

Application of Artificial Neural Network Models (MLP and RBF) and Support Vector Machine (SVM) to Estimate the Shadow in Flat-plate Solar Collectors in Iran

MORTEZA TAKI¹, ROUHOLLAH FARHADI¹

1. Department of Agricultural Machinery and Mechanization, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Natural Resources University of Khuzestan, P.O. Box: 6341773637, Mollasani, Iran

*Corresponding author's Email: mtaki@asnrkh.ac.ir

(Received: Sep. 23, 2020- Revised: Jan. 11, 2021- Accepted: Jan. 16, 2021)

ABSTRACT

In this study, the amount of shadow in different types of flat-plate solar collectors according to the geographical conditions of Iran was estimated by using artificial neural network models (MLP and RBF) and Support Vector Machine (SVM). In this study, two types of LM and BR training algorithms with sigmoid tangent transfer function (TanSig) and different number of neurons in a hidden layer with k-fold cross validation method were used to create random datasets at each stage of modeling. The results showed that the MLP model with BR training algorithm and (5-23-1) structure, can create high-precision data similar to real values. The average MAPE and R^2 statistics for the above model were estimated to be 0.42 ± 0.10 and 0.99 ± 0.01 , respectively. Also, there was no significant difference between the actual data and the predicted values (95% probability) at mean, variance and distribution. The results of sensitivity analysis showed that the distance of the absorber plate and the glass cover is the most important factor influencing the formation of shadows.

Keywords: Artificial intelligence, k-fold cross validation model, Energy efficiency

کاربرد مدل‌های شبکه عصبی مصنوعی (MLP و RBF) و ماشین بردار پشتیبان (SVM) به منظور تخمین میزان سایه در جمع‌کننده‌های خورشیدی صفحه تخت در ایران

مرتضی تاکی^{*}، روح اله فرهادی^۱

۱. گروه مهندسی ماشین‌های کشاورزی و مکانیزاسیون، دانشکده مهندسی زراعی و عمران روستایی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، ملاثانی
(تاریخ دریافت: ۱۳۹۹/۷/۲ - تاریخ بازنگری: ۱۳۹۹/۱۰/۱۲ - تاریخ تصویب: ۱۳۹۹/۱۰/۲۷)

چکیده

در این تحقیق از مدل شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان به منظور تخمین میزان سایه در جمع‌کننده صفحه تخت خورشیدی با توجه به شرایط جغرافیایی ایران استفاده شد. دو نوع الگوریتم آموزش LM و BR همراه با تابع انتقال تانژانت سیگموئیدی و تعداد متنوعی از نورون‌ها در لایه پنهان همراه با مدل اعتبارسنجی تقاطعی به منظور ایجاد مجموعه داده‌های تصادفی مورد استفاده قرار گرفت. نتایج نشان داد که مدل MLP با الگوریتم آموزشی BR و ساختار (۵-۲۳-۱) می‌تواند داده‌هایی با دقت بالا و شبیه به مقادیر واقعی ایجاد کند. میانگین آماره‌های MAPE و R^2 برای مدل فوق به ترتیب ۰/۴۲±۰/۱۰ درصد و ۰/۹۹±۰/۰۱، برآورد شد و نتایج آماری مقایسه میانگین، واریانس و توزیع آماری در سطح احتمال ۹۵٪ بین داده‌های واقعی و مقادیر پیش‌بینی شده، معنی‌دار نبودند. نتایج آنالیز حساسیت نشان داد که فاصله صفحه جاذب تا پوشش شیشه‌ای مهم‌ترین فاکتور تاثیرگذار بر ایجاد سایه است.

واژه‌های کلیدی: هوش مصنوعی، مدل اعتبارسنجی تقاطعی، بازده انرژی

مقدمه

در زندگی مدرن انرژی نسبت به زندگی‌های سنتی، وابستگی به منابع انرژی شدت یافته است. به طوری که امروزه انسان‌ها برای اکثر فعالیت‌هایشان نیازمند صورت‌های مختلف انرژی هستند که عمدتاً از منابع فسیلی تامین می‌شوند (Jia et al., 2019). در این بین، به دلیل آلاینده‌های زیست محیطی و از طرفی منابع محدود فسیلی، تامین انرژی توسط منابع تجدیدپذیر مورد توجه قرار گرفته است (Elsheikh et al., 2019). از بین همه منابع انرژی‌های تجدیدپذیر موجود، انرژی گرمایی خورشیدی فراوان‌ترین و در دسترس‌ترین نوع انرژی محسوب شده (Roy et al., 2019) و از بین تمامی سیستم‌های گرمایی خورشیدی، گردآورنده‌های صفحه تخت در حال حاضر مهم‌ترین وسیله برای تبدیل انرژی خورشیدی به سایر شکل‌های مفید انرژی، به حساب می‌آیند که از جنبه‌های مختلف با مبدل‌های حرارتی معمولی متفاوتند (Al-Waeli et al., 2019). به دلیل کاربرد این نوع جمع‌کننده‌ها در صنعت، کشاورزی و مصارف خانگی، تحقیقات متنوعی در زمینه افزایش کارایی و بازده جمع‌کننده‌های خورشیدی صفحه تخت در سراسر دنیا انجام شده است. در جمع‌کننده‌های خورشیدی صفحه تخت برای کاهش تلفات ناشی

از جریان همرفتی هوا، به طور معمول از یک یا دو لایه پوشش شفاف روی صفحه جاذب استفاده می‌شود. این پوشش با فاصله‌ای از صفحه جاذب قرار می‌گیرد که افزایش این فاصله موجب کاهش تلفات همرفتی می‌گردد (Duffie and Beckman, 2013) اما از طرف دیگر باعث ایجاد سایه روی صفحه جاذب و کاهش جذب خورشید و در نهایت کاهش عملکرد می‌شود. در تحقیقی، این فاصله ۴ تا ۵ سانتی‌متر پیشنهاد شد (Nahar and Garg, 1980). در پژوهشی دیگر، برای مجموعه‌ای از جمع‌کننده‌های تخت در کنار هم قرار گرفته، تاثیر نسبت طول به عرض مجموعه بر میانگین نسبت سایه (مساحت سایه به مساحت کل) در روز بررسی شد و نتایج نشان داد، برای مساحت ۵۰ تا ۱۰۰۰ مترمربع هرچه مساحت مجموعه کوچکتر باشد، با افزایش نسبت طول به عرض، نسبت سایه سریع‌تر افزایش می‌یابد. برای عرض‌های جغرافیایی کم‌تر از ۳۰ درجه، میانگین نسبت سایه از ۰/۸۵ تجاوز نکرد در حالی که بیشینه مقدار متوسط نسبت سایه برای عرض‌های جغرافیایی نزدیک به ۴۰ درجه شمالی، به ۰/۱۴ رسید (Hu et al., 2013). در پژوهش دیگری، به منظور تعیین زاویه بهینه در آرایه‌ای از جمع‌کننده‌های خورشیدی با در نظر گرفتن سایه، مدلی ریاضی توسعه یافت و نتایج نشان داد که فاصله ردیفی

تحقیق شامل انواع ضرایب تلفات حرارتی جمع کننده و متغیر پیش‌بینی شده، دمای خروجی جمع کننده خورشیدی بود. نتایج نشان داد که مدل هوش مصنوعی با ترکیب فوق، قادر است با خطایی کم‌تر از ۱٪، دمای خروجی جمع کننده را به درستی تخمین بزند.

با توجه به مطالب فوق، هدف اصلی این تحقیق استفاده از دو مدل شبکه عصبی (MLP و RBF) و ماشین بردار پشتیبان (SVM) به منظور تخمین میزان سایه در جمع‌کننده‌های معمولی صفحه تخت در ایران است. در این تحقیق از الگوریتم‌های آموزشی متفاوت و همچنین مدل اعتبارسنجی تقاطعی (k-fold cross validation) به منظور افزایش دقت، صحت و قابلیت اعتمادپذیری نتایج همراه با محدوده متنوعی از ابعاد جمع‌کننده‌های صفحه تخت خورشیدی استفاده می‌شود. در صورت رضایت بخش بودن نتایج، می‌توان با توجه به هر عرض جغرافیایی، با تغییراتی اندک در ساختمان و طراحی جمع‌کننده صفحه تخت خورشیدی، میزان بازده نهایی آن را افزایش داد.

مواد و روش‌ها

جمع‌کننده‌های خورشیدی صفحه تخت کاربرد زیادی در گرم کردن هوا و آب برای مصارف کشاورزی، خانگی و صنعتی با استفاده از منبع پاک، رایگان، در دسترس و پایدار خورشید دارند (Dimri *et al.*, 2019). بیشترین اتلاف انرژی در این جمع‌کننده‌ها مربوط به افت گرمایی از بالاست. فاصله بین صفحه جاذب و پوشش، یکی از متغیرهای تاثیرگذار بر این افت است. هرچند روابط محاسبه افت از بالا در جمع‌کننده‌های خورشیدی صفحه تخت در پژوهش‌های گذشته ارائه شده است اما از آنجایی که تعدادی از متغیرهای موثر در آن تابعی از شرایط آب و هوایی هستند، توصیه‌ای برای مقدار مناسب فاصله بین صفحه جاذب و پوشش برای ایران وجود ندارد. در تحقیق گذشته (Farhadi and Taki, 2020)، میزان تشکیل سایه تحت تاثیر شرایط مختلف (طول و عرض جمع کننده، فاصله صفحه جاذب تا پوشش شیشه‌ای، عرض جغرافیایی و زاویه شیب جمع‌کننده) برای عرض‌های جغرافیایی مختلف توسط مدل ریاضی، بررسی شد. در این مطالعه حاضر، هدف تخمین میزان تشکیل سایه در جمع‌کننده‌های صفحه تخت با ابعاد مرسوم (طول و عرض ۲/۵-۱ متر) تحت تاثیر شرایط جغرافیایی ایران توسط مدل‌های هوش مصنوعی است. سرعت و دقت بالا و عدم نیاز به محاسبات پیچیده ریاضی از دلایل بکارگیری هوش مصنوعی در حل این مسئله است.

داده‌های مورد نیاز در این تحقیق از مطالعه (Farhadi and

دو جمع‌کننده تاثیر قابل ملاحظه‌ای روی جذب تابش سالانه دارد. همچنین نسبت ارتفاع عمودی جمع‌کننده به فاصله دو ردیف مجاور بیشتر از (۲۳/۴۵ + عرض جغرافیایی محل) \tan توصیه شد (Tang and Liu, 2012). در تحقیق دیگری، مهمترین عوامل تشکیل سایه در جمع‌کننده‌های صفحه تخت مورد بررسی قرار گرفتند (Farhadi and Taki, 2020). نتایج نشان داد که فاصله مناسب بین صفحه جاذب تا پوشش برای ایران در محدوده میانگین متغیرها، ۲۵ میلی‌متر است و دامنه آن ۱۲ تا ۳۸ میلی‌متر با توجه به شرایط مختلف آب و هوایی قابل تغییر است. پژوهش‌های مشابهی نیز برای سایه در آرایه‌های سلول‌های خورشیدی (photovoltaic) انجام گرفته است (Batzelis *et al.*, 2015). بررسی منابع موجود نشان می‌دهد که اکثر مطالعات مربوط به بررسی کارایی و شرایط جمع‌کننده‌های خورشیدی، توسط مدل‌های ریاضی یا تحقیقات تجربی صورت گرفته است. با توسعه هوش مصنوعی، تحقیقات مختلفی در زمینه افزایش دقت مدل‌های ریاضی در مطالعات مربوط به انواع سیستم‌های خورشیدی شامل انواع جمع‌کننده‌های خورشیدی (تخت و لوله خلاء)، آب‌گرم‌کن‌های خورشیدی، اجاق پزهای خورشیدی، گلخانه‌های خورشیدی و... صورت گرفته است. در تحقیقی از شبکه‌های عصبی مصنوعی به منظور مدل‌سازی عملکرد حرارتی جمع‌کننده‌های سهموی خطی استفاده شد (Heng *et al.*, 2019). نتایج نشان داد که مدل شبکه عصبی مصنوعی (Artificial Neural Network) یا ANN قادر به تخمین عملکرد حرارتی با خطای کمتر از ۲٪ و در زمان کمتر از ۱ دقیقه است. در تحقیق دیگری، از دو مدل شبکه عصبی Multilayer Neural Network و Radial Basis Function یا (MLP و RBF) و ماشین بردار پشتیبان (Machine Support Vector) یا (SVM) به منظور بررسی جریان انرژی و تخمین شرایط محیطی داخل گلخانه گنبدی پلاستیکی استفاده شد (Taki *et al.*, 2018a). نتایج نشان داد که مدل RBF کمترین میزان خطا را بین دو مدل دیگر دارد و قادر است حتی با مجموعه‌های کوچک داده نیز نتایج قابل اعتماد فراهم کند. در تحقیق دیگری از مدل ANN به منظور بررسی عملکرد یک دودکش خورشیدی استفاده شد (Loni *et al.*, 2018). نتایج نشان داد که مدل هوش مصنوعی قادر است مقادیر بازده حرارتی و انرژی دریافتی این سیستم خورشیدی را با صحت بالا (به ترتیب با $R^2=0.9567$ و $R^2=0.9709$)، تخمین بزند. در زمینه جمع‌کننده‌های صفحه تخت نیز تحقیقات متنوعی صورت گرفته است. در تحقیقی از مدل ANN به منظور تخمین میزان بازده روزانه یک جمع‌کننده صفحه تخت استفاده شد (Lalot and Lecoeuche, 2005). متغیرهای ورودی در این

و لایه خروجی (مساحت سایه تشکیل شده در جمع کننده در طول یکسال) تشکیل شده است. شبکه MLP با دریافت بردار ورودی، بردار خروجی تولید خواهد کرد. هدف، اتخاذ پارامترهای صحیح شبکه به منظور دستیابی به کمترین خطای پیش‌بینی است (Taki et al., 2018b).

(Taki, 2020) استخراج شد (جدول ۱). در این مطالعه از دو نوع مدل شبکه عصبی (MLP و RBF) و همچنین مدل رگرسیون بردار پشتیبان (SVM) استفاده می‌شود. در این تحقیق، شبکه عصبی مصنوعی پرسپترون چندلایه (MLP)، از لایه‌ی ورودی (طول و عرض جمع کننده، فاصله صفحه جاذب تا پوشش شیشه‌ای، عرض جغرافیایی و زاویه شیب جمع کننده)، لایه مخفی

جدول ۱- مشخصات آماری داده‌های بکار رفته در تحقیق حاضر (برگرفته از تحقیق Farhadi and Taki, 2020)

چولگی	کشیدگی	بیشینه	کمینه	انحراف معیار	میانگین	ابعاد جمع کننده بر حسب متر (طول×عرض)
۰/۴۱	-۰/۱۶	۲۵۹۹/۶۸	۵۰/۲۶	۴۵۰/۲۰	۷۷۷/۱۰	طول: ۱-۲/۵ عرض: ۱-۲/۵

$$Y = W^T \Phi = \sum_{j=1}^{L_2} w_{ij} \phi(\|x - c_i\|) \quad (\text{رابطه ۱})$$

که در آن، w بردار وزن اتصالات بین لایه مخفی و خروجی، L_2 تعداد نورون‌ها در لایه مخفی، c مرکز نورون‌ها در لایه مخفی و Φ تابع گوسین می‌باشد. مقدار (Φ) نیز از رابطه (۲) قابل محاسبه است (Dimri et al., 2019):

$$\phi_i(x) = \exp\left(-\frac{\|x - c_i\|^2}{\sigma_i^2}\right) \quad (\text{رابطه ۲})$$

که در آن، σ پارامتر توزیع (Spread parameter) است. در این تحقیق به منظور افزایش میزان دقت از مدل ماشین بردار پشتیبان (Support Vector Machine) SVM نیز در کنار مدل‌های شبکه عصبی مصنوعی استفاده شد. بیان ریاضی رگرسیون بردار پشتیبانی (SVR) با مجموع داده‌ها شروع می‌شود (Al-Waeli et al., 2019):

$$s = \{(x_1, y_1), \dots, (x_n, y_n)\} \quad (\text{رابطه ۳})$$

که در (x_i, y_i) ، $x_i \in R^d$ و $y_i \in R$ هر y_i مقدار مطلوب خروجی برای بردار ورودی x_i است. مدل رگرسیون از این الگوها آموزش دیده و برای پیش‌بینی مقدار مطلوب هدف از بردار ورودی‌های از قبل دیده نشده، استفاده می‌کند.

در بسیاری از مسائل ارتباط بین مؤلفه‌های خروجی و ورودی غیر خطی است؛ در نتیجه به منظور انجام انتقال، به توابع کرنل (Kernel) نیاز است. ایده تابع کرنل فراهم نمودن امکان انجام عملیات در فضای ورودی به جای فضای ویژگی چند بعدی است (Dimri et al., 2019). در این پژوهش از تابع شعاعی پایه (RBF) که یکی از تابع کرنل‌هایی است که به طور گسترده در مسائل خطی و غیرخطی استفاده شده است و به صورت رابطه زیر تعریف می‌شود، استفاده شد (Çakmak et al., 2011):

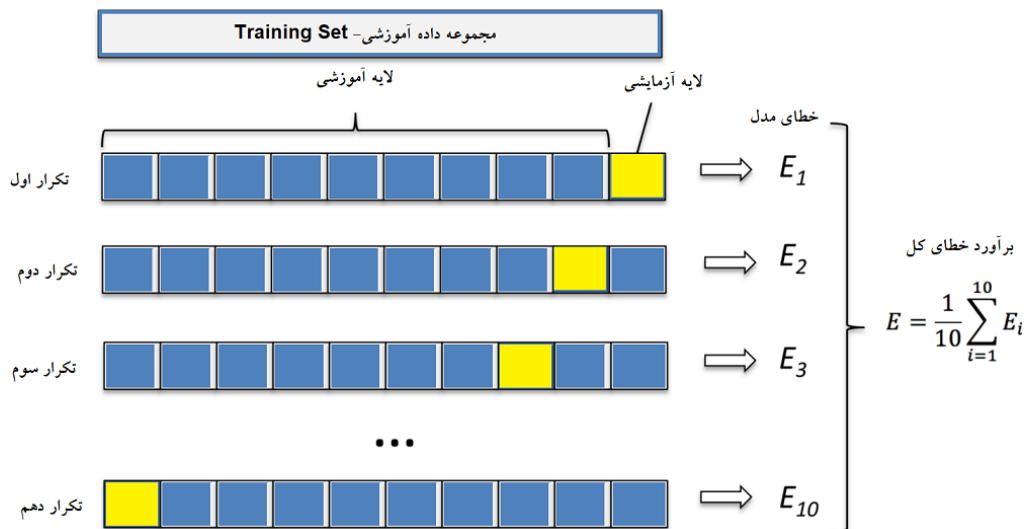
قبل از به‌کارگیری داده‌های خام اولیه، باید عمل نرمال-سازی داده‌ها انجام شود تا همگرایی شبکه تضمین شود. زمانی که از تابع تانژانت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها $[-1, +1]$ می‌باشد (Rohani et al., 2018). در این مطالعه از دو الگوریتم آموزش بایاس پس‌انتشار خطا (Bayesian regulation backpropagation or Trainbr) و لونبرگ ماکوارت پس‌انتشار خطا (Levenberg-Marquardt or Trainlm) استفاده شد. تعداد نورون‌های هر شبکه تا زمانی که نتایج رو به بهبودی میل می‌کند افزایش داده شد و پس از افزایش خطا، ثابت در نظر گرفته شد.

در این پژوهش از شبکه عصبی (RBF Radial Bias Function) نیز به منظور تخمین مساحت سایه در جمع کننده خورشیدی صفحه تخت استفاده شد. RBF مانند سایر شبکه‌های عصبی قادر به یادگیری رابطه بین متغیر وابسته و متغیرهای مستقل از روی مثال‌های مختلف از مجموعه داده‌های موجود می‌باشد. RBF تنها از یک لایه مخفی با تعدادی از نورون تشکیل شده است. در لایه ورودی، متغیرهای مستقل به شبکه داده می‌شود. در لایه مخفی، نورون‌ها، محاسباتی را روی مجموعه متغیرهای ورودی به‌منظور رسیدن به خروجی مطلوب انجام می‌دهند. در صورتی که شبکه RBF از تعداد کافی نورون برخوردار باشد، قادر به تخمین هر تابع پیچیده با هر دقت مورد نیاز است. RBF یک نوع شبکه عصبی با ناظر است. هر نورون در لایه مخفی بر اساس یک تابع فعال‌ساز غیرخطی (Φ) عمل می‌کند. وجود عامل بایاس به همگرا شدن شبکه عصبی RBF در طول مرحله آموزش و رسیدن به کمینه عمومی کمک می‌کند. خروجی شبکه عصبی RBF برای هر بردار ورودی x مطابق رابطه (۱) قابل محاسبه است (Dimri et al., 2019):

گوسی RBF استفاده شد و بهترین آنها مورد انتخاب قرار گرفت. در این تحقیق، به منظور افزایش اعتماد به خروجی شبکه عصبی از روش اعتبارسنجی تقاطعی (k-fold cross validation) استفاده شد (شکل ۱).

$$K_R(x, x) = e^{-\gamma \|x-x\|^2}, \quad \gamma > 0 \quad (\text{رابطه ۴})$$

که در آن C پارامتر عرض کرنل است. برای رسیدن به عملکرد مطلوب SVM، در این تحقیق از چهار نوع تابع هسته‌ای شامل توابع خطی، چند جمله‌ای درجه دوم و سوم و نیز تابع



شکل ۱- ساختار روش اعتبارسنجی تقاطعی

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_a - y_p)^2}{n}} \quad (\text{رابطه ۶})$$

$$EF = 1 - \frac{\sum_{i=1}^n (y_a - y_p)^2}{\sum_{i=1}^n (y_a - \bar{y}_p)^2} \quad (\text{رابطه ۷})$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_a - y_p)^2}{\sum_{i=1}^n (y_a - \bar{y}_a)^2} \quad (\text{رابطه ۸})$$

که در آن، y_a و y_p مقادیر واقعی و پیش بینی شده مدل \bar{y}_p و \bar{y}_a مقادیر میانگین آن‌ها هستند. بهترین عملکرد مدل‌ها زمانی بدست می‌آید که معیارهای خطا شامل (MAPE and RMSE) حداقل و معیارهای عملکردی شامل (EF and R^2) حداکثر و نزدیک به یک باشد. علاوه بر این موارد، برای ارزیابی توافق بین مقادیر واقعی و پیش بینی شده از خط رگرسیونی ($y_a = a + by_p$) بین آن‌ها نیز استفاده شد. بر اساس این معیار، بهترین حالت زمانی است که شیب خط نزدیک به یک ($b \cong 1$) و عرض از مبدا ($a \cong 0$) آن نیز نزدیک به صفر باشد (Taki et al., 2018a). به منظور تحلیل روش شبکه عصبی در این تحقیق،

در این روش، داده‌های بخش اعتبارسنجی بسته به نوع و تعداد آن‌ها به k دسته مختلف تقسیم می‌شوند و با هر الگوریتم، مورد بررسی قرار می‌گیرند. در واقع، در این نوع اعتبارسنجی، داده‌ها به k زیرمجموعه افزاز می‌شوند. از این k زیرمجموعه، هر بار یکی برای اعتبارسنجی و k-1 تای دیگر برای آموزش به کار می‌روند. این روال، k بار تکرار می‌شود و همه داده‌ها دقیقاً یک بار برای آموزش و یک بار برای اعتبارسنجی به کار می‌روند. در نهایت میانگین نتیجه این k بار اعتبارسنجی به عنوان یک تخمین نهایی برگزیده می‌شود (Taki et al., 2018b). مزیت استفاده از زیرمجموعه‌سازی تصادفی داده‌ها در این روش، تأثیر نحوه توزیع داده‌ها بر فرآیند مدل‌سازی است و باعث می‌شود که شبکه عصبی در حالت عادی به عنوان یک روش کاربردی با نتایج قابل قبول مورد استفاده قرار گیرد (Rohani et al., 2018).

برای ارزیابی کیفیت مدل‌ها و مقایسه آن‌ها با یکدیگر از شاخص‌های عملکردی متوسط درصد قدرمطلق خطا (MAPE)، متوسط ریشه مربعات خطا (RMSE)، بازده مدل (EF) و ضریب تبیین بین مقادیر واقعی و پیش بینی شده (R^2) استفاده شد.


$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_a - y_p}{y_a} \right| \times 100 \quad (\text{رابطه ۵})$$

از نرم افزار MATLAB نسخه ۲۰۱۸ استفاده شد.

نتایج و بحث

شکل ۲ مقادیر میانگین و انحراف معیار مدل MLP به ازای مقادیر مختلف تعداد نورون‌ها در لایه مخفی برای مراحل آموزش و آزمون شبکه با مجموعه داده‌های ساخته شده توسط مدل k-fold را نشان می‌دهد. همانطور که نتایج نشان می‌دهد، با افزایش تعداد نورون‌ها در لایه مخفی میزان خطای مدل MLP با الگوریتم BR روند نزولی دارد. این روند تا نورون ۲۳ نزولی است و پس از آن

تقریباً ثابت می‌ماند. در مقابل با الگوریتم LM در مراحل آزمایش و آزمون با روند خاصی روبرو نبوده و کمترین میزان خطا در نورون شماره ۲۰ اتفاق افتاده است. بنابراین نتایج این شکل نشان می‌دهد که در کل، دقت الگوریتم آموزشی BR بسیار بهتر از الگوریتم LM است (حدود ۱۴ برابر). نکته دیگر که از نتایج شکل ۲ بر می‌آید آن است که مقدار انحراف معیار به ازای تکرارهای مختلف، مخالف صفر است (در الگوریتم LM مقدار انحراف معیار در هر تکرار بیشتر از الگوریتم BR می‌باشد)؛ بنابراین، نوع مجموعه آموزش بر عملکرد شبکه تاثیر گذار است.



شکل ۲- دقت مدل MLP با تغییر تعداد نورون‌ها در لایه پنهان با دو الگوریتم آموزشی LM و BR در مراحل آموزش و آزمون (الف و ب)

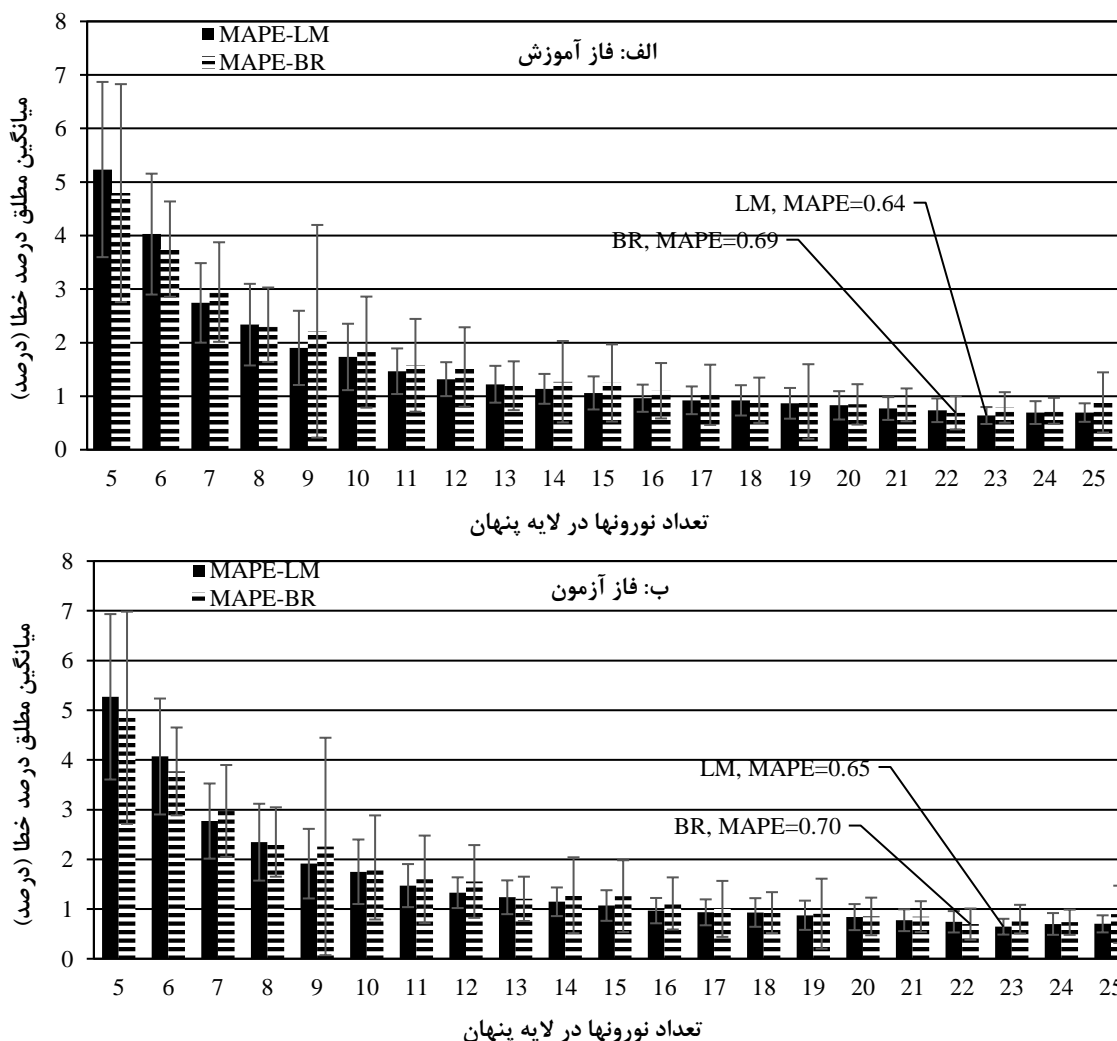
اطمینان بیشتر در عمل از آن استفاده کرد. مشابه با قسمت قبل، برای مدل RBF نیز با توجه به روش اعتبارسنجی تقاطعی، مجموعه‌ای از داده‌ها تشکیل شد. از الگوریتم‌های آموزشی مختلف (LM و BR) و تابع انتقال تانژانت سیگموئید برای آموزش شبکه RBF با یک لایه پنهان و تعداد مختلفی از نورون‌ها در لایه پنهان (از ۵ تا ۲۵) استفاده شد. شکل ۳ نتایج مربوط به مدل RBF با نورون‌های مختلف در لایه پنهان با استفاده از آماره میانگین مطلق درصد خطا را نشان می‌دهد.

با توجه به نتایج شکل ۲، می‌توند دریافت که الگوریتم BR در مدل MLP از دقت بیشتری برخوردار است. جدول ۲ به مقایسه پارامترهای آماری بهترین توپولوژی‌ها در مدل MLP با توجه به الگوریتم‌های آموزشی و نتایج حاصل از مدل k-fold می‌پردازد. همانطور که نتایج این جدول نشان می‌دهد، برای مدل MLP، توپولوژی ۱-۲۳-۵ (۵ نورون در لایه ورودی، ۲۳ نورون در لایه پنهان و یک نورون در لایه خروجی) همراه با الگوریتم آموزشی BR به عنوان بهترین ساختار شناخته می‌شود. این مدل علاوه بر دقت بالا، از انحراف معیار کمتری نیز برخوردار است و می‌توان با

جدول ۲- انتخاب بهترین توپولوژی با توجه به الگوریتم‌های آموزشی و نتایج پارامترهای آماری توسط آنالیزهای متعدد با مدل MLP توسط مجموعه داده‌های مدل k-fold (میانگین مراحل آموزش و آزمون)

مدل و الگوریتم آموزش	توپولوژی	پارامترهای آماری			
		R^2 (-)	EF (-)	RMSE (-)	MAPE (%)
$\bar{x} \pm SD$		$\bar{x} \pm SD$	$\bar{x} \pm SD$	$\bar{x} \pm SD$	$\bar{x} \pm SD$
MLP-LM	۵-۲۰-۱	۰/۹۹±۰/۰۱	۰/۹۹±۰/۰۱	۳۳/۰۴±۶/۳۷	۶/۰۳±۱/۳۳
MLP-BR	۵-۲۳-۱	۰/۹۹±۰/۰۱	۰/۹۹±۰/۰۱	۲/۲۲±۰/۴۸	۰/۴۲±۰/۱۰

MAPE: میانگین مطلق درصد خطا، RMSE: ریشه میانگین مربعات خطا، EF: فاکتور کارایی، R^2 : ضریب تبیین



شکل ۳- دقت مدل RBF با تغییر تعداد نورون‌ها در لایه پنهان با دو الگوریتم آموزشی LM و BR در مراحل آموزش و آزمون (الف و ب)

تاکنون، می‌توان به این نتیجه رسید که همچنان میزان خطا در بهترین ساختار مدل RBF (مدل RBF با الگوریتم LM و توپولوژی ۵-۲۳-۱) بیش از ۱/۵ برابر مقدار مشابه در بهترین ساختار مدل MLP (مدل MLP با الگوریتم آموزش BR و توپولوژی ۵-۲۳-۱) است.

همان‌طور که نتایج شکل ۳ نشان می‌دهد، الگوریتم آموزشی LM با اختلاف بسیار کم (۰/۰۵ درصد در MAPE) بیشترین میزان دقت در تولید داده‌های پیش‌بینی شده را دارد. طبق نتایج جدول ۳، مدل RBF با الگوریتم آموزشی LM و ساختار ۵-۲۳-۱ بیشترین میزان دقت و کمترین میزان خطا را در بین سایر ساختارها دارد. با مقایسه بین مدل‌های RBF و MLP

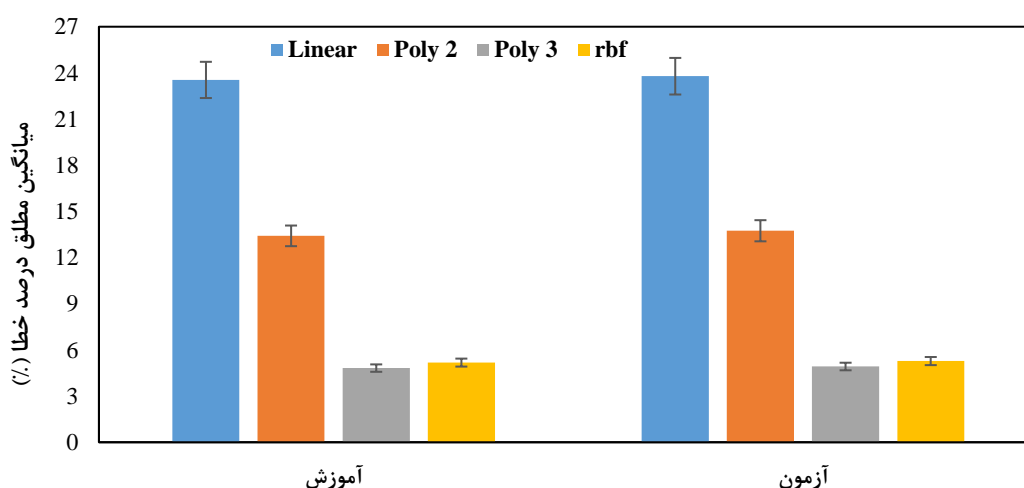
جدول ۳- انتخاب بهترین توپولوژی با توجه به الگوریتم‌های آموزشی و نتایج پارامترهای آماری توسط آنالیزهای متعدد با مدل RBF (میانگین مراحل آموزش و آزمون)

پارامترهای آماری				توپولوژی	مدل و الگوریتم آموزش
R ² (-) $\bar{x} \pm SD$	EF (-) $\bar{x} \pm SD$	RMSE (-) $\bar{x} \pm SD$	MAPE (%) $\bar{x} \pm SD$		
۰/۹۹±۰/۰۱	۰/۹۹±۰/۰۱	۳/۷۱±۰/۹۶	۰/۶۴±۰/۱۶	۵-۲۳-۱	RBF-LM
۰/۹۹±۰/۰۱	۰/۹۹±۰/۰۱	۳/۸۰±۱/۸۱	۰/۶۹±۰/۳۱	۵-۲۲-۱	RBF-BR

MAPE: میانگین مطلق درصد خطا، RMSE: ریشه میانگین مربعات خطا، EF: فاکتور کارایی، R²: ضریب تبیین

بررسی قرار گرفت (شکل ۴). نتایج شکل ۴ نشان می‌دهد که از بین تمامی توابع هسته‌ای انتخاب شده، تابع درجه سوم، دارای کم‌ترین میزان خطا و بیشترین میزان دقت است. لذا در این مرحله، نتایج حاصل از مدل SVM با تابع هسته‌ای درجه سوم، بعنوان بهترین نتیجه از مدل SVM در نظر گرفته می‌شود.

پس از مدل‌های MLP و RBF، صدر این مرحله مدل SVM با داده‌هایی مشابه، مورد بررسی قرار می‌گیرد. در این مطالعه از چهار نوع تابع هسته‌ای (خطی، درجه دوم، درجه سوم و RBF) بعنوان تابع فعال مدل SVM استفاده شد. در این مرحله نیز با توجه به روش اعتبارسنجی تقاطعی، تعداد ۱۰۰ مجموعه داده تصادفی ساخته شد و مدل SVM با توابع مختلف هسته‌ای مورد



شکل ۴- تغییرات دقت مدل SVM با تغییر نوع توابع هسته‌ای در مراحل آموزش و آزمون با استفاده از آمار MAPE

میزان کارایی و کمترین میزان خطا، بهترین مجموعه از ۱۰۰ مجموعه ساخته شده توسط مدل k-fold است. لذا این مجموعه داده دوباره مورد بررسی قرار گرفت و نتایج ثبت گردید.

جدول ۵ برخی از ویژگی‌های آماری داده‌های استفاده شده در مراحل آموزش، آزمون و مجموع را همراه با مقادیر پیش‌بینی شده توسط مجموعه داده شماره ۶۱ام در مدل MLP نشان می‌دهد. همانطور که نتایج نشان می‌دهند، اختلاف بسیار ناچیزی بین مقادیر کمینه، بیشینه، میانگین، واریانس و مجموع داده‌ها وجود دارد که در عمل بسیار جزئی هستند. به منظور بررسی بیشتر از آزمون‌های آماری موجود در این زمینه استفاده شد. در این مرحله، میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش‌بینی شده توسط مدل MLP، در مراحل مختلف آموزش، آزمون و مجموع مورد بررسی قرار گرفت. در این قسمت، فرضیه

به منظور انتخاب بهترین مدل از بین MLP، RBF و SVM، بهترین نتایج هریک از مدل‌ها در قسمت‌های قبل همراه با مجموعه‌ای کامل از پارامترهای ارزیابی کارایی شبکه، در جدول ۴ خلاصه شده است. همانطور که نتایج این جدول نشان می‌دهد، مدل MLP با الگوریتم آموزشی BR و توپولوژی (۵-۲۳-۱) دارای کمترین میزان خطا و بیشترین میزان دقت است. لذا این مدل از بین بقیه، برای ارزیابی‌های بعدی و نگاه دقیق‌تر همراه با آنالیزهای آماری بیشتر انتخاب می‌شود.

در این قسمت به منظور انتخاب بهترین مجموعه داده‌های تصادفی و عبارتی بهترین نتایج مدل MLP با الگوریتم BR و توپولوژی (۵-۲۳-۱) از بین ۱۰۰ مجموعه‌ای که مدل k-fold برای هر آنالیز آماری ساخته است، از دستور gname در محیط متلب استفاده شد. نتیجه نشان داد که مجموعه ۶۱ام با بیشترین

میانگین، واریانس و توزیع آماری، از آزمون‌های F ، t و کولموگروف-اسمیرنو استفاده شد. مقادیر p محاسبه شده برای هر سه مرحله (آموزش، آزمون و مجموع) در جدول ۶ نشان داده شده است. نتایج این جدول نشان می‌دهد که مقادیر میانگین، واریانس و توزیع آماری داده‌های حاصل از MLP با مقادیر واقعی آن، اختلاف معنی‌دار ندارند و لذا این مدل می‌تواند با قابلیت اعتماد بالا مورد استفاده قرار گیرد.

صفر بر تساوی میانگین، واریانس و توزیع آماری هر دو سری داده دلالت دارد:

(رابطه ۹)

$$\left\{ \begin{array}{l} H_0: \bar{y}_a = \bar{y}_p \\ H_1: \bar{y}_a \neq \bar{y}_p \end{array} \right\} \text{ and } \left\{ \begin{array}{l} H_0: \sigma_{y_a}^2 = \sigma_{y_p}^2 \\ H_1: \sigma_{y_a}^2 \neq \sigma_{y_p}^2 \end{array} \right\} \text{ and } \left\{ \begin{array}{l} H_0: d_a = d_p \\ H_1: d_a \neq d_p \end{array} \right\}$$

هر فرضیه در سطح احتمال ۹۵ درصد به کمک پارامتر p آزمون شد. بنابراین اگر p محاسبه شده برای هر مرحله بیشتر از ۰/۰۵ باشد، فرضیه صفر را نمی‌توان رد کرد. برای مقایسه

جدول ۴- انتخاب بهترین مدل همراه با الگوریتم آموزش از بین مدل‌های MLP، RBF و SVM بر اساس پارامترهای آماری و انجام آنالیزهای متعدد توسط مجموعه داده‌های مدل k-fold (میانگین مراحل آموزش و آزمون)

مدل	توپولوژی	پارامترهای آماری		
		MAPE (%) $\bar{x} \pm SD$	RMSE (-) $\bar{x} \pm SD$	EF (-) $\bar{x} \pm SD$
MLP-BR	۵-۲۳-۱	۰/۴۲±۰/۱۰	۲/۲۲±۰/۴۸	۰/۹۹±۰/۰۱
RBF-LM	۵-۲۳-۱	۰/۶۴±۰/۱۶	۳/۷۱±۰/۹۶	۰/۹۹±۰/۰۱
SVM-Poly2	-	۴/۸۷±۰/۲۴	۲۳/۹۲±۰/۶۹	۰/۹۹±۰/۰۴

MAPE: میانگین مطلق درصد خطا، RMSE: ریشه میانگین مربعات خطا، EF: فاکتور کارایی، R^2 : ضریب تبیین

جدول ۵- ویژگی‌های آماری مقادیر داده‌های واقعی و پیش‌بینی شده توسط بهترین ارزیابی مدل MLP (مجموعه داده شماره ۱۶۱)

مدل و مرحله	میانگین	انحراف معیار	کمینه	بیشینه	کشیدگی	چولگی	مجموع
MLP-BR مقدار واقعی	۷۷۰/۶۳	۴۴۶/۰۷	۵۰/۲۶	۲۵۹۹/۶۸	۲/۸۸	۰/۴۴	۱۲۴۳۰۲۷/۹۳
آموزش مقدار پیش‌بینی شده	۷۷۰/۶۳	۴۴۶/۰۷	۴۸/۰۶	۲۶۱۱/۹۶	۲/۸۸	۰/۴۴	۱۲۴۳۰۲۹/۲۷
MLP-BR مقدار واقعی	۷۸۱/۴۱	۴۵۲/۹۸	۵۳/۸۵	۲۴۷۱/۲۸	۲/۸۱	۰/۴۰	۱۸۹۰۲۰۷/۱۳
آزمون مقدار پیش‌بینی شده	۷۸۱/۴۰	۴۵۲/۹۸	۴۹/۳۰	۲۴۷۵/۶۴	۲/۸۱	۰/۴۰	۱۸۹۰۲۰۷/۲۱
MLP-BR مقدار واقعی	۷۷۷/۱۰	۴۵۰/۲۰	۵۰/۲۶	۲۵۹۹/۶۸	۲/۸۴	۰/۴۲	۳۱۳۳۲۶۲/۰۶
کل مقدار پیش‌بینی شده	۷۷۷/۰۹	۴۵۰/۲۰	۴۸/۰۶	۲۶۱۱/۹۶	۲/۸۴	۰/۴۲	۳۱۳۳۲۳۶/۴۸

جدول ۶- مقایسه آماری مقادیر واقعی و پیش‌بینی شده از مجموعه داده شماره ۱۶۱


مدل و مرحله	نوع تحلیل آماری		
	مقایسه میانگین	مقایسه واریانس	مقایسه توزیع
MLP-BR آموزش	۰/۹۹	۰/۹۷	۰/۹۹
MLP-BR آزمون	۱/۰۰	۰/۹۹	۱/۰۰
MLP-BR کل	۰/۹۹	۰/۹۸	۰/۹۹

شکل ۵، به بیان همگرایی بهترین ارزیابی مدل MLP در این تحقیق می‌پردازد. همانطور که نتایج نشان می‌دهند، مدل مورد مطالعه در ایپاک ۴۱۸ به بهترین یا بعبارتی کم‌ترین میزان خطا در مجموع مراحل آموزش، آزمون و ارزیابی رسیده است.

شکل ۶، میزان خطا در بهترین ارزیابی مدل MLP (قسمت الف) و همبستگی بین داده‌های واقعی و پیش‌بینی شده توسط این مدل (قسمت ب) را نشان می‌دهد. بهترین نتایج هنگامی حاصل می‌شوند که معادله خطی مابین مقادیر واقعی و پیش‌بینی شده

مختلف، با کمترین میزان عرض از مبدا و شیب نزدیک به یک برخوردار است. لذا این مدل به راحتی توانایی تبدیل شدن به بهترین مدل پیش‌بینی کننده برای مجموع سایه تشکیل شده در جمع‌کننده‌های صفحه تخت برای عرض جغرافیایی ایران را دارد.

توسط مدل MLP، علاوه بر داشتن بالاترین ضریب تبیین، کمترین میزان عرض از مبدا (نزدیک به صفر) و شیب نزدیک به یک باشد ($pv=1.00dv+0$). همانطور که قسمت ب از شکل ۶ نشان می‌دهد، مدل MLP علاوه بر داشتن ضریب تبیین بالا در مراحل آموزش و آزمون، از رابطه‌های رگرسیونی در مراحل



شکل ۵- نمودار همگرایی بهترین ارزیابی مدل MLP

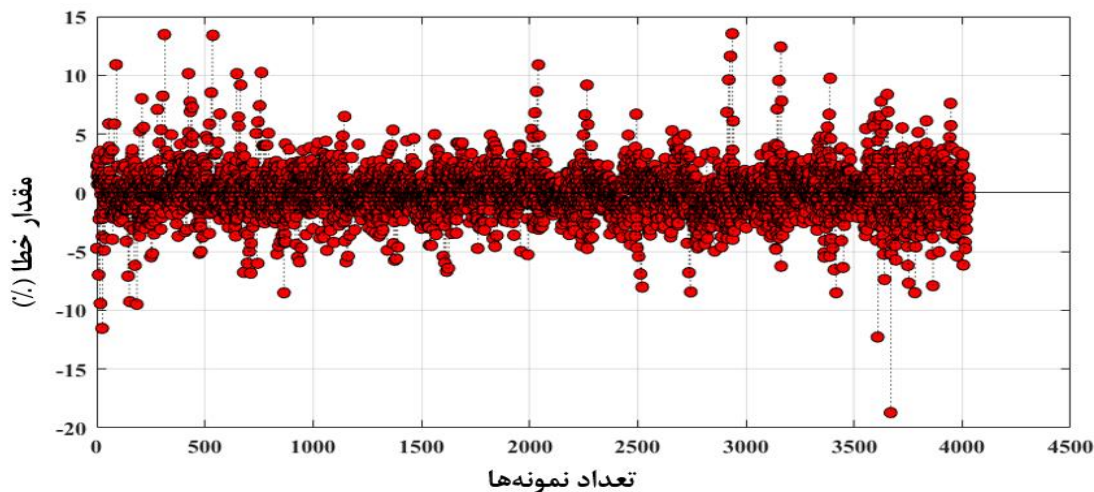
کود تولید شده را هم با دقت بالا برای هر دوره استفاده، پیش‌بینی کند. علاوه بر موارد فوق در تحقیقات دیگری نیز به موفقیت آمیز بودن استفاده از هوش مصنوعی در جنبه‌های مختلف علوم و مهندسی اشاره شده است (Blaga *et al.*, 2019; Hamdan *et al.*, 2016; Kalani *et al.*, 2017). بر طبق نتایج بدست آمده از جدول ۴ در این مطالعه، می‌توان دریافت که دقت مدل MLP نهایی در این پژوهش بسیار بیشتر از مقادیری است که در فوق به آن‌ها اشاره شده است (MAPE=0.419%).

در نهایت آنالیز حساسیت هر یک از ورودی‌های مدل نهایی شده (MLP) در برابر میزان تغییرات ضریب تبیین خروجی مدل، مورد بررسی قرار گرفت (شکل ۷). نتایج نشان داد که بیشترین سهم از تغییرات خروجی در اثر تغییر میزان فاصله شیشه تا صفحه جاذب جمع‌کننده (۵۴/۶۰ درصد) ایجاد می‌شود و پس از آن عرض جمع‌کننده (۳۰ درصد) و زاویه شیب جمع‌کننده (۱۹/۴۰ درصد) به ترتیب بیشترین تغییرات در خروجی مدل را باعث می‌شوند. نتایج آنالیز حساسیت در این تحقیق به خوبی اثر تغییرات میزان فاصله شیشه تا صفحه جاذب بر تشکیل سایه و افت انرژی در جمع‌کننده‌های خورشیدی صفحه تخت را نشان داد. بنابراین می‌توان نتیجه گرفت که بهینه‌سازی این متغیر با توجه به شرایط آب و هوایی منطقه مورد استفاده می‌تواند منجر

تاکنون تحقیقات زیادی در مورد استفاده از هوش مصنوعی و شبکه عصبی به منظور پیش‌بینی خروجی‌های سیستم‌های مختلف خورشیدی (جمع‌کننده‌ها، سلول‌های خورشیدی، برج‌های هلیوستات، جمع‌کننده‌های ناودانی سهموی، گلخانه‌ها و خشک‌کن‌های خورشیدی و ...) صورت گرفته است (Dimri *et al.*, 2019) ولی تحقیقی مشابه با مطالعه حاضر ملاحظه نشده است. مثلاً در تحقیقی از شبکه‌های عصبی مصنوعی به منظور تخمین عملکرد حرارتی یک نوع اجاق خورشیدی استفاده شد (Ghritlahre and Prasad, 2018). نتایج نشان داد که مدل شبکه عصبی توسعه داده شده قادر است با دقتی کمتر از ۳٪ عملکرد حرارتی اجاق خورشیدی را بصورت ساعتی تخمین بزند. در تحقیق دیگری از هوش مصنوعی به منظور تخمین عملکرد یک جمع‌کننده سهموی شکل استفاده شد (Heng *et al.*, 2019). نتایج نشان داد که مدل توسعه داده شده علاوه بر دقت بالا از سرعت قابل قبولی برخوردار است و می‌تواند به‌عنوان ابزاری به منظور کنترل اتوماتیک سامانه مد نظر مورد استفاده قرار گیرد. در تحقیق دیگری از یک مدل توسعه داده شده RBF به منظور پیش‌بینی عملکرد سالن مرغ تخم‌گذار استفاده شد (Amini *et al.*, 2020). نتایج نشان داد که مدل مورد استفاده قادر است با خطای کمتر از ۲٪ علاوه بر تخمین میزان گوشت مصرفی، میزان


تشکیل سایه در جمع کننده خورشیدی صفحه تخت پرداخته شد بود (Farhadi and Taki, 2020).

به کاهش تلفات انرژی شود. نتایج آنالیز حساسیت با مدل شبکه عصبی همراستا با نتایج آنالیز حساسیت با مدل ریاضی است که در آن دقیقاً با استفاده از همین نهاده‌های ورودی به بررسی میزان




(الف)

Test: R=0.99



(ب)

شکل ۶- میزان خطای کل در پیش‌بینی نتایج توسط مدل MLP، ب: مقایسه مقادیر واقعی و پیش‌بینی شده توسط مدل MLP در مرحله آزمون



شکل ۷- آنالیز حساسیت هر یک از ورودی‌های مدل MLP در برابر میزان تغییرات R^2 خروجی مدل

نتیجه‌گیری کلی

در این تحقیق، به منظور تخمین مساحت سایه ایجاد شده در انواع مختلف جمع‌کننده‌های صفحه تخت (در ابعاد مختلف) در ایران، از دو نوع مدل شبکه عصبی (MLP و RBF) و همچنین مدل رگرسیون بردار پشتیبان (SVM) استفاده شد. دو نوع الگوریتم آموزشی مختلف (LM و BR)، تابع انتقال تانژانت سیگموئید و ترکیب‌های مختلفی از انواع نورون‌ها در لایه پنهان (۵ تا ۲۵) برای دو مدل شبکه عصبی در نظر گرفته شد. از چهار نوع تابع انتقال (خطی، درجه دوم، درجه سوم و RBF) به‌عنوان توابع فعال مدل SVM استفاده شد. در طی آنالیز داده‌ها، از مدل اعتبارسنجی تقاطعی (k-fold cross validation) به منظور ایجاد ۱۰۰ مجموعه داده تصادفی در هر مرحله استفاده شد. نتایج کلی این تحقیق نشان داد که از بین تمامی مدل‌ها، مدل MLP با الگوریتم آموزشی LM و توپولوژی (۱-۲۳-۵) بهترین و دقیق‌ترین نتایج را ایجاد می‌کند. از بین ۱۰۰ مجموعه داده‌ای که توسط مدل k-fold برای ساختار (۱-۲۳-۵) ایجاد شده بود،

مجموعه ۱۶ام بیشترین دقت ممکن را داشت. نتایج آماری حاصل از بررسی این مجموعه نشان داد که بین میانگین، واریانس و توزیع آماری مجموعه داده‌های پیش‌بینی شده با مقادیر واقعی در سطح احتمال ۹۵٪ اختلاف معنی‌دار وجود ندارد و می‌توان نتیجه گرفت که این مدل با دقت بالا می‌تواند به‌عنوان بهترین مدل پیشگو در این مورد خاص مورد استفاده قرار گیرد.

سپاسگزاری

بدین‌وسیله از معاونت پژوهش و فناوری دانشگاه علوم کشاورزی و منابع طبیعی خوزستان به دلیل مساعدت‌های مالی در اجرای این تحقیق که بخشی از طرح پژوهشی داخلی دانشگاه با عنوان "کاربرد هوش مصنوعی در تخمین میزان سایه و افت انرژی در جمع‌کننده‌های تخت خورشیدی است"، کمال تشکر و قدردانی می‌شود.

هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد.

REFERENCES

- Al-Waeli, A.H., Sopian, A. & Yousif, K. (2019). Artificial neural network modeling and analysis of photovoltaic/thermal system based on the experimental study. *Energy Conversion and Management*, 186, 368–379.
- Amini, S., Taki, M. & Rohani, A. (2020). Applied improved RBF neural network model for predicting the broiler output energies. *Applied Soft Computing Journal*, 87, 106006.
- Batzelis, E., Georgilakis, I. & Papathanassiou, S.A. (2015). Energy models for photovoltaic systems under partial shading conditions: a comprehensive review. *IET Renewable Power Generation*, 9 (4), 340-349
- Blaça, R., Sabadus, A., Stefu, N., Dughir, C., Paulescu, M. & Badescu, V. (2019). A current perspective on the accuracy of incoming solar energy forecasting. *Progress in Energy Combustion Sciences*, 70, 119–44.
- Çakmak, G. & Yıldız, C. (2011). The prediction of seedy grape drying rate using a neural network method. *Computer and Electronic in Agriculture*, 75 (1), 132–138.
- Dimri, N., Tiwari, A. & Tiwari, G.N. (2019). An overall exergy analysis of glass-temlar photovoltaic thermal air collector incorporating thermoelectric cooler: A comparative study using artificial neural networks. *Energy Conversion and Management*, 195, 1350–1358.
- Duffie, J.A. & Beckman, W.A. (2013). *Solar Engineering of Thermal Processes*, Hoboken, New Jersey, John Wiley & Sons, Inc
- Elsheikh, A.H., Sharshir, S.W., Abd Elaziz, M., Kabeel, A.E., Guilan, W. & Haiou, Z. (2019). Modeling of solar energy systems using artificial neural network: a comprehensive review. *Solar Energy*, 180, 622–39.
- Esen, H., Esen, M. & Ozsolak, O. (2017). Modelling and experimental performance analysis of solar-assisted ground source heat pump system. *Journal of experimental and theoretical artificial intelligence*, 29 (1), 1–17.
- Farhadi, R. & Taki, M. (2020). The energy gain reduction due to shadow inside a flat-plate solar collector. *Renewable Energy* 147, 730-740
- Ghritlahre, H.K. & Prasad, R.K. (2018). Prediction of heat transfer of two different types of roughened solar air heater using Artificial Neural Network technique. *Thermal science and engineering progress*. 8, 145–153.
- Hamdan, M.A., Abdelhafez, E.A., Hamdan, A.M. & Khalil, R.A.H. (2016). Heat transfer analysis of a flat-plate solar air collector by using an artificial neural network. *Journal of infrastructure systems*, 22 (4), A4014004.
- Heng, S.Y., Asako, Y., Suwa, T. & Nagasaka, K. (2019). Transient thermal prediction methodology for parabolic trough solar collector tube using artificial neural network. *Renewable Energy*, 131, 168–179.
- Hu, F., Wei, E. & Wang, Z.J. (2013). Average Daily Shading Factor Variations with Aspect Ratios for Different Flat-Plate Collector Arrays. *Applied Mechanics and Materials*, 368, 949-952
- Jia, Y., Alva, G. & Fang, G. (2019). Development and applications of photovoltaic-thermal systems: a review. *Renewable and sustainable energy review*, 102, 249–65.

- Kalani, H., Sardarabadi, M. & Passandideh-Fard, M. (2017). Using artificial neural network models and particle swarm optimization for manner prediction of a photovoltaic thermal nanofluid based collector. *Applied Thermal Engineering*, 113, 1170–1177.
- Lalot, S. & Lecoeuche, S. (2003). Neural models of solar collectors for prediction of daily performance. *International journal of sustainable energy*, 23 (1–2), 39–49.
- Loni, R., Asli-Ardeh, E.A., Ghobadian, B., Ahmadi, M.H. & Bellos, E. (2018). GMDH modeling and experimental investigation of thermal performance enhancement of hemispherical cavity receiver using MWCNT/oil nanofluid. *Solar Energy*, 171, 790–803.
- Nahar, NM. & Gar, HP. (1980). Free convection and shading due to gap spacing between an absorber plate and the cover glazing in solar energy flat-plate collectors. *Applied Energy*, 7 (1), 129-145
- Rohani, A., Taki, M. & Aodollahpour M. (2018). A novel soft computing model (Gaussian process regression with K-fold cross validation) for daily and monthly solar radiation forecasting (Part: I). *Renewable Energy*, 115, 411-422
- Roy, K., Mandal, K.K. & Mandal, AC. (2019). Ant-Lion Optimizer algorithm and recurrent neural network for energy management of micro grid connected system. *Energy*, 167, 402–16.
- Taki, M., Abdanan Mehdizade, S., Rohani, A., Rahnama, M. & Rahmati-Joneidabad, M. (2018a). Applied machine learning in greenhouse simulation; new application and analysis. *Information Processing in Agriculture*, 252-268.
- Taki, M., Rohani, A., Soheilifard, F. & Abdeshahi, A. (2018b). Assessment of energy consumption and modeling of output energy for wheat production by neural network (MLP and RBF) and Gaussian process regression (GPR) models. *Journal of Cleaner Production*, 172, 3028-3041.
- Tang, RS. & Liu, NY. (2012). Shading Effect and Optimal Tilt-Angle of Collectors in a Collector Array. *Advanced Materials Research*, 588, 2078-2082.