

## Forecasting the Outlet Fluid Temperature from a Flat Plate Collector Using Artificial Neural Networks (ANNs) and Support Vector Regression (SVR)

LIDA DEHLAGHI<sup>1</sup>, HEKMAT RABBANI<sup>2</sup>, ESMAEIL MIRZAEI- GHALEH<sup>\*3</sup>, KAMRAN KHEIRALIPOUR<sup>4</sup>

1. MSc. Student, Mechanical Engineering of Biosystem Department, Razi University, Kermanshah, Iran
  2. Associate Professor, Mechanical Engineering of Biosystem Department, Razi University, Kermanshah, Iran
  3. Assistant Professor, Mechanical Engineering of Biosystem Department, Razi University, Kermanshah, Iran
  4. Assistant Professor, Mechanical Engineering of Biosystem Department, Ilam University, Ilam, Iran
- (Received: Jan. 14, 2018- Revised: May. 28, 2018- Accepted: June. 23, 2018)

### ABSTRACT

In the present study, the outlet water temperature from flat plate solar collector using artificial neural networks (ANNs) and support vector regression (SVR) was modeled and compared with experimental results. Based on the results, with increasing input parameters of models, the accuracy of the model was increased. According to the results the values of  $R^2$ , RMSE and MAPE in the SVR method for the first model were 0.97, 3.25 and 2.77, respectively. While these values for the second model was 0.99, 0.10 and 0.55, respectively. On the other hand, for the ANN method and for the first model these values were 0.99 and 0.02 and 0.28, respectively. And for the second model were 0.99 and 0.01 and 0.19, respectively. The results showed that the accuracy of artificial neural network model for predicting the water outlet temperature was better than that of the support vector regression model.

**Keywords:** Support Vector Regression, Solar Collector, Water Temperature, Artificial neural network

---

\*Corresponding Author's Email: e.mirzaei@razi.ac.ir

## پیش‌بینی دمای سیال خروجی از جمع‌کننده خورشیدی صفحه تخت با دو روش شبکه عصبی مصنوعی (ANN) و تخمین گر بردار پشتیبان (SVR)

لیدا دهلقی<sup>۱</sup>، حکمت ربانی<sup>۲</sup>، اسماعیل میرزایی قلعه<sup>۳\*</sup>، کامران خیرعلی پور<sup>۴</sup>

۱. دانشجوی کارشناسی ارشد، گروه مهندسی مکانیک بیوسیستم، دانشگاه رازی، کرمانشاه، ایران

۲. دانشیار، گروه مهندسی مکانیک بیوسیستم، دانشگاه رازی، کرمانشاه، ایران

۳. استادیار، گروه مهندسی مکانیک بیوسیستم، دانشگاه رازی، کرمانشاه، ایران

۴. استادیار، گروه مهندسی مکانیک بیوسیستم، دانشگاه ایلام، ایلام، ایران

(تاریخ دریافت: ۱۳۹۶/۱۰/۲۴ - تاریخ بازنگری: ۱۳۹۷/۳/۷ - تاریخ تصویب: ۱۳۹۷/۴/۲)

### چکیده

در مطالعه حاضر دمای آب خروجی از جمع‌کننده خورشیدی صفحه تخت با استفاده از شبکه‌های عصبی مصنوعی (ANN) و تخمین‌گر بردار پشتیبان (SVR) در دو حالت مدل و با نتایج تجربی مقایسه شد. نتایج نشان داد که با افزایش پارامترهای ورودی مدل‌ها، دقت مدل افزایش یافت. بر اساس نتایج مقادیر  $R^2$ ، MSE و MAPE در روش SVR برای مدل اول به ترتیب برابر ۰/۹۷، ۳/۲۵ و ۲/۷۷ و برای پارامترهای مدل دوم به ترتیب برابر ۰/۹۹، ۰/۱۰ و ۰/۵۵ به دست آمد. در حالی که این مقادیر برای روش ANN برای مدل اول به ترتیب برابر ۰/۹۹، ۰/۰۲ و ۰/۲۸ و برای مدل دوم به ترتیب برابر ۰/۹۹، ۰/۰۱ و ۰/۱۹ به دست آمد. نتایج نشان داد که مدل شبکه عصبی مصنوعی نسبت به مدل تخمین‌گر بردار پشتیبان با دقت بیشتری دمای آب خروجی از جمع‌کننده خورشیدی صفحه تخت را پیش‌بینی کرد.

**واژه‌های کلیدی:** تخمین‌گر بردار پشتیبان، جمع‌کننده خورشیدی، دمای آب، شبکه عصبی مصنوعی

### مقدمه

بر اساس استانداردهای بین‌المللی اگر میانگین انرژی تابشی خورشید در روز بالاتر از ۳/۵ کیلووات ساعت در متر مربع باشد، استفاده از وسایل انرژی خورشیدی نظیر جمع‌کننده‌های خورشیدی یا سامانه‌های فتوولتائیک می‌تواند اقتصادی و مقرون‌به‌صرفه باشد (Anonymous, 2013).

جمع‌کننده‌های خورشیدی یکی از تکنولوژی‌های مهم در زمینه انرژی‌های تجدیدپذیر می‌باشند. جمع‌کننده خورشیدی، اصلی‌ترین جزء سامانه گرمایش خورشیدی می‌باشد. عمل جذب تابش خورشیدی و انتقال گرما به سیال توسط این قسمت انجام می‌گیرد. اجزای تشکیل‌دهنده جمع‌کننده خورشیدی صفحه تخت شامل پوشش، بدنه، عایق، صفحه‌ی جاذب، لوله‌ی انتقال سیال و سیال عامل می‌باشد (El-Kassaby, 1988).

به دست آوردن پارامترهای خروجی تحت شرایط آزمایش‌های متفاوت، نسبتاً هزینه‌بر، طولانی و غیرممکن است. لذا به کارگیری روش‌های مختلف جهت پیش‌بینی پارامتر خروجی مورد نظر اطلاعات با ارزشی فراهم می‌کند. دامنه‌ی کاربردی بسیار گسترده‌ی ابزارهای پیش‌بینی، نشان‌دهنده‌ی اهمیت این ابزارها است. یکی از روش‌های نسبتاً جدید در مسائل دسته‌بندی و رگرسیون روش ماشین بردار پشتیبان

انرژی، مهم‌ترین رکن توسعه و پیشرفت بشری در همه زمینه‌ها شامل صنعت، کشاورزی و حمل و نقل می‌باشد (Karimzadeh et al., 2013). اگرچه سوخت‌های فسیلی رشد سریع اقتصادی جوامع بشری را به‌همراه داشته، اما انتشار آلاینده‌های ناشی از مصرف این سوخت‌ها، باعث بروز تغییرات آب و هوایی شده است. از سوی دیگر، منابع سوخت‌های فسیلی به تدریج در حال کاهش است. امروزه انرژی‌های نو به رغم ناشناخته ماندن، به سرعت در حال گسترش بوده و غفلت از آن‌ها، غیر قابل جبران خواهد بود (Homayounifer et al., 2013). این موضوع، پژوهش در زمینه انرژی‌های تجدیدپذیر مانند انرژی خورشیدی را ضروری می‌سازد (Maleki, 2011).

انرژی خورشید، به‌عنوان یک منبع انرژی تجدیدپذیر، پاک و بدون آسیب به محیط زیست، برای تولید الکتریسته و گرما قابل استفاده است (Fahad et al., 2011; Zhai et al., 2013). استفاده از انرژی خورشیدی در میان کشورهای توسعه یافته از جمله مباحثی است که طی سال‌های اخیر مورد توجه سیاستمداران و سازمان‌های محیط‌زیست قرار گرفته است.

بر اساس بررسی منابع انجام شده، تاکنون مطالعه‌ای در زمینه مقایسه عملکرد دو روش شبکه عصبی مصنوعی و تخمین گر بردار پشتیبان در پیش‌بینی دمای سیال خروجی از جمع‌کننده صفحه تخت خورشیدی بر اساس ورودی‌های مختلف انجام نگرفته است. صورت نگرفته است. با توجه به این که در گرمایش خورشیدی دانستن محدوده‌ی دمای سیال خروجی در شرایط کاری مختلف معیار مهمی در طراحی اجزاء سامانه‌های گرمایشی شامل حجم مخزن، اتصالات، تعیین سطح جمع‌کننده مورد نظر، دمای کاری بهینه، تعیین توان منبع مکمل و ارزیابی اقتصادی است. در این پژوهش عملکرد دو روش شبکه عصبی مصنوعی (ANN) و تخمین‌گر بردار پشتیبان برای پیش‌بینی دمای سیال خروجی از جمع‌کننده خورشیدی صفحه تخت بررسی و مورد مقایسه قرار گرفت.

## مواد و روش‌ها

### انجام آزمایش‌ها

این تحقیق در شهر کرمانشاه با موقعیت جغرافیایی ۴۷/۷ درجه طول شمالی و ۳۴/۲۳ درجه عرض شمالی انجام شد. جهت انجام پژوهش از آبگرمکن خورشیدی صفحه تخت با سامانه گردش اجباری - مدار بسته (ساخت شرکت سولار پولار) با سیال عامل آب استفاده شد (شکل ۱). صفحه جاذب استفاده شده در این جمع‌کننده از تعداد ۶ ورقه آلومینیوم با عرض ۱۵ سانتی‌متر و طول ۱۸۰ سانتی‌متر به ضخامت ۰/۵ میلی‌متر و ضریب جذب ۰/۸۱ استفاده شده است. لوله‌های صفحه جاذب از جنس مس بوده که قطر و ضخامت آن به ترتیب ۶ و ۱ میلی‌متر بود. از شیشه معمولی با ضریب عبور ۰/۹ به عنوان پوشش شفاف استفاده شده است. همچنین جهت انجام بهتر عمل سیرکولاسیون از پمپ گرندفوس<sup>۴</sup> با قابلیت تغییر دبی در سه سطح برای به گردش درآوردن آب در سامانه استفاده شد (شکل ۲).

مخزن دو جداره یکی از ساده‌ترین و ارزان‌ترین راه تولید مبدل حرارتی با کارایی بالا در پیشبرد طبقه‌بندی حرارتی است. در این تحقیق از مخزن استوانه‌ای شکل (به طول ۱ متر و قطر ۰/۵ متر) با حجم ۱۲۰ لیتر استفاده شد. جنس مخزن آهن گالوانیزه به ضخامت ۳ میلی‌متر می‌باشد. به منظور جلوگیری از انتقال حرارت از مخزن به محیط و در حقیقت جلوگیری از اتلاف انرژی، سطح مخزن توسط پشم‌شیشه پوشانده شد. با توجه به قرارگیری کشور ایران در نیمکره شمالی جهت

(SVM)<sup>۱</sup> است که امروزه از آن به عنوان یکی از معتبرترین ابزارهای یادگیری ماشین استفاده می‌شود.

در سال‌های اخیر (SVR)<sup>۲</sup> توسط بسیاری از محققین برای پیش‌بینی در زمینه‌های مختلف بکار گرفته شده است که می‌توان به تحقیقات (Dibike et al., 2001) و (Shokri et al., 2013) اشاره کرد. در تحقیقی با استفاده از مدل حداقل مربعات ماشین بردار پشتیبان سری زمانی هواشناسی (مثل تابش خورشیدی، دمای هوا، رطوبت نسبی و ...) برای دوره کوتاه مدت پیش‌بینی شد (Mellit et al., 2013).

شبکه عصبی مصنوعی مدلی است که همانند مغز انسان اطلاعات را پردازش می‌کند. شبکه‌های عصبی مصنوعی به طور گسترده‌ای در حل مسائل مختلف از جمله پیش‌بینی مورد مطالعه قرار گرفته است. لکوچه و لالوت با استفاده از شبکه‌های عصبی مصنوعی (ANN)<sup>۳</sup> عملکرد حرارتی جمع‌کننده صفحه تخت خورشیدی را پیش‌بینی کردند (Lecoeuche & Lalot, 2005). هیبرت و همکاران خصوصیات حرارتی یک آبگرمکن خانگی را با استفاده از شبکه عصبی بررسی کردند و براساس مدل ANN دمای آب برداشت شده از مخزن ذخیره انرژی را با دقت بالایی پیش‌بینی نمودند (Hibbert et al., 2009). در پژوهشی از یک شبکه پس انتشار خطا به منظور برآورد ماهانه متوسط تابش خورشیدی در یک سطح افقی در شهر گوساو نیجریه استفاده شد. مدت زمان تابش، حداکثر درجه حرارت محیط و رطوبت نسبی به عنوان پارامترهای ورودی و تابش خورشیدی به عنوان پارامتر خروجی در نظر گرفته شدند. براساس نتایج به دست آمده هم‌راستایی مناسبی بین مقادیر برآورد و اندازه‌گیری تابش خورشیدی وجود داشت (Azeez, 2011). در جدول (۱) به تحقیقات مشابه به صورت خلاصه اشاره شده است:

جدول ۱- مروری بر کارهای گذشته

پژوهشگران	عنوان پژوهش
Ramedani et al., 2014	بررسی پتانسیل تخمین‌گر بردار پشتیبان براساس توابع پایه شعاعی (Rbf) جهت پیش‌بینی تابش‌های خورشیدی جهانی
Nadi et al., 2017	پیش‌بینی دمای خروجی جمع‌کننده خورشیدی تخت با نتایج تجربی، دینامیک سیالات محاسباتی و شبکه عصبی مصنوعی
Benli, 2013	پیش‌بینی رفتار غیرخطی عملکرد جمع‌کننده خورشیدی با استفاده از الگوریتم لونیبرگ-مارکوات
Zamani Mohayabadi, 2015	مدل‌سازی و پیش‌بینی دمای سیال خروجی از کلکتور تخت با استفاده از شبکه عصبی مصنوعی (ANN)

1. Support Vector Machine (SVM)  
2. Support Vector Regression (SVR)  
3. Artificial Neural Network (ANN)

کار آزموده‌تر گشته، قادر به نتیجه‌گیری منطقی بوده و قابلیت تعمیم نیز دارد. برای مدل سازی به کمک هر دو روش از دو ساختار با پارامترهای زیر به‌عنوان ورودی استفاده شد. در هر دو ساختار، دمای آب خروجی از جمع کننده به عنوان خروجی مدل پیش بینی در نظر گرفته شد:

مدل اول: ورودی مدل شامل دمای سیال ورودی، دمای محیط، دبی سیال عبوری، و زمان انجام آزمایش  
مدل دوم: ورودی مدل شامل دمای سیال ورودی، دمای محیط، دبی سیال ورودی، زمان انجام آزمایش، دمای نقطه میانی صفحه جاذب، دمای نقطه پایینی صفحه جاذب و دمای پوشش شیشه‌ای

### روش رگرسیون بردار پشتیبان (SVR)

روش (SVM) یکی از روش‌های یادگیری ماشین قلمداد می‌گردد. تخمین گر بردار پشتیبان (SVM) نوع خاصی از شبکه های عصبی هستند که بر خلاف سایر انواع شبکه عصبی (مانند پرسپترون چندلایه<sup>۱</sup>) به جای کمینه کردن خطا، اقدام به کمینه کردن ریسک عملیاتی طبقه بندی یا مدل سازی می‌کند (Cristianini & Shaw-Taylor, 2000). مدل های ماشین های بردار پشتیبان به دو گروه عمده الف) مدل طبقه بندی ماشین بردار پشتیبان و ب) مدل رگرسیون ماشین بردار پشتیبان تقسیم بندی می‌شوند. از مدل طبقه بندی ماشین بردار پشتیبان جهت حل مسائل طبقه بندی داده‌هایی که در کلاس‌های مختلف قرار می‌گیرند استفاده می‌گردد و مدل رگرسیون ماشین بردار پشتیبان در حل مسائل پیش‌بینی کاربرد دارد (Vapnik, 1998).

در روش رگرسیون SVR، تابعی برآورد می‌شود که با آن بتوان بر مبنای داده‌های آموزشی، یک بردار ورودی را به یک عدد حقیقی نگاشت می‌کند. SVR دارای همان خواص بیشینه سازی حاشیه و روش کرنل برای نگاشت غیر خطی می‌باشد. از زمان ابداع الگوریتم SVM و به تبع آن SVR، الگوریتم‌های فرعی فراوانی برای SVM ابداع شده است که با اصلاحات یا تغییرات جزئی، موجب بهبود و ارتقای الگوریتم مذکور شده‌اند (Vapnik & Chervonenkis, 1971). در SVM حل مسأله رگرسیون با معرفی یک تابع تلفات<sup>۲</sup> جدید که در آن حداقل خطایی به میزان  $\epsilon$  قابل صرف نظر کردن است، بررسی می‌گردد. یک مجموعه داده به صورت داده‌های ورودی و خروجی به صورت  $\{(X_1, y_1), \dots, (X_i, y_i)\} \in R^N, y \in R$  که

جمع کننده به سمت جنوب و به‌نحوی که با افق زاویه‌ای برابر با عرض جغرافیایی بسازد، قرار گرفت (Mirzaee Ghaleh, 2013).



شکل ۱- نمایی از جمع کننده خورشیدی صفحه تخت مورد استفاده



شکل ۲- محل نصب پمپ گردفوس در سامانه مورد آزمایش


به منظور داده برداری، از ۶ حسگر ترموکوپل نوع K با دقت  $\pm 0.1$  درجه سلسیوس برای اندازه گیری دماهای سیال ورودی به جمع کننده، سیال خروجی از جمع کننده، دمای پوشش شیشه‌ای، دمای نقطه میانی صفحه جاذب، دمای بخش پایینی صفحه جاذب و دمای محیط استفاده شد. برای هر دبی سه تکرار و هر تکرار از ساعت ۸ صبح تا ۱۹ بعد از ظهر (در کل به مدت ۹ روز) داده برداری صورت گرفت. داده‌ها به صورت هر ۵ دقیقه یکبار توسط دیتالاگر (مدل PROVA 800 ساخت کشور تایوان) ثبت گردید. لذا در این تحقیق تعداد ۱۱۸۹ داده استخراج شده که هر کدام از داده‌ها شامل ۶ پارامتر اندازه‌گیری (به تعداد حسگرها) می‌باشد.

### مدل سازی و تحلیل داده ها

در این پژوهش به منظور پیش‌بینی دمای سیال خروجی از دو روش تخمین گر بردار پشتیبان (SVR) و شبکه های عصبی مصنوعی (ANN) استفاده شد. شبکه از طریق مثال تعلیم می‌بیند. این مدل برای انجام کار خاصی برنامه‌ریزی نشده است بلکه به گونه‌ای است که به مرور زمان و تعامل بیشتر با محیط

1. Multi Linear Perceptron (MLP)  
2. Loss Function

است. در این پژوهش برای آموزش مدل و ارزیابی آن از نرم‌افزار MATLAB 2013 استفاده شد. روش آموزش داده‌ها Online انتخاب شده است. در این روش آموزش، مدل به صورت مرحله به مرحله توسط قسمتی از داده‌ها (داده‌های آموزش) آموزش داده می‌شود. به عبارت دیگر مدل آموزش داده شده با هر داده جدید به‌هنگام می‌شود. پس از اتمام فرآیند آموزش مدل، عملکرد آن توسط داده‌هایی که در فرآیند آموزش استفاده نشده‌اند (داده‌های آزمایش) ارزیابی می‌شوند.



شکل ۳- چگونگی برازش داده‌ها در فضای ورودی در روش SVR

### روش شبکه‌های عصبی مصنوعی (ANN)

شبکه‌های عصبی از یک سری لایه‌ها شامل اجزای ساده پردازشگر به نام نرون تشکیل شده‌اند که به صورت موازی با هم عمل می‌کنند. هر لایه ورودی به یک یا تعداد بیشتری لایه میانی مرتبط می‌شوند و لایه‌های میانی نیز به لایه‌های خروجی مرتبط می‌شوند. جواب شبکه نیز نقش خروج را برای سامانه ایفا می‌کند (Zamani Mohyabadi, 2013). اکثر الگوریتم‌ها و معماری‌های شبکه‌های عصبی مصنوعی به‌وسیله تغییر در مدل نرون، ارتباط بین نرون‌های به‌کار رفته و وزن‌های اعمال شده بین نرون‌ها تغییر می‌کند. متداول‌ترین نوع شبکه‌های عصبی مصنوعی، عبارتند از پیش‌خورده، بازخوردی، رقابتی (Dogan et al., 2008). در این پژوهش از شبکه عصبی پیش‌خورده استفاده شد. به‌منظور ارتباط میان لایه ورودی با لایه پنهان و لایه پنهان با خروجی به‌ترتیب از توابع tansig و purelin استفاده شد. جهت آموزش مدل به شبکه از روش آموزش لونیگ-مارکوات<sup>۱</sup> استفاده شد، زیرا این روش آموزش دارای سرعت و دقت بالاتری از الگوریتم پس‌انتشار استاندارد می‌باشد و داده‌های ورودی کم‌تری نیز برای آموزش نیاز دارد. تابع تحریک خروجی purelin در نظر گرفته شد. به عنوان مثال در شکل (۴) ساختار شبکه عصبی به‌کار برده شده برای مدل شماره (۱) آورده شده است.

در آن  $X$  ورودی و  $y$  خروجی است، مفروض می‌باشد. هدف این است که با یک تابع خطی به شکل  $f(X) = (W \cdot X) + b$  خروجی‌ها بر مبنای ورودی‌ها تخمین زده شود. در این رابطه  $w$  بردار وزن و  $b$  بایاس می‌باشد. تابع تلفات Vanpnik با منطقه غیرحساس به عرض  $\epsilon$  (خطای مورد قبول در تابع تلفات) به‌صورت زیر تعریف می‌گردد (Dibike et al., 2001):

$$L_e(y) = |y - f(x)|_\epsilon = \begin{cases} 0 & \text{if } |y - f(x)| \leq \epsilon \\ |y - f(x)| & \text{otherwise} \end{cases} \quad (\text{رابطه ۱})$$

با توجه به مطالب بالا، بهترین تابعی که عملیات رگرسیون را در روش ماشین بردار پشتیبان انجام می‌دهد، با کمینه‌کردن تابع زیر به‌دست می‌آید (Cristianini Shaw-Taylor, 2000):

$$\begin{aligned} \phi(w, \zeta_i, \zeta_i^*) &= \frac{1}{2} \|w\|^2 + c (\sum \zeta_i^* + \sum \zeta_i) \\ &\begin{cases} \text{Minimize} \\ \text{Subject to} \end{cases} \\ &\begin{cases} y_i - (w \cdot X_i + b) \leq \epsilon + \zeta_i^* \\ (w \cdot X_i + b) - y_i \leq \epsilon + \zeta_i \\ \zeta_i^*, \zeta_i \geq 0 \quad i = 1, \dots, n \end{cases} \end{aligned}$$

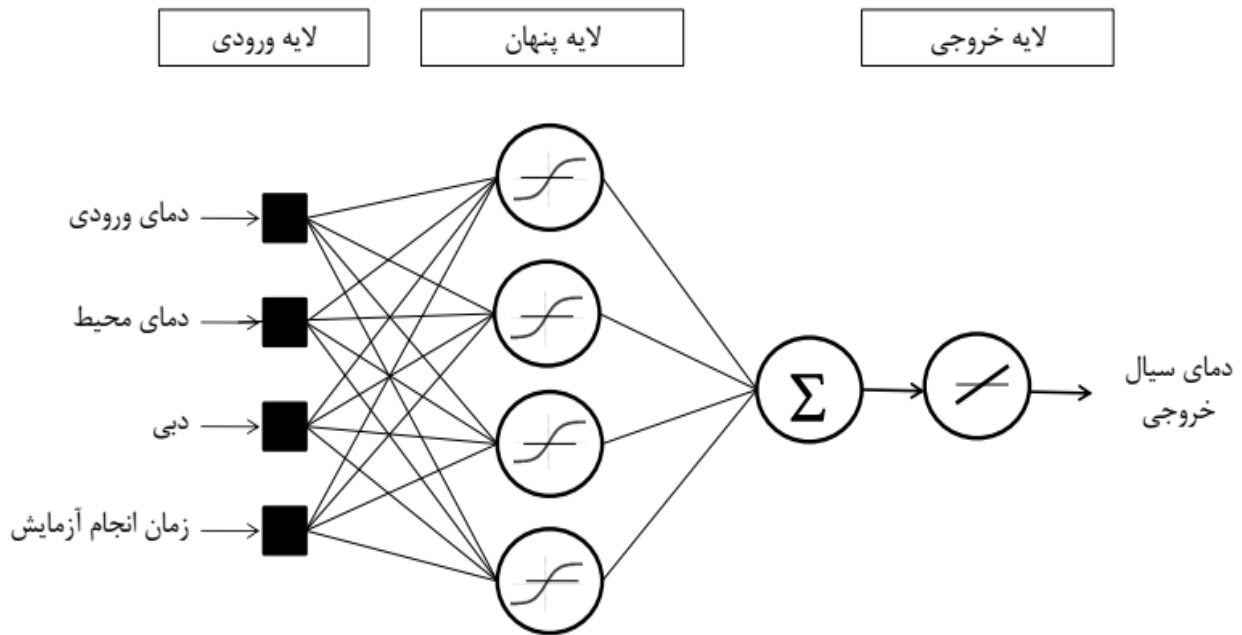
که در رابطه فوق،  $\|w\|^2$ ، مقیاس بردار وزن (این مقدار برابر با  $\sum w_i^2$  می‌باشد)،  $\zeta_i$  و  $\zeta_i^*$  نیز متغیرهای کمکی می‌باشند که این پارامترها در شکل (۳) مشخص شده‌اند. پارامتر  $C$  تعادل میان پیچیدگی ماشین و تعداد نقاط تفکیک‌پذیر را کنترل می‌کند و می‌تواند به عنوان یک پارامتر تنظیم‌کننده شناخته شود. مقدار آن عموماً از طریق سعی و خطا با به‌کارگیری داده‌های آموزش و آزمایش تعیین می‌گردد. اگر به  $C$  مقدار بزرگی اختصاص داده شود، در حقیقت به ماشین آموزش داده شده است تا خطا را روی داده‌های آموزش کم کند، اما قابلیت تعمیم‌یابی کاهش می‌یابد. حال اگر به  $C$  مقدار کوچکی اختصاص یابد، جریمه کمتری برای خطا وجود دارد (ماشین اجازه دارد بر روی داده‌های آموزش خطای بیشتری بپذیرد) که موجب کمینه‌سازی حاشیه با خطاها می‌شود، پس قابلیت تعمیم‌یابی بالا می‌رود. بنابراین اگر  $C$  بی‌نهایت بزرگ باشد، ماشین اجازه وقوع هیچ خطایی را در داده‌های آموزش ندارد و حاصل یک مدل پیچیده خواهد بود. از سوی دیگر، وقتی  $C$  به سمت صفر میل می‌کند، نتایج می‌توانند مقدار زیادی خطا را تحمل کرده و پیچیدگی مدل کمتر خواهد بود (Pal & Deswal, 2008).

مقدار پارامتر  $\epsilon$  نیز در وضعیت بردارهای پشتیبان و در نتیجه کارایی مدل بسیار مؤثر است. با انتخاب مقادیر خیلی بزرگ برای  $\epsilon$  بردارهای پشتیبان کاهش داده می‌شود، ولی باند  $\epsilon$  عریض‌تر می‌شود و دامنه خطای مجاز بالا می‌رود. مقادیر خیلی کوچک  $\epsilon$  نیز موجب می‌شود تا بردارهای پشتیبان زیاد شده و احتمال خطر بیش آموزش افزایش می‌یابد (Pal & Deswal, 2008). برای گسترش مدل از تابع کرنل استفاده شده

1. Levenberg marquardt

پایان برای ارزیابی شبکه از گروه سوم داده، یعنی گروه آزمون، استفاده شد. در این پژوهش داده‌های به دست آمده از استخراج ویژگی، ۶۰ درصد برای آموزش، ۲۰ درصد برای اعتبارسنجی و ۲۰ درصد برای آزمون به کار رفتند. تعداد تکرارهای شبکه نیز ۱۰۰ دور در نظر گرفته شد. در این پژوهش برای آموزش مدل و ارزیابی آن از نرم‌افزار MATLAB 2013 استفاده شد.

پس از آموزش شبکه، داده‌های مجموعه اعتبارسنجی شده تا قدرت شبکه ارزیابی شود. بدین شکل که هر چه اختلاف بین خروجی واقعی مطلوب در سری اعتبارسنجی کمتر باشد شبکه از قدرت تعمیم بالایی برخوردار است. مزیت دیگر مجموعه اعتبارسنجی این است که در تعیین زمان توقف آموزش شبکه مفید می‌باشد و از بیش آموزش دیدن شبکه ممانعت می‌کند. در



شکل ۴- ساختار شبکه عصبی مصنوعی به کار برده شده برای مدل شماره ۱

تعیین  $0.99$ ، میانگین مربعات خطا  $0.10$  و درصد میانگین خطای مطلق  $0.55$  دارای عملکرد بهتری است. منحنی تغییرات مقادیر پیش بینی شده دمای سیال خروجی در برابر مقادیر واقعی مربوطه برای ۲ مدل ارزیابی شده به ترتیب در شکل‌های (۵) و (۶) آورده شده است. پراکندگی نقاط در شکل‌ها نشان‌دهنده دقت مدل‌ها در پیش‌بینی مقادیر دمای سیال خروجی از آبگرم‌کن خورشیدی را نشان می‌دهد. مقادیر ضریب تعیین نشان می‌دهد که ساختار اول به دلیل کم بودن تعداد پارامترهای ورودی برای پیش‌بینی دمای سیال خروجی از دقت کمتری نسبت به ساختار دوم با تعداد پارامترهای ورودی بیشتر برخوردار است. نتایج مشابهی توسط (Jamadi, 2016) گزارش شد. ایشان در تحقیق خود با استفاده از شبکه عصبی مصنوعی مدلی کارآمد برای پیش‌بینی راندمان آبگرم‌کن پیشنهاد داد. ایشان با در نظر گرفتن تعداد متفاوتی از متغیرهای ورودی و نرون‌ها به این نتیجه دست یافت که با افزایش تعداد پارامترهای ورودی، پیش‌بینی و دقت مدل افزایش می‌یابد.

## نتایج و بحث

### نتایج مدل‌سازی به روش رگرسیون بردار پشتیبان (SVR)


منظور از رگرسیون، به دست آوردن یک ابرصفحه است که بر داده‌های مورد نظر برازش داده می‌شود. فاصله هر نقطه از این ابرصفحه نشان‌دهنده خطای آن نقطه خاص است. در این تحقیق از  $70\%$  داده‌ها برای آموزش و  $30\%$  داده‌ها برای آزمایش کارایی مدل مورد استفاده قرار گرفت. مدل برتر به کمک سه شاخص ضریب تعیین ( $R^2$ )، میانگین مربعات خطا (MSE) و درصد میانگین خطای مطلق (MAPE) انتخاب شد. نتایج ارزیابی دو مدل در نظر گرفته شده در جدول (۲) ارائه شده است.

بر اساس نتایج (جدول ۲) مدل شماره ۲ با مقادیر ضریب


1. Coefficient of determination
2. Mean Square Error (MSE)
3. Mean absolute percentage error

جدول ۲- نتایج حاصل از مدل‌سازی به روش SVR

ردیف	ورودی مدل	خروجی مدل	R <sup>2</sup>	MSE	MAPE
۱	دمای ورودی، دمای محیط، دبی و زمان انجام آزمایش	دمای خروجی	۰/۹۷	۳/۲۵	۲/۷۷
۲	دمای ورودی، دمای محیط، دبی، زمان انجام آزمایش، دمای نقطه میانی صفحه جاذب، دمای نقطه پایینی صفحه جاذب و دمای پوشش شیشه‌ای	دمای خروجی	۰/۹۹	۰/۱۰	۰/۵۵



شکل ۵- تغییرات مقادیر دمای خروجی (سلسیوس) پیش‌بینی شده در برابر مقادیر واقعی (سلسیوس) برای مدل ۱



شکل ۶- تغییرات مقادیر دمای خروجی (سلسیوس) پیش‌بینی شده در برابر مقادیر واقعی (سلسیوس) برای مدل ۲

که از جدول (۳) مشاهده می‌شود، بالاترین دقت پیش‌بینی مربوط به ساختار ۱-۹-۴ می‌باشد که در واقع این شبکه دارای ۴ نرون در لایه ورودی، ۹ نرون در لایه پنهان و ۱ نرون در لایه خروجی می‌باشد. بر اساس نتایج مقادیر میانگین مربعات خطا، ضریب تعیین و درصد میانگین خطای مطلق برای بهترین مدل به ترتیب برابر ۰/۰۲، ۰/۹۹ و ۰/۲۸ بود. مقادیر رگرسیون بخش

#### پیش‌بینی به روش شبکه عصبی مصنوعی (ANN)

پیش‌بینی به روش شبکه عصبی مصنوعی مدل ۱

نتایج پیش‌بینی دمای سیال خروجی به کمک مدل ۱ (ورودی‌ها شامل دمای سیال ورودی، دمای محیط، دبی سیال عبوری، و زمان انجام آزمایش) و با روش شبکه‌های عصبی مصنوعی (ANN1) در جدول ۳ نشان داده شده است. همان‌طور

های عصبی مصنوعی (ANN2) در جدول ۳ نشان داده شده است. در این مدل سازی ۶۰ درصد داده ها جهت آموزش شبکه، ۲۰ درصد برای اعتبار سنجی و ۲۰ درصد نیز برای تست سامانه در نظر گرفته شد. همانطور که از جدول (۳) مشاهده می شود، بالاترین دقت پیش بینی مربوط به ساختار ۱-۱۰-۷ می باشد که در واقع این شبکه دارای ۷ نرون در لایه ورودی، ۱۰ نرون در لایه پنهان و ۱ نرون در لایه خروجی می باشد. نتایج حاکی از دقت پیش بینی به روش شبکه عصبی برابر ۹۹/۹۸٪ می باشد. بر اساس نتایج مقادیر میانگین مربعات خطا، ضریب تعیین و درصد میانگین مربعات خطا برای بهترین مدل به ترتیب برابر ۰/۰۱۵۶، ۰/۹۹۹ و ۰/۱۹ بود. مقادیر رگرسیون بخش های مختلف مدل شامل آموزش، اعتبار سنجی و تست را برای مدل ۲ در شکل (۸) نشان داده شده است.

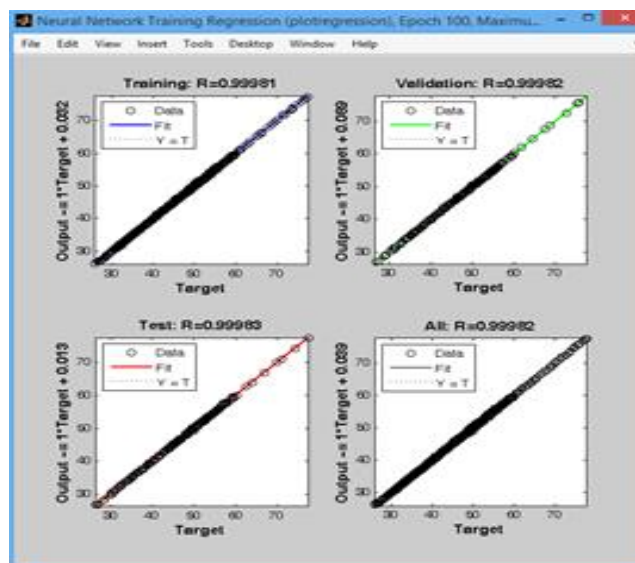
های مختلف مدل شامل آموزش، اعتبار سنجی و تست در شکل (۷) نشان داده شده است. همان گونه که مشاهده می شود، ضریب رگرسیون آموزش، اعتبار سنجی، آزمون و کل در شبکه بهینه به ترتیب برابر ۰/۹۹۹، ۰/۹۹۹، ۰/۹۹۹ و ۰/۹۹۹ به دست آمده است. همانطور که در شکل مشخص است، روند خطی میان دمای واقعی و برآورد شده نشان از موفقیت شبکه عصبی در یادگیری تغییرات دمای جمع کننده دارد. این نتایج با نتایج (Nadi et al., 2017) و (Zamani Mohyabadi, 2015) مطابقت داشت.

#### پیش بینی به روش شبکه عصبی مصنوعی مدل ۲

نتایج پیش بینی دمای سیال خروجی مدل ۲ ( ورودی مدل شامل دمای سیال ورودی، دمای محیط، دبی سیال ورودی، زمان انجام آزمایش، دمای نقطه میانی صفحه جاذب، دمای نقطه پایینی صفحه جاذب و دمای پوشش شیشه ای) و با روش شبکه

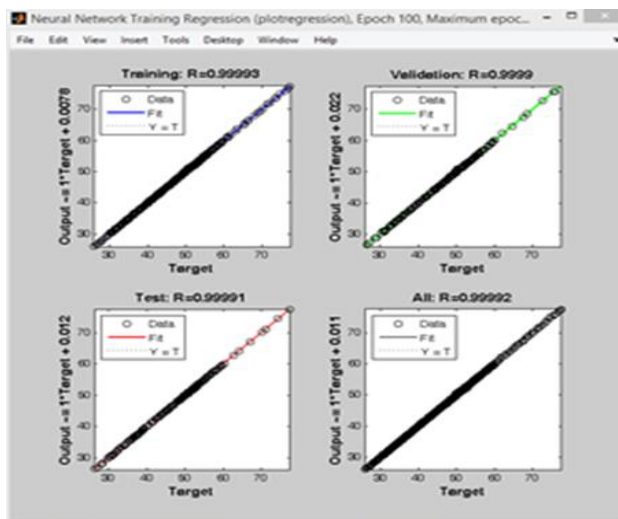
جدول ۳- نتایج پیش بینی ساختارهای مختلف شبکه عصبی ارزیابی شده بر اساس مدل های ۱ و ۲

ردیف	ساختار	میانگین مربعات خطا (MSE)	ضریب همبستگی (r, %)	دقت پیش بینی (%)	درصد میانگین خطای مطلق (MAPE)
ANN1	۱-۸-۴	۰/۰۳	۰/۹۹	۹۹/۹۵	۰/۳۱
	۲-۹-۴	۰/۰۲	۰/۹۹	۹۹/۹۶	۰/۲۸
	۳-۱۰-۴	۰/۰۳	۰/۹۹	۹۹/۹۶	۰/۳
ANN2	۱-۸-۷	۰/۰۱۷۹	۰/۹۹۹۸	۹۹/۹۷	۰/۲۱
	۲-۹-۷	۰/۰۱۵۸	۰/۹۹۹	۹۹/۹۸	۰/۱۹
	۳-۱۰-۷	۰/۰۱۵۶	۰/۹۹۹	۹۹/۹۸	۰/۱۹



شکل ۷- نمودارهای رگرسیون شبکه عصبی مصنوعی بهینه برای مدل ۱





شکل ۸- نمودارهای رگرسیون شبکه عصبی مصنوعی بهینه برای مدل ۱

### نتیجه‌گیری کلی

در این تحقیق عملکرد دو روش تخمین‌گر بردار پشتیبان و شبکه عصبی مصنوعی در پیش‌بینی دمای آب خروجی از جمع‌کننده صفحه تخت خورشیدی مقایسه شد. نتایج حاصل از تحقیق نشان داد:

دقت پیش‌بینی مدل‌سازی به روش‌های رگرسیون بردار پشتیبان (SVR) و شبکه عصبی مصنوعی با افزایش تعداد پارامترهای ورودی به مدل افزایش یافت.

ضریب تعیین، میانگین مربعات خطا و درصد میانگین خطای مطلق دمای سیال خروجی توسط روش رگرسیون بردار پشتیبان، با پارامترهای ورودی دبی، زمان، دمای محیط و دمای سیال ورودی (SVR1) به ترتیب ۰/۹۷، ۳/۲۵ و ۲/۷۷ به دست آمد.

ضریب تعیین، میانگین مربعات خطا و درصد میانگین خطای مطلق دمای سیال خروجی توسط روش رگرسیون بردار پشتیبان، با پارامترهای ورودی دبی، زمان، دمای محیط، دمای سیال ورودی، دمای سیال خروجی، دمای نقطه میانی صفحه جاذب، دمای نقطه پایینی صفحه جاذب و دمای پوشش شیشه‌ای (SVR2) به ترتیب ۰/۹۹، ۱/۰ و ۰/۵۵ به دست آمد.

پیش‌بینی دمای سیال خروجی توسط شبکه عصبی مصنوعی با پارامترهای ورودی دبی، زمان، دمای محیط و دمای سیال ورودی (ANN1) با ضریب تعیین ۰/۹۹، میانگین مربعات خطای ۰/۰۲ و درصد میانگین خطای مطلق ۰/۲۸ انجام گرفت.

پیش‌بینی دمای سیال خروجی توسط شبکه عصبی مصنوعی با پارامترهای ورودی دبی، زمان، دمای محیط و دمای سیال ورودی دمای سیال خروجی، دمای نقطه میانی صفحه جاذب، دمای نقطه پایینی صفحه جاذب و دمای پوشش

همان‌گونه که مشاهده می‌شود، ضریب رگرسیون آموزش، اعتبارسنجی، آزمون و کل در شبکه بهینه به ترتیب برابر ۰/۹۹۹، ۰/۹۹۹، ۰/۹۹۹ و ۰/۹۹۹ به دست آمد. مقایسه‌ی نتایج حاصل از دو روش ANN1 و ANN2 نشان داد که با افزایش تعداد پارامترهای ورودی به مدل، دقت مدل نیز افزایش می‌یابد. (Zamani Mohyabadi, 2015) با استفاده از شبکه عصبی مدلی را جهت پیش‌بینی دمای سیال خروجی از جمع‌کننده صفحه تخت خورشیدی ارائه داد. در این مدل تابش خورشیدی، دمای محیط، سرعت باد، دمای سیال ورودی و دبی سیال به‌عنوان ورودی شبکه عصبی در نظر گرفته شده و دمای سیال خروجی و پیش‌بینی ۵ دقیقه آینده آن به‌عنوان خروجی شبکه عصبی در نظر گرفته شده است. نتایج نشان دهنده مدل‌سازی قابل اعتماد مجموعه است. (Zanjani, 2011) در مطالعه خود با استفاده از شبکه عصبی مصنوعی، دبی بهینه جمع‌کننده‌های صفحه تخت خورشیدی در تابش‌های مختلف به ازاء دبی‌های مختلف آبگرم خروجی از مخزن را پیش‌بینی نمود. نتایج مشابهی توسط (Jamadi, 2016) گزارش شد. ایشان در تحقیق خود با استفاده از شبکه عصبی مصنوعی مدلی کارآمد برای پیش‌بینی راندمان آبگرمکن پیشنهاد داد. ایشان با در نظر گرفتن تعداد متفاوتی از متغیرهای ورودی و نرون‌ها به این نتیجه دست یافت که با افزایش تعداد پارامترهای ورودی، پیش‌بینی و دقت مدل افزایش می‌یابد.

نتایج پیش‌بینی حاکی از دقت خوب هر دو روش مدل‌سازی است. با توجه به نتایج به‌دست آمده در بخش مدل‌سازی با روش رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی، عملکرد مدل شبکه عصبی در پیش‌بینی دمای سیال خروجی از جمع‌کننده صفحه تخت بهتر بود.

## سپاسگزاری

از حمایت‌های مادی و معنوی دانشگاه رازی تشکر می‌گردد.

شیشه‌ای (ANN2) با ضریب تعیین ۰/۹۹، میانگین مربعات خطای ۰/۰۱ و درصد میانگین خطای مطلق ۰/۱۹ انجام گرفت.

## REFERENCES

- Anonymous. (2013). Iranian solar energy scientific society. Available at: <http://www.irses.ir>.
- Azeez, M. A. A. (2011). Artificial neural network estimation of global solar radiation using meteorological parameters in Gusau, Nigeria. *Archives of Applied Science Research*, 3, 586-95.
- Benli, H. (2013). "Determination of thermal performance calculation of two different types' solar air collectors with the use of artificial neural networks". *International Journal of Heat and Mass Transfer*. 60(1), 1-7.
- Cristianini, N., Shaw-Taylor, J. (2000). "An introduction to support vector machines and other kernel-based learning methods" Cambridge: Cambridge University Press
- Dibike, Y.B., Velickov, S., Solomatine, D., Abbott, M.B. (2001). Model Induction with support vector machines: Introduction and Application. *Computing in Civil Engineering*. 15(3): 208-216.
- Dogan, A., H. Demirpençe, and M. Cobaner. (2008). Prediction of Groundwater Levels From Lake Levels and Climate Data Using ANN Approach. *Water SA*, 34 (2), 199.
- El-Kassaby, M.M. (1988). Monthly and daily optimum tilt angle for south facing solar collectors; theoretical model- experimental and empirical correlations. *Solar and wind technology*. 5(6), 589-596.
- Fahad, A.A., D. Ibrahim, and H. Feridum. (2011). Exergy modeling of a new solar driven trigeneration System. *Solar Energy*, 85, 2228-2243.
- Hibbert, CH. B., Gillott, M., Kendall, M. (2009). An artificial neural network for predicting domestic hot water characteristics, *International Journal of Low-Carbon Technologies, Advance Access published*, 4(2), 112-119.
- Homayounifer, M., Adibian, M.S., GeorgiPour, M.J., Mohajeri, M. (2013). Solar Energy, Opportunities and Challenges. Second National Conference on New and Clean Energy, 10560. (In Farsi).
- Jamadi, F. (2016). Comparison of methods for determining the angle of gravity of solar collector plates. The first national conference on clean and fresh energy management. Hamedan. Hegmatane Environment Forum. Mofattah Shahid Faculty. (In Farsi)
- Karimzadeh, M., Mohajeri, M., Adibian, M. S., Georgypour, M. J. (2013). Evaluating the Economic Aspects of New Energy. Second National Conference on New and Clean Energy, 10560. (In Farsi)
- Lecoeuche, S., and T. S. Lalot. (2005). Prediction of the daily performance of solar collectors, *International Communications in Heat and Mass Transfer*, 32, 603-611.
- Maleki A., (2011). Energy Policy. Encyclopedia of Energy. Material and Energy Research Center. (In Farsi)
- Mellit, A. Massi Pavan, A. Benghanem, M. (2013). Least squares support vector machine for short-term *Theoretical and Applied Climatology*, 111 (1-2), 297-307.
- MirzaeeGhaleh, A. (2013). Development of a Solar Intelligent Solar System Based on Fuzzy Logic Controller for Heating Nesting Ph. D. University of Tehran. (In Farsi).
- Nadi, F., AbdananMahdizadeh, A., NouraniZenouz. (2017). Comparison of the predicted temperature of flat panel solder collector with experimental results: Computational Fluid Dynamics and Artificial Neural Network. *Agricultural Machinery Journal*, 7 (1), 298-311. (In Farsi)
- Pal, M., Deswal, S. (2008). "Modeling Pile Capacity Using Support Vector Machines and Generalized Regression Neural Network," *Journal of Geotechnical and Geoenvironmental Engineering, ASCE*. (134),1021-1024.
- Ramedani, Z., Omid, M., Keyhani, A., Shamsirband, SH. D., Khoshnevisan, B. (2014). "Potential of radial basis function based support vector regression for global solar radiation prediction". *Renewable and Sustainable Energy Reviews*. 39. 1005-1011
- Sedaghatkerdar, A. A. Fatahi, A. (2008). Drought Drought Indicators in Iran. *Journal of Geography and Development*, 11,59-76. (In Farsi)
- Vapnik, V. (1998). Statistical learning theory. John Wiley, New York.
- Vapnik, V.N., Chervonenkis, A.Y. (1971). "On the uniform convergence of relative frequencies of events to their probabilities," *Theory of Probability and its Applications*.16: 264-280.
- Zamani Mohayabadi, M. (2015). Instantaneous prediction of total solar radiation in Rafsanjan city by neural network. *Energy of iran*, 16 (3), 56-63. (In Farsi)
- Zanjani, M. (2011). Optimal Diffraction Forecast of Solar Panel Solar Collector with Artificial Intelligence Approach. Master's thesis of mechanical engineering. Razi University, Faculty of Engineering. (In Farsi)
- Zhai, R, R., Y. Zhu, Y. P. Yang, K. Y. Tan, and H. Eric. (2013). Exergetic and Parametric Study of a Solar Aided Coal-Fired Power Plant. *Entropy* 15, 1014-1034.