

## تأثیر پارامترهای اقلیمی در مدل سازی تابش خورشیدی با استفاده از مدل های هوش مصنوعی (مطالعه موردی: ایستگاه سینوپتیک یزد)

حمیده افخمی<sup>\*۱</sup>

<sup>۱</sup> دکتری علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی و کویر شناسی، دانشگاه یزد، یزد، ایران

(تاریخ دریافت: ۱۳۹۶/۱۱/۲۸، تاریخ پذیرش: ۱۳۹۷/۰۹/۲۱)

### چکیده

تابش خورشیدی یکی از پارامترهای مهم اقلیمی است که بر بسیاری از فرایندهای آب و خاک مانند تبخیر، ذوب برف و رشد گیاهان اثر می‌گذارد. از این رو، برآورد میزان صحیح تابش خورشیدی در توسعه پژوهش‌های کاربردی ضروری به نظر می‌رسد. در این مقاله سعی شده است کارایی دو روش شبکه عصبی مصنوعی و مدل‌های استنتاج فازی در پیش‌بینی میزان تابش خورشیدی برای ۱۲ ماه آینده در ایستگاه یزد بررسی شود. به این منظور، با استفاده از تحلیل حساسیت پارامترهای اقلیمی مختلف، دمای بیشینه روزانه، دمای میانگین روزانه، بیشینه ساعات آفتابی، میانگین رطوبت نسبی هوا و تبخیر به عنوان عوامل مؤثر در پیش‌بینی تابش خورشیدی شناسایی و با ایجاد ترکیبات مختلف داده‌ها، دو مدل ارزیابی شدند. در نهایت، بعد از اطمینان از کارایی دو مدل در مرحله آزمایش و حصول بهترین نتایج که بیشترین ضریب همبستگی و کمترین خطا را در فرایند پیش‌بینی تابش خورشیدی به دنبال داشت، تنها با وارد کردن پارامترهای اقلیمی مؤثر سال ۲۰۰۵ به عنوان ورودی، مقدار تابش خورشیدی سال ۲۰۰۶ به عنوان خروجی، پیش‌بینی و نتایج پیش‌بینی شده با داده‌های واقعی مقایسه شد. نتایج پیش‌بینی‌ها، کارایی زیاد شبکه‌های عصبی و فازی-عصبی را هم در مرحله آزمایش مدل و هم در فرایند پیش‌بینی نشان می‌داد. در مجموع، شبکه‌های عصبی مصنوعی با ضریب همبستگی ۰/۹۱ و میزان RMSE و MAE به ترتیب ۰/۱۱ و ۰/۰۸، در پیش‌بینی‌ها خطای کمتری را در مقایسه با شبکه‌های فازی-عصبی داشتند. همچنین کمیت BIAS نیز ۰/۳۰- محاسبه شد که مقدار منفی، فروتخمینی جزئی را در داده‌ها نشان می‌دهد. در این پژوهش، ساعات آفتابی و دمای متوسط مؤثرترین پارامترها در پیش‌بینی تابش خورشیدی شناخته شدند در حالی که رطوبت نسبی، کمترین نقش را در این فرایند ایفا کرد.

**واژه‌های کلیدی:** مدل سازی، تابش خورشیدی، شبکه عصبی مصنوعی، سیستم استنتاج فازی، ایستگاه یزد

## ۱ مقدمه

در بسیاری از نواحی ایران از جمله نواحی مرکزی، علی‌رغم دریافت بارش کم، میزان تبخیر و تعرق، بسیار زیاد و در بیشتر موارد، میزان تبخیر پتانسیل از سطح منطقه بیش از چندین برابر بارش دریافتی است. به تشخیص سازمان فائو، مقدار تابش خورشیدی از جمله عوامل مؤثر در تخمین تبخیر و تعرق پتانسیل است. داده‌های تابش خورشیدی از نیازهای اساسی مدل‌های ذوب برف، همانندسازی رشد گیاهان برای پیش‌بینی فتوسنتز، پردازش‌های وابسته به نورپردازی ساختمان‌ها، طراحی سامانه‌های فعال و غیرفعال خورشیدی مانند سامانه‌های گرمایش خورشیدی در ساختمان‌ها (مانند آب‌گرم‌کن‌های خورشیدی) و نظیر آن است (بکرکی، ۲۰۰۹). علاوه بر این، باد و خورشید یکی از بزرگ‌ترین منابع انرژی تجدیدپذیر هستند، اما به دلیل عدم قطعیت کمتر تابش خورشید نسبت به باد، به نظر می‌رسد آینده از آن تولیدات پراکنده با استفاده از تابش خورشید خواهد بود. این پارامتر از ارکان اساسی توسعه پژوهش‌های کاربردی انرژی خورشیدی به‌شمار می‌رود. مطالعه در زمینه انرژی خورشید از سال ۱۹۷۰ شروع شد. تعیین دقیق مؤلفه‌های تابش، مهم‌ترین نیاز در طراحی‌های کاربردی انرژی خورشیدی است. کاهش عرض جغرافیایی منجر به افزایش میزان تابش خورشیدی می‌شود. کشور ایران به دلیل گستردگی وسیع از نظر عرض جغرافیایی، میزان متنوعی از تابش خورشیدی را دریافت می‌کند. جهت محاسبه انرژی خورشیدی روابط متفاوتی پیشنهاد شده است. نخستین بار آنگستروم توانست با به‌کارگیری داده‌های جوی نظیر ساعات آفتابی مدل ساده‌ای برای تخمین مقدار تابش کل خورشیدی ارائه کند (آنگستروم، ۱۹۲۴). پس از وی، دانشمندان زیادی اقدام به بهبود و تعدیل مدل آنگستروم در شرایط اقلیمی مختلف کردند. پالتریچ و پروکتور (۱۹۷۶) به‌منظور افزایش دقت مدل خود، مؤلفه‌های مستقیم و پراکنده نور خورشید را به‌طور مجزا محاسبه کردند. آنها در

مدل ساده‌ای، مقادیر تابش مستقیم و پراکنده روزانه را با استفاده از نسبت  $(n/N)$  که  $n$ : ساعات آفتابی و  $N$ : پتانسیل ساعات آفتابی در روز مورد مطالعه است و همچنین زاویه سمت الراس خورشید  $(\theta)$  محاسبه کردند. سبزی پرور (۲۰۰۷) مدل اصلاح‌شده دانشیار (دانشیار، ۱۹۷۸) را برای تخمین تابش خورشیدی روزانه در مناطق ساحلی ایران به‌عنوان روش قابل قبول پیشنهاد کرد. سبزی پرور و شتایی (۲۰۰۷) پارامتر آبرناکی را عاملی مؤثر در تخمین تابش خورشیدی در اقلیم‌های خشک و نیمه‌خشک تشخیص دادند. با توجه به کیفیت نداشتن داده‌های ثبت شده و محدودیت ایستگاه‌های اندازه‌گیری تابش خورشیدی، پیش‌بینی تابش خورشیدی به‌عنوان عاملی مهم در کاربردهای متفاوت انرژی خورشید ضروری به‌نظر می‌رسد. مدل‌های تجربی مورد استفاده در تخمین تابش خورشیدی، مدل‌هایی خطی هستند که داده‌ها در آنها ثابت فرض می‌شود و توانایی محدودی در مواجهه با داده‌های غیرخطی دارند. با توجه به آنچه بیان شد، نیاز به مدل‌های غیرآماري و غیرخطی در پیش‌بینی‌ها ضروری است. در دهه‌های اخیر، استفاده از روش شبکه‌های عصبی مصنوعی (ANN) در پیش‌بینی‌ها از میان انواع مدل‌های غیرخطی، نتایج درخشانی را نشان داده است (میشرا و همکاران، ۲۰۰۷). اولین بار کاوجیرو و همکاران (۱۹۸۶)، کاربرد شبکه عصبی مصنوعی را در مدل کردن مقدار تابش خورشید مطرح کردند. سوزن و همکاران (۲۰۰۵) و مویرو و باندا (۲۰۰۸) از نتایج شبکه عصبی مصنوعی در پهنه‌بندی تابش خورشیدی استفاده کردند. ریمان و همکاران (۲۰۰۸) با استفاده از نتایج آزمون گاما (Gama) میزان تابش خورشیدی و دما را از میان سایر پارامترهای اقلیمی به‌عنوان مؤثرترین پارامترهای ورودی شبکه عصبی مصنوعی معرفی کردند. فادار (۲۰۰۹) میزان تابش خورشیدی را با استفاده از شبکه‌های عصبی مصنوعی در منطقه نیجر به پیش‌بینی کرد و به نتایج قابل ملاحظه‌ای دست یافت. در آن تحقیق،

در ایران نیز مطالعاتی در زمینه پیش‌بینی تابش خورشیدی با استفاده از شبکه‌های عصبی مصنوعی و با اهداف مختلف انجام شده است که از جمله می‌توان به نتیجه مطالعه سلطانی و مرید (۱۳۸۴) در پیش‌بینی تابش خورشیدی با استفاده از دو روش شبکه عصبی مصنوعی و شبکه عصبی هارگریوز-سامانی اشاره کرد که نتایج، حاکی از عملکرد بهتر شبکه عصبی مصنوعی نسبت به روش شبکه عصبی مصنوعی هارگریوز-سامانی بود. سبزی پرور و بیات ورکشی (۱۳۸۹) نیز جهت شبیه‌سازی مقدار تابش کل خورشیدی از شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی عصبی-فازی (ANFIS) استفاده کردند. نتایج پیش‌بینی با استفاده از شبکه عصبی مصنوعی تا اندازه‌ای بهتر از سیستم استنتاجی عصبی-فازی گزارش شد. آقا ابراهیمی و باقرزاده (۱۳۹۰) با استفاده از شبکه عصبی مصنوعی، تابش سالانه خورشید را با کمترین خطا و بیشترین دقت ممکن پیش‌بینی کردند و از نتایج آن، جهت تولید انرژی الکتریکی از سلول‌های خورشیدی بهره گرفتند. شبانی و کاظمی نسب (۱۳۹۱) پیش‌بینی میزان تابش خورشید با استفاده از شبکه عصبی مصنوعی را جهت مدل‌سازی یک سیستم هیدروژن خورشیدی برای تغذیه یک بار متغیر به کار بردند.

مطالعه حاضر، برای ارزیابی شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی در پیش‌بینی مقدار تابش خورشیدی در بازه زمانی ۱۲ ماه آینده در ایستگاه یزد انجام گرفت. هدف از ارزیابی، مقایسه روش‌های هوش مصنوعی و تحلیل حساسیت جهت تعیین مهم‌ترین پارامترهای مؤثر بر این پیش‌بینی است.

## ۲ مواد و روش‌ها


### ۲-۱ ناحیه مورد مطالعه

در این تحقیق، از آمار ایستگاه هواشناسی همدیدی یزد در بازه زمانی سال‌های ۱۹۸۲ تا ۲۰۰۶ استفاده شده است.

پارامترهای ورودی شبکه شامل مختصات جغرافیایی، ارتفاع از سطح دریا، میانگین دما، میانگین ساعات آفتابی و رطوبت نسبی بود. مقدم‌نیا و همکاران (۲۰۰۹) نیز به‌منظور تعیین پارامترهای هواشناسی مؤثر در مقدار تابش خورشیدی، با به‌کارگیری آزمون گاما، اقدام به پیش‌بینی مقدار تابش خورشیدی با استفاده از شبکه عصبی مصنوعی و فازی در حوضه آبریز انگلستان کردند و در نهایت، توانایی شبیه‌سازی تابش خورشیدی با استفاده از شبکه عصبی مصنوعی را بهتر از مدل فازی ارزیابی کردند. ایبه و همکاران (۲۰۱۲) پیش‌بینی تابش روزانه خورشید در نیجریه را با دو روش شبکه عصبی و رگرسیون چندمتغیره انجام دادند که نتایج شبکه عصبی مصنوعی، کارایی بهتری را در پیش‌بینی سری زمانی تابش خورشیدی نشان می‌داد. اوزگرن و همکاران (۲۰۱۲) به پیش‌بینی تابش خورشیدی ماهانه با استفاده از شبکه‌های عصبی مصنوعی و رگرسیون غیرخطی چندگانه در ترکیه پرداختند. در آن مطالعه، آموزش مدل با استفاده از بیست و هفت ایستگاه انجام و نتایج در چهار ایستگاه آزمایش شد و ضریب همبستگی بالایی در پیش‌بینی میزان تابش خورشیدی با استفاده از شبکه عصبی به‌دست آمد. منصور و همکاران (۲۰۱۷) با استفاده از شبکه‌های پرسپترون چندلایه، انرژی تابشی خورشید در مقیاس ماهانه را در منطقه جنوب غرب مراکش پیش‌بینی کردند. ایشان از مجموعه‌ای از داده‌های هواشناسی و جغرافیایی مانند عرض جغرافیایی، طول جغرافیایی، ماه-های سال، دمای متوسط، مدت زمان تابش خورشید، رطوبت نسبی و متوسط ماهانه تابش خورشیدی جهانی برای مدل‌سازی استفاده کردند. حسین والعلیلی (۲۰۱۷) به‌منظور پیش‌بینی تابش خورشیدی، از یک مدل هیبریدی متشکل از چندین شبکه عصبی مصنوعی و موجک استفاده کردند و در نهایت تأثیر توابع موجک در بهبود عملکرد شبکه عصبی را بیش از ۶/۸۴ درصد تخمین زدند.

## ۲-۳ شبکه‌های پرسپترون چندلایه

شبکه‌های پرسپترون یک نوع ویژه از شبکه‌های عصبی مصنوعی هستند که توانایی و مهارت خاصی را در شناخت الگو و تابع حاکم بر مسائل غیرخطی دارند (جیرکا و همکاران، ۱۹۹۶). شبکه پرسپترون، یک شبکه پیشرو چندلایه متشکل از سه لایه ورودی، خروجی و پنهان است. نقش لایه ورودی، دریافت اطلاعات خامی است که شبکه را تغذیه می‌کنند. لایه پنهان به وسیله ورودی‌ها و وزن‌دهی به آنها، ارتباط بین لایه ورودی و لایه پنهان را تعیین می‌کند و لایه خروجی، وظیفه وزن‌دهی و ارتباط بین لایه پنهان و لایه خروجی را دارد (هسو و همکاران، ۱۹۹۵). شبکه پیشرو از مجموع اطلاعات لایه‌های ورودی، یک پاسخ در مسیر روبه‌جلو تولید می‌کند. همچنین اتصالات این شبکه کامل است؛ یعنی هر نرون در هر لایه به نرون‌های لایه بعدی اتصال دارد. شکل ۱ نمای کلی از یک شبکه پرسپترون را نمایش می‌دهد (کادیل، ۱۹۸۷).



شکل ۱. نمونه ساده‌ای از شبکه‌های پرسپترون استفاده شده در این تحقیق

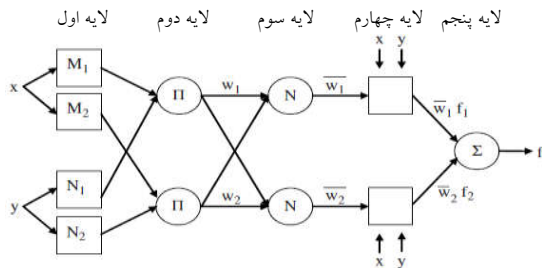
شبکه‌های پرسپترون با الگوریتم‌های متفاوتی آموزش می‌بینند. از جمله الگوریتم‌های یادگیری در شبکه‌های پرسپترون، می‌توان به الگوریتم لونیگ-مارکوآرت (Levenberg-Marquardt)، قانون یادگیری دلتا (Delta) و پس‌انتشار خطا (back propagation) اشاره کرد که در الگوریتم پس‌انتشار خطا جهت تسریع در همگرایی خطا از الگوریتم دیگری موسوم به قانون یادگیری مومنت

ایستگاه همدیدی یزد در شهرستان یزد واقع و ارتفاع آن از سطح دریا ۱۲۳۰ متر است. این ایستگاه با موقعیت ۵۴ درجه و ۱۷ دقیقه طول شمالی و ۳۱ درجه و ۵۳ دقیقه عرض جغرافیایی در بین سایر ایستگاه‌های موجود در استان، کامل‌ترین آمار اقلیمی را دارد. دلیل انتخاب بازه یاد شده، پیوستگی و کامل بودن داده‌های مربوط به ساعات آفتاب و همچنین طول دوره مشترک آمار بلندمدت پارامترهای اقلیمی است. به این ترتیب، تعداد داده‌های مورد استفاده هریک از پارامترهای هواشناسی نامبرده حدود ۳۰۰ داده و معادل ۲۵ سال است که به صورت ماهیانه استفاده شد.

## ۲-۲ شبکه‌های عصبی مصنوعی

روش شبکه عصبی مصنوعی یک روش جدید در حل مسائل پیچیده و زمان‌بر است. بیشترین کاربرد این روش در مورد مسائلی است که ارتباط غیرخطی میان پارامترهای معلوم و مجهول آن وجود دارد؛ زیرا یکی از قابلیت‌های مهم شبکه عصبی مصنوعی، درک رفتار غیرخطی سیستم است (غضنفری و همکاران، ۲۰۰۸). قدرت انعطاف و تصحیح‌پذیری زیاد این شبکه‌ها با داده‌های موجود به گونه‌ای است که قادرند با سازماندهی مشخص، نظم و هماهنگی بین داده‌ها را پیدا و براساس بردارهای ورودی، مقادیر و بزرگی یک پدیده را پیش‌بینی کنند (کنرادس و روهل، ۱۹۹۹). اساس کار شبکه‌های عصبی مصنوعی بر پایه یادگیری فرایند با استفاده از الگو است (لوکیو، ۲۰۰۷). این شبکه‌ها با داده‌هایی آموزش می‌بینند که دربرگیرنده ورودی و خروجی باشد. به این دسته از داده‌ها، داده‌های آموزشی گفته می‌شود. در پایان مرحله آموزش، شبکه با بخش دیگری از داده‌ها آزمایش می‌شود. این داده‌ها که به داده‌های آزمایشی مشهور هستند، قبلاً در آموزش مدل استفاده نشده‌اند و جهت ارزیابی کارایی مدل آموزش دیده استفاده می‌شوند (منهاج، ۱۳۸۴).

$M_i$  و  $N_i$  به ترتیب مجموعه‌های فازی نرون‌های  $x$  و  $y$  هستند.



شکل ۲. ساختار شبکه‌های ANFIS استفاده شده در این تحقیق

تابع عضویت مجموعه‌های فازی معمولاً با توابع زنگوله‌ای شکل تعمیم‌یافته رابطه (۱) تعریف می‌شود (جانگ، ۱۹۹۳):

$$\mu_{M_i}(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2N_i}}, \quad (1)$$

پارامترهای  $a_i$ ,  $N_i$  و  $c_i$  پارامترهای توابع عضویت این مجموعه هستند. این پارامترها را پارامترهای شرط نیز می‌نامند. در لایه دوم تابع عضویت  $x$  در تابع عضویت  $y$  ضرب و با رابطه (۲) محاسبه می‌شود:

$$w_i = \mu_{M_i}(x) \mu_{N_i}(y), \quad (i=1,2). \quad (2)$$

در لایه سوم نسبت خروجی هر نرون به خروجی کلیه نرون‌ها طبق رابطه (۳) محاسبه می‌شود:

$$\bar{w}_i = \frac{w_i}{\sum w_i}, \quad (i=1,2). \quad (3)$$

نرون‌ها در لایه چهارم از نرخ لایه سوم به‌عنوان وزن استفاده می‌کنند و مقدار به‌دست‌آمده در پارامتر خروجی ضرب می‌شود. در این لایه، قانون اگر-آنگاه حاکم است.

(momentum) استفاده می‌شود. علاوه‌براین، در این شبکه‌ها برای انتقال خروجی‌های هر لایه به لایه‌های بعدی، از توابع محرک استفاده می‌شود که از جمله این توابع می‌توان سیگموئید، تانژانت هایپربولیک، آکسون و توابع خطی در لایه‌های پنهان و لایه خروجی را نام برد. بدیهی است تعیین قانون یادگیری و توابع انتقال با توجه به نوع داده‌ها و براساس آزمون خطا صورت می‌گیرد.

## ۲-۴ سیستم تطبیقی استنتاج فازی-عصبی (ANFIS)

سیستم تطبیقی فازی-عصبی، یک سیستم فازی است که از الگوریتم آموزشی به‌دست‌آمده از نظریه شبکه عصبی تبعیت می‌کند و تشخیص پارامترهای فازی (توابع عضویت فازی و قانون‌های فازی) را با استفاده از پردازش داده‌ها انجام می‌دهد. در واقع، در سیستم فازی-عصبی، استخراج توابع عضویت، نگاشت مجموعه‌های فازی به قانون‌های فازی و تکمیل مرحله غیرفازی‌سازی به‌وسیله یک شبکه عصبی انجام می‌گیرد. در این نوع سیستم‌ها، شبکه عصبی مصنوعی، الگوها را شناسایی می‌کند و سیستم را با محیط تطبیق می‌دهد. مدل فازی-عصبی شامل طراحی سیستم‌های فازی و عصبی است که این شبکه‌های عصبی، در واقع سیستم فازی را به توانایی آموزش مجهز می‌کنند. به‌طور کلی مرسوم‌ترین سیستم فازی که به‌کار می‌رود، سیستم قاعده‌بنیاد فازی است و شبکه عصبی مورد استفاده نیز معمولاً شبکه پیشرو (Feed Forward) چندلایه با الگوریتم آموزشی پس‌انتشار خطا است. این شبکه‌ها مطابق شکل ۲ عمل می‌کنند: پس از آنکه مقادیر ورودی  $x$  و  $y$  به نرون‌های لایه ورودی (لایه اول) وارد شدند، وارد توابع عضویت زنگوله‌ای شکل می‌شوند و مقادیر خروجی حاصل می‌شود (جانگ و جانگ، ۲۰۰۶). در این شکل،  $w$  خروجی یک نرون و  $\mu$  تابع عضویت است.

با مقادیر واقعی سال ۲۰۰۶ مقایسه شد. براین اساس، داده‌ها به سه دسته تقسیم‌بندی شدند. هفتاد درصد داده‌ها به صورت تصادفی به عنوان داده‌های آموزشی و سی درصد داده‌ها به عنوان داده‌های آزمایشی استفاده شدند و میزان تابش سال ۲۰۰۶ پیش‌بینی و با نتایج واقعی در این سال مقایسه شد (از آمار سال ۲۰۰۵ در آموزش و آزمایش مدل استفاده نشد).

$$X_n = \frac{X_0 - X_{\min}}{X_{\max} - X_{\min}}, \quad (5)$$

که در آن  $X_n$  داده‌های نرمال شده،  $X_0$  داده‌های واقعی،  $X_{\max}$  بیشینه داده‌های واقعی و  $X_{\min}$  کمینه داده‌های واقعی است.

علاوه بر این، در دو مدل شبکه عصبی مصنوعی و استنتاج فازی، با استفاده از پارامترهای مختلف، ترکیبات متفاوت ایجاد و به مدل‌ها معرفی شد سپس تابش خورشیدی برای ۱۲ ماه آینده پیش‌بینی و در نهایت، بهترین ترکیب با مطلوب‌ترین نتیجه تعیین شد. در ادامه، با استفاده از بهترین ترکیب حاصل از دو مدل، مقادیر تابش داده‌های سال ۲۰۰۵ به مدل معرفی، مقادیر سال ۲۰۰۶ پیش‌بینی و با مقادیر واقعی موجود در سال ۲۰۰۶ مقایسه شد.

## ۷-۲ فرایند پیش‌بینی

امروزه به علت پیشرفت سریع فناوری در پردازش داده‌ها و ابزارهای شبیه‌سازی، فرایند پیش‌بینی تا حد زیادی بهبود یافته است. در این تحقیق فرایند پیش‌بینی تابش خورشیدی برای ۱۲ ماه آینده صورت گرفته است. در واقع براساس داده‌های گذشته و حال، شرایط برای مقطع زمانی آینده پیش‌بینی می‌شود. به عبارت دیگر، چنانچه  $S$  ساعات آفتابی در زمان  $t$  باشد، مقدار تابش خورشیدی در زمان

به عنوان مثال اگر  $x$  معادل  $M_i$  و  $y$  برابر  $N_i$  باشد، آنگاه

$$f_i = (p_i x + q_i y + r_i)$$

$$\overline{w_i f_i} = \overline{w_i} (p_i x + q_i y + r_i). \quad (4)$$

در رابطه بالا،  $r_i$ ،  $p_i$  و  $q_i$ ، پارامترهای تطبیقی لایه یا پارامترهای نتیجه هستند. در نهایت،  $f$  که خروجی شبکه و مجموع کل سیگنال خروجی است، با رابطه (۴) محاسبه و به وسیله نرون‌های لایه پنجم حاصل می‌شود. به این ترتیب، می‌توان یک سیستم فازی با قابلیت یادگیری را پیاده‌سازی کرد (ازاماتولا و همکاران، ۲۰۰۹).

روش آموزش اصلی در این مدل، روش پس‌انتشار خطا است. در این روش با استفاده از الگوریتم شیب کاهشی سعی می‌شود تا مجموع مربعات خطاها بین خروجی‌های شبکه و تابع هدف، کمینه شود. الگوریتم شیب کاهشی در فضای وزن‌ها به دنبال برداری می‌گردد که خطا را حداقل کند، اما تضمینی برای رسیدن این الگوریتم به کمینه مطلق، وجود ندارد (جانگ، ۱۹۹۳).

## ۵-۲ آماده‌سازی داده‌ها

پس از اخذ اطلاعات لازم، همگنی داده‌ها به کمک آزمون توالی آزمایش شد و نواقص اندک آماری با استفاده از سایر ایستگاه‌های موجود و روش نسبت نرمال بازسازی شد. پارامترهای مورد استفاده در این مطالعه عبارت‌اند از: دمای بیشینه، دمای متوسط، دمای کمینه، میانگین رطوبت نسبی، حداکثر سرعت باد، جهت باد، تبخیر، ساعات آفتابی و تابش خورشیدی. به این ترتیب، داده‌های سال‌های ۱۹۸۲ تا ۲۰۰۴ به مدت ۲۳ سال جهت آموزش و آزمایش دو مدل شبکه عصبی و شبکه‌های فازی-عصبی به کار گرفته شد. پس از اخذ بهترین نتایج از این دو مدل، با استفاده از آمار سال ۲۰۰۵ پارامتر تابش خورشیدی در سال ۲۰۰۶ (۱۲ ماه بعد) پیش‌بینی و نتایج

$$r = \sqrt{1 - \frac{\sum_{i=1}^n (O_i - P_i)}{\sum_{i=1}^n (O_i - \bar{O}_i)}} \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (14)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \quad (15)$$

$$BIAS = \frac{1}{n} \sum_{i=1}^n (P_i - O_i) \quad (16)$$

که  $O_i$  داده‌های مشاهده‌ای،  $P_i$  داده‌های شبیه‌سازی شده و  $n$  تعداد داده‌ها است.

### ۳ نتایج و بحث

#### ۳-۱ نتایج کاربرد شبکه عصبی مصنوعی در

##### پیش‌بینی تابش خورشیدی

در این تحقیق به منظور ارزیابی کارایی شبکه عصبی در پیش‌بینی میزان تابش خورشیدی ایستگاه یزد از آمار سال-های ۱۹۸۲ تا ۲۰۰۴ استفاده شد. در این بازه ابتدا تمام سطرها به صورت تصادفی جابه‌جا و سپس هفتاد درصد داده‌ها در مرحله آموزش و سی درصد باقی‌مانده در مرحله آزمایش استفاده شدند. در اولین مرحله، داده‌های ورودی که شامل ساعات آفتابی، دمای کمینه، دمای متوسط، دمای بیشینه، سرعت و جهت باد، رطوبت نسبی و تبخیر بودند، با نرم‌افزار Neural Solution تحلیل و مهم‌ترین عوامل مؤثر در پیش‌بینی تابش خورشیدی تعیین شد. براین اساس، پنج پارامتر ساعات آفتابی، دمای متوسط، دمای بیشینه، رطوبت نسبی و تبخیر نسبت به سایر پارامترها مؤثر تشخیص داده شدند. در ادامه، سه ترکیب متفاوت آماده و به مدل معرفی و میزان تابش خورشیدی برای ۱۲ ماه آینده پیش‌بینی شد. درنهایت، جهت ارزیابی مدل، از آماره ضریب همبستگی استفاده و میزان خطا نیز با استفاده از سه آماره RMSE، MSE و BIAS تعیین شد.

آینده،  $S_{A(t+1)}$  پیش‌بینی می‌شود. تابع پارامترهایی است که در زیر معرفی می‌شود (روابط (۶) تا (۱۲)):

$$S_{A(t+1)} = f(S_{(t)}, S_{(t-1)}, \dots, S_{(t-n)}), \quad (6)$$

$$S_{A(t+1)} = f(T_{\min(t)}, T_{\min(t-1)}, \dots, T_{\min(t-n)}), \quad (7)$$

$$S_{A(t+1)} = f(T_{\text{ave}(t)}, T_{\text{ave}(t-1)}, \dots, T_{\text{ave}(t-n)}), \quad (8)$$

$$S_{A(t+1)} = f(W_{s(t)}, W_{s(t-1)}, \dots, W_{s(t-n)}), \quad (9)$$

$$S_{A(t+1)} = f(W_{a(t)}, W_{a(t-1)}, \dots, W_{a(t-n)}), \quad (10)$$

$$S_{A(t+1)} = f(R_{H(t)}, R_{H(t-1)}, \dots, R_{H(t-n)}), \quad (11)$$


$$S_{A(t+1)} = f(E_{R(t)}, E_{R(t-1)}, \dots, E_{R(t-n)}). \quad (12)$$

که  $f$  یک تابع غیرخطی نامعین،  $S_{(t)}$  میزان ساعات آفتابی در زمان  $t$ ،  $S_{A(t+1)}$  میزان تابش خورشیدی در زمان آینده در ایستگاه یزد و  $n$  تعداد داده‌های مربوط به مقطع‌های زمانی حال و گذشته است که جهت پیش‌بینی‌ها استفاده شده است.  $T_{\min(t)}$  دمای کمینه،  $T_{\text{ave}(t)}$  دمای متوسط،  $W_{s(t)}$  سرعت شدیدترین باد،  $W_{s(t)}$  جهت باد غالب،  $R_{H(t)}$  رطوبت نسبی و  $E_{R(t)}$  تبخیر در زمان  $t$  است.

#### ۲-۸ ارزیابی کارایی مدل‌ها

به منظور ارزیابی کارایی بین داده‌های واقعی و داده‌های شبیه‌سازی شده از آماره ضریب همبستگی ( $r$ ) و جهت برآورد خطا از سه آماره ریشه میانگین مربعات خطا (RMSE)، میانگین مطلق خطا (MAR) و بایاس (BIAS) استفاده شد که معادلات آماره‌های فوق در روابط (۱۳) تا (۱۶) آورده شده است (میشرا و همکاران، ۲۰۰۷):

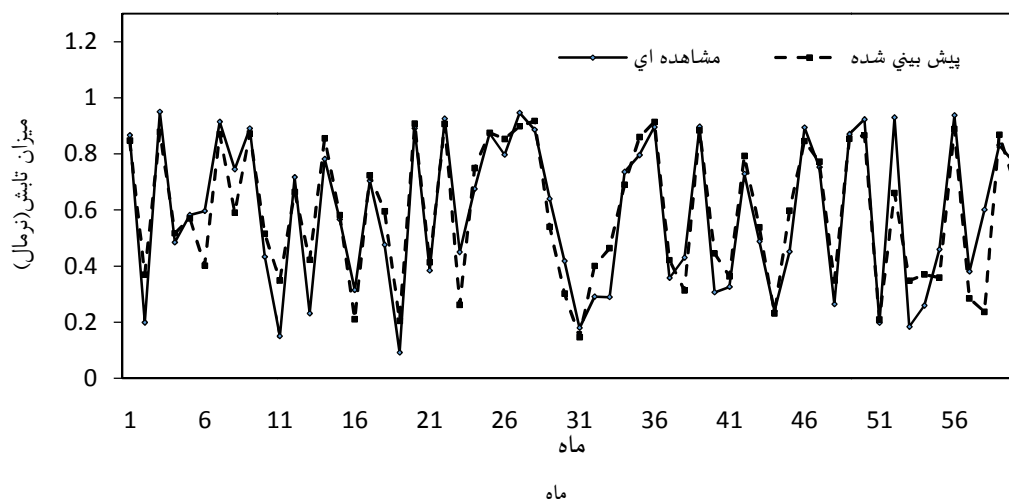
همان گونه که ملاحظه می شود بهترین ترکیب در این مرحله، ضریب همبستگی  $0/91$  و میزان RMSE و MAE به ترتیب  $0/11$  و  $0/08$  را دارد. مقدار BIAS نیز  $0/30-$  است که مقدار منفی، فروتخمینی جزئی را در داده ها نشان می دهد. این نتایج مربوط به همان ترکیب ساعات آفتابی، دمای متوسط، دمای بیشینه، رطوبت نسبی و تبخیر در حالت نرمال است. نتایج تحلیل حساسیت در این ترکیب، حساسیت بیشتر ساعات آفتابی را نسبت به سایر پارامترها در پیش بینی تابش خورشیدی نشان داد. همچنین نتایج حاکی از تأثیر بیشتر دمای متوسط نسبت به دمای بیشینه است (شکل ۳). شکل ۴ مقایسه مقادیر واقعی و پیش بینی شده را با استفاده از شبکه های پرسپترون نشان می دهد.



شکل ۳. تحلیل حساسیت پارامترهای ورودی به شبکه عصبی پرسپترون

در میان مدل های شبکه عصبی، جهت پیش بینی تابش خورشیدی، شبکه های پرسپترون توانایی بیشتری در شبیه سازی و پیش بینی از خود نشان دادند. براین اساس، تعداد نرون های لایه پنهان متناسب با  $2n$  در نظر گرفته شد که  $n$  تعداد عوامل ورودی به شبکه است. سایر پارامترها از قبیل تعداد لایه پنهان و لایه خروجی، توابع انتقال در لایه ورودی و خروجی، الگوریتم یادگیری و تعداد دور، براساس آزمون و خطا تعیین شد.

به منظور افزایش عملکرد شبکه های عصبی، ورودی های مدل با استفاده از رابطه (۵) نرمال و سپس طبق ترکیبات ذکر شده در مرحله قبل، سه ترکیب فوق در حالت نرمال شده به مدل پرسپترون معرفی و نتایج بررسی شد. نتایج در تمام موارد، وجود یک لایه پنهان را با تابع انتقال سیگموئید در لایه پنهان و خروجی به عنوان بهترین تابع نشان داد. همچنین الگوریتم یادگیری لونیبرگ-مارکوورت به دلیل سرعت زیاد همگرایی، نسبت به دیگر الگوریتم ها، در بهبود نتایج تأثیر بیشتری داشت. تعداد دور مناسب شبکه نیز بین ده هزار تا دوازده هزار تعیین شد. ترکیبات و نتایج این مرحله در جدول ۱ نمایش داده شده است.



شکل ۴. مقایسه نتایج مشاهده ای و پیش بینی شده با استفاده از شبکه های پرسپترون چندلایه




جدول ۱. نتایج پیش‌بینی تابش با استفاده از شبکه‌های عصبی مصنوعی (داده‌های نرمال)

MAE	PBIAS	RMSE	r verification	r evaluation	R <sup>2</sup>	دور	تابع خروجی	تابع میانی	ترکیب ورودی
۰/۰۸	-۰/۳۰	۰/۱۱	۰/۹۵	۰/۹۱	۰/۸۳	۱۰۰۰۰	Sigmoid	Sigmoid	T <sub>ave</sub> -T <sub>max</sub> -H-E-S
۰/۰۸	۲/۰۸	۰/۱۱	۰/۸۷	۰/۹۰	۰/۸۱	۱۰۰۰۰	Sigmoid	Sigmoid	T <sub>ave</sub> -T <sub>max</sub> -H-S
۰/۰۸	-۰/۹۶	۰/۱۱	۰/۸۳	۰/۹۱	۰/۸۲	۱۰۰۰۰	Sigmoid	Sigmoid	T <sub>ave</sub> -T <sub>max</sub> -S

جدول ۲. نتایج پیش‌بینی تابش با استفاده از شبکه‌های فازی در حالت استفاده از نرمال

MAE	PBIAS	RMSE	r verification	r evaluation	R <sup>2</sup>	تعداد دور	تابع لایه خروجی	مدل فازی	تابع عضویت	ترکیب ورودی
۰/۰۹	-۳/۸۵	۰/۱۲	۰/۹۵	۰/۹۰	۰/۸۱	۲۰۰۰	Axon	TSK	Bell	T <sub>ave</sub> -T <sub>max</sub> -H-E-S
۰/۰۹	-۵/۷	۰/۱۲	۰/۹۱	۰/۹۱	۰/۸۳	۲۰۰۰	Axon	TSK	Bell	T <sub>ave</sub> -T <sub>max</sub> -H-S
۰/۰۸	۲/۵۲	۰/۱۰	۰/۹۰	۰/۹۲	۰/۸۵	۲۰۰۰	Axon	TSK	Bell	T <sub>ave</sub> -T <sub>max</sub> -S

این ترکیب، دمای متوسط و ساعات آفتابی مؤثرتر از سایر عوامل هستند (شکل ۵). شکل ۶ نیز مقایسه مقادیر پیش‌بینی شده و واقعی را در شبکه‌های فازی-عصبی نشان می‌دهد.



شکل ۵. تحلیل حساسیت پارامترهای ورودی به شبکه فازی-عصبی

درنهایت، با توجه به کارایی و عملکرد دو مدل و همچنین حصول بهترین نتایج، داده‌های نرمال شده سال ۲۰۰۵ که تاکنون در هیچ مرحله آموزش و آزمایش استفاده نشده بودند، به دو مدل MLP و ANFIS معرفی شد و عملیات پیش‌بینی مقادیر تابش برای سال ۲۰۰۶ انجام گرفت. بعد از فرایند پیش‌بینی مدل، ابتدا عملیات معکوس


### ۲-۳ نتایج شبکه‌های استنتاج فازی در پیش‌بینی تابش خورشیدی

در این مرحله نیز از ترکیبات مختلف به‌عنوان ورودی مدل ANFIS استفاده شد. در مدل ANFIS، در لایه پنهان تابع عضویت زنگوله‌ای نسبت به تابع گوسی عملکرد بهتری داشت و در لایه خروجی، تابع آکسون برتری قابل ملاحظه‌ای را نسبت به توابع سیگموئید و تانژانت هایپربولیک از خود نشان داد. علاوه‌براین، به‌منظور استنتاج قوانین فازی از اطلاعات ورودی-خروجی، مدل فازی تاکاگی نسبت به مدل سوگنو عملکرد بهتری از خود نشان داد. شایان ذکر است که در این مدل، از الگوریتم آموزشی پس‌انتشار خطا و قانون مومنتم استفاده شد. نتایج مربوط به این مرحله در جدول ۲ آورده شده است.


بهترین ضریب همبستگی در این مرحله با استفاده از ترکیب ساعات آفتابی، دمای بیشینه و دمای متوسط بود که ۰/۹۲ برآورد شد. مقادیر RMSE و MAE نیز به‌ترتیب ۰/۱۰ و ۰/۰۸ برآورد شد. مقدار BIAS در این ترکیب نیز مثبت برآورد شد که بیش‌تخمینی در داده‌ها را نشان می‌دهد. تحلیل حساسیت در این مرحله نیز نشان می‌دهد در

مقایسه نتایج تحقیق حاضر با سایر پژوهش‌ها نشان داد نتایج این تحقیق همخوانی زیادی با نتایج مقدم‌نیا و همکاران (۲۰۰۹) و سبزی پرور و بیات ورکشی (۱۳۸۹) در پیش‌بینی میزان تابش خورشیدی دارد. این پژوهشگران، شبکه عصبی مصنوعی را نسبت به مدل ANFIS توانا تر دانستند. ملیت و همکاران (۲۰۰۵) و مایرو و باندا (۲۰۰۸) نیز شبکه عصبی مصنوعی را نسبت به روش‌های تجربی پیش‌بینی تابش کل خورشیدی، برتر معرفی کردند.

نرمال روی داده‌های پیش‌بینی شده انجام و سپس با داده‌های واقعی در اختیار، مقایسه شد. در این مرحله ضریب همبستگی داده‌های پیش‌بینی شده سال ۲۰۰۶ با داده‌های واقعی برای مدل پرسپترون، ۰/۹۵ و برای مدل ANFIS، ۰/۹۰ به دست آمد که در این مرحله نیز کارایی زیاد مدل شبکه عصبی پرسپترون در فرایند پیش‌بینی به اثبات رسید. شکل ۷ نمودار تطابق مقادیر واقعی و پیش‌بینی شده با دو مدل را برای سال ۲۰۰۶ نشان می‌دهد.



شکل ۶. مقایسه نتایج مشاهده‌ای و پیش‌بینی شده با استفاده از شبکه‌های عصبی - فازی



شکل ۷. مقایسه نتایج پیش‌بینی شده و واقعی تابش سال ۲۰۰۶ با استفاده از دو مدل عصبی و فازی - عصبی

## ۴ نتیجه‌گیری

با توجه به اهمیت مقدار تابش در علوم کاربردی مربوط به انرژی خورشیدی و همچنین وجود مشکلات فراوان در ثبت این پارامتر از یک سو و موفقیت مدل‌های هوشمند در پیش‌بینی پارامترهای پیچیده از سوی دیگر، لزوم استفاده از مدل‌های ANFIS و ANN در پیش‌بینی پارامتر تابش ضروری به نظر می‌رسد. نتایج تحقیق حاضر نیز توانایی خوب دو روش را در شبیه‌سازی پارامتر تابش خورشیدی نشان داد. ضریب همبستگی زیاد و خطای کم، مؤید قابل‌اعتماد بودن نتایج است. با توجه به نتایج، بیشترین ضریب همبستگی با استفاده از شبکه عصبی مصنوعی حاصل شد؛ اما در مجموع، نتایج هر دو مدل در دو مرحله آزمایش و ارزیابی بعد از پیش‌بینی رضایت‌بخش بود و تا حدود زیادی نزدیک به هم برآورد شد. همچنین ترکیب ساعات آفتابی، دمای متوسط و دمای بیشینه به‌عنوان ترکیب بهینه شناسایی شد. علاوه بر این، مشخص شد ساعات آفتابی و دمای متوسط، مؤثرترین پارامترها در پیش‌بینی تابش خورشیدی است در حالی که رطوبت نسبی کمترین تأثیر را در پیش‌بینی تابش خورشیدی دارد.

## منابع

- آقا ابراهیمی، م. ر.، باقرزاده قنبرآبادی، ح.، ۱۳۹۰، پیش‌بینی تابش سالانه خورشید توسط شبکه عصبی مصنوعی و به‌کارگیری آن در استفاده نرم‌افزاری جهت تغذیه بار محلی و استفاده در منابع تولید پراکنده: دومین کنفرانس انرژی‌های تجدیدپذیر و تولید پراکنده ایران، دانشگاه تهران.
- سبزی پرور، ع. ا.، بیات ورکشی، م.، ۱۳۸۹، ارزیابی دقت روش‌های شبکه عصبی مصنوعی و عصبی-فازی در شبیه‌سازی تابش کل خورشیدی: مجله پژوهش فیزیک ایران، ۱۰(۴)، ۳۴۷-۳۵۷.
- سلطانی، س.، مرید، س.، ۱۳۸۴، مقایسه برآورد تابش خورشید با استفاده از روش هارگریوز-سامانی و شبکه‌های عصبی: مجله دانش کشاورزی، ۱۵(۱)، ۶۹.
- شبان، م.، کاظمی نسب، م. م.، ۱۳۹۱، پیش‌بینی میزان تابش خورشید به روش شبکه عصبی جهت مدل‌سازی یک سیستم هیدروژن خورشیدی برای تغذیه یک بار متغیر: یازدهمین کنفرانس بین‌المللی دانشجویی ایران، کاشان، سازمان علمی دانشجویی مهندسی برق کشور.
- منه‌اج، م. ب.، ۱۳۸۴، مبانی شبکه‌های عصبی هوش محاسباتی، جلد ۱، چاپ سوم، مرکز نشر دانشگاه صنعتی امیرکبیر.
- Angstrom, A., 1924, Solar and terrestrial radiation. Report to the international commission for solar research on actinometric investigations of solar and atmospheric radiation: Quarterly Journal of the Royal Meteorological Society, 50(210), 121-126.
- Azamathulla, H. Md., Chang, C. K., Ghani, A. Ab., Ariffin, J., Azazi Zakaria, N., and Abu Hasan, Z., 2009, An ANFIS-based approach for predicting the bed load for moderately sized rivers: Journal of Hydro-environment Research, 3(1), 35-44.
- Bakirci, K., 2009, Correlations for estimation of daily global solar radiation with hours of bright sunshine in Turkey: Energy, 34(4), 485-501.
- Caudill, M., 1987, Neural networks primer, Part I, AI Expert, 46-52.
- Chang, J., and Chang, Y. T., 2006, Adaptive neuro fuzzy inference systems for prediction of water level in reservoir: Advanced in Water Resource Researches, 29(1), 1-10.
- Conrads, P. A., and Roehle., E. A., 1999, Comparing physics-based and neural network model simulating salinity. Temperature and dissolved in a complex, tidally affected river basin: South Carolina Environmental Conference, Myrtle Beach, March 15-16.
- Daneshyar, M., 1978, Solar radiation statistics for Iran: Sol. Energy, (United States), 21(4).

- 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.
- Mishra, A., Desai, V., and Singh, V., 2007, Drought forecasting using a hybrid stochastic and neural network model: *Journal of Hydrologic Engineering*, **12**(6), 626-638.
- Moghaddamnia, A., Remesan, R., Hassanpour Kashani, M., Mohammadi, M., Han, D., and Piri, J., 2009, Comparison of LLR, MLP, Elman, NNARX and ANFIS Models—with a case study in solar radiation estimation: *Journal of Atmospheric and Solar-Terrestrial Physics*, **71**(8-9), 975-982.
- Mubiru, J., and Banda, E. J. K. B., 2008, Estimation of monthly average daily global solar irradiation using artificial neural networks: *Solar Energy*, **82**(2), 181-187.
- Paltridge, G. W., Proctor, D., 1976, Monthly mean solar radiation statistics for Australia: *Solar Energy*, **18**(3), 235-43.
- Ozgoren, M., Bilgili, M., and shahin, B., 2012, Estimation of global solar radiation using ANN over Turkey: *Journal Expert Systems with Applications, An International Journal*, **39**(5), 5043-5051.
- Remesan, R., Shamim, M. A., and Han, D., 2008, Model data selection using gamma test for daily solar radiation estimation: *Hydrological Processes*, **22**(21), 4301-4309.
- Sabziparvar, A. A., 2007, General formula for estimation of monthly mean global solar radiation in different climates on the south and north coasts of Iran: *International Journal of Photoenergy*, **9**(1), 94786.
- Sabziparvar, A., and Shetaee, H., 2007, Estimation of global solar radiation in arid and semi-arid climates of East and West Iran: *Energy (The International Journal)*, **32**(5), 649-655.
- Sozan, A., Arcaklioglu, E., Ozalp, M., and Galip, K., 2005, Solar-energy potential in Turkey: *Applied Energy*, **80**(4), 367-381.
- Fadare, D. A., 2009, Modelling of solar energy potential in Nigeria using an artificial neural network model: *Applied Energy*, **86**(9), 1410-1422.
- Ghazanfari, M., Alizadeh, S., and Pour babak, T., 2008, *Data Mining and Discovering Knowledge*: Press center of Ferdowsi University.
- Hsu, K. L., Gupta, H. V., and Sorooshian, S., 1995, Artificial neural network modeling of the rainfall-runoff process: *Advanced in Water Resource Researches*, **31**(10), 2517-2530.
- Hussain, S., and AlAlili, A., 2017, A hybrid solar radiation modeling approach using wavelet multiresolution analysis and artificial neural networks: *Applied Energy*, **208**, 540-550.
- Ibeh, G. F., Agbo, G. A., Ekpe, J. E., and Isikwue, B. C., 2012, Estimation of global solar radiation at Calabar using two models: *Journal of Natural Sciences Research*, **2**(5), 2224-3186.
- Jang, R., 1993, ANFIS: Adaptive-Neural-based Fuzzy Inference System: *IEEE Transactions on Systems, Man and Cybernetics*, **23**(3), 665-685.
- Jirka, G. H., Doneker, R. L., and Hinston, S. W., 1996, *User's Manual for Cormix: A Hydrodynamic Mixing Zone Model and Decision Support System for Pollutant Discharge into Surface Waters*: Office of Science and Technology US-EPA, Washington, DC 20460.
- Lucio, P. S., Conde, F. C., Cavalcanti, I. F. A., Serrano, A. I., Ramos, A. M., and Cardoso, A. O., 2007, Spatio temporal monthly rainfall reconstruction via artificial neural network (case study: South Brazil): *Advances in Geosciences*, **10**, 67-76.
- Mellit, A., Benghanem, M., Hadj Arab, A., and Guessoum, A., 2005, A simplified model for generating sequences of global solar radiation data for isolated sites: Using artificial neural network and a library of Markov transition matrices approach: *Solar Energy*, **79**(5), 469-482.
- Mensour, O. N., El

## The effect of climatic parameters in the modeling of solar radiation using artificial intelligence (Case study: Yazd synoptic station)

Hamideh Afkhami<sup>1\*</sup>

<sup>1</sup>Ph. D. in Watershed Management Science and Engineering, Faculty of Natural Resources, Yazd University, Yazd, Iran

(Received: 17 February 2018, Accepted: 12 December 2018)

### Summary

Solar radiation is one of the important parameters that affects on many soil and water processes such as evaporation, snow melting and plant growth. Considering the importance of the amount of radiation in the the application of solar energy and the many problems in recording this parameter and the success of intelligent models in predicting complex parameters, it is reasonable to use ANFIS and ANN models to predict the radiation parameter.

In this study, using a large database on a wide period which contained a set of meteorological and geographical data such as latitude, longitude, months of the year, the average temperature, the sunshine duration, relative humidity and the average of the monthly global solar irradiation, the performance of two techniques, artificial neural network and Active Neuro-Fuzzy Inference System, was investigated for the next 12 months in the Yazd station. Sensitivity analysis of different climate parameters such as maximum temperature, average temperature, sunshine hours, relative humidity, solar radiation and evaporation, showed that they were important factors in predicting of solar radiation. Then, the two models were analyzed with different combinations of data. After ensuring the performance of the two models in the testing phase and achieving the best results with the highest efficiency and lowest error rate in the prediction of solar radiation, only by entering the most effective climatic parameters of 2005, the solar radiation value of 2006 was forecasted, and the predicted values were compared with actual values. The results of this study showed that both methods have the ability to simulate the amount of solar radiation. High values of the correlation coefficient and low error, confirm the reliability of the results. According to the results, although the highest correlation coefficient was obtained using artificial neural network, the results of both models were satisfactory in two stages of testing and evaluation and are estimated to be close to each other. In total, artificial neural networks with a correlation coefficient of 0.91 and RMSE and MAE rates of 0.19 and 0.08, respectively, produced less error in predictions in comparison with fuzzy-neural networks. Also, the BIAS value is -0.30, which shows a small negative overstimation in the data. Finally, the composition of sunny hours, average temperature, maximum temperature as the optimal combination was identified. In addition, it was determined that sunny hours and average temperatures are the most effective parameters in prediction of solar radiation, while relative humidity has the least effect on it.

**Keywords:** modeling, solar radiation, artificial neural networks, active neuro-fuzzy inference, Yazd station

---

\*Corresponding author:

Hamide.afkhami@gmail.com