akinoglu. 2011. A Simple correlation to estimate global solar irradiation on a horizontal surface using METEOSTAT satellite images. *Turkish Journal of Engineering and Environmental Sciences* 35 (2): 125-137.
- Allen, R. G. 1997. Self-calibrating method for estimating solar radiation from air temperature. *Journal of Hydrologic Engineering* 2 (2): 56-67.
- Almorox, J., M. Bocco, and E. Willington. 2013. Estimation of daily global solar radiation from measured temperatures at Canada de Lague, Cordoba, Argentina. *Renewable Energy* 60: 382-387.
- Anjavi Arsanjani, M., M. Yaghoubi, and K. JafarPour, 2014. Evaluation of solar energy potential in some climatological zones of Iran using artificial neural network. *The first International Solar Energy Conference and Exhibition, Tehran, Iran. (In Farsi)*.
- Anonymous. 2017. I.R. of Iran Meteorological Organization. from: <http://www.razavimet.ir/node/114>. Accessed 7 March 2017.
- Anonymous. 2015. Pacific Northwest Region. from: <https://www.usbr.gov/pn/agrimet/>. Accessed 10 April 2016.
- Behboudian, J. 2015. *Introductory Probability and Statistics*. Emam Reza publication. (In Farsi).
- Bindi, M., and F. Miglietta. 1991. Estimating daily global radiation from air temperature and rainfall measurements. *Climate Research* 1 (2): 117-124.
- Bristow, K. L. and G. S. Campbell. 1984. On the relationship between incoming solar radiation and daily maximum and minimum temperature. *Agricultural and Forest Meteorology* 31: 159-166.
- Burden, F., and D. Winkler. 2008. Bayesian regularization of neural networks. *Methods in Molecular Biology* 458: 25-44.
- Cornaro, C. F. 2013. Solar radiation forecast using neural networks for the prediction of grid connected PV plants energy production (DSP). *Proceedings of 28th European Photovoltaic Solar Energy Conference and Exhibition, Paris, France*.
- Dehghani, R., M. Ghorbani, M. Teshnehlab, A. Rikhtehgar Gheasi, and E. Asadi, 2015. Comparison and evaluation of bayesian neural network, gene gramming, support vector machine and multiple expression proLinear regression in river discharge estimation (Case Study: Sufi Chay Basin). *Journal of Irrigation and Water Engineering* 20: 66-85. (In Farsi).
- Faraji Mahyari, K., Z. Faraji Mahyari, and M. Khanali. 2015a. Modeling daily solar radiation temperature-based in four climate regions of Iran. *9th National Congress on Agricultural Machinery Engineering (Mechanics of Biosystems) and Mechanization, Tehran, Iran. (In Farsi)*.
- Faraji Mahyari, Z., K. Faraji Mahyari, and M. Khanali. 2015b. Evaluation of performance of empirical sunshine-based models for predicting the daily global solar radiation (Case Study: Bandar Abbas Station). *9th National Congress on Agricultural Machinery Engineering (Mechanics of Biosystems) and Mechanization,*

- Tehran, Iran. (In Farsi).
16. Forsee, F., and M. Hagan. 1997. Gauss-Newton approximation to bayesian learning. In 1997 IEEE international conference on neural networks, 1-4, pp. 1930-1935.
 17. Gadiwala, M., A. Usman, M. Akhtar, and K. Jamil. 2013. Empirical models for the estimation of global solar radiation with sunshine hours on horizontal surface in various cities of Pakistan. *Pakistan Journal of Meteorology* 9 (18): 43-49.
 18. Ghahreman, N., and B. Bakhtiari. 2009. Solar radiation estimation from rainfall and temperature data in arid and semi-arid climates of Iran. *Desert* 14: 141-150.
 19. Hargreaves, G. L., G. H. Hargreaves, and J. P. Riley. 1985. Irrigation water requirements for Senegal River basin. *Journal of Irrigation and Drainage Engineering, ASCE*, 111 (3): 265-275.
 20. Hunt, L. A., L. Kuchar, and C. J. Swanton. 1998. Estimation of solar radiation for use in crop modeling. *Agric. Forest. Meteorol.* 91: 293-300.
 21. Kia, M. 2010. Soft Computing in MATLAB. Kian Rayaneh Sabz. (In Farsi).
 22. Kim, K. H., J. C. Baltazar, and J. S. Haberl. 2014. Evaluation of meteorological base models for estimating hourly global solar radiation in Texas. *Energy Procedia* 57: 1189-1198.
 23. Layeghi, M. 2015. Solar energy, technologies and applications. Jahad daneshgahi publication. (In Farsi).
 24. Li, H., F. Cao, X. Wang, and W. Ma. 2014. A temperature-based model for estimating monthly average daily global solar radiation in China. *The Scientific World Journal*. 2014, 9 pages.
 25. Li, M. F., L. Fan, H. B. Liu, P. T. Guo, and W. Wu. 2013a. A general model for estimation of daily global solar radiation using air temperature and site parameters in Southwest China. *Journal of Atmospheric and Solar-Terrestrial Physics* 92: 145-150.
 26. Li, M. F., X. P. Tang, W. Wu, and H. B. Liu. 2013b. General models for estimating daily global solar radiation for different solar radiation zones in Mainland China. *Energy Conversion and Management* 70: 139-148.
 27. Liu, X., M. Xurong, Y. Li, Q. Wang, J. Raunso Jensen, Y. Zhang, and J. R. Porter. 2009. Evaluation of temperature-based global solar radiation models in China. *Agricultural and Forest Meteorology* 149: 1433-1446.
 28. Mackay, D. J. 1992. A practical bayesian framework for backpropagation networks. *Neural Computation* 4: 448-472.
 29. Mirzaee ghale, E., M. Omid, A. Keyhani, and S. Behzadi Pour. 2014. The use of solar energy for a model heating poultry house. Fifth International Conference on heating, cooling and ventilation Systems. Tehran, Iran. (In Farsi).
 30. Motamed-Shariati, H. R., H. Mobli, M. Sharifi, and H. Ahmadi. 2016. Prediction of solar radiation by ordinary weather data for Mashhad climate. *Iranian Journal of Biosystem Engineering* 47 (1): 185-196. (In Farsi).
 31. Mousazadeh, H. K. 2010. Optimal power and energy modeling and range evaluation of a solar assist plug-in hybrid electric tractor (SAPHT). *Transaction on ASABE*, 53 (4): 1-11.
 32. Mubiru, J. 2011. Using artificial neural network to predict direct solar irradiation. *Advances in Artificial Neural Systems*. 2011, 6 pages.
 33. Namrata, K., S. Sharma, and S. Saksena. 2013. Comparison of different models for estimation of global solar radiation in Jharkhand (India) Region. *Smart Grid and Renewable Energy* 4: 384-352.
 34. Paoli, C., C. Voyant, M. Muselli, and M. L. Nivet. 2009. Solar radiation forecasting using ad-hoc time series preprocessing and neural network. *Emerging Intelligent Computing Technology and Applications 5th International Conference on Intelligent Computing*. Ulsan, South Korea.
 35. Razafiarison, I., L. Andriazafimahazo, B. Ramamonjisoa, and B. Zeghmati. 2011. Using multilayered neural networks for determining global solar radiation upon tilted surface in Fianarantsoa Madagascar. *Reveu des Energies Renouvelables* 14: 329-342.
 36. Rivington, M., G. Bellocchi, K. B. Matthews, and K. Buchan. 2005. Evaluation of three model estimation of solar radiation at 24 UK stations. *Agriculture and Forest Meteorology* 132: 228-243.
 37. Rohani, A., S. Saedi, H. Gerailu, and M. H. Aghkhani. 2015. Prediction of lateral surface, volume and sphericity of pomegranate using MLP artificial neural network. *Journal of Agricultural Machinery* 5: 292-

301. (In Farsi).
38. Sabziparvar, A. A. 2008. A Simple formula for estimation global solar radiation in central arid deserts of Iran. *Renewable Energy* 33: 1002-1010.
39. Samani, Z. 2000. Estimating solar radiation and evapotranspiration using minimum climatological data. *Journal of Irrigation and Drainage Engineering* 126 (4): 265-275.
40. Ticknor, J. L. 2013. A bayesian regularized artificial neural network for stock market forecasting. *Expert Systems with Applications* 40: 5501-5506.
41. Wang, F., Z. Mi, S. Su, and H. Zhao. 2012. Short term solar irradiance forecasting model based on artificial neural network using statistical feature parameters. *Energies* 5: 1355-1370.
42. Yano, A. O. 2014. Prototype semi-transparent photovoltaic modules for greenhouse roof application. *Biosystems Engineering*, 122: 62-73.

Prediction of Daily Global Solar Radiation by Daily Temperatures and Artificial Neural Networks in Different Climates

S. I. Saedi¹ - R. Alimardani^{2*} - H. Mousazadeh³

Received: 05-02-2017

Accepted: 13-05-2017

Introduction

Global solar radiation is the sum of direct, diffuse, and reflected solar radiation. Weather forecasts, agricultural practices, and solar equipment development are three major fields that need proper information about solar radiation. Furthermore, sun is regarded as a huge source of renewable and clean energy which can be used in numerous applications to get rid of environmental impacts of non-renewable fossil fuels. Therefore, easy and fast estimation of daily global solar radiation would play an effective role in these affairs.

Materials and Methods

This study aimed at predicting the daily global solar radiation by means of artificial neural network (ANN) method, based on easy-to-gain weather data i.e. daily mean, minimum and maximum temperatures. Having a variety of climates with long-term valid weather data, Washington State, located at the northwestern part of USA was chosen for this purpose. It has a total number of 19 weather stations to cover all the State climates. First, a station with the largest number of valid historical weather data (Lind) was chosen to develop, validate, and test different ANN models. Three training algorithms i.e. Levenberg – Marquardt (LM), Scaled Conjugate Gradient (SCG), and Bayesian regularization (BR) were tested in one and two hidden layer networks each with up to 20 neurons to derive six best architectures. R, RMSE, MAPE, and scatter plots were considered to evaluate each network in all steps. In order to investigate the generalizability of the best six models, they were tested in other Washington State weather stations. The most accurate and general models were evaluated in an Iran sample weather station which was chosen to be Mashhad.

Results and Discussion

The variation of MSE for the three training functions in one hidden layer models for Lind station indicated that SCG converged weights and biases in shorter time than LM, and LM did that faster than BR. It means that SCG provided the fastest performance. However, the story for accuracies was different i.e. the BR, LM, and SCG algorithms provided the most accurate performances, respectively, both among one or two hidden layers. According to the evaluation criteria, six most accurate derived models out of 1260 tested ones for Lind station were 3-14-1 and 3-11-19-1 with LM, 3-20-1 and 3-20-19-1 with BR, and 3-9-1 and 3-20-17-1 with SCG training algorithm, and 3-20-19-1 topology with BR showed the best performance out of all architectures. Results of the evaluation of the six accurate models in the remaining 18 stations of Washington State proved that regardless of the climate, in each weather station, BR with its inherent automatic regularization, provided the most accurate models ($0.87 < R < 0.92$, $3.54 < RMSE < 4.78$ MJm⁻², $28.81 < MAPE < 62.75$ %), then LM ($0.91 < R < 0.85$, $3.64 < RMSE < 5.02$ MJm⁻², $29.14 < MAPE < 67.41$ %), and then SCG ($0.90 < R < 0.83$, $3.91 < RMSE < 5.30$ MJm⁻², $33.74 < MAPE < 77.28$ %). Therefore, the Bayesian neural networks, which showed the best performance among all Washington State weather stations, were evaluated for Mashhad station, as an Iran sample climate. The results proved the ability of the said networks for this climate ($R=0.82$, $RMSE=3.92$ MJm⁻², $MAPE=79.92$ %).

Conclusions

The results indicated that the Bayesian neural networks are capable of predicting global solar radiation with minimum inputs in different climates. This was concluded both in Washington State weather stations, which has a variety of climates, and also in Mashhad as an Iran sample weather station. These models would eliminate the

1- Assistant Professor, Faculty of Agriculture, Shahrood University of Technology, Shahrood, Iran

2- Professor, Department of Agricultural Machinery, Faculty of Agricultural Engineering and Technology, University College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

3- Associate Professor, Department of Agricultural Machinery, Faculty of Agricultural Engineering and Technology, University College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

(* - Corresponding Author Email: rwardani@ut.ac.ir)

need for complex climate-dependent mathematical relations or other models which are mostly dependent on many inputs. So, this algorithm would be a good means first in weather forecast practices, also in the design and development of solar assisted equipment, as well as in managerial practices in agriculture when monitoring crop solar-dependent processes like photosynthesis and evapotranspiration.

Keywords: Bayesian regularization, Daily temperature, Global solar radiation, Neural network