

ارزیابی عملکرد شبکه عصبی مصنوعی در پیش‌بینی تابش خورشیدی روزانه کشور

ایران

محمد هادی پور^۱، مهران عامری^{۲*}

^۱ کارشناس ارشد گروه مهندسی مکانیک، دانشگاه شهید باهنر کرمان، ایران

mmhadipoor@gmail.com

^۲ استاد گروه مهندسی مکانیک و پژوهشکده انرژی و محیط زیست، دانشگاه شهید باهنر کرمان، ایران

ameri_mm@uk.ac.ir

چکیده: در ایران به طور متوسط، ۵/۵ کیلووات ساعت انرژی خورشیدی بر هر مترمربع از سطح زمین می‌تابد و ۳۰۰ روز آفتابی در ۹۰٪ خاک ایران موجود است. با توجه به این میزان تابش و لزوم آگاهی از پهنه‌بندی پتانسیل خورشیدی جهت بهره‌وری مناسب، نیاز به رسم نقشه‌های پتانسیل خورشیدی است. در این مطالعه، از داده‌های ماهیانه ۱۰ ساله (۱۹۹۱-۲۰۰۰ میلادی)، موجود ۳۹ ایستگاه سینوپتیک هواشناسی ایران به‌عنوان داده‌های ورودی به نرم‌افزار Matlab و شبکه عصبی مصنوعی استفاده شد. از یک مدل چندلایه پیشخور در شبکه عصبی مصنوعی استفاده شده است. پس از اعمال داده‌های ورودی به شبکه با معماری مورد نظر در لایه خروجی، تشعشع خورشیدی پیش‌بینی شده است. تشعشع خورشیدی پیش‌بینی شده توسط شبکه عصبی مصنوعی همخوانی قابل توجهی با داده‌های هواشناسی داشته، به طوری که ضریب همبستگی نهایی به‌دست‌آمده از شبکه عصبی مصنوعی ۰/۹۶ است که حاکی از دقت بالای داده‌های به‌دست‌آمده از نرم‌افزار است. با انتخاب داده‌های پیش‌بینی شده از شبکه عصبی مصنوعی به‌عنوان ورودی برای نرم‌افزار ArcGIS نقشه پتانسیل خورشیدی سالیانه برای ایران به‌دست آمده است.

واژه‌های کلیدی: انرژی خورشیدی، شبکه‌های عصبی مصنوعی (ANN)، مدل چندلایه پیشخور، نقشه پتانسیل خورشیدی.

* نویسنده مسئول

۱. مقدمه

یکی از منابع قابل دسترس و فراوان، انرژی خورشیدی است که یکی از پاک‌ترین و بزرگ‌ترین منابع تجدیدپذیر زمین است. اگر فقط یک درصد از تابش بیابان‌های جهان توسط نیروگاه‌های خورشیدی به کار گرفته شود، توانایی تأمین برق جهان را خواهد داشت. در زمینه تولید برق، از انرژی خورشید با فناوری‌های مختلف سرمایه‌گذاری و فعالیت‌های فراوان، به‌ویژه در کشورهای صنعتی صورت گرفته است. در شرایطی که در بیشتر کشورها به‌خصوص کشورهای پیشرفته صنعتی، تولید انرژی‌های نو جزء اولویت‌های اول محسوب می‌شود، ایجاد مشکلات گوناگون برای فراگیر شدن آن در سایر نقاط جهان مانند ممانعت از انتقال فناوری و سرمایه‌گذاری و...، چشم‌انداز گسترش آن را در کشورهای توسعه‌نیافته و کشورهای تولیدکننده انرژی فسیلی تاریک ساخته است.

در زمینه انرژی خورشیدی، ایران در کمربند انرژی واقع شده و اراضی بکر زیادی در این پهنه وجود دارد که به اشکال گوناگون، از نیروگاه‌های تولید برق تا آبگرمکن‌های خورشیدی قابل بهره‌برداری است. میزان تابش خورشیدی در ایران، بین ۱۸۰۰ تا ۲۲۰۰ کیلووات ساعت بر مترمربع در سال تخمین زده شده است که البته بالاتر از میزان متوسط جهانی است.

صفائی و همکاران، پتانسیل تابش خورشیدی را با استفاده از مدل‌های ریاضی (آنگستروم-پریسکات، حداکثر احتمال، هیبرید) به دست آوردند و نتایج را به صورت نقشه سالانه برای ایران ارائه کردند [۱]. سبزی‌پرور برای تخمین پتانسیل خورشیدی در کویر مرکزی ایران، یک رابطه ساده ریاضی پیشنهاد کرد [۲]. معینی و همکاران، پتانسیل تابش خورشیدی را با استفاده از مدل‌های ریاضی (مدل آنگستروم^۱) در شهر یزد برآورد کردند [۳].

به‌طور کلی، برای پیدا کردن نقاط مستعد برای بهره‌وری حداکثری، از انرژی خورشیدی روش‌های گوناگون استفاده شده است. در سال‌های اخیر، کارهای زیادی برای گسترش مدل‌های همانندسازی و پیش‌بینی که بر پایه روش‌های هوش مصنوعی و سامانه‌های هوشمند بنا نهاده شده‌اند، صورت گرفته است. مدل شبکه عصبی مصنوعی (ANN)^۲ از جمله این مدل‌هاست که کاربرد روزافزونی در مدل‌سازی و همانندسازی پدیده‌های گوناگون دارد. تاکنون مدل شبکه عصبی مصنوعی برای پیش‌بینی تابش جهانی خورشیدی از سوی پژوهشگران فراوانی به کار رفته است [۴ و ۵]. همه این کوشش‌ها کم‌وبیش حکایت

از برتری و توانمندی زیاد این مدل نسبت به دیگر مدل‌های به‌کاررفته دارند. اگرچه تحقیقات اخیر، شبکه‌های عصبی سودمندتری برای کاربردهای مختلف را عرضه کردند، همچنان پرسپترون‌های چندلایه مورد توجه است.

اللاوی و الهنای، با استفاده از شبکه عصبی مصنوعی و پارامترهای هواشناسی (مکان، ماه، فشار، میانگین فشار بخار، میانگین رطوبت نسبی، میانگین سرعت باد و میانگین ساعت آفتابی) تابش جهانی را برای مناطقی که بدون دستگاه اندازه‌گیری کرده بودند، پیش‌بینی کردند [۶]. دورولو و همکاران، با استفاده از پرسپترون‌های چندلایه و تابع ردیال بیسیک، تشعشع خورشیدی را برای چند شهر کشور عمان تخمین زدند و این دو روش را با یکدیگر مقایسه کردند و در آخر به این نتیجه رسیدند که پرسپترون‌های چندلایه جواب نزدیک‌تری به واقعیت دارند [۷]. ریدی و رانجان، تشعشع خورشیدی را با استفاده از شبکه عصبی مصنوعی (پرسپترون‌های چندلایه با روش پیش‌رو) تخمین زدند و با دیگر روش‌های همبستگی مقایسه کردند و در آخر به این نتیجه رسیدند که شبکه‌های عصبی مصنوعی جواب مطلوب‌تری نسبت به بقیه روش‌ها می‌دهد [۸].

سوزن و همکاران، پتانسیل خورشیدی را با استفاده از داده‌های هواشناسی و جغرافیایی (به مدت سه سال) و شبکه عصبی مصنوعی (الگوریتم‌های LM^۳، SCG^۴، CGP^۵) برای کشور ترکیه به دست آورده و نتایج را به صورت نقشه‌های خورشیدی برای ۱۲ ماه سال به دست آوردند [۹]. هونتوریا و همکاران، با استفاده از پرسپترون‌های چندلایه، پتانسیل خورشیدی را برای کشور اسپانیا تخمین زده و نتایج را به صورت نقشه ارائه کردند [۱۰]. مویبرو و باندا، با استفاده از شبکه عصبی مصنوعی و پارامترهای هواشناسی و جغرافیایی میانگین ماهیانه تشعشع خورشیدی را برای کشور آگاندرا تخمین زدند [۱۱]. لام و همکاران، برای آب‌وهوای مختلف، با استفاده از شبکه عصبی مصنوعی، تشعشع خورشیدی را برای کشور چین مدل کردند [۱۲]. هوکاقلو و همکاران، با استفاده از روش (فیلتر)^۶ خطی دوبعدی و الگوریتم پیش‌رو در شبکه عصبی مصنوعی، پتانسیل خورشیدی را به صورت ساعتی در کشور ترکیه تخمین زدند [۱۳].

فادری با استفاده از شبکه عصبی مصنوعی، پتانسیل خورشیدی را برای کشور نیجریه مدل کرده و نتایج را به صورت نقشه برای ۱۲ ماه سال ارائه کرد و با استفاده از رابط گرافیکی در متلب، نتایج را

3. Pola-Ribiere Conjugate Gradient
4. Scaled Conjugate Gradient
5. Levenberg-Marquardt
6. Filter

1. Angström
2. Artificial Neural Network

نزدیک ۷۰ درصد داده‌ها برای آموزش، ۱۵ درصد داده‌ها برای صحت‌سنجی و ۱۵ درصد باقی‌مانده (به‌طور خاص ایستگاه‌های تبریز، تهران، مشهد، شیراز، یزد و رامسر) به‌عنوان نماینده شش اقلیم خاص از ایران برای آزمون کارایی شبکه به‌کار گرفته شد.

۲.۲. شبکه‌های عصبی مصنوعی (ANNs)

شبکه‌های عصبی مصنوعی (ANN) الگویی برای پردازش اطلاعات هستند که با تقلید از شبکه‌های عصبی بیولوژیکی مثل مغز انسان ساخته شده‌اند. عنصر کلیدی این الگو ساختار جدید سیستم پردازش اطلاعات آن است و از تعداد زیادی عنصر (نورون) با ارتباطات قوی داخلی که هماهنگ با هم برای حل مسائل مخصوص کار می‌کنند، تشکیل شده‌اند. شبکه‌های عصبی مصنوعی با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کند؛ به این عمل یادگیری می‌گویند. یک نورون مصنوعی مدل ریاضی ساده شده یک نورون زیستی است. سعی زیادی در ارائه عملکرد نورون مصنوعی به‌صورت مدل ریاضی شده است. نورون دارای دو حالت آموزش و عملکرد است: در حالت آموزش نورون یاد می‌گیرد که در مقابل الگوهای ورودی خاص برانگیخته شود یا در اصطلاح آتش کند و در حالت عملکرد، وقتی یک الگوی ورودی شناسایی شده وارد شود، خروجی متناظر با آن ارائه می‌شود.

اگر ورودی جزء ورودی‌های از پیش شناسایی شده نباشد، قوانین آتش برای برانگیختگی یا عدم آن تصمیم‌گیری می‌کند. با کنار گذاشتن برخی از خواص حیاتی نورون‌ها و ارتباطات درونی آن‌ها می‌توان یک مدل ابتدایی از نورون را به‌وسیله کامپیوتر شبیه‌سازی کرد.

یک شبکه عصبی مصنوعی شامل اجزای سازنده لایه‌ها و وزن‌ها می‌باشد. رفتار شبکه نیز وابسته به ارتباط بین اعضاست. در حالت کلی، در شبکه‌های عصبی مصنوعی سه نوع لایه نورونی وجود دارد: لایه ورودی: دریافت اطلاعات خامی که به شبکه تغذیه شده است.

لایه‌های پنهان: عملکرد این لایه‌ها به‌وسیله ورودی‌ها و وزن ارتباط بین آن‌ها و لایه‌های پنهان تعیین می‌شود. وزن‌های بین واحدهای ورودی و پنهان تعیین می‌کنند که چه وقت یک واحد پنهان باید فعال شود.

لایه خروجی: عملکرد واحد خروجی بسته به فعالیت واحد پنهان و وزن ارتباط بین واحد پنهان و خروجی می‌باشد. خروجی شبکه y به صورت رابطه (۱) مدل می‌شود:

به‌صورت برنامه‌ای برای تخمین پتانسیل خورشیدی به‌دست آورد [۱۴]. بیات و میرطیفی، تابش کل خورشیدی را به‌صورت روزانه با استفاده از مدل‌های رگرسیونی و شبکه عصبی مصنوعی تخمین زده و این روش‌ها را با هم مقایسه کردند [۱۵]. رحیمی خوب، با استفاده از شبکه عصبی مصنوعی و داده‌های دما برای مناطق خشک (اهواز) تشعشع خورشیدی را تخمین زد [۱۶]. سبزی‌پرور و علیانی، تابش خورشیدی کل روزانه را با استفاده از عملکرد شبکه عصبی مصنوعی برای ایستگاه همدیدی تبریز ارزیابی کرده و نتایج را با مدل آنگستروم مقایسه کردند [۱۷].

هدف از این تحقیق، به‌کارگیری یک شبکه عصبی مصنوعی (پرسترون چندلایه)^۱ برای پیش‌بینی تابش روزانه خورشیدی کشور ایران است. از این‌رو، سازه‌های اقلیم‌شناختی گوناگونی در ریخت یک شبکه عصبی مصنوعی به‌کار گرفته شده است. با توجه به پیشینه پژوهش‌های صورت‌گرفته، در این بررسی، پارامترهای گوناگونی در حکم ورودی شبکه عصبی در نظر گرفته شده است که برخی از آن‌ها همچون مقدار ارتفاع جغرافیایی و ماه قبلاً توسط محققان دیگر مورد توجه قرار نگرفته است، به نحوی که با در نظر گرفتن این دو پارامتر خطای محاسبات در حدود ۵ درصد نسبت به پژوهش‌های پیشین کاهش یافته است. لذا نتایج برآمده از این تحقیق به لحاظ تعداد پارامترهای وابسته، از جامعیت بیشتری برخوردار بوده است. در پایان، نقش پتانسیل خورشیدی سالیانه برای کشور ایران رسم شده است.

۲. روش تحقیق


۱.۲. داده‌ها و منطقه مورد بررسی

در این پژوهش، مدل پیشنهاد شده برای کشور ایران به‌کار گرفته شد. کشور ایران در محدوده ۲۵/۵ تا ۳۹/۷۸ درجه عرض شمالی و ۴۴/۸ تا ۶۳/۳۰ درجه طول شرقی قرار گرفته است و در منطقه‌ای واقع شده که به‌لحاظ دریافت انرژی خورشیدی در بین نقاط جهان در بالاترین رده‌ها قرار دارد. همه داده‌ها و پارامترهای به‌کاررفته از سازمان هواشناسی ایران دریافت شده که در این راستا پارامترهای هواشناسی روزانه برای یک دوره ۱۰ ساله از سال ۱۹۹۱ تا ۲۰۰۰ گردآوری و بهره‌برداری شده است.

داده‌های گردآوری‌شده در سه دسته جدا از هم دربرگیرنده داده‌های آموزش^۲، صحت‌سنجی^۳ و آزمون^۴ جای گرفتند. از این‌رو،

1. Multi Layers Perceptron
2. Train
3. Validation
4. Test

ساعت آفتابی هستند. همچنین سعی شده است تا پیش‌بینی صورت‌گرفته از جامعیت بیشتری نسبت به روش‌های مرسوم مورد استفاده برخوردار باشد. به این منظور، شبکه عصبی مصنوعی پرسپترون چندلایه انتخاب شد. شایان ذکر است که همه پارامترهای هواشناسی ورودی مورد استفاده در تحقیق در مقیاس ماهیانه هستند. شبکه عصبی مصنوعی با این پارامترها آموزش یافته‌اند و در نهایت، پیش‌بینی‌های مدل شده حاصل از شبکه عصبی مصنوعی با داده‌های واقعی مقایسه (راستی‌آزمایی) شده است. گفتنی است که بهترین ساختار شبکه با کمترین میزان خطا شناسایی شده و علاوه بر آن، برای ارزیابی عملکرد شبکه عصبی منتخب، نتایج حاصل با مقدار اندازه‌گیری شده مقایسه می‌شود. ساختار کلی شبکه عصبی مصنوعی پرسپترون سه لایه مورد استفاده در این تحقیق، در شکل (۱) نمایش داده شده است.



شکل (۱): مدل شبکه عصبی پرسپترون چندلایه به کاررفته در این تحقیق

۳.۲. شبیه‌سازی تابش خورشیدی کل به روش شبکه

عصبی مصنوعی

در این بررسی، به منظور مدل‌سازی تابش خورشیدی کل، شبکه‌های عصبی مصنوعی پرسپترون چندلایه متفاوتی طراحی شد و مورد ارزیابی قرار گرفت. تابع انتقال برای لایه ورودی و خروجی یک تابع خطی و برای لایه مخفی تابع تانژانت سیگموئید در نظر گرفته شد. این تابع در اغلب مدل‌سازی‌های صورت‌گرفته از پارامترهای هیدرولوژیکی و هواشناسی تابعی مرسوم است [۴ و ۵]. برای آموزش شبکه نیز از الگوریتم انتشار به عقب استفاده شد. برای دستیابی به ساختار بهینه شبکه عصبی پارامترهای مورد نیاز برای ورودی شبکه در طول ۱۰ سال (از ۱۹۹۱ تا ۲۰۰۰ میلادی) جمع‌آوری شد. در جدول (۱) پراکنش داده‌ها براساس مقادیر میانگین حداقل و حداکثر پارامترهای مورد استفاده در ساختار شبکه عصبی آورده شده است.

$$Y_i = \sum_j^n W_{ij} X_{ij} + \Theta_i \quad (1)$$

که در آن، X_{ij} سیگنال ورودی از j امین نرون (در لایه ورودی) W_{ij} وزن اتصال نرون j به نرون i (در لایه مخفی) است. Θ_i نیز آریبی^۱ نرون i خواهد بود. طی فرایند آموزش این وزن‌ها و مقادیر ثابتی که با آن‌ها جمع می‌شود و در اصطلاح آریبی نامیده می‌شوند، به‌طور پی‌درپی تغییر می‌کند تا خطا به کمترین مقدار خود برسد.

پس از محاسبه هر Δ شبکه تحت یک تابع محرک، شروع به اصلاح آن می‌کند. تابع محرک از نوع یک تابع یکنواخت کراندار مانند تابع استاندارد تانژانت سیگموئید است که به صورت رابطه (۲) تعریف می‌شود [۱۷]:

$$F(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

با توجه به اینکه طی سال‌های اخیر، شبکه عصبی مصنوعی پرسپترون چندلایه (MLP)^۲ به‌خوبی قابلیتش را در مدل‌سازی و پیش‌بینی پارامترهای اقلیمی متفاوت از جمله تابش خورشیدی نشان داده است [۵ و ۹]. در این تحقیق نیز یک نمونه از شبکه‌های چندلایه پرسپترون مورد استفاده قرار گرفته است. در این نوع شبکه، داده‌ها به صورت پیوسته و بدون هرگونه بازخوردی^۳ به سمت خروجی انتقال می‌یابند. فرایند آموزش در شبکه‌های عصبی مصنوعی در واقع به معنای روزآمد کردن اتصالات بین نرون‌هاست. تاکنون الگوریتم‌های گوناگونی برای آموزش شبکه عصبی مصنوعی عرضه شده است که معروف‌ترین آن‌ها الگوریتم قاعده انتشار به عقب (BP)^۴ است. قاعده انتشار به عقب استاندارد یک الگوریتم با کاهش شیب است که در آن، وزن‌های شبکه در جهت خلاف شیب تابع کارایی حرکت می‌کنند.

لغت «پس‌انتشار» به رفتار شبکه BP در محاسبه شیب، در شبکه‌های غیرخطی چندلایه اشاره دارد. در شبکه پس‌انتشار، از بردار ورودی و هدف در راستای آموزش شبکه برای تقریب زدن یک تابع، یافتن رابطه بین ورودی و خروجی و دسته‌بندی ورودی‌ها استفاده می‌شود. یک شبکه پس‌انتشار با دارا بودن بایاس، یک لایه سیگموئید و یک لایه خروجی خطی توانایی تخمین زدن هر تابعی با تعداد نقاط ناپیوستگی محدود را داراست.

در تحقیق حاضر، پارامترهای مهم گوناگونی برای پی‌بینی تابش خورشیدی کل مورد توجه قرار گرفته است. این پارامترها شامل طول، عرض، ارتفاع جغرافیایی، ماه، دمای میانگین ماهیانه، رطوبت نسبی و

1. Bias
2. Multi Layers Perceptron
3. Feedback
4. Back Propagation

الگوریتم لونیبرگ-مارکات (LM) را در متلب نشان می‌دهد. در شکل (۲)، کیفیت داده‌های ورودی در سه بخش آموزش (Train)، صحت‌سنجی (Validation) و آزمون (Test) آورده شده است.

جدول (۱): دامنه تغییرات پارامترهای هواشناسی مورد استفاده در ساختار

شبکه عصبی مصنوعی برای کل ایران			
میانگین دما (°C)			
ماه	ماکزیمم	میانگین	مینیمم
JAN.	۲۱/۲۷	۵/۸۲	-۲/۸۰
FEB.	۲۲/۱۰	۷/۳۴	-۱/۸۳
MAR.	۲۳/۷۳	۱۰/۷۴	۲/۳۵
APR.	۲۷/۳۰	۱۷/۱۲	۹/۷۴
MAY	۳۱/۵۸	۲۱/۶۷	۱۲/۵۶
JUNE	۳۵/۷۶	۲۶/۲۵	۱۵/۶۵
JULY	۳۷/۸۰	۲۸/۷۳	۱۷/۵۵
AUG.	۳۷/۵۲	۲۸/۲۱	۱۷/۹۴
SEP.	۳۳/۴۶	۲۴/۲۰	۱۴/۹۴
OCT.	۲۹/۲۲	۱۸/۷۷	۱۰/۸۶
NOV.	۲۶/۰۲	۱۲/۸۷	۵/۱۲
DEC.	۲۳/۰۰	۸/۲۹	۰/۶۲
رطوبت نسبی (%)			
ماه	ماکزیمم	میانگین	مینیمم
JAN.	۸۷/۰۰	۶۹/۱۱	۵۳/۲۰
FEB.	۸۷/۲۰	۶۳/۷۸	۴۱/۴۰
MAR.	۸۸/۳۰	۶۰/۶۳	۳۹/۱۰
APR.	۸۵/۸۰	۵۳/۰۷	۲۹/۶۰
MAY	۸۵/۲۰	۴۷/۹۰	۳۳/۲۰
JUNE	۸۳/۶۰	۴۱/۶۵	۱۷/۱۰
JULY	۸۳/۳۰	۴۱/۴۴	۱۶/۶۰
AUG.	۸۳/۶۰	۴۱/۶۷	۱۵/۵۰
SEP.	۸۶/۰۰	۴۳/۴۱	۱۶/۸۰
OCT.	۸۹/۹۰	۵۰/۰۶	۲۵/۴۰
NOV.	۸۸/۹۰	۵۸/۹۸	۳۴/۶۰
DEC.	۸۸/۸۰	۶۶/۷۹	۴۴/۵۰
ساعت آفتابی (hr)			
ماه	ماکزیمم	میانگین	مینیمم
JAN.	۲۲۹/۴۸	۱۶۶/۷۶	۹۰/۸۴
FEB.	۲۳۰/۸۵	۱۷۸/۲۰	۹۳/۳۵
MAR.	۲۴۱/۸۷	۱۹۵/۸۹	۹۹/۰۷
APR.	۲۹۴/۰۲	۲۳۲/۴۴	۱۳۴/۲۸
MAY	۳۲۷/۶۹	۲۸۴/۷۵	۱۶۹/۹۵
JUNE	۳۵۶/۲۷	۳۱۹/۵۲	۱۸۷/۲۲
JULY	۳۷۶/۶۶	۳۲۳/۶۵	۱۸۷/۱۸
AUG.	۳۶۴/۴۳	۳۱۵/۳۲	۱۵۸/۱۲
SEP.	۳۱۹/۳۵	۲۸۰/۵۴	۱۲۷/۶۹
OCT.	۲۹۵/۴۲	۲۵۴/۱۸	۱۳۲/۷۱
NOV.	۲۷۰/۹۵	۱۹۸/۲۴	۹۳/۷۵
DEC.	۲۵۱/۸۲	۱۶۹/۰۳	۹۱/۰۱

به منظور ارزیابی مدل‌های مورد نظر از شاخص‌های جذر میانگین مربعات (RMS)، کسر مطلق واریانس (R^2) و میانگین درصد خطای مطلق (MAPE) بهره برده شده است که با استفاده از روابط (۳) تا (۵) قابل محاسبه است:

$$RMS = \sqrt{\frac{1}{p} \sum_j |t_j - o_j|^2} \quad (3)$$

$$R^2 = 1 - \left(\frac{\sum_j |t_j - o_j|^2}{\sum_j |o_j|^2} \right) \quad (4)$$

$$MAPE = \frac{1}{N} \sum_{j=1}^N \left(\frac{o_j - t_j}{o_j} \right) \times 100 \quad (5)$$

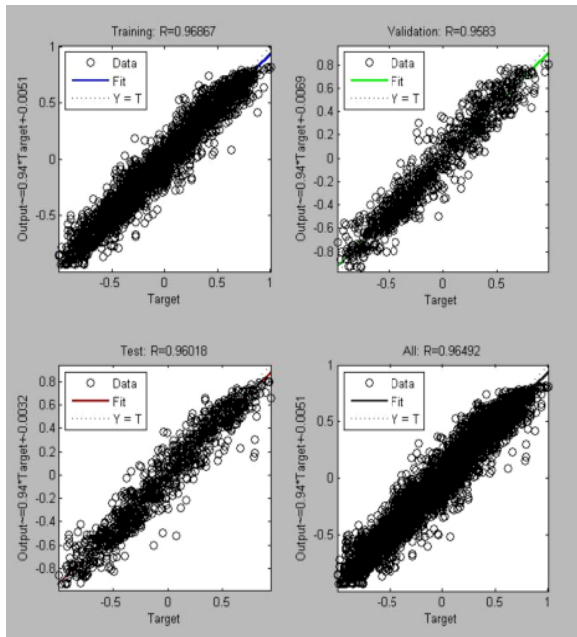
در فرمول‌های بالا، t_j داده‌های هدف، o_j داده‌های خروجی از نرم‌افزار و p تعداد داده‌هاست. مقدار جذر میانگین مربعات (RMS) نشان‌دهنده میزان انحراف برآوردها نسبت به مشاهدات است. مقادیر مثبت میانگین درصد خطای مطلق (MAPE) نشان‌دهنده بیش برآورد کردن مقادیر با مدل و مقادیر منفی آن، نشان‌دهنده کم برآورد کردن مقادیر با مدل است. کسر مطلق واریانس (R^2) نشان‌دهنده میزان انحراف داده‌های خروجی از داده‌های هدف است که هرچه به عدد ۱ نزدیک‌تر باشد، میزان خطا کمتر خواهد بود. برای هر یک از الگوهای ورودی با تغییر در تعداد لایه‌های پنهان و تعداد نرون‌های لایه پنهان که اغلب به صورت سعی و خطا صورت می‌گیرد، شبکه‌های عصبی مصنوعی گوناگونی ساخته شده و پس از آموزش شبکه، بهترین ساختار برای هر الگو انتخاب شده است. محاسبات مربوط به شبکه عصبی مصنوعی با نرم‌افزار (متلب) ^۱ و با روش الگوریتم (لونیبرگ-مارکات) ^۲ (LM) صورت گرفت [۱۴].

با توجه به اینکه اطلاعات اولیه بین اعداد ۱ تا ۱- نرمال‌سازی شده‌اند، از تابع انتقال تانژانت سیگموئید در لایه ورودی و خروجی استفاده شد. نتایج آماری برآمده از آرایش بهینه شبکه عصبی مصنوعی در جدول (۲) آمده است. با توجه به اینکه ۷ پارامتر در حکم پارامترهای ورودی شبکه لحاظ شده است، ساختار پیشنهادی شبکه به منظور برآورد پارامتر تابش خورشیدی کل به صورت ۷-p-۱ یا ۱-۷-p-q-۱ خواهد بود که p و q به ترتیب، تعداد نرون‌ها در اولین و دومین لایه مخفی هستند. ساختار مطلوب شبکه در تعداد ۱۰۰۰ دور تکرار برای آموزش به دست آمد. همان‌گونه که قبلاً گفته شد، تعداد متفاوت نرون‌ها در لایه مخفی و انتخاب ساختار بهینه شبکه عصبی با استفاده از روش سعی و خطا صورت پذیرفت. شکل (۲) نتایج

1. Matlab
2. Levenberg-Marquardt

ارزیابی عملکرد شبکه عصبی مصنوعی در پیش‌بینی تابش خورشیدی روزانه کشور ایران ۴۳

معیار کیفیت مناسب آموزش به این صورت است که شاخص R بین ۰.۹۵ تا ۱ باشد. همان‌طور که در نمودارها مشاهده می‌گردد، به‌ازای هرچند ورودی که در کل یک ورودی خوانده می‌شود، یک خروجی داریم. پس از رسم نقاط، بهترین خط از بین آن‌ها برآزش می‌شود که این خط همان تابع انتقال است. فرمول مشاهده شده در کنار هر نمودار، همان فرمول تابع انتقال است که در نمودار نهایی (ALL) به‌صورت کلی مشاهده می‌شود. برای تبدیل هر داده به یک خروجی مناسب، از این فرمول می‌توان استفاده کرد.



شکل (۲): نتایج الگوریتم لونیبرگ-مارکات در برنامه متلب

۳. نتایج

در این تحقیق، با استفاده از نرم افزار متلب، تشعشع خورشیدی با آمار ۱۰ ساله برای ۳۹ ایستگاه سینوپتیک بین دوره ۱۹۹۱ تا ۲۰۰۰ میلادی پیش‌بینی شد. اعداد پیش‌بینی شده با اعداد برگرفته از ایستگاه هواشناسی همبستگی مطلوبی دارد، به‌طوری‌که برای اعداد به‌دست آمده از الگوریتم لونیبرگ-مارکات (LM) مقدار عدد همبستگی بین ۰/۹۵۱۶۶ تا ۰/۹۹۷۹۷ متغیر بوده است. لازم است نتایج به‌دست آمده از مدل پیشنهادی شبکه عصبی مصنوعی، مورد اعتبارسنجی قرار گیرد. عملکرد نتایج حاصل از مدل شبکه عصبی مصنوعی با داده‌های هواشناسی مورد ارزیابی قرار گرفت و در جدول (۳)، اعداد حقیقی قرائت شده توسط هواشناسی برای ایستگاه‌های سینوپتیک مختلف و

جدول (۲): مقایسه خطای الگوریتم لونیبرگ-مارکات در سه حالت مختلف

نوع الگوریتم	LM-15		
	R ²	RMS(%)	MAPE(%)
نام ایستگاه			
تبریز	۰/۹۹۴	۳/۶۹	۰/۶۳۵
ارومیه	۰/۹۸۹	۵/۰۱	-۰/۱۷۴
خوروبابانک	۰/۹۹۱	۳/۷۵	۰/۰۳۴
اصفهان	۰/۹۹۵	۳/۳۶	۰/۰۵۹
بوشهر	۰/۹۹۲	۳/۳۸	۰/۸۸۷
تهران	۰/۹۹۱	۴/۲۵	-۱/۱۷۶
کرج	۰/۹۸۷	۴/۷۵	۰/۱۳۷
بیرجند	۰/۹۸۹	۴/۵۵	۰/۴۴۸
مشهد	۰/۹۸۵	۶/۰۷	۱/۹۱۱
بجنورد	۰/۹۹۶	۲/۷۶	۰/۲۵۵
زنجان	۰/۹۸۵	۵/۹۷	۱/۶۴۹
زاهدان	۰/۹۹۰	۳/۹۶	-۰/۰۳۸
شیراز	۰/۹۹۳	۳/۵۲	-۰/۱۴۱
کرمان	۰/۹۹۴	۳/۵۶	۰/۴۱۸
کرمانشاه	۰/۹۸۲	۵/۴۸	۱/۴۳۹
رامسر	۰/۹۹۵	۴/۲۶	-۰/۰۴۱
بندرعباس	۰/۹۹۳	۲/۶۷	-۰/۴۹۱
همدان	۰/۹۸۷	۴/۲۴	-۰/۱۷۳
یزد	۰/۹۹۷	۲/۵۰	-۰/۰۶۴
طیس	۰/۹۹۷	۲/۶۴	-۰/۰۰۹
جاسک	۰/۹۹۱	۲/۹۴	-۱/۱۷۱
اردبیل	۰/۹۹۶	۲/۷۴	-۰/۰۲۵
ایلام	۰/۹۸۷	۵/۰۲	۰/۲۶۱
شهرکرد	۰/۹۹۶	۲/۴۵	-۱/۱۰۰
اهواز	۰/۹۹۶	۲/۷۰	-۰/۰۸۷
سمنان	۰/۹۹۳	۳/۷۴	-۰/۳۹۸
قم	۰/۹۵۱	۹/۰۶	۳/۵۲۴
سنندج	۰/۹۸۵	۵/۸۷	-۰/۳۷۱
ياسوج	۰/۹۹۷	۲/۳۶	۱/۳۲۸
گرگان	۰/۹۹۲	۴/۷۰	-۰/۱۹۵
رشت	۰/۹۹۲	۴/۹۲	۰/۰۷۳
خرم‌آباد	۰/۹۸۷	۵/۰۳	-۰/۷۶۷
بابلسر	۰/۹۷۸	۷/۴۷	۰/۲۳۶
اراک	۰/۹۸۷	۵/۴۶	۱/۰۱۴
قزوین	۰/۹۹۲	۴/۸۲	۰/۱۰۲
نوشهر	۰/۹۹۱	۴/۷۰	-۰/۴۵۵
آبادان	۰/۹۹۶	۲/۷۵	-۰/۰۲۴
بندر لنگه	۰/۹۷۰	۵/۵۹	۰/۳۷۴
چابهار	۰/۹۹۱	۲/۹۹	۱/۲۱۷

جدول (۳): مقایسه اعداد حقیقی و پیش‌بینی شده به صورت میانگین سالیانه


تشعشع خورشیدی (KWh/m ² day)		
نام ایستگاه	میانگین	LM-15
تبریز	۴/۰۱	۴/۰۳
ارومیه	۳/۹۱	۳/۹۴
خوروبیانک	۵/۷۵	۵/۸۰
اصفهان	۵/۳۴	۵/۳۹
بوشهر	۴/۸۶	۴/۹۰
تهران	۴/۸۵	۴/۸۹
کرج	۴/۸۴	۴/۸۴
بیرجند	۵/۵۰	۵/۵۰
مشهد	۵/۱۷	۵/۲۱
بجنورد	۳/۹۷	۴/۰۰
زنجان	۴/۲۱	۴/۴۷
زاهدان	۵/۵۵	۵/۵۹
شیراز	۵/۶۱	۵/۶۶
کرمان	۵/۶۸	۵/۷۳
کرمانشاه	۴/۹۳	۴/۹۷
رامسر	۲/۹۶	۲/۹۸
بندرعباس	۴/۹۱	۴/۹۵
همدان	۴/۵۱	۴/۵۴
یزد	۶/۰۲	۵/۶۳
طبرس	۵/۶۲	۵/۶۶
جاسک	۴/۹۵	۴/۹۹
اردبیل	۳/۶۵	۳/۶۷
ایلام	۵/۰۶	۵/۱۰
شهرکرد	۴/۷۶	۴/۸۱
اهواز	۴/۷۳	۴/۷۷
سمنان	۴/۸۹	۴/۹۲
قم	۴/۹۷	۵/۰۱
سنندج	۵/۰۹	۵/۱۳
یاسوج	۴/۸۱	۴/۸۴
گرگان	۳/۱۵	۳/۲۰
رشت	۳/۰۲	۳/۰۷
خرم آباد	۵/۴۳	۵/۴۸
بابلسر	۳/۱۸	۳/۲۲
اراک	۴/۸۷	۴/۹۱
قزوین	۴/۸۴	۴/۸۸
نوشهر	۳/۱۸	۳/۲۲
آبادان	۵/۳۸	۵/۴۲
بندرلنگه	۴/۹۱	۴/۹۵
چابهار	۴/۹۵	۴/۹۹

اعداد پیش‌بینی شده توسط نرم‌افزار شبکه عصبی مصنوعی برای همین ایستگاه‌ها جهت مقایسه ارائه شده است.


با توجه به جدول (۳) می‌توان مشاهده کرد که اعداد به‌دست‌آمده از نرم‌افزار شبکه عصبی مصنوعی در مقایسه با داده‌های هواشناسی از نزدیکی خاصی برخوردار بوده است، به طوری که می‌توان از این روش برای تخمین تشعشع خورشیدی در ایستگاه‌هایی که تشعشع سنج خورشیدی ندارند، استفاده کرد.

در شکل‌های (۳) تا (۸) میانگین سالیانه تشعشع خورشیدی برگرفته از سازمان هواشناسی کل ایران و پیش‌بینی شده توسط شبکه عصبی مصنوعی و الگوریتم لونبرگ - مارکات (LM) برای شش ایستگاه هواشناسی تبریز، تهران، مشهد، شیراز، یزد و رامسر که نماینده اقلیم‌های مختلف ایران هستند، مقایسه شده است. با توجه به شکل‌های رسم‌شده برای شش ایستگاه هواشناسی می‌توان به این نکته اشاره کرد که در مسائل تخمین تابع، با تعداد پارامترهای شبکه کمتر از ۱۰۰ عدد الگوریتم لونبرگ - مارکات کارایی، سرعت و دقت بالایی از خود نشان می‌دهد [۱۸]. با توجه به جدول (۳) بیشترین و کمترین مقدار تشعشع خورشیدی سالیانه به ترتیب در ایستگاه‌های یزد و رامسر وجود دارد. همچنین با توجه به شکل‌های (۳) تا (۸) برای ایستگاه‌های هواشناسی بیشترین مقدار تشعشع خورشیدی در هر ایستگاه در ماه خرداد (June) و کمترین مقدار تشعشع خورشیدی در ماه‌های آذر (December) و دی (January) رخ می‌دهد.


برای به‌دست‌آوردن نقشه سالیانه تشعشع خورشیدی، طول و عرض جغرافیایی هر ایستگاه به‌همراه میانگین سالیانه تشعشع خورشیدی پیش‌بینی شده توسط شبکه عصبی مصنوعی برای همان ایستگاه به‌عنوان داده‌های ورودی به نرم‌افزار ArcGIS داده شده است. خروجی این نرم‌افزار نقشه پتانسیل خورشیدی سالیانه کشور ایران است که با تقسیم‌بندی ایران به ۴ ناحیه مشخص از نظر میزان تشعشع خورشیدی قابل مشاهده است (شکل ۹).




شکل (۶): مقایسه داده‌های هواشناسی ایستگاه شیراز و الگوریتم LM در ۱۲ ماه سال




شکل (۳): مقایسه داده‌های هواشناسی ایستگاه تبریز و الگوریتم LM در ۱۲ ماه سال




شکل (۷): مقایسه داده‌های هواشناسی ایستگاه رامسر و الگوریتم LM در ۱۲ ماه سال



شکل (۴): مقایسه داده‌های هواشناسی ایستگاه تهران و الگوریتم LM در ۱۲ ماه سال



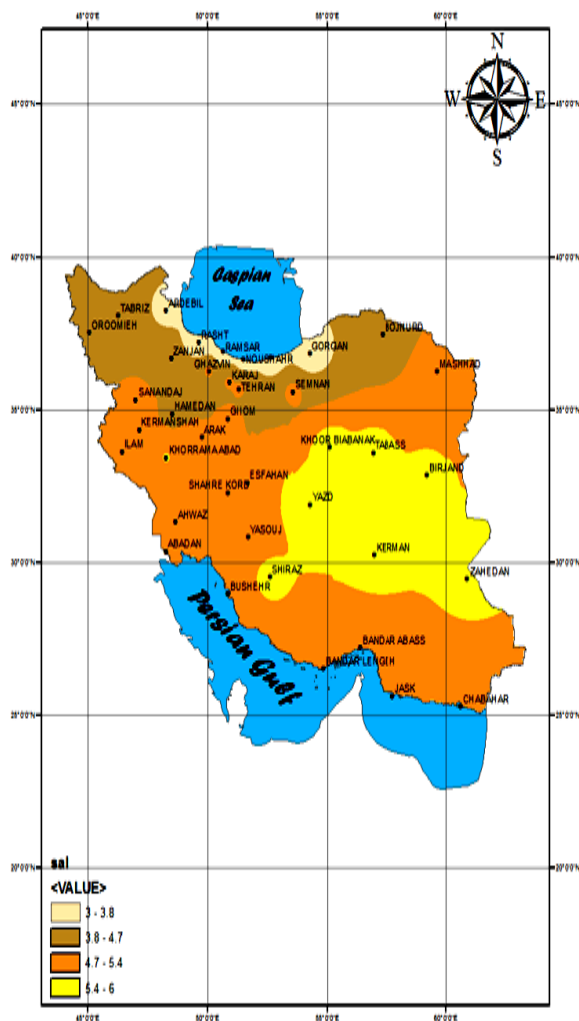
شکل (۸): مقایسه داده‌های هواشناسی ایستگاه یزد و الگوریتم LM در ۱۲ ماه سال



شکل (۵): مقایسه داده‌های هواشناسی ایستگاه مشهد و الگوریتم LM در ۱۲ ماه سال

۴. نتیجه گیری

۳۰° تا ۳۵° واقع شده که ایستگاه‌های شیراز، یزد، طبس، خرو و بیابانک، زاهدان، کرمان و بیرجند را شامل می‌شود.



شکل (۹): نقشه پتانسیل خورشیدی سالیانه برحسب (KWh/m² day)

در این تحقیق، مدل شبکه عصبی مصنوعی در برآورد تابش کل خورشیدی برای ایران به کار گرفته شد. به این منظور، مجموعه‌هایی از پارامترهای اقلیمی و هواشناسی مؤثر در برآورد تابش خورشیدی در حکم ورودی و تعیین ساختار شبکه استفاده شد. پارامترهای فوق از جمله پارامترهایی هستند که از سوی سازمان هواشناسی به صورت ماهیانه اندازه‌گیری و ثبت می‌شوند. با استفاده از نرم‌افزار متلب و شبکه عصبی مصنوعی، تشعشع خورشیدی با آمار ۱۰ ساله برای ۳۹ ایستگاه سینوپتیک بین دوره ۱۹۹۱ تا ۲۰۰۰ میلادی پیش‌بینی شد که اعداد پیش‌بینی شده با اعداد برگرفته از ایستگاه هواشناسی، همبستگی مطلوبی دارد، به طوری که برای اعداد به دست آمده از الگوریتم لونیبرگ-مارکات (LM) مقدار عدد همبستگی بین ۰/۹۵۱۶۶ تا ۰/۹۹۷۹۷ متغیر بوده که عدد همبستگی به دست آمده برای کل ایران، در محدوده خوبی قرار گرفته است.

عملکرد نتایج حاصل از مدل شبکه عصبی مصنوعی با داده‌های هواشناسی مورد ارزیابی قرار گرفت و اعداد حقیقی قرائت شده توسط هواشناسی برای ایستگاه‌های سینوپتیک مختلف و اعداد پیش‌بینی شده توسط نرم‌افزار متلب برای همین ایستگاه‌ها جهت مقایسه ارائه شده است. اعداد به دست آمده از نرم‌افزار شبکه عصبی مصنوعی و متلب در مقایسه با داده‌های هواشناسی، از نزدیکی خاصی برخوردار بوده است، به طوری که به نظر می‌آید می‌توان از این روش، برای تخمین تشعشع خورشیدی در ایستگاه‌هایی که تشعشع سنج خورشیدی ندارند، استفاده کرد.

گفتنی است که بیشترین و کم‌ترین مقدار تشعشع خورشیدی سالیانه به ترتیب در ایستگاه‌های یزد و رامسر وجود دارد، با توجه به شکل‌های رسم شده برای شش ایستگاه هواشناسی می‌توان به این نکته اشاره کرد که در مسائل تخمین تابع، با تعداد پارامترهای شبکه کمتر از ۱۰۰ عدد الگوریتم لونیبرگ-مارکات (LM) کارایی، سرعت و دقت بالایی از خود نشان می‌دهد، زیرا در بسیاری از موارد، این الگوریتم به حداقل خطا رسیده است. با توجه به نقشه سالیانه بیش‌ترین مقدار تشعشع خورشیدی بین خطوط طولی ۵۰° تا ۶۰° و خطوط عرضی

- [۱] صفائی، ب.، اسدی، م.، تقی‌زاده، ح.، جیلادوی، ا.، طالقانی، گ.، دانش، م.، «برآورد پتانسیل تابش خورشیدی در ایران و تهیه اطلس تابشی آن»، مجله علوم و فنون هسته‌ای، ۳۳، ۲۷-۳۴، ۱۳۸۴.
- [2] Sabziparvar, A.A., "A Simple Formula For Estimating Global Solar Radiation In Central Arid Deserts Of Iran", *Renewable Energy*, Vol.33, PP.1002-1010, 2008.
- [۳] معینی، ص.، جوادی، ش.، دهقان مشادی، م.، اسماعیلی، ر.، «برآورد پتانسیل تابش خورشیدی در یزد»، نشریه انرژی ایران، ۱۳، ۱، ۷۱-۷۸، ۱۳۸۹.
- [4] Elminir, K., Areed, F., Elsayeel, S., "Estimation Of Solar Radiation Components Incident On Helwan Site Using Neural Networks", *Solar Energy*, Vol.79, PP. 270-279, 2005.
- [5] Sozen, A., Arcaklioglu, E., "Solar potential In Turkey", *Applied Energy*, Vol.80, PP. 39-45, 2005.
- [6] Al-Alawi, S.M., Al-Hinai, H.A., "An ANN-Based Approach For Predicting Global Radiation In Locations With NoDirect Measurement InStrumentation", *Renewable Energy*, Vol. 14, Nos.1-4, PP.199-204, 1998.
- [7] Dorvlo, S.S., Jervase, A., Al-lawati, A., "Solar Radiation Estimation Using Artificial Neural Networks", *Applied Energy*, Vol.71, PP. 307-319, 2002.
- [8] Reddy, K.S., Ranjan, M., "Solar Resource Estimation Using Artifical Neural Networks And Comparision With Other Correlation Models", *Energy Conversion and Management*, Vol.44, PP. 2519-2530, 2003.
- [9] Sozen, A., Arcaklioglu, E., Ozalp, M., "Estimation Of Solar Potential In Turkey By Artificial Neural Networks Using Meteorological and Geographical Data", *Energy Conversion and Management*, Vol.45, PP. 3033-3052, 2004.
- [10] Hontoria, L., Aguilera, J., Zufiria, P., "An Application Of The Multilayer Perceptron: Solar Radiation Map In Spain", *Solar Energy*, Vol.79, PP. 523-530, 2005.
- [11] Mubiru, J., Banda, E.J.K.B., "Estimation Of Monthly Average Daily Global Solar Irradiation Using Artificial Neural Networks", *Solar Energy*, Vol.82, pp. 181-187, 2008.
- [12] Lam, C., Wan, K.W., Yang, L., "Solar Radiation Modelling Using ANNs For Different Climates In China", *Energy Conversion and Management*, Vol.49, PP.1080-1090, 2008.
- [13] Hocaoglu, O., Gerek, N., Kurban, M., "Hourly Solar Radiation Forecasting Using Optimal Coefficient 2-D Linear Filter And Feed-Forward Neural Networks", *Solar Energy*, Vol.82, PP. 714-726, 2008.
- [14] Fadare, D.A., "Modelling Of Solar Energy Potential In Nigeria Using An Artificial Neural Network Model", *Applied Energy*, Vol.86, PP. 1410-1422, 2009.
- [۱۵] بیات، ک.، میرلطفی، ص.م.، «تخمین تابش کل خورشیدی روزانه با استفاده از مدل رگرسیونی و شبکه‌های عصبی مصنوعی»، مجله علوم کشاورزی و منابع طبیعی، ۱۶، ۳، ۱-۱۱، ۱۳۸۸.
- [16] Rahimikhoob, A., "Estimating Global Solar Radiation Using Artificial Neural Network And Air Temperature Data In A Semi-Arid Environment", *Renewable Energy*, Vol.35, PP. 2131-2135, 2010.
- [۱۷] سبزی پرور، ع.ا.، علیانی، ا.، «ارزیابی عملکرد شبکه عصبی مصنوعی در پیش‌بینی تابش خورشیدی کل روزانه و مقایسه آن با نتایج مدل آنگستروم (مطالعه موردی، ایستگاه همدیدی تبریز)»، مجله ژئوفیزیک ایران، ۵، ۳، ۳۰-۴۱، ۱۳۹۰.
- [۱۸] منهای، محمداقرا، مبانی شبکه‌های عصبی، جلد ۱، تهران، مرکز نشر دانشگاه صنعتی امیرکبیر، ۱۳۷۹.