



# ارزیابی روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان در برآورد انرژی کل خورشیدی در دو منطقه کرمان و یزد

صدیقه عوض‌پور<sup>۱</sup>، بهرام بختیاری<sup>۲\*</sup>، کوروش قادری<sup>۳</sup>

- ۱- دانشجوی کارشناسی ارشد، بخش مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان و عضو انجمن پژوهشگران جوان، دانشگاه شهید باهنر کرمان  
 ۲- \*دانشیار، بخش مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان  
 Drbakhtiari@uk.ac.ir  
 ۳- دانشیار، بخش مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان

## چکیده

مقدار انرژی تابشی، اصلی‌ترین مولفه جهت طراحی تجهیزات مربوط به انرژی‌های پاک محسوب می‌شود. با توجه به اینکه در بیشتر ایستگاه‌های تابش‌سنجی ایران، این مقدار اندازه‌گیری نشده و یا در مواردی ایستگاه تابش‌سنجی در دسترس نباشد، لذا ضروری است تا بتوان این مؤلفه را برآورد نمود. در این مطالعه، کرمان و یزد به عنوان مناطقی که دارای پتانسیل حداکثری انرژی خورشید هستند، انتخاب شدند. سپس قابلیت روش‌های شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) در برآورد انرژی خورشیدی مورد بررسی قرار گرفت. بدین منظور داده‌های روزانه ۲۵ ساله (۱۹۹۲-۲۰۱۷) شامل دمای حداکثر، میانگین دما، میانگین رطوبت نسبی، ساعات آفتابی و تابش خورشیدی ایستگاه‌های هم‌مدیدی این مناطق جمع‌آوری گردید. برای روش ANN از سه آرایش تعداد نورون در لایه پنهان و برای روش SVM از سه الگو با تابع کرنل متفاوت استفاده شد. جهت بررسی عملکرد مدل‌ها، از آماره‌های ارزیابی متداول استفاده شد. نتایج نشان داد که در ایستگاه یزد، در روش ANN کمترین مقادیر RMSE، MAE و بیشترین مقادیر IA و R<sup>2</sup> به ترتیب ۲/۳۸۱، ۱/۷۶۰، ۰/۸۶۹ و ۰/۹۶۲ می‌باشد. این مقادیر در ایستگاه کرمان به ترتیب برابر ۲/۷۰۸، ۲/۰۵۰، ۰/۹۴۵ و ۰/۸۱۰ می‌باشد. در روش SVM، کمترین مقادیر MAE، RMSE و بیشترین مقدار IA و R<sup>2</sup> در ایستگاه یزد به ترتیب ۲/۰۲۸، ۱/۵۴۰، ۰/۹۰۱ و ۰/۹۷۳ و در ایستگاه کرمان به ترتیب ۲/۴۰۷، ۱/۸۹۶، ۰/۹۵۶ و ۰/۸۴۶ محاسبه گردید. به طور کلی کارایی روش SVM در هر دو منطقه نسبت به مدل شبکه عصبی دارای دقت بیشتری بود.

کلمات کلیدی: انرژی خورشیدی، شدت تابش خورشیدی، محاسبات نرم، متغیرهای جوی

## Evaluation of artificial neural network and support vector machine methods in estimating total solar radiation at Kerman and Yazd

Sedigheh Avazpour<sup>1</sup>, Bahram Bakhtiari<sup>2\*</sup>, Kourosh Qaderi<sup>3</sup>

۱. M. Sc. Student in Water Resources Engineering, Water Engineering Department, Faculty of Agriculture, Shahid Bahonar University of Kerman and member of Young Researchers Society, Kerman, Iran  
 ۲. Associate Professor, Department of Water Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran  
 (\*Corresponding Author Email Address: [Drbakhtiari@uk.ac.ir](mailto:Drbakhtiari@uk.ac.ir))  
 ۳. Associate Professor, Department of Water Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran

Received: 25 May 2019 Accepted: 10 December 2019

### Abstract

The value of radiation energy is considered to be the main component of the design of clean energy devices. Due to the fact that this amount is not measured or in some cases the radiation station may not be available in Iran, so it is necessary to estimate this component. In this study, Kerman and Yazd were selected as the regions with the maximum potential of solar energy. Then Artificial Neural Network (ANN) and Support Vector Machine (SVM) capabilities were evaluated in solar energy estimation. For this purpose, the daily data of 25 years (1992-2017) including maximum temperature, mean



temperature, relative humidity, sunshine hours and solar radiation were collected at the synoptic stations of these regions. To evaluate the performance of models, common evaluation statistics were used. The results showed that at the Yazd station, in the ANN method, the lowest values of RMSE, MAE and the highest values of IA and  $R^2$  were 2.381, 1.760, 0.869, and 0.962, respectively. These values at Kerman Station are equal to 2.708, 2.050, 0.945 and 0.810, respectively. In the SVM method, the lowest values of RMSE, MAE and the highest values of IA and  $R^2$  at the Yazd station were 2.028, 1.540, 0.901 and 0.973, respectively, and at Kerman station were 2.407, 1.896, 0.956 and 0.846, respectively. Overall, the efficiency of the SVM method in both regions was more accurate than the ANN method.

**Keywords:** Atmospheric variables, Soft computing, Solar energy, Solar radiation



## ۱- مقدمه

انرژی خورشیدی به عنوان یک منبع انرژی تجدیدپذیر و کم هزینه با محاسن زیست محیطی بسیار، شناخته می‌شود. با توجه به آن که در هر ساعت از روز، میزان قابل توجهی از این به زمین می‌رسد بنابراین لزوم استفاده از آن به جای استفاده از سوخت‌های فسیلی ارجحیت می‌یابد. با توجه به مطالعات انجام شده در مورد میزان آفتاب‌گیر بودن، مناطق مختلف زمین به چهار دسته عالی، خوب، متوسط و ضعیف تقسیم‌بندی شده‌اند. بر این اساس بیشتر مناطق ایران جزء مناطق خوب و حتی در استان‌هایی هم چون یزد، اصفهان و فارس جزء مناطق عالی بوده‌اند [۱]. در مطالعه کاربردی انرژی خورشیدی، اطلاع از میزان و چگونگی تابش روزانه آفتاب در هر مکان بسیار اهمیت دارد. از مزیت‌های اصلی استفاده از انرژی‌های نو تجدیدپذیر بودن، پایان‌ناپذیری، صرفه اقتصادی و سازگاری آن‌ها با محیط زیست است. اندازه‌گیری شدت تابش خورشید<sup>(R<sub>s</sub>)</sup>، اگرچه در ایران دارای سابقه نسبتاً طولانی است ولی به دلیل هزینه بالای وسایل اندازه‌گیری، بسیاری از ایستگاه‌های موجود در کشور به دستگاه تابش‌سنج مجهز نیستند. اما، در اغلب این ایستگاه‌ها تعداد ساعات آفتابی (n) به طور روزانه اندازه‌گیری می‌شود. در مطالعات مربوط به برآورد شدت تابش خورشید نمی‌توان تمام عناصر موثر را در معادلات وارد نمود؛ در نتیجه برای تخمین مقدار شدت تابش خورشید توسط معادلات تجربی و نیمه تجربی تنها از تعداد محدودی از متغیرهای اقلیمی استفاده می‌شود. در سال‌های اخیر پژوهشگران مطالعات خود را بر مبنای استفاده از روش‌های داده-محور و محاسبات نرم در برآورد متغیرهای هواشناسی معطوف داشته‌اند. نتایج این مطالعات نشان داده است که استفاده از این روش‌ها دارای مزایا و معایبی می‌باشد. مهم‌ترین مزیت شبکه عصبی مصنوعی<sup>(ANN)</sup> تشریح و آشکارسازی روابط پیچیده، حساس نبودن شبکه به وجود خطا در آمار و اطلاعات در ANN دسترس، مقاوم بودن می‌باشد [۲،۳]. با وجود برتری‌هایی که شبکه‌های عصبی نسبت به روش‌های تجربی و نیمه تجربی دارند، معایبی نیز دارند از جمله دقت نتایج بستگی زیادی به اندازه مجموعه آموزش دارد. آموزش شبکه ممکن است مشکل و یا حتی غیر ممکن باشد [۴]. مهم‌ترین مزایای ماشین بردار پشتیبان<sup>(SVM)</sup>؛ الف) با نمونه‌های آموزشی کم، نتایج خوبی را ایجاد می‌کند. ب) برخلاف ANN نیاز به بهینه‌یابی محلی ندارد و بهترین مدل را پیدا می‌کند. ج) داده‌هایی با ابعاد زیاد را به خوبی مقیاس‌گذاری می‌کند. معایب این روش نیاز به انتخاب تابع هسته‌ای مناسب دارد [۵]. در ایران مطالعاتی درباره ارائه‌ی مدل برای تخمین انرژی خورشیدی در برخی از نقاط صورت گرفته است. در تحقیقی با استفاده از داده‌های ایستگاه همدیدی تبریز در دوره آماری ۸ ساله یک مدل شبکه عصبی برای برآورد تابش کل خورشیدی دریافتی در سطح زمین ایجاد و یافته‌های آن را با نتایج دستاوردهای مدل آنگستروم مقایسه کردند. نتایج حاکی از برتری ANN نسبت به آنگستروم بود [۶]. در مطالعه‌ای دیگر دو روش برآورد تابش خورشیدی بر روی سطح افقی شهر یزد را پیشنهاد و نتایج را با اندازه‌گیری‌های پیرانومتری مقایسه و خطاهای آماری موجود را معین کردند [۷]. در تهران یک مدل پایه شعاعی SVM(SVM-rbf) برای پیش‌بینی تابش خورشیدی مورد بررسی قرار گرفت. پیش‌بینی SVM-rbf با دو روش ANFIS و ANN مقایسه شد. نتایج نشان داد که SVM-rbf دارای عملکرد بالاتری نسبت به مدل‌های دیگر می‌باشد [۸]. در مطالعه‌ای دیگر در دو شهر زاهدان و بجنورد

یک بررسی مقایسه‌ای برای تابش خورشید براساس مدل‌های تجربی و مدل‌های SVM انجام شد. نتایج حاکی از عملکرد بهتر SVM نسبت به مدل‌های تجربی بود [۹]. برای پیش‌بینی تابش خورشیدی در بندرعباس براساس دو روش ANFIS و SVM مورد بررسی قرار گرفت. نتایج نشان داد روش‌های SVM بهتر از ANFIS عمل می‌کنند [۱۰]. از طرفی نتایج بسیاری از تحقیقات در سایر نقاط دنیا نشان داده است که روش SVM نسبت به مدل‌های دیگر عملکرد بهتری داشته‌اند [۱۱-۱۳]. به طور مثال در چین توانایی مدل‌های مختلف SVM برای مدل‌سازی تابش خورشیدی مورد بررسی قرار گرفت. نتایج بدست آمده نشان می‌دهد که مدل‌های SVM را می‌توان با موفقیت در مدل‌سازی تابش خورشیدی مورد استفاده قرار داد [۱۴]. تابش خورشیدی در ۵ ایستگاه در ترکیه با استفاده از الگوریتم<sup>(RP)</sup> در روش ANN ارزیابی شد. روش ANN نتایج بهتری نسبت به الگوریتم‌های دیگر داشته است [۱۵]. در نیجریه برای مدل‌سازی تابش خورشیدی دقت SVM با روش ANFIS مقایسه گردید. نتایج حاکی از عملکرد بهتر روش SVM از ANFIS و مدل‌های تجربی است [۱۶]. در برزیل تابش مستقیم ساعتی و روزانه را با استفاده از دو روش ANN و SVM برای ۱۳ سال ارزیابی کردند. در مقایسه با مدل‌های آماری برای دو مدل بیان شده R<sup>2</sup> بالاتری بدست آمد [۱۷]. در مطالعه‌ای دیگر در مکزیک صحت و عملکرد سه روش ANN، SVM و ANFIS را برای پیش‌بینی تابش خورشیدی روزانه انجام شد. نتایج نشان داد که روش SVM عملکرد بهتری نسبت به روش‌های دیگر برای پیش‌بینی تابش خورشیدی دارد [۱۸]. با توجه به اهمیت تخمین دقیق‌تر شدت تابش خورشید در ایستگاه‌هایی که امکان اندازه‌گیری آن وجود ندارد از یک سو و به کارگیری متغیرهای بسیار اندک در معادلات تجربی از سوی دیگر، ضروری است تا روابط غیرخطی موجود بین متغیرهای هواشناسی موثر بر شدت تابش خورشیدی با استفاده از روش‌های محاسبات نرم بررسی شود.

از آنجایی که پیشینه تحقیقات در ایران نشان داد که بیشتر پژوهش‌ها مبتنی بر استفاده از مدل‌های تجربی می‌باشند و نظر به کم بودن تعداد ایستگاه‌های تابش‌سنجی در ایران ضروری است که کارایی روش‌های محاسبات نرم در برآورد شدت تابش خورشیدی ارزیابی شود. در این مطالعه تلاش گردید تا دقت روش‌های SVM و ANN جهت برآورد R<sub>s</sub> با یکدیگر مقایسه شوند. اساساً انتخاب مناسب و قابل توجه متغیرهای ورودی برای ارزیابی R<sub>s</sub> به منظور دقت بیشتر و کمبود پیچیدگی در مدل از اهمیت زیادی برخوردار است. لذا سعی شد که برآورد شدت تابش خورشید، با استفاده از متغیرهایی که در ایستگاه‌ها قابلیت اندازه‌گیری دارند صورت گیرد. علت این عمل، یکی جلوگیری از وارد شدن مجموع خطاهای ناشی از ابزار اندازه‌گیری متغیرهای ورودی است که در ارزیابی شدت تابش خورشید استفاده می‌گردند و دیگری افزایش سرعت عملکرد شبکه در مراحل آموزش و یادگیری است. جهت دستیابی به این هدف، اهداف زیر در این مطالعه دنبال می‌شوند: (۱) تعیین مقدار بهینه ضرایب سه گانه روش SVM، (۲) تعیین تعداد نورون مناسب برای بدست آوردن ساختار بهینه در روش ANN، (۳) واسنجی و صحت‌سنجی روش‌های ANN و SVM در برآورد R<sub>s</sub> در ایستگاه‌های مورد مطالعه.

## ۲- مواد و روش‌ها

## ۲-۱- داده‌ها و مناطق مورد مطالعه

<sup>†</sup>Support Vector Machines  
<sup>‡</sup>Resilient Propagation

<sup>۱</sup>Solar Radiation  
<sup>۲</sup>Artificial Neural Network



سه مرحله صحت آن‌ها تایید گردید برای مدل‌سازی و ادامه مطالعه انتخاب شدند. با توجه به عملکرد کنترل کیفیت داده‌ها در ایستگاه‌های مورد مطالعه، تعداد ۲۸/۶۳٪ داده‌ها در کرمان و ۱۷/۱۱٪ داده‌ها در یزد حذف شدند. برای مدل‌سازی شدت تابش خورشید با استفاده از ANN از الگوریتم لونیبرگ مارکوات (LM) استفاده شد. همچنین برای مدل‌سازی SVM از سه الگو با پارامترهای متفاوت پارامتر کنترل ظرفیت اضافی (C)، تابع اتلاف (ε) و تابع کرنل یا پارامتر تنظیم (γ) استفاده شد. برای اعمال این عملکردها بر روی مدل، نرم افزار Matlab (version 9.3.0.713579, R2017b) به کار گرفته شد. این نرم افزار امکان طراحی، ساخت، یادگیری و ارزیابی شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان را در اختیار می‌دهد و در برگزیده شبکه‌های متفاوت با قوانین یادگیری مختلف می‌باشد. قبل از انجام مدل‌ها به علت اینکه متغیرهای نامبرده در برآورد  $R_s$  ابعاد مختلفی و دامنه تغییرات متفاوتی دارند، عمل نرمال‌سازی بر روی داده‌های خام انجام گرفته تا سرعت آزمایش و دقت شبکه افزایش یابد. به این منظور داده‌ها با استفاده از رابطه ۱ نرمال می‌شوند [۲۱].

$$x_i = 0.1 \left( \frac{x - x_{min}}{x_{max} - x_{min}} \right) + 0.1 \quad (1)$$


که در آن  $X_i$  مقدار نرمال شده،  $X$  مقدار هر یک از داده‌ها،  $X_{min}$  کمترین مقدار داده‌ها و  $X_{max}$  بیشترین مقدار داده‌ها است.

برای انجام مراحل آموزش و اعتبارسنجی مدل، داده‌ها به دو قسمت تقسیم شدند. سری داده‌ها از تاریخ ۱۹۹۲/۶/۱ تا ۲۰۱۴/۹/۲۳ برای مرحله آموزش و از تاریخ ۲۰۱۴/۹/۲۴ تا ۲۰۱۷/۱۲/۳۰ برای مرحله اعتبارسنجی مورد استفاده قرار گرفتند. کل داده‌های ورودی برای ایستگاه کرمان و یزد به ترتیب برابر با ۶۰۷۵ و ۵۷۵۶ بود که ۷۵٪ داده‌ها در مرحله آموزش و ۲۵٪ در مرحله اعتبارسنجی مورد استفاده قرار گرفت.

## ۲-۲- شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی شامل یک الگوی پردازش اطلاعات و ابزاری قدرتمند به منظور شبیه‌سازی الهام گرفته از نورون زیستی است. با این رویکرد، شبکه‌های عصبی مصنوعی همانند ساختار زیست شناختی مغز انسان با ترکیب ویژگی‌هایی همچون قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری، قابلیت حل کامل مسائلی پیچیده با ماهیتی خطی یا غیرخطی را خواهند داشت [۲۲]. اولین چیزی که در شبکه عصبی باید در نظر گرفت خروجی یک مدل است. مورد دوم که باید در نظر گرفته شود، ورودی یک مدل ANN است. پارامتر ورودی بیشتر بدان معنی است که مدل نیاز به پیش‌نیازهای بیشتری برای اجرا دارد. از لحاظ تطابق، یک مدل ANN معمولاً شامل لایه ورودی، لایه پنهان و لایه خروجی است. اندازه یک لایه پنهان معمولاً به طور تجربی به دست می‌آید. برای یک شبکه عصبی با اندازه معقول تعداد نورون‌های مخفی با یک نسبت کوچکی از تعداد ورودی‌ها انتخابی می‌گردد. اگر شبکه به جواب مطلوب همگرا نگردد تعداد نورون‌های لایه مخفی را افزایش می‌دهند و اگر شبکه همگرا گردید و از قدرت تعمیم خوبی هم برخوردار بود در صورت امکان تعداد نورون‌های مخفی کمتری را مورد آزمایش قرار می‌دهند [۲۳]. از لحاظ روند عملکرد عمدتاً شامل دو مرحله آموزش و آزمون می‌باشد. در بخش آموزش، ANN اطلاعات یادگیری و ذخیره‌سازی پایگاه داده

در این مطالعه، دو ایستگاه همدیدی کرمان و یزد با اقلیم خشک سردسیر (براساس طبقه‌بندی اقلیمی دومارتن گسترش یافته) انتخاب شدند [۱۹] (شکل ۱). در جدول ۱ ویژگی‌های جغرافیایی و اقلیمی ایستگاه‌های مورد مطالعه آورده شده است. داده‌های مورد استفاده در این مطالعه، متغیرهای حداکثر دمای هوا ( $T_{max}$ )، میانگین دمای هوا ( $T_{mean}$ )، میانگین رطوبت نسبی ( $RH_{mean}$ ) و ساعات آفتابی ( $n$ ) به عنوان ورودی و تابش خورشیدی ( $R_s$ )، به عنوان خروجی مدل‌ها، در مقیاس زمانی روزانه از ایستگاه‌های مطالعاتی طی دوره آماری ۲۰۱۷-۱۹۹۲ (۲۵ سال) از سازمان هواشناسی کشور (IRIMO, ۱۳۹۶) اخذ گردیدند. جدول ۲ میانگین‌های اقلیمی متغیرهای مورد استفاده طی این دوره آماری را نشان می‌دهد.



شکل ۱ موقعیت ایستگاه‌های مورد مطالعه

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

ایستگاه	طول جغرافیایی (°E)	عرض جغرافیایی (°N)	ارتفاع از سطح دریا (m)	اقلیم
کرمان	۵۷/۰۸	۳۰/۲۸	۱۷۵۳	خشک سردسیر
یزد	۵۴/۳۵	۳۱/۸۹	۱۲۳۰	خشک سردسیر


جدول ۲ میانگین متغیرهای هواشناسی مورد استفاده در ایستگاه‌های همدیدی مطالعاتی

ایستگاه	متغیر	بیشینه	کمینه	میانگین	انحراف معیار
کرمان	$T_{max}$ (°C)	۴۲	-۴/۰	۲۵/۹	۸/۸
	$T_{mean}$ (°C)	۳۲/۴	-۹/۳	۱۷/۳	۸/۷
	$RH_{mean}$ (%)	۹۸/۰	۶/۵	۳۳/۰	۱۷/۱
	$n$ (h)	۱۳/۵	۰/۰	۹/۳	۳/۰
یزد	$R_s$ (MJ m <sup>-2</sup> d <sup>-1</sup> )	۳۹/۴	۱/۴	۲۱/۴	۶/۹
	$T_{max}$ (°C)	۴۵/۶	-۳/۶	۲۷/۲	۱۰/۱
	$T_{mean}$ (°C)	۳۸/۴	-۶/۷	۲۰/۱	۹/۹
	$RH_{mean}$ (%)	۹۷/۵	۴	۲۸/۸	۱۸/۶
	$n$ (h)	۱۳/۲	۰/۰	۸/۹	۲/۹
	$R_s$ (MJ m <sup>-2</sup> d <sup>-1</sup> )	۳۹/۸	۱/۱۷	۱۹/۴	۶/۷

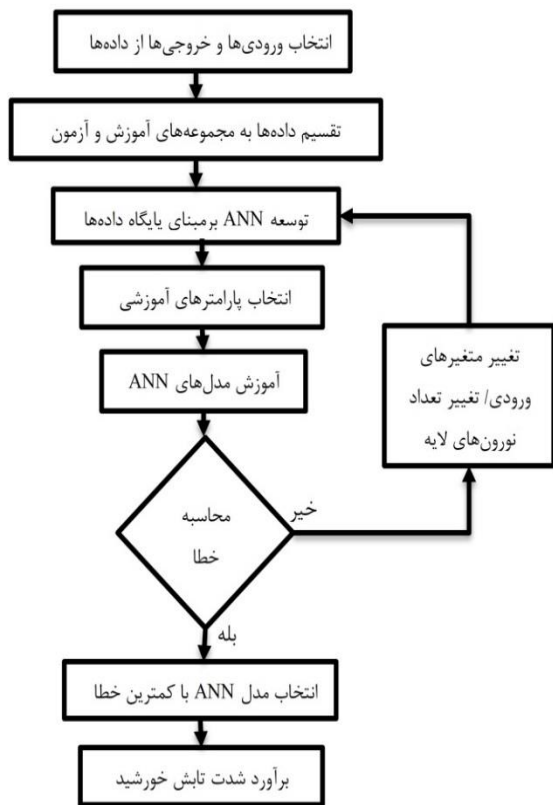
به منظور کنترل کیفیت داده‌های اندازه‌گیری شده، از الگوریتم ارائه شده به منظور کنترل کیفیت داده‌های تابش استفاده شد [۲۰]. براساس این الگوریتم داده‌های  $R_s$  با سه شرط مقایسه گردیدند و تنها داده‌هایی که در هر

!Levenberg Marquardt





شکل ۳ معماری یک شبکه عصبی مصنوعی (ANN) جهت برآورد شدت تابش خورشید



شکل ۴ مراحل انجام عملکرد ANN

### ۲-۳- ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یکی از روش های یادگیری تحت نظارت است که هم برای دسته بندی و هم رگرسیون قابل استفاده است. این روش توسط Vapnik (۱۹۹۸) بر پایه تئوری یادگیری آماری بنا نهاده شده است. SVM روشی برای طبقه بندی دوتائی در فضای ویژگی های دلخواه است و از این روش برای مسائل پیش بینی به شمار می رود [۲۷، ۲۸]. ماشین بردار پشتیبان برای مسائل در اصل یک دسته بندی کننده دو کلاسی است که کلاس ها را توسط یک مرز خطی از هم جدا می کند. در این روش نزدیک ترین نمونه ها به مرز تصمیم گیری را بردارهای پشتیبان می نامند. این بردارها معادله مرز تصمیم گیری را مشخص می کنند. الگوریتم های شبیه سازی هوشمند کلاسیک مانند شبکه های عصبی مصنوعی، معمولاً قدرمطلق یا مجموع مربعات خطای داده های آموزشی را حداقل می کنند، ولی مدل های SVM، اصل حداقل سازی خطای ساختاری را به کار می گیرند [۲۹]. در یک مدل رگرسیونی SVM لازم است وابستگی تابعی متغیر وابسته  $y$  به مجموعه ای از

موجود را ذخیره می کند. در بخش آزمون، ANN اطلاعاتی را برای تولید داده های خروجی براساس پایگاه داده ورودی فرا می خواند. واحدهای محاسبه ANN، نورون ها را در لایه ها متصل می کنند.

یک نورون مصنوعی مدل ریاضی ساده شده یک عصب زیستی است. عملیاتی که در هر نورون صورت می گیرد به این صورت است که نورون همه ورودی هایی را که به سلول رسیده است جمع می کند، آن را از یک تابع محرک عبور می دهد و در نهایت خروجی نورون را ایجاد می کند [۷].

شبکه های عصبی از چندین لایه تشکیل می شوند. لایه های ابتدایی و انتهایی به ترتیب لایه ورودی و لایه خروجی نام دارند، همچنین مابین این دو لایه ممکن است یک یا چند لایه مخفی وجود داشته باشد. خروجی شبکه  $y_i$  به صورت زیر مدل می شود:

$$y_i = \sum_{j=1}^n w_{i,j} x_{i,j} + \theta_i \quad (2)$$

که در آن،  $x_{i,j}$  سیگنال ورودی از زامین نورون (در لایه ورودی)، متغیر ورودی،  $w_{i,j}$  وزن اتصال نورون زبه نورون  $i$  (در لایه مخفی) است.  $\theta_i$  نیز آربی (bias) نورون  $i$  خواهد بود. طی فرآیند آموزش، این وزن ها و مقادیر ثابتی که با آن ها جمع می شود و در اصطلاح آربی نامیده می شوند، به طور پی در پی تغییر می کند تا خطا به کمترین مقدار خود برسد. پس از محاسبه هر  $y_i$  شبکه تحت یک تابع محرک شروع به اصلاح آن می کند. تابع محرک نوعاً یک تابع یکنواخت کراندار مانند تابع استاندارد سیگموئید است که به صورت زیر تعریف می شود [۲۴]:

$$f_x = \frac{1}{1 + \exp(-x)} \quad (3)$$

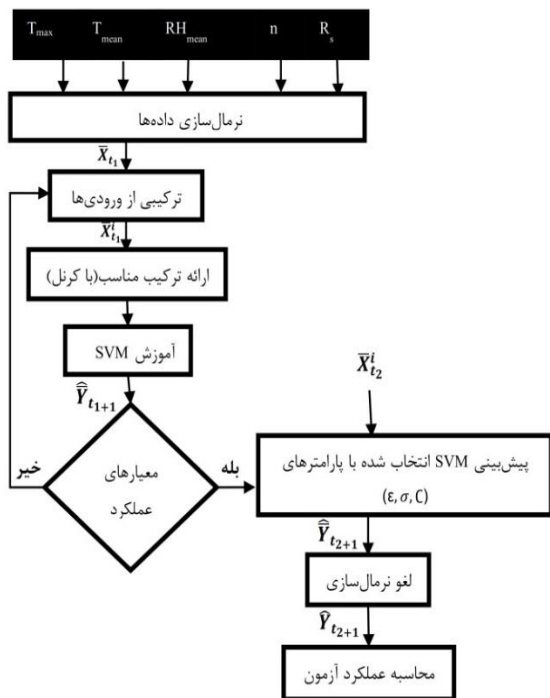
در این مطالعه از پرسپترون چند لایه در شبکه عصبی استفاده گردید که شامل نورون هایی است که در چند لایه قرار گرفته اند، شکل ۳ طرز قرارگیری نورون ها را نشان می دهد. نورون در ابتدا از یک افزایشنده که از ضرب ورودی ها توسط ضریب های سری هایی که وزن سنوپیکی نام دارند تشکیل می شود. هدف از الگوریتم یادگیری به دست آوردن مقادیر بهینه برای وزن های سینوپیکی می باشد [۲۵]. در بخش دوم نورون هدف پیدا کردن تابع فعال می باشد که رفتار غیرخطی مدل شبکه عصبی را به ما نشان می دهد.

فرآیند آموزش در شبکه های عصبی در واقع به معنای روزآمد کردن اتصالات بین نورون ها است. پژوهش های صورت گرفته نشان می دهد که MLP پیش خور با قانون یادگیری پس انتشار خطا<sup>۱</sup> (FFBP)، ساده ترین و پرکاربردترین نوع شبکه عصبی است که در خصوص تخمین پارامترهای مجهول مناسب ارزیابی شده است [۲۶]. شبکه FFBP دارای یک لایه ورودی، یک یا چند لایه مخفی و یک لایه خروجی است. در این روش خطای خروجی مدل به عقب و به داخل سامانه برگردانده می شود تا شرایط تجدید سازگاری بیشتر وزن ها صورت گیرد. بدین منظور داده های مجموعه آموزش متشکل از زوج ورودی-خروجی که شامل اطلاعات آماری از پدیده مورد نظر هستند، برای اصلاح وزن ها در شبکه و برای رساندن مجموع مربع خطا<sup>۲</sup> (SSE) به حداقل مقدار خود از راه الگوریتم فوق مورد آزمایش قرار می گیرند همچنین به منظور بررسی دقت شبکه آموزش یافته لازم است آزمون شبکه صورت گیرد. این کار با دادن زوج داده های آزمون به شبکه و محاسبه میزان خطای شبکه صورت می گیرد. به طور کلی ویژگی های یک شبکه عصبی مصنوعی، ساختار شبکه و روش آموزش شبکه، با نوع تابع محرک نورون ها مشخص می شود [۲۴]. مراحل انجام کار شبکه عصبی در شکل ۳ ارائه شده است.

<sup>۲</sup>Sum Squared Error

<sup>۱</sup>Feed-Forward Back Propagation





شکل ۵ مراحل انجام عملکرد SVM

### ۳- معیارهای ارزیابی عملکرد مدل‌ها

به منظور ارزیابی و مقایسه دقت مدل‌های مورد استفاده از معیارهای ضریب تعیین ( $R^2$ )؛ مجذور میانگین مربعات خطا (RMSE)؛ میانگین مطلق خطا (MAE)؛ و شاخص توافق (IA) استفاده شد.  $R^2$  نشان‌دهنده این است که چه مقدار از تغییرات متغیر وابسته تحت تاثیر متغیر مستقل مربوطه بوده و مابقی تغییرات متغیر وابسته مربوط به سایر عوامل می‌باشد. ضریب تعیین همیشه بین صفر تا یک تغییر می‌کند. صفر نشان می‌دهد که مدل هیچ یک از تغییرپذیری داده‌های پاسخ در اطراف میانگین آن را تعیین نمی‌کند. اما مقدار یک نشان می‌دهد که تمام مقادیر مشاهده شده با مقادیر برازش شده یکسان خواهند بود و همه نقاط داده‌ها بر روی خط برازش شده قرار خواهند گرفت.

$$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})]^2}{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2} \quad (9)$$

RMSE، تفاوت میان مقدار پیش‌بینی شده توسط مدل و مقدار واقعی است و یک ابزار خوب برای مقایسه خطاهای پیش‌بینی توسط یک مجموعه داده است و برای مقایسه چند مجموعه داده کاربرد ندارد (رابطه ۶). یک شاخص درجه دو است و به مقادیر بالای خطا، وزن بالاتری اختصاص می‌دهد [۳۳].

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (10)$$

MAE، در حالت ایده آل باید صفر باشد، که مقادیر مثبت و منفی به ترتیب نشان‌دهنده بیش برآورد و کم برآورد می‌باشند (رابطه ۷). این پارامتر معرف دقت روش و مقدار متوسط خطا است [۳۳].

متغیرهای مستقل  $x$  تخمین زده شود. فرض بر این است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط یک تابع معین  $f$  به علاوه یک مقدار اضافی نویز مشخص می‌شود.

$$y = f(x) + \text{Noise} \quad (4)$$

$$f(x) = W^T \cdot \phi(x) + b \quad (5)$$

بنابراین موضوع اصلی، پیدا کردن فرم تابع  $f$  است که بتواند به صورت صحیح، موارد جدیدی را که SVM تاکنون تجزیه نکرده است پیش‌بینی کند. این تابع به وسیله آموزش که شامل فرآیندی به منظور بهینه‌سازی دائمی تابع خطا است، قابل دسترسی است. بر مبنای تعریف این تابع خطا، دو نمونه از مدل‌های SVM شناخته شده است که عبارتند از الف) مدل‌های رگرسیونی SVM نوع اول که مدل‌های  $v$ -SVM نیز نامیده می‌شوند و ب) مدل‌های رگرسیونی SVM نوع دوم که با نام  $\epsilon$ -SVM شناخته شده هستند. در این مطالعه  $\epsilon$ -SVM به دلیل کاربرد گسترده آن در مسائل رگرسیونی مورد استفاده قرار گرفت. برای این مدل، تابع خطا به صورت زیر تعریف می‌شود:

$$\frac{1}{2} W^T W + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i^* \quad (6)$$

تابع خطای فوق لازم است که با توجه به محدودیت‌های زیر کمینه گردد [۳۰].

$$W^T \phi(x_i) + b - y_i \leq \epsilon + \xi_i^* \quad (7)$$

$$y_i - W^T \phi(x_i) - b \leq \epsilon + \xi_i \quad \xi_i, \xi_i^* \geq 0 \quad (8)$$

که در این روابط  $C$  عددی صحیح و مثبت است که عامل تعیین جرمه در هنگام رخ دادن خطای واسنجی مدل است.  $W$  بردار ضریب،  $W^T$  ترانزپوز بردار ضریب،  $b$  ضریب ثابت،  $N$  تعداد نمونه‌ها،  $\phi$  تابع کرنل و دو مشخصه  $\xi_i, \xi_i^*$  متغیرهای کمبود هستند که حد بالا و پایین خطای آموزش مرتبط با مقدار خطای مجاز  $\epsilon$  را مشخص می‌کنند [۳۱].

ماشین‌های بردار پشتیبان برای حل مسائل غیرخطی، ابعاد مساله را از طریق توابع کرنل تغییر می‌دهند. انتخاب کرنل برای SVM به حجم داده‌های آموزشی و ابعاد بردار ویژگی بستگی دارد. به عبارت دیگر، باید با توجه به این پارامترها تابع کرنلی را انتخاب نمود که توانایی آموزش برای ورودی‌های مساله را داشته باشد. در عمل چهار نوع کرنل خطی، کرنل چند جمله‌ای، کرنل تانژانت هایپربولیک و کرنل گوسی (RBF) به کار گرفته می‌شوند.

در نهایت تابع تصمیم رگرسیون بردار پشتیبان غیرخطی به صورت معادله زیر خواهد بود که کنترل‌کننده میزان نوسان تابع گوسی و همچنین کنترل‌کننده نتایج پیش‌بینی و تصمیم‌دهنده مدل SVM است [۳۲]. در شکل ۵ مراحل انجام کار SVM نشان داده شده است. در این شکل  $\bar{X}_{t1}$  ورودی داده‌ها برای آموزش (۷۵٪)،  $\bar{X}_{t1}$  ورودی داده‌ها برای آزمون (۲۵٪)،  $\bar{Y}_{t1+1}$  انرژی خورشیدی آموزش دیده،  $\bar{Y}_{t2+1}$  انرژی خورشیدی ارزیابی شده می‌باشد.



†Radial Base Function Kernel  
 †Coefficient of Determination  
 †Root Mean Square Error  
 †Mean Absolute Error  
 †Index of Agreement

†Noise  
 †Kernel function  
 †Slack variable  
 †Linear Kernel  
 †Polynomial Kernel  
 †Hyperbolic tangent Kernel

۰/۰۳	۵/۰	۵۰۰	SVM <sub>2</sub>
۰/۰۳	۱۰/۰	۵۰۰	SVM <sub>3</sub>
۰/۰۳	۱۰/۰	۵۰۰	SVM <sub>1</sub>
۰/۰۳	۱۵/۰	۵۰۰	SVM <sub>2</sub> یزد
۰/۰۳	۲۰/۰	۵۰۰	SVM <sub>3</sub>

#### ۴-۲- نتایج اجرای مدل های مورد مطالعه

جهت دستیابی به بهترین مدل شبکه عصبی مصنوعی، مدل ها و توابع متفاوت با آرایش نورون های مختلفی آزمایش شدند. به منظور ارزیابی و مقایسه عملکرد شبکه ها با یکدیگر از داده های آموزش و آزمون استفاده گردید. در نهایت ANN با قانون آموزش LM به دلیل خطای کمتر به عنوان الگوریتم بهینه شبکه با توابع محرک و تعداد نورون های مختلف در لایه میانی مورد استفاده قرار گرفت. مقادیر خروجی از هر شبکه با مقادیر مشاهده ای متناظر آن مقایسه شد و جزئیات آن براساس آماره های خطاسنجی مورد بررسی قرار گرفت. نتایج ساختارهای بهینه ANN و SVM در برآورد مقدار R<sub>s</sub> به تفکیک هر ایستگاه در جدول ۵ ارائه شده است. مقایسه نتایج اجرای آرایش های مختلف شبکه عصبی و ماشین بردار پشتیبان، با معیارهای خطاسنجی نشان می دهد، این مدل ها توانمندی پیش بینی انرژی خورشیدی را دارا هستند.

با توجه به نتایج به دست آمده برای شبکه ها کمترین مقادیر RMSE، MAE و بیشترین مقدار d-index و R<sup>2</sup> مربوط به ایستگاه یزد به ترتیب برای روش ANN ۲/۳۸۱، ۲/۱۷۶، ۱/۸۶۹، ۰/۱۹۶۲ می باشد. در روش SVM کمترین مقادیر RMSE، MAE و بیشترین مقدار IA و R<sup>2</sup> در ایستگاه یزد بوده که به ترتیب دارای مقادیر ۲/۰۲۸، ۱/۵۴، ۰/۹۰۱، ۰/۹۷۳ می باشد. با توجه به نتایج بدست آمده از جدول ۵ روش SVM نتایج بهتری در مقایسه با ANN داشته است. بنابراین شبکه با این ساختار با ورودی های T<sub>max</sub>، T<sub>mean</sub> و RH<sub>mean</sub> و n با یک لایه پنهان بهترین شبکه برای مدل سازی تابش خورشید برای ایستگاه های مورد مطالعه می باشد. در روش ANN برای کنترل کارایی و عملکرد شبکه در حین آموزش، از MSE داده ها استفاده شد. کارایی دو ایستگاه کرمان و یزد در شکل ۶ نمایش داده شده است که بهترین مقدار آن در ایستگاه کرمان ۰/۰۴۷ در دوره ایست و یکم بود (شکل ۶).

برای ایستگاه یزد مقدار MSE برابر با ۰/۰۴۹ در Epoch سی و چهارم به دست آمد (شکل ۷). در واقع در هر مرحله که برنامه جواب جدیدی در هر Epoch تولید می کند، آن را ارزیابی می کند که آیا از جواب قبلی بهتر است یا نه، و چنانچه جواب جدید بدتر از قبلی باشد، خطا اتفاق افتاده است و در واقع الگوریتم در جهت نامناسب حرکت کرده است. برای این برنامه تعداد خطا برای خاتمه الگوریتم، شش خطا پشت سر هم در نظر گرفته شد. با در نظر گرفتن شرط خاتمه برنامه، شبکه به Epoch شماره ۴۱ در ایستگاه کرمان و Epoch شماره ۵۴ در ایستگاه یزد رسید.

جدول ۵ نتایج تحلیل آماری الگوهای مختلف ورودی مدل های ANN و SVM در ارزیابی انرژی خورشیدی

ایستگاه	مدل	آموزش				آزمون			
		IA	MAE (%)	RMSE (Mj m <sup>-2</sup> d <sup>-1</sup> )	R <sup>2</sup>	IA	MAE (%)	RMSE (Mj m <sup>-2</sup> d <sup>-1</sup> )	R <sup>2</sup>
کرمان	ANN <sub>1</sub>	۰/۸۱۰	۲/۷۰۸	۲/۱۴۰	۰/۸۱۰	۰/۹۴۵	۲/۰۵۱	۲/۷۲۸	۰/۸۰۷
	ANN <sub>2</sub>	۰/۷۶۳	۳/۰۴۳	۲/۱۴۰	۰/۷۳۵	۰/۹۲۹	۲/۲۹۱	۳/۳۲۸	۰/۷۳۵
	ANN <sub>3</sub>	۰/۷۶۵	۳/۰۲۰	۲/۱۴۰	۰/۷۲۵	۰/۹۳۰	۲/۳۸۴	۳/۴۱۲	۰/۷۲۵

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (11)$$

IA، دارای مقداری بین صفر تا یک است که مقدار یک، بیان گر بهترین برازش است و طبق رابطه ۸ محاسبه می شود [۳۴].

$$IA = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^r}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^r} \quad (12)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \quad (13)$$

که در آن ها، P<sub>i</sub> شدت تابش پیش بینی شده،  $\bar{P}_i$  میانگین شدت تابش پیش بینی شده، O<sub>i</sub> شدت تابش اندازه گیری شده،  $\bar{O}_i$  میانگین شدت تابش اندازه گیری شده و n تعداد داده های ثبت شده می باشد.

#### ۴-۱- نتایج روش های ANN و SVM برای ارزیابی انرژی خورشیدی

در جدول ۳ برای هر ایستگاه همدمی سه نمونه از بهترین مدل ها در روش ANN به دست آمده است. در بین مدل های انتخاب شده ANN<sub>1</sub> در ایستگاه کرمان با تابع محرک لوگ سیگموئید و با آرایش (۴-۱-۱۵) و مدل ANN<sub>3</sub> در ایستگاه یزد با تابع لوگ سیگموئید و آرایش شبکه (۴-۱-۲۵) با تعداد نورون در لایه پنهان ۲۵ بهترین مدل می باشد. در روش SVM بعد از ۴۳ بار اجرای الگوریتم، پارامترهای بهینه مورد نظر بدست آمد. اعدادی که بعد از پارامترهای منتخب بدست می آمد دچار بیش برازش در مرحله آزمون می شدند.

جدول ۳ الگوهای مختلف ورودی ANN در ایستگاه های مورد مطالعه

ایستگاه	مدل	لایه پنهان	تابع محرک لایه خروجی	تعداد نورون لایه پنهان
کرمان	ANN <sub>1</sub>	لوگ سیگموئید	خطی	۱۵
	ANN <sub>2</sub>	لوگ سیگموئید	خطی	۲۰
	ANN <sub>3</sub>	لوگ سیگموئید	خطی	۲۵
یزد	ANN <sub>1</sub>	لوگ سیگموئید	خطی	۱۵
	ANN <sub>2</sub>	لوگ سیگموئید	خطی	۲۰
	ANN <sub>3</sub>	لوگ سیگموئید	خطی	۲۵

طبق جدول ۴ برای روش SVM سه نمونه از بهترین مدل های به دست آمده که در ایستگاه کرمان مدل SVM<sub>1</sub> با مقدار ۵۰۰ برای پارامتر C و مقدار ۱/۰ برای پارامتر γ و مقدار ۰/۰۳ برای پارامتر خطای E و در ایستگاه یزد مدل SVM<sub>3</sub> با پارامترهای بهینه C، γ و E به ترتیب دارای مقادیر ۵۰۰، ۰/۰۳ و ۲۰/۰ به عنوان بهترین مدل انتخاب گردید.



جدول ۴ الگوهای مختلف ورودی SVM در ایستگاه های مورد مطالعه

ایستگاه	مدل	پارامتر بهینه
		C
		γ
		E
کرمان	SVM <sub>1</sub>	۵۰۰
		۱/۰
		۰/۰۳



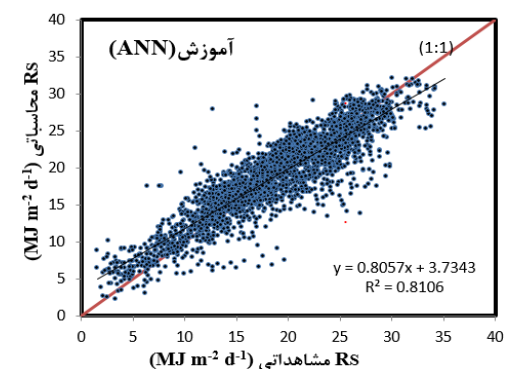

!Epoch



۰/۹۵۱	۱/۹۰۳	۲/۴۸۸	۰/۸۳۰	۰/۹۵۶	۱/۸۹	۲/۴۰۷	۰/۸۴۶	SVM <sub>1</sub>	
۰/۹۰۱	۲/۲۶۰	۳/۶۱۴	۰/۶۷۶	۰/۹۳۲	۲/۰۹۰	۳/۰۶۶	۰/۷۶۶	SVM <sub>2</sub>	
۰/۸۹۷	۲/۳۳۱	۳/۶۹۹	۰/۶۶۲	۰/۹۳۵	۲/۰۳۷	۳/۰۰۳	۰/۷۷۵	SVM <sub>3</sub>	
۰/۹۲۹	۲/۱۹۵	۳/۲۴۰	۰/۷۷۹	۰/۹۲۷	۲/۱۶۸	۳/۳۴۱	۰/۷۵۶	ANN <sub>1</sub>	
۰/۹۳۶	۲/۰۰۴	۳/۱۴۰	۰/۷۸۴	۰/۹۳۶	۲/۰۳۴	۳/۱۴۷	۰/۷۸۰	ANN <sub>2</sub>	
۰/۹۴۸	۲/۰۱۰	۲/۷۸۹	۰/۸۳۱	۰/۹۶۲	۱/۷۶۵	۲/۳۸۱	۰/۸۶۹	ANN <sub>3</sub>	
۰/۹۲۳	۲/۰۱۷	۳/۳۸۷	۰/۷۵۲	۰/۹۴۰	۱/۸۷۵	۲/۹۶۳	۰/۷۹۰	SVM <sub>1</sub>	یزد
۰/۹۱۰	۲/۱۷۸	۳/۸۴۶	۰/۷۰۴	۰/۹۴۳	۱/۸۸۲	۲/۹۹۷	۰/۷۹۹	SVM <sub>2</sub>	
۰/۹۶۲	۱/۷۷۶	۲/۴۱۱	۰/۸۷۸	۰/۹۷۳	۱/۵۴۴	۲/۰۲۸	۰/۹۰۱	SVM <sub>3</sub>	



شکل ۶ بهترین کارایی شبکه در حین کنترل آموزش. الف) ایستگاه کرمان و ب) یزد



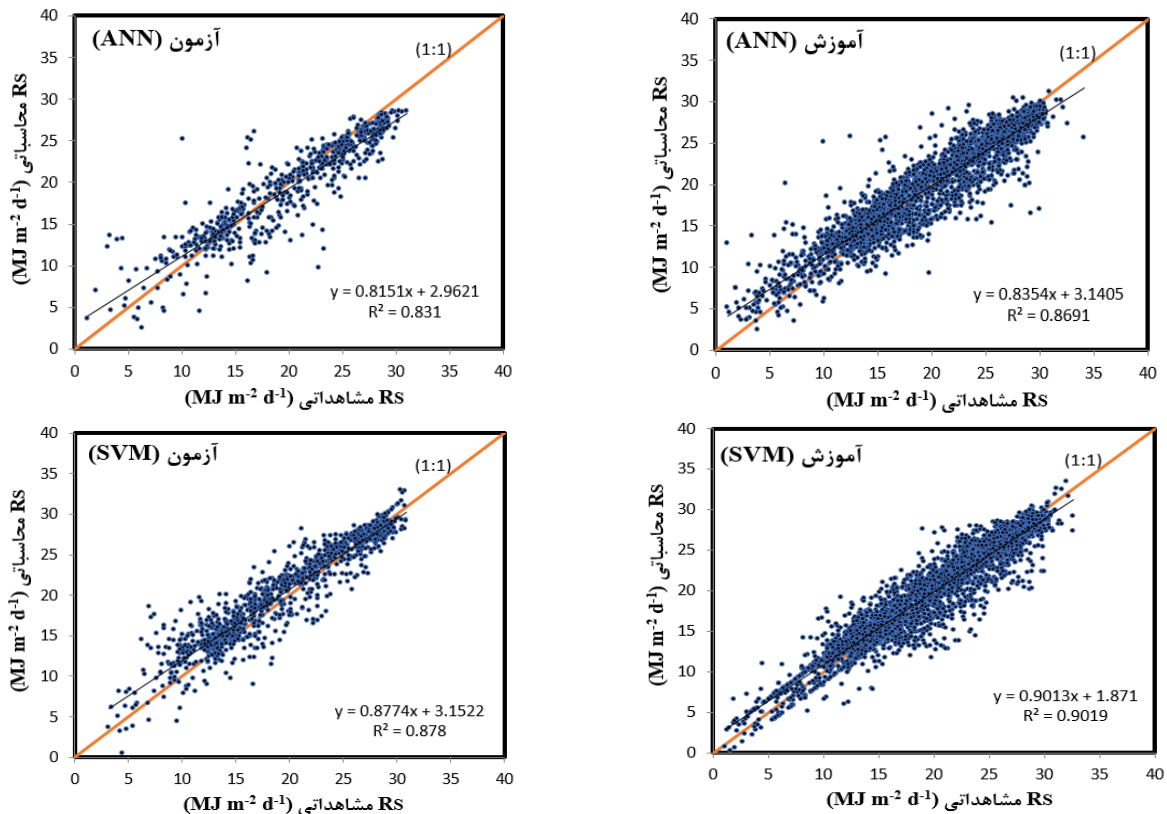
شکل ۷. همبستگی بین شدت تابش (R<sub>s</sub>) برآورد شده با روش ANN و SVM و مقادیر مشاهده‌ای در ایستگاه کرمان در دو مرحله آموزش و آزمون



همبستگی بین مقادیر R<sub>s</sub> برآورد شده با ANN و SVM و مقادیر مشاهده ای هر ایستگاه به تفکیک دو مرحله آموزش و آزمون، در شکل‌های ۷ و ۸ نشان داده شده است. نشان دهنده ارتباط بین مقادیر واقعی R<sub>s</sub> با مقادیر برآورد از شبکه ANN و SVM است.

نتایج این تحقیق و پژوهش‌های مشابه نشان داد که متغیرهای n, T<sub>mean</sub>, T<sub>max</sub> و RH<sub>mean</sub> از مهم‌ترین متغیرهای هستند که می‌توان به عنوان ورودی شبکه عصبی مصنوعی برای مدل‌سازی شدت تابش خورشید استفاده کرد.





شکل ۸. همبستگی بین شدت تابش (RS) برآورد شده با روش ANN و روش SVM و مقادیر مشاهده‌ای در ایستگاه یزد در دو مرحله آموزش و آزمون

#### ۵- نتیجه‌گیری

امروزه برآورد و پیش‌بینی انرژی خورشیدی جهت استفاده در با استفاده از مدل‌های محاسبات نرم توسعه یافته است. این مطالعه با هدف ارزیابی کارایی روش‌های ANN و SVM در برآورد انرژی خورشیدی در دو ایستگاه همدیدی کرمان و یزد به انجام رسید. به این منظور تعداد چهار متغیر روزانه (حداکثر دمای هوا، میانگین دمای هوا، میانگین رطوبت نسبی و ساعات آفتابی) به عنوان ورودی مدل‌ها مورد توجه قرار گرفت. در روش ANN با استفاده از الگوریتم LM و تابع محرک لوگ سیگموئید و در نورون ۱۵ در ایستگاه کرمان و نورون ۲۵ در ایستگاه یزد مقدار بهینه بدست آمد. این مقدار بهینه با استفاده از شاخص‌های آماری برای ایستگاه یزد  $R^2=0/869$  و  $MAE=1/76$ ،  $IA=0/962$  و  $RMSE=2/381$  مگاژول بر متر بر روز و در ایستگاه کرمان  $R^2=0/810$  و  $MAE=2/05$ ،  $IA=0/945$  و  $RMSE=2/708$  مگاژول بر متر بر روز بدست آمد. در روش SVM مقادیر بهینه برای پارامترهای مورد نظر برای ایستگاه یزد  $R^2=0/901$  و  $MAE=1/544$ ،  $IA=0/973$  و  $RMSE=2/028$  مگاژول بر متر بر روز و برای ایستگاه کرمان  $R^2=0/846$  و  $MAE=1/890$ ،  $IA=0/956$  و  $RMSE=2/407$  مگاژول بر متر بر روز بدست آمد. نتایج این مطالعات نشان داد که استفاده از روش ANN در مدل‌سازی انرژی خورشیدی در مقایسه با مدل‌های SVM، دقت کمتری دارند. همچنین در ایستگاه یزد هر دو روش مورد مطالعه نسبت به ایستگاه کرمان نتایج بهتری داشته است. نتایج این پژوهش قابل مقایسه با نتایج برخی مطالعات می‌باشد که در آن مطالعات روش SVM را برتر از روش ANN دانسته‌اند [۳۵،۳۶]. معیارهای عملکرد آماری برای هر یک از مدل‌ها در جدول ۵ برای هر دو مجموعه داده-های آموزش و آزمون ارائه شده است. به طوری که مقدار  $R^2$  در مدل SVM<sub>3</sub> در ایستگاه یزد ( $R^2=0/901$ ) و در ایستگاه کرمان ( $R^2=0/846$ ) مشاهده شد.

از آنجاییکه روش ANN نیاز به زمان آموزش بیشتری برای مجموعه داده بزرگ دارد و همچنین گام بهینه‌سازی بسیار پیچیده دارد پیشنهاد می‌شود روش SVM با ارائه یک راه حل منحصر به فرد در مطالعات مربوط به انرژی خورشیدی استفاده شود.

#### ۶- فهرست علائم

$RH_{mean}$	میانگین رطوبت نسبی (%)
$R_s$	انرژی تابش خورشیدی ( $MJ m^{-2} d^{-1}$ )
$T_{max}$	حداکثر دمای هوا ( $^{\circ}C$ )
$T_{mean}$	میانگین دمای هوا ( $^{\circ}C$ )
$n$	ساعات آفتابی (h)
$C$	پارامتر کنترل ظرفیت اضافی
$\epsilon$	تابع اتلاف
$\gamma$	پارامتر تنظیم
$IA$	شاخص توافق ویلموت
$MSE$	خطای میانگین مربعات
$MAE$	میانگین مطلق خطا (%)
$RMSE$	مجدور میانگین مربعات خطا ( $MJ m^{-2} d^{-1}$ )
$R^2$	ضریب تبیین
$SSE$	مجموع مربعات خطا
$FFBP$	پس انتشار خطا
$MLP$	پرسترون چند لایه

#### ۷- قدردانی



- algorithm-based model for global solar radiation prediction, *Solar Energy*, Vol. 115, pp. 632-644, 2015.
- [17] C. M. dos Santos, J. F. Escobedo, E. T. Teramoto, S. H. M. G. da Silva, Assessment of ANN and SVM models for estimating normal direct irradiation (H<sub>b</sub>). *Energy conversion and management*, Vol. 126, pp. 826-836, 2016.
- [18] V. H. Quej, J. Almorox, J. A. Arnaldo, L. Saito, L. ANFIS, SVM and ANN soft-computing techniques to estimate daily global solar radiation in a warm sub-humid environment. *Journal of Atmospheric and Solar-Terrestrial Physics*, Vol. 155, pp. 62-70, 2017.
- [19] J. Rahimi, M. Ebrahimpour, A. Khalili, Spatial changes of extended De Martonne climatic zones affected by climate change in Iran. *Theoretical and applied climatology*, Vol. 112, pp. 409-418, 2013.
- [20] I. Moradi, Quality control of global solar radiation using sunshine duration hours. *Energy*, Vol. 34, No. 1, pp. 1-6, 2009.
- [21] H. DehghaniSanij, T. Yamamoto, V. Rasiah, Assessment of evapotranspiration estimation models for use in semi-arid environments. *Agricultural water management*, Vol. 64, No. 2, pp. 91-106, 2004.
- [22] M. Turhan, Neural networks and computation of neural network weights and biases by the generalized delta rule and backpropagation of errors, *Rock Solid Images Press*, 1995.
- [۲۳] م. ب. منهج، مبانی شبکه‌های عصبی، دانشگاه صنعتی امیرکبیر، تهران، ۱۳۸۴، چاپ سوم.
- [۲۴] ا. علیانی، م. ع. قربانی، و ح. جباری خامنه، عملکرد حافظه مدل اتورگرسیو و شبکه های عصبی مصنوعی در پیش بینی جریان روزانه رودخانه لیقوان، مجموعه مقالات سومین کنفرانس مدیریت منابع آب ایران، دانشکده مهندسی عمران، دانشگاه تبریز، پاییز ۸۷.
- [25] S. Haykin, *Neural networks and learning machines*, Three Edition, Pearson Education, New York: Prentice Hall, 2006.
- [26] R. Hecht-Nielsen, (1987). Kolmogorov's mapping neural network existence theorem. In *Proceedings of the International Conference on Neural Networks*, IEEE Press, Vol. 3, pp. 11-14, 1987.
- [27] P. F. Pai, W.C. Hong, A recurrent support vector regression model in rainfall forecasting, *Hydrological Process*, Vol. 21, No. 6, pp. 819-827, 2007.
- [28] V. N. Vapnik, *Statistical Learning Theory*, First Edition, pp. 156-160, New York: Wiley, 1998.
- [29] L. Hamel, *Knowledge Discovery with Support Vector Machines*, First Edition, Hoboken: John Wiley, 2009.
- [30] O. Kisi, M. Cimen, Evapotranspiration modelling using support vector machines, *Hydrological Sciences*. Vol. ۵۴, No. 5, pp. 918-928, 2010.
- [۳۱] ع. اسکندری، ر. نوری، ح. معراجی و ا. کیفادی، توسعه مدلی مناسب بر مبنای شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش بینی به هنگام آکسیژنخواهی بیوشیمیایی ۵ روزه، محیط شناسی، سال سی و هشتم، شماره ۶۱، بهار ۹۱.
- [32] P. S. Yu, S. T. Chen, I. F. Chang, Support vector regression for real-time flood stage forecasting, *Journal of Hydrology*, Vol. 328, pp. 704-716, 2006.
- [۳۳] ع. رضایی، ع. میبیدی، آمار و احتمالات، انتشارات دانشگاه صنعتی اصفهان، ۱۳۸۴، چاپ اول.
- [34] C. J. Willmott, Some comments on the evaluation of model performance, *Bulletin of the American Meteorological Society*, Vol. 63, No. 11, pp. 1309-1313, 1982.
- [35] R. Meenal, A. I. Selvakumar, Assessment of SVM, empirical and ANN based solar radiation prediction models with most influencing input parameters. *Renewable Energy*, Vol. 121, pp. 324-343, 2018.
- [36] S. A. Ahmad, M. Y. Hassan, M. P. Abdullah, H. A. Rahman, F. Hussin, H. Abdullah, R. Saidur, A review on applications of ANN and SVM for building electrical energy consumption forecasting, *Renewable and Sustainable Energy Reviews*, Vol. 33, No. 1, pp. 102-109, 2014.
- این پژوهش مستخرج از قسمتی از پایان نامه دوره کارشناسی ارشد مهندسی منابع آب تحت عنوان "مدل سازی تابش خورشیدی با استفاده از چند مدل داده محور در ایستگاه های منتخب تابش سنجی ایران" در بخش مهندسی آب دانشگاه شهید باهنر کرمان بوده که به این وسیله تشکر می شود.
- ۸- مراجع
- [1] K. E. N'Tsoukpoe, K. Y. Azoumah, E. Ramde, A.K. Fiagbe, P. Neveu, X. Py, M. Gaye, A. Jourdan, Integrated design and construction of a micro-central tower power plant, *Energy for Sustainable Development*, Vol. 31, pp. 1-13, 2016.
- [2] A. Qazi, H. Fayaz, A. Wadi, R. G. Raj, N. A. Rahim, W. A. Khan, The artificial neural network for solar radiation prediction and designing solar systems: a systematic literature review. *Journal of cleaner production*, Vol. 104, PP. 1-12, 2015.
- [3] J. Jang, S. Roger, ANFIS: Adaptive-network-based fuzzy inference systems, *IEEE transactions on systems, man, and cybernetics*, Vol. 23, pp. 665-685, 2003.
- [4] X. Yan, D. Abbes, B. Francois, Solar radiation forecasting using Artificial Neural Network for local power reserve, *International Conference on Electrical Sciences and Technologies in Maghreb, (CISTEM)*, Tunisia, Tunisia, PP. 1-6, 2014.
- [۵] اکرم سیفی، توسعه یک سیستم خبره برای پیش بینی تبخیر و تعرق مرجع روزانه با استفاده از ماشین بردار پشتیبان (SVM) و مقایسه نتایج آن با ANN، ANFIS و روش های تجربی، دانشکده کشاورزی دانشگاه تربیت مدرس، پایان نامه کارشناسی ارشد، ۱۳۸۹.
- [۶] ع. سبزی پرور، و ا. علیانی، ارزیابی عملکرد شبکه عصبی مصنوعی در پیش بینی تابش خورشیدی کل روزانه و مقایسه آن با نتایج مدل آنکستروم (مطالعه موردی: ایستگاه همدیدی تبریز)، *مجله ژئوفیزیک ایران*، شماره سوم، سال پنجم، بهار ۹۰.
- [۷] س. معینی، ش. جوادی، م. دهقان منشادی، ر. اسماعیلی، برآورد پتانسیل تابش خورشیدی در شهر یزد، نشریه انرژی ایران، سال سیزدهم، شماره یکم، بهار ۸۹.
- [8] Z. Ramedani, M. Omid, A. Keyhani, Modeling solar energy potential in a Tehran province using artificial neural networks, *International Journal of Green Energy*, Vol. 10, pp. 427-441, 2013.
- [9] J. Piri, S. Shamsirband, D. Petković, C. W. Tong, M. H. ur Rehman, Prediction of the solar radiation on the Earth using support vector regression technique, *Infrared Phys. Infrared Physics and Technol*, Vol. 68, pp. 179-185, 2015.
- [10] K. Mohammadi, S. Shamsirband, A. S. Danesh, M. S. Abdullah, M. Zamani, Temperature-based estimation of global solar radiation using soft computing methodologies, *Theoretical and Applied Climatology*, Vol. 125, pp. 101-112, 2015.
- [11] N. KUMAR, S. P. Sharma, U. K. Sinha, Y. K. Nayak, Prediction of solar energy based on intelligent ANN modeling. *International Journal of Renewable Energy Research (IJRER)*, Vol. 6, No. 1, pp. 183-188, 2016.
- [12] H. C. Bayrakçı, C. Demircan, A. Keçebaş, The development of empirical models for estimating global solar radiation on horizontal surface: a case study, *Renewable and Sustainable Energy Reviews*, Vol. 81, pp. 2771-2782, 2018.
- [13] V. Z. Antonopoulos, D. M. Papamichail, V. G. Aschonitis, A. V. Antonopoulos, Solar radiation estimation methods using ANN and empirical models. *Computers and Electronics in Agriculture*, Vol. 160, pp. 160-167, 2019.
- [14] J. L. Chen, G. S. Li, Evaluation of support vector machine for estimation of solar radiation from measured meteorological variables, *Theoretical and Applied Climatology*, Vol. 115, pp. 627-638, 2014.
- [15] O. Şenkal, Solar radiation and precipitable water modeling for Turkey using artificial neural networks. *Meteorology and Atmospheric Physics*, Vol. 127, pp. 481-488, 2015.
- [16] L. Olatomiwa, S. Mekhilef, S. Shamsirband, K. Mohammadi, D. Petković, C. Sudheer, A support vector machine-firefly

