

## پیش‌بینی مقادیر تبخیر روزانه با الگوریتم هیبریدی رگرسیون بردار پشتیبان - کرم شبتاب و پرسپکترون چندلایه

میلاد شرفی<sup>۱\*</sup>, سعید صمدیان فرد<sup>۲</sup>

۱. دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه  
۲. دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

تاریخ دریافت: ۱۴۰۰/۰۹

تاریخ پذیرش: ۱۴۰۱/۰۲

صفحات: ۵۳-۶۶

نوع مقاله: علمی-پژوهشی

### چکیده

پیش‌بینی تبخیر روزانه یک ابزار تعیین‌کننده و مفید در کشاورزی پایدار و مسائل هیدرولوژیکی، بهویژه در طراحی و مدیریت سیستم‌های منابع آب است. بنابراین، در این مطالعه توانایی مدل‌های هوش مصنوعی پرسپکترون چندلایه (MLP)، رگرسیون بردار پشتیبان (SVR) و مدل ترکیبی رگرسیون بردار پشتیبان با الگوریتم کرم شبتاب (SVR-FFA) در برآورد تبخیر روزانه در ایستگاه تکاب، طی دوره ۲۰۰۲-۲۰۲۰ با استفاده از چهار معیار آماری مورد ارزیابی قرار گرفت. در هر سه مدل بکار گرفته شده، سناریوی برتر مدلی بود که ورودی آن شامل پارامترهای میانگین دما، حداقل دما، حداکثر دما، رطوبت نسبی متوسط، حداقل رطوبت نسبی، حداکثر رطوبت نسبی، سرعت باد و ساعات آفتابی بود. در میان پارامترهای ورودی نیز پارامتر ساعات آفتابی از مؤلفه‌های موثر بر پیش‌بینی تبخیر بوده که باعث کاهش خطای در تمام مدل‌ها شده است. نتایج به دست آمده نشان داد که سناریو ششم مدل MLP بهترین عملکرد را با کمترین خطای (۲/۱۸) نسبت به تمامی مدل‌ها ارائه داد. همچنین نتیجه گرفته شد که سناریو ششم مدل SVR-FFA خطای کمتری (۲/۲) را نسبت به سایر مدل‌ها داشته است. در بین سناریوهای مدل SVR نیز سناریو ششم کمترین خطای را (۳/۲۷)، نسبت به سایر ترکیبات SVR از خود نشان داد. نتایج حاصل از این پژوهش نشان داد که سناریو ششم مدل MLP بهترین عملکرد را داشته و نیز الگوریتم هیبریدی کرم شبتاب باعث بهبود عملکرد رگرسیون بردار پشتیبان در برآورد تبخیر روزانه شد.

**واژه‌های کلیدی:** الگوریتم کرم شبتاب، پیش‌بینی، تبخیر، رگرسیون بردار پشتیبان.

### مقدمه

تبخیر<sup>۱</sup> یکی از مؤلفه‌های اصلی چرخه هیدرولوژیکی است که نقش حیاتی در برنامه‌ریزی و توسعه منابع آب در مناطق آب و هوایی خشک و نیمه‌خشک ایفا می‌کند (Shirsath & Singh, 2010). لذا مدیریت منابع آب در این مناطق برای تولید محصول پایدار امری مهم بشمار می‌رود (Shirgure & Rajput, 2012). پیش‌بینی دقیق تبخیر برای تعیین نیاز آبی محصول، طراحی برنامه‌های آبیاری، برنامه‌ریزی و مدیریت منابع آب در مطالعات کشاورزی و هیدرولوژیکی از اهمیت بالایی برخوردار است (Fan et al., 2015; Kisi, 2016; Zhang et al., 2018).

<sup>1</sup>\* Email: miladsharafi1@gmail.com

<sup>2</sup> Evaporation

جمله بررسی تبخیر، یکی از موارد اساسی در طراحی، بهره‌برداری و مطالعات مربوط به این سامانه‌ها به شمار می‌رود. لذا پیش‌بینی دقیق این پارامتر با دقت قابل قبول، گامی بسیار مهم در مدیریت منابع آبی می‌باشد. با توجه به اهمیت تبخیر و میزان تأثیرگذاری زیاد آن بر منابع آب شیرین کشور و تغییرات اقلیمی که موجب افزایش گرما و میزان خورشید، که به طور طبیعی موجب افزایش تبخیر شده و کاهش منابع آب شیرین اعم از ذخایر زیرزمینی و سطحی را به دنیا داشته است، پیش‌بینی دقیق میزان تبخیر امری ضروری به نظر می‌رسد. متغیرهای مختلف هواشناسی، مانند تابش خورشیدی، دمای هوای رطوبت نسبی و سرعت باد، می‌توانند به طور تعاملی بر مولفه تبخیر تأثیر بگذارند. بنابراین، تاکنون تلاش‌های زیادی برای استخراج روابط ریاضی یا رگرسیونی بین تبخیر و عوامل محرك آن صورت گرفته است (Allen et al., 1998; Chen et al., 2019; Yu et al., 2019; Feng et al., 2016; Wang et al., 2020). با توجه به اینکه پیچیدگی سیستم‌های هیدرولوژیکی از نظر تعیین تمام پارامترهای دخیل و ناقص بودن اطلاعات آماری، امکان مدل‌سازی کامل سیستم‌های هیدرولوژیکی را غیرممکن می‌سازد. در نتیجه استفاده از مدل‌سازی سیستمی که مبتنی بر روابط ریاضی باشد، مورد توجه قرار می‌گیرد (Kisi et al., 2016). دهقانی و همکاران، در مطالعه‌ای به تخمین تبخیر روزانه با استفاده از شبکه‌های عصبی بازگشتی، پرسپترون چندلایه<sup>۱</sup> و تابع پایه شعاعی پرداختند (Dehghani et al., 2010). نتایج این تحقیق نشان داد که مدل‌های شبکه عصبی مصنوعی بهتر از روابط تجربی موجود عمل می‌کنند. در مطالعه‌ای دیگر رحیم‌خوب، به تخمین تبخیر روزانه تشت با استفاده از عصبی مصنوعی شبکه در منطقه نیمه خشک پرداخت (Rahimikhoob, 2009). نتایج این بررسی نشان داد که هم مدل تجربی و هم مدل عصبی نتایجی نزدیک به مقادیر اندازه‌گیری شده ارائه کردند ( $R^2 > 0.88$  و RMSE  $< 1.2$  میلی‌متر بر روز)، اما روش ANN تخمین‌های بهتری نسبت به روش هارگریوز کالیبره شده ارائه داد. مطالعات اخیر نشان داده‌اند که استفاده از روش‌های شبیه‌سازی با بکارگیری الگوریتم‌های یادگیری ماشینی ضروری است (Isazadeh et al., 2017; Mosavi et al., 2017). در سال‌های اخیر، ماشین بردار پشتیبان (SVM<sup>۲</sup>) ثابت کرده است که یک الگوریتم قوی و قابل اعتماد برای تخمین است، و همچنین به طور گسترش مورد استفاده قرار گرفته است (Chen et al., 2015). در مطالعه‌ای چن و همکاران، به برآورد تبخیر با استفاده از ماشین بردار پشتیبان در منطقه‌ای در چین پرداختند، نتایج نشان داد که روش SVM جایگزینی امیدوارکننده، برای رویکردهای سنتی در برآورد تبخیر از متغیرهای اندازه‌گیری شده هواشناسی خواهد بود (Chen et al., 2019).

در سال‌های اخیر مطالعات متعددی نشان داده‌اند که الگوریتم‌های بهینه‌سازی می‌توانند برای بهینه‌سازی آموزش مدل‌های هوش مصنوعی موثر باشند (Chau, 2007; Cheng-Ping et al., 2011; Gholami et al., 2015). الگوریتم کرم شب تاب یک تکنیک بهینه‌سازی نسبتاً جدید است که دو مزیت نسبت به سایر الگوریتم‌های مشابه دارد. اولاً بر اساس جاذبه است و با بیشتر شدن فاصله از جاذبه کم می‌شود. این بدان معنی است که کل جمعیت به طور خودکار به زیر گروه‌هایی تقسیم می‌شود که در اطراف محلی بهینه، ازدحام می‌کنند تا درنهایت بهترین راه حل پیدا شود. دوماً، این زیر گروه‌ها الگوریتم کرم شب تاب را قادر می‌سازند تا به طور همزمان تمام حالت‌های بهینه را پیدا کند (Yang & He, 2013). در پژوهشی برای پیش‌بینی بارندگی ماهانه در ایستگاه‌های تبریز و ارومیه واقع در شمال غرب ایران، بر اساس الگوریتم رگرسیون بردار پشتیبان (SVR<sup>۳</sup>) و الگوریتم کرم شب تاب (FFA) انجام شد. برای هر دو ایستگاه، نتایج نشان داد که مدل ترکیبی، بسیار بهتر از رگرسیون بردار پشتیبان عمل کرد (Danandeh Mehr et al., 2019). در مطالعه دیگری برای پیش‌بینی نوسانات سطح آب دریاچه ارومیه واقع در شمال غرب ایران، کیشی و همکاران از SVR و FFA استفاده کردند. نتایج نشان داد که استفاده از SVR-FFA نقش مهمی در افزایش دقت پیش‌بینی دارد (Kisi et al., 2015).

<sup>1</sup> Multi-layer perceptron

<sup>2</sup> Support vector regression

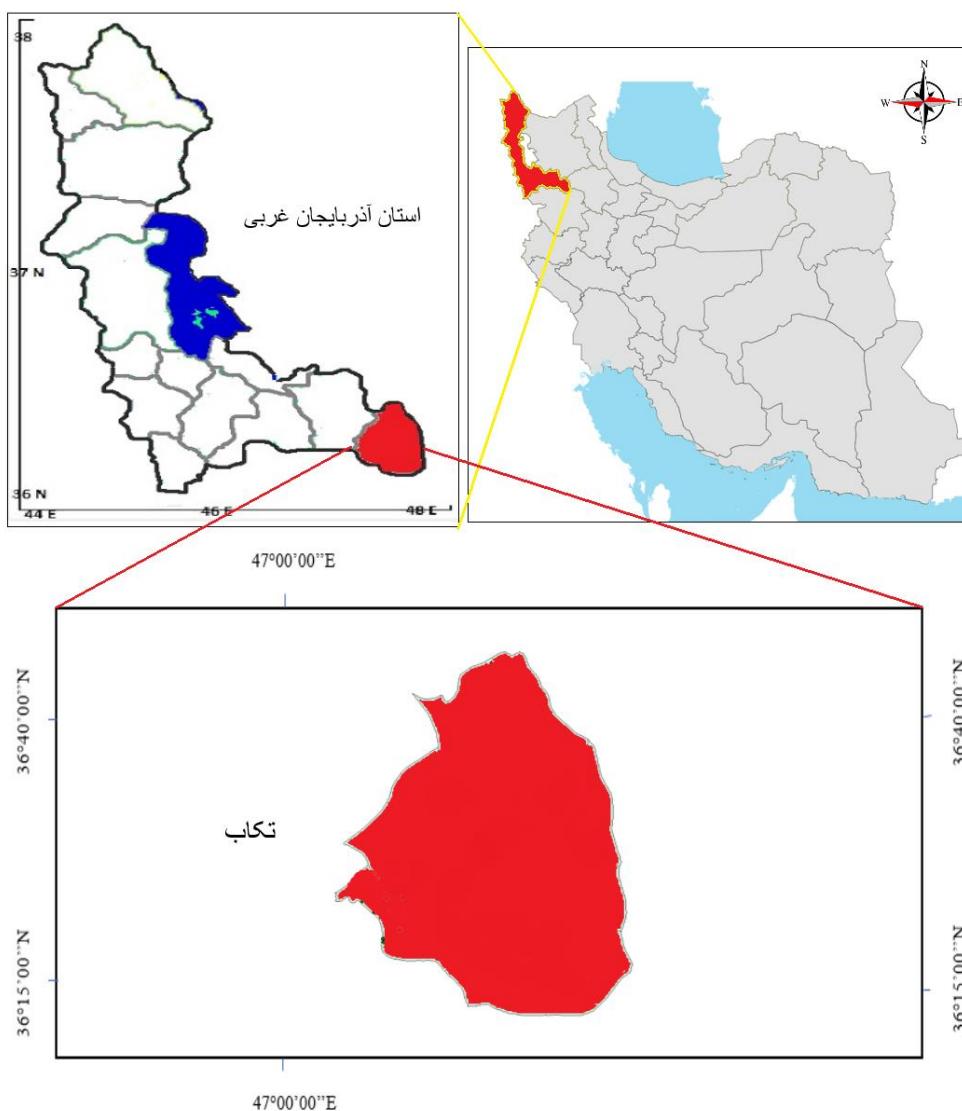
<sup>3</sup> Support vector machine

Ghorbani و همکاران (۲۰۱۷) از SVR و SVR-FFA برای پیش‌بینی ظرفیت زراعی و نقطه پژمردگی دائم، ۲۱۵ نمونه خاک جمع‌آوری شده از استان آذربایجان شرقی در ایران استفاده کرد و دریافت که روش SVR بهتر از SVR-FFA عمل می‌کند. نتایج این تحقیق نشان داد که برای نقطه پژمردگی دائم، مقادیر جذر میانگین مربعات خطای ۱۸/۳۶ و ۸/۷۴ میلی‌متر بر متر به ترتیب برای روش‌های SVR و SVR-FFA پیش‌بینی شده، و نیز برای نقطه پژمردگی دائم، مقادیر جذر میانگین مربعات خطای ۲۱/۷۵ را ۱۰/۶۱ میلی‌متر بر متر برای روش‌های SVR و SVR-FFA پیش‌بینی گردید. تبخیر به عنوان یکی از مولفه‌های اصلی چرخه هیدرولوژیکی، در معرض تغییرات غیرخطی است و کمبود داده‌های تبخیر اندازه‌گیری شده در بسیاری از ایستگاه‌های هواشناسی برای دوره‌های زمانی خاص وجود دارد، مشکلی که با توزیع نابرابر ایستگاه‌ها تشدید می‌شود. با در نظر گرفتن موارد مذکور، هدف از مطالعه حاضر، ارزیابی قابلیت‌های SVR بهینه شده با FFA در تخمین تبخیر روزانه در ایستگاه تکاب، واقع در شمال غرب ایران می‌باشد. در نهایت، از برخی معیارهای ارزیابی برای برآورد میزان خطای عملکرد مدل‌های در نظر گرفته شده، استفاده شد.

## مواد و روش‌ها

### منطقه مورد مطالعه

در تحقیق حاضر مقادیر تبخیر روزانه در طی دوره آماری ۱۸ ساله در سال‌های ۲۰۰۲-۲۰۲۰ در ایستگاه تکاب در نظر گرفته شد. این شهرستان با طول ۴۷ درجه و ۷ دقیقه، عرض ۳۶ درجه و ۸ دقیقه و ۳۰ ثانیه، ارتفاع از سطح دریاهای آزاد ۱۸۴۰ متر، در شمال غربی کشور ایران و جنوب شرقی استان آذربایجان غربی واقع شده‌است. میانگین بارش سالانه در این شهرستان حدود ۳۰۰ میلی‌متر و میانگین تبخیر سالانه حدود ۲۶۶۴/۵ میلی‌متر است (Sharifi et al., 2016). آب و هوای تکاب تابعی است از اقلیم حاکم بر آذربایجان، منتهی توپوگرافی ارتفاع و جهت گسترش ناهمواری‌ها و دوری منطقه تکاب از دریا و کانون‌های رطوبتی شرایط ویژه‌ای به آب و هوای منطقه بخشیده که بارزترین مشخصه آن، زمستانهای سرد و برفی و تابستانهای معتدل و خشک می‌باشد و از این بابت اندک تفاوتی با اقلیم حاکم بر آذربایجان دارد. با در نظر گرفتن میانگین بارش سالانه تکاب در گروه رژیم بارانی نیمه بیابانی یا نیمه خشک محسوب می‌شود. بیشتر درآمد مردم این شهرستان از راه کشاورزی بوده و کمتر واحد صنعتی در این شهر به چشم می‌خورد. لذا پیش‌بینی صحیح تبخیر باعث بهبود مدیریت بر منابع و کشاورزی خواهد گردید. شکل (۱) نقشه موقعیت جغرافیایی شهرستان تکاب را نشان می‌دهد.



شکل (۱): نقشه موقعیت جغرافیایی شهرستان تکاب

جدول (۱) پارامترهای آماری روزانه داده‌های آموزش و آزمون مورد استفاده در طی دوره آماری را نشان می‌دهد.

جدول (۱): پارامترهای آماری روزانه داده‌های مورد استفاده

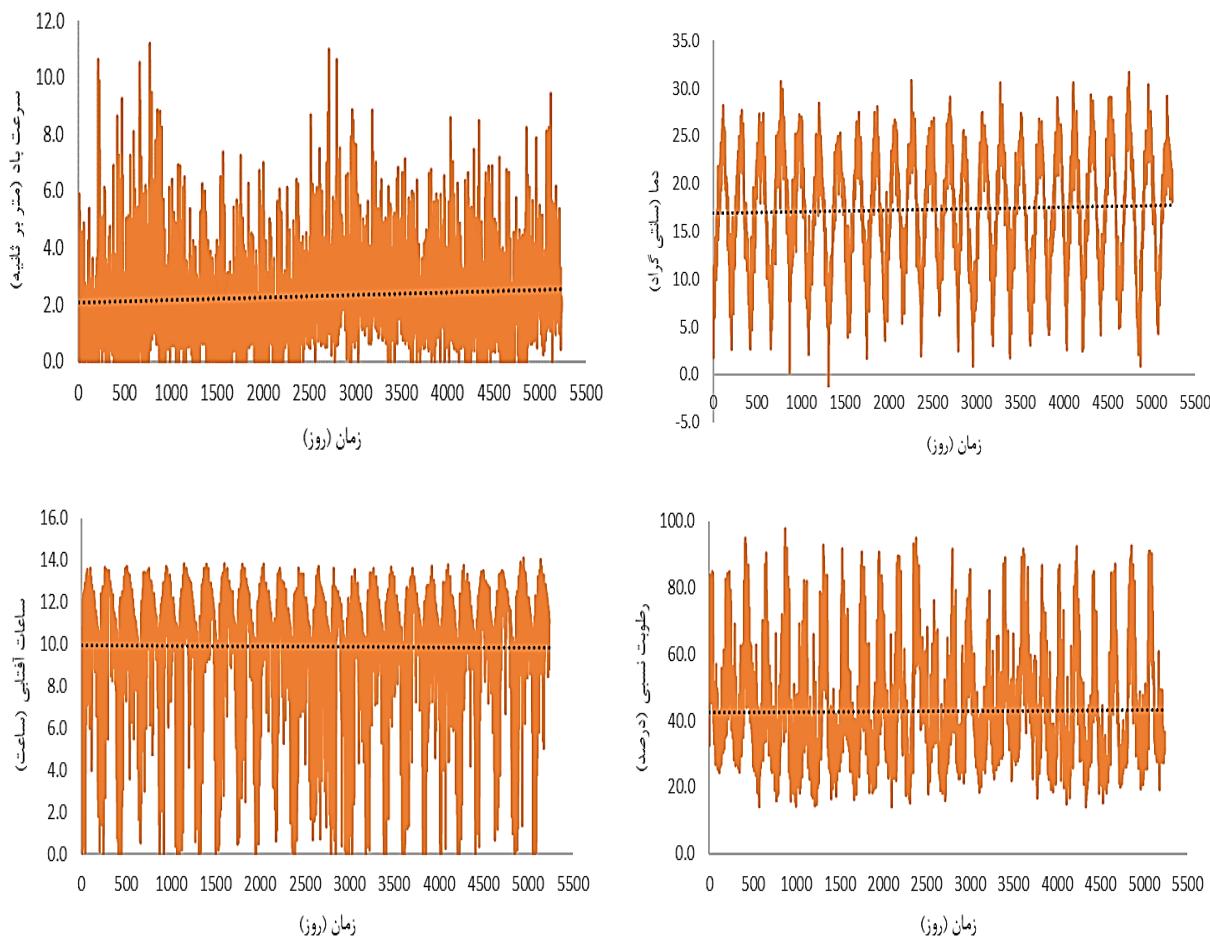
پارامترهای آماری	داده‌های آموزش						داده‌های آزمون					
	(mm)	(°C)	درصد رطوبت نسبی	ساعت (hr)	سرعت باد آفتابی (m/s)	(mm)	(°C)	درصد رطوبت نسبی	ساعت (hr)	سرعت باد آفتابی (m/s)	(mm)	
میانگین	۹/۲۷	۱۷/۹۳	۴۲/۳۹	۱۰/۱	۲/۳۳	۸/۲۱	۱۷/۰۸	۴۲/۹۱	۹/۷۸	۲/۲۹	۲/۲۹	
مینیمم	۰/۱	۱	۱۴/۱۲	۰	۰	۰/۱	-۱/۱	۱۴/۳۷	۰	۰	۰	
ماکریمم	۲۶/۲	۳۱/۷	۹۲/۵	۱۴/۱	۹/۳۷	۴۰	۳۰/۸	۹۷/۴	۱۳/۸	۱۱/۲	۱۱/۲	
انحراف استاندارد	۴	۶/۴۱	۱۶/۸	۳/۰۵	۱/۴۸	۳/۹۴	۵/۹۸	۱۶/۳۷	۳/۱۵	۱/۵۹	۱/۵۹	

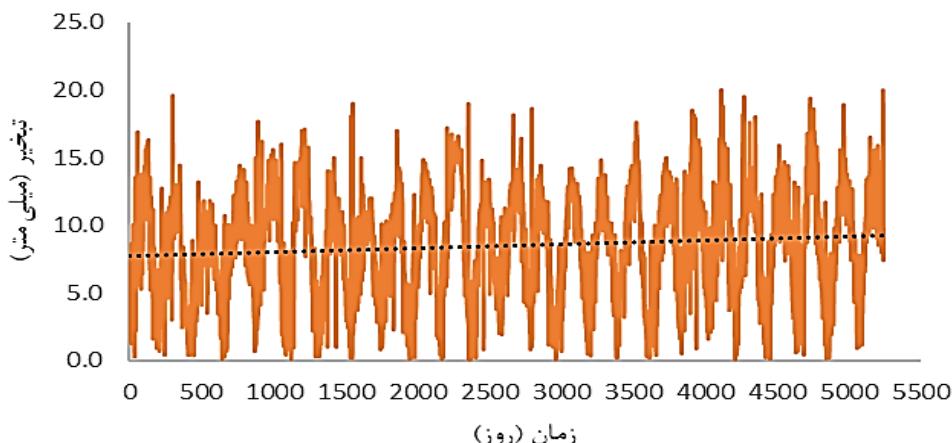
جدول (۱) سناریوهای مختلفی را که به عنوان ورودی و خروجی مدل‌ها در نظر گرفته شده‌اند، نشان می‌دهد. پارامترهای میانگین دما ( $T_{avg}$ ), حداقل دما ( $T_{min}$ ), حداکثر دما ( $T_{max}$ ), رطوبت نسبی متوسط ( $RH_{avg}$ ), حداقل رطوبت نسبی ( $RH_{min}$ ), حداکثر رطوبت نسبی ( $RH_{max}$ ), سرعت باد ( $U$ ), ساعات آفتابی (SSH) به عنوان پارامترهای ورودی و تبخیر روزانه (E) به عنوان پارامتر هدف می‌باشند. نحوه انتخاب ترکیبات مختلف ورودی، برای تخمین مقدار تبخیر روزانه در مدل‌های مورد مطالعه براساس داشتن همبستگی بالاتر نسبت به سایر ترکیبات، صورت گرفته است.

جدول (۱) : ترکیب‌های مختلف ورودی، برای تخمین مقدار تبخیر روزانه در مدل‌های مورد مطالعه

سناریو	پارامترهای ورودی	خرجی
1	$T_{avg}$	E
2	$T_{avg}$ $T_{min}$ $T_{max}$	E
3	$T_{avg}$ $T_{min}$ $T_{max}$ $RH_{avg}$	E
4	$T_{avg}$ $T_{min}$ $T_{max}$ $RH_{avg}$ $RH_{min}$ $RH_{max}$	E
5	$T_{avg}$ $T_{min}$ $T_{max}$ $RH_{avg}$ $RH_{min}$ $RH_{max}$ $U_2$	E
6	$T_{avg}$ $T_{min}$ $T_{max}$ $RH_{avg}$ $RH_{min}$ $RH_{max}$ $U_2$ $SSH$	E

شکل (۲) نمودارهای سری زمانی پارامترهای دما، رطوبت نسبی، سرعت باد، ساعات آفتابی و تبخیر را نشان می‌دهد در این نمودارها، خطوط نقطه‌چین متوسط آن پارامتر را در طول زمان نشان می‌دهد.





شکل (۲): نمودارهای سری زمانی پارامترهای مورد استفاده در مدل‌ها

#### شبکه عصبی مصنوعی پرسپترون چندلایه (ANN-MLP)

شبکه عصبی مصنوعی بهطور گسترده در تحقیقات هوش مصنوعی استفاده می‌شود و در جایی کاربرد دارد که یکتابع تقریبی برای نگاشت غیرخطی بین پارامترهای ورودی و خروجی نیاز است (Kim et al., 2005). طراحی یک شبکه عبارت است از تعیین تعداد لایه‌های مناسب، تعداد مناسب نورون‌ها در هر لایه و نوع تابع تحریک در هر لایه به گونه‌ای که خطای آموزش و آزمایش شبکه به حداقل برسد (Nasri et al., 2010). برای بدست آوردن تعداد لایه میانی و همچنین تعداد گره مناسب، می‌توان از روش لونبرگ مارکوارت<sup>۱</sup> استفاده کرد که از سریع‌ترین روش‌های آموزش است (Hagan & Menhaj, 1994). برای مطالعات بیشتر به (Gardner & Dorling, 1998) مراجعه گردد.

#### رگرسیون بردار پشتیبان (SVR)

روش SVR می‌تواند مقادیر را با توجه به مجموعه داده‌های داده شده  $n \times n$  (پیش‌بینی کند، جایی که  $x_i$  نشان‌دهنده داده‌های ورودی،  $y_i$  نشان‌دهنده مقدار خروجی (تبخیر)، و  $n$  مقدار کل داده‌های مورد استفاده بود. معادله رگرسیون خطی به صورت زیر است:

$$y(x) = w^T \varphi(x) + c \quad (1)$$

که در آن  $w$  وزن است و  $c$  ضریب قابل محاسبه از داده‌های خام است. معادله غیرخطی ( $\varphi(x)$ ) است و  $(x)$  در فضای ویژگی نگاشت می‌شود. با نگاشت غیرخطی، رگرسیون تابع خطی شده در دامنه مشخصه ابعادی بالاتر انجام می‌شود (Aljanabi et al., 2018; Keshtegar et al., 2016) پارامترهای  $w$  و  $c$  با کاهش مقدار ریسک در قسمت اولیه معادله (۲) و عبارت پیچیدگی در قسمت دوم معادله (۳) محاسبه شدند:

$$R(C) = C \left( \sum_{a=1}^u (X_a + X_a^*) + \frac{1}{2} \|E\|^2 \right) \quad (2)$$

$$\begin{cases} d_i - w\varphi(y_a) - l_a \leq X + X_a, & a = 1, 2, 3, \dots, u \\ w\varphi(y_a) + l_a - r_a \leq X + X_a^*, & a = 1, 2, 3, \dots, u \\ X + X_a^* \geq 0, & a = 1, 2, 3, \dots, u \end{cases} \quad (3)$$

که در آن  $C$  و  $\|E\|^2$  یک ثابت مثبت، تابع کاهش غیرحساس و عبارت منظم‌سازی هستند که به ترتیب تابع اقلیدسی را نشان می‌دهند. در فرمول رگرسیون غیرخطی فرض می‌شود که رابطه (۲) را کاهش می‌دهد و به رابطه (۳) وابسته است.

<sup>۱</sup> Levenberg-Marquardt

### الگوریتم بهینه‌سازی کرم شبتاب (FFA)

الگوریتم کرم شبتاب اولین بار توسط یانگ ارائه شد که رفتار اجتماعی کرم شبتاب را شبیه سازی می‌کند (Yang, 2009). سه قانون اساسی برای این الگوریتم ایجاد شده است (KumarSrivastava & Singh, 2016; Yang, 2009)؛ ۱- هر کرم شبتاب می‌تواند توسط کرم شبتاب دیگری جذب شود. ۲- در برخی از کرم شبتاب‌ها، کرم شبتاب با نور کمتر به سمت کرم شبتاب دیگری می‌رود. اگر روشنایی هر دو یکسان باشد، حرکت آنها تصادفی خواهد بود. ۳- روشنایی کرم شبتاب با تابع هدف به دست می‌آید.

امتیاز تناسب به عنوان شدت نور با توجه به عملکرد هدف هر کرم شبتاب تعیین می‌شود. جذب کرم شبتاب به این صورت است که کرم‌های شبتاب که نور کمتری دارند توسط نورهای روشن اطراف جذب می‌شوند.

$$x_i^{t+1} = x_i^t + \beta_0 e^{-\gamma r_{ij}^2} (x_j^t - x_i^t) + \alpha_t \varepsilon_t \quad (4)$$

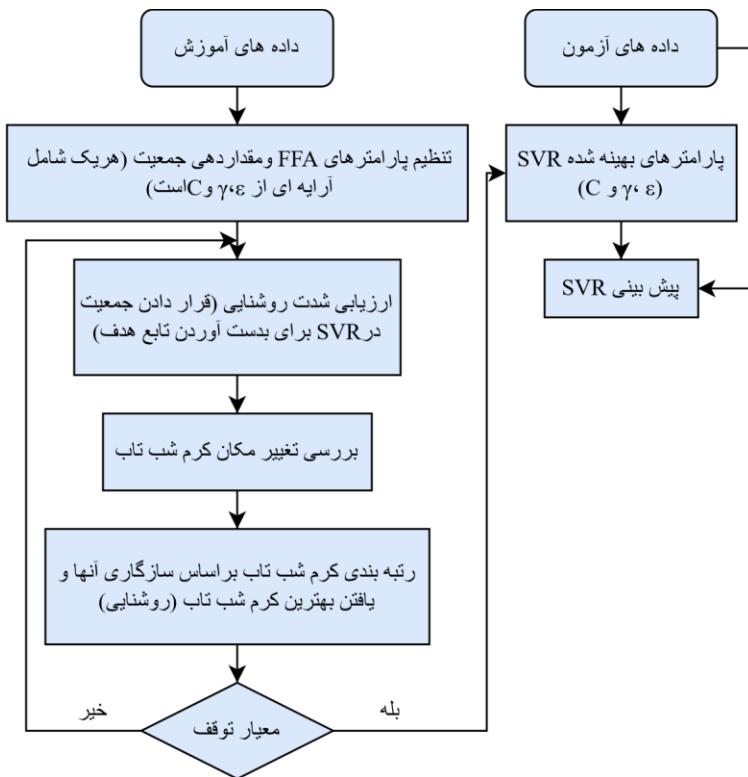
در رابطه (4)،  $\alpha$  و  $\beta$  نمایانگر کرم‌های شبتاب باشد نور متفاوت هستند. در حالی که  $x_i^t$  و  $x_j^t$  به ترتیب موقعیت‌های فعلی کرم شبتاب  $i$  و  $j$  را در تکرار  $t$  ام نشان می‌دهند. پارامتر  $\beta_0$  نشانگر جاذبه اولیه،  $\gamma$  ضریب جذب نور و  $r_{ij}$  فاصله بین کرم شبتاب  $i$  و  $j$  است. مزیت اصلی FFA مکانیسم جذب آن است. حرکت مبتنی بر جذابیت باعث می‌شود که ازدحام کرم شبتاب به طور خودکار به زیرگروه‌ها تقسیم شود و هر گروه حول یک راه حل بهینه جمع شوند. وقتی اندازه جمعیت به اندازه‌ای بزرگ باشد که از تعداد راه حل‌های بهینه محلی فراتر رود، در اصل، توانایی تقسیم‌بندی FFA می‌تواند همه مقادیر بهینه را همزمان پیدا کند، بنابراین مقدار بهینه را به دست می‌آورد. این توانایی تقسیم خودکار FFA را قادر می‌سازد تا مسائل بهینه‌سازی را با حالت‌های غیرخطی بالا و چندگانه مدیریت کند. غیرخطی بودن قوی در FFA معمولاً می‌تواند منجر به تقسیم کل ازدحام به زیرگروه‌های متعدد شود. بنابراین، FFA برای مسائل بهینه‌سازی چندوجهی مناسب است و مطالعات این را تایید کرده‌اند (Fister et al., 2013; Marichelvam & Geetha, 2014; Osaba et al., 2017; Yang & He, 2013).

شکل(۳)، فلوچارت مدل ترکیبی SVR-FFA را نشان می‌دهد (Nait Amar & Zeraibi, 2019). در این فلوچارت  $\gamma$  به عنوان پهنای باند تابع هسته و  $\epsilon$  و  $C$  سه پارامتر از پیش تعیین شده، تعریف می‌شود. در این تحقیق  $0.001$  و  $0.01$  به ترتیب به عنوان پیش فرض برای هر سه پارامتر  $\epsilon$  و  $C$  انتخاب شدند.

روش‌های محاسباتی، از جمله توسعه مدل‌های SVR و SVR-FFA، در محیط MATLAB (The MathWorks 2018) پیاده‌سازی شدند و پارامترهای تابع هسته از طریق آزمون و خطاب بهینه‌سازی شدند.

در این مطالعه برای ایجاد مدل‌هایی برای پیش‌بینی تبخیر، از ۷۰ درصد داده‌ها (۳۶۷۰ داده) برای آموزش و ۳۰ درصد از آنها (۱۵۷۰ داده) برای مرحله آزمون به طور تصادفی استفاده گردید. همچنین داده‌های پرت نیز به علت ایجاد خطای صحت نتایج، از مجموع داده‌های مورد استفاده حذف گردید.

<sup>1</sup> Firefly Optimization Algorithm



شکل (۳) : فلوچارت مدل ترکیبی SVR-FFA

## معیارهای ارزیابی مدل

در این پژوهش برای ارزیابی عملکرد ستاریوهای مختلف تعریف شده برای روش‌های مورد مطالعه از پارامترهای آماری ضریب همبستگی ( $R^1$ )، جذر میانگین مربعات خطأ (RMSE)<sup>۲</sup>، ضریب نش ساتکلیف (NS)<sup>۳</sup> و شاخص توافق ویلموت (WI)<sup>۴</sup> استفاده شده است.

$$R = \frac{\left( \sum_{i=1}^N O_i P_i - \frac{1}{N} \sum_{i=1}^N O_i \sum_{i=1}^N P_i \right)}{\left( \left( \sum_{i=1}^N O_i^2 - \frac{1}{N} (\sum_{i=1}^N O_i)^2 \right) \left( \sum_{i=1}^N P_i^2 - \frac{1}{N} (\sum_{i=1}^N P_i)^2 \right) \right)} \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (6)$$

$$NS = 1 - \left[ \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2} \right] \quad (7)$$

$$WI = 1 - \left[ \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (|P_i - \bar{O}_i| + |O_i - \bar{O}_i|)^2} \right] \quad (8)$$

در روابط (۵-۸)، پارامترهای  $P_i$  و  $O_i$  به ترتیب مقادیر پیش‌بینی و مشاهداتی می‌باشند.

<sup>1</sup> Correlation coefficient

<sup>2</sup> Root mean squared error

<sup>3</sup> Nash-Sutcliffe coefficient

<sup>4</sup> Willmott's index of agreement

## نتایج و بحث

در این مطالعه، شش ترکیب مختلف از متغیرهای پیش‌بینی‌کننده پارامترهای میانگین دما ( $T_{avg}$ ), حداقل دما ( $T_{min}$ ), حداکثر دما ( $T_{max}$ ), رطوبت نسبی متوسط ( $RH_{avg}$ ), حداقل رطوبت نسبی ( $RH_{min}$ ), حداکثر رطوبت نسبی ( $RH_{max}$ ), سرعت باد (U)، ساعات آفتابی (SSH)، به عنوان ورودی مدل‌ها در جدول (۱) در نظر گرفته شد. در این بخش، الگوریتم‌های MLP و SVR-FFA بر روی شش مجموعه داده برای پیش‌بینی مقادیر تبخیر روزانه استفاده شده است. تطابق بین مقادیر اندازه‌گیری شده و پیش‌بینی شده تبخیر در جدول (۲) از نظر ضریب همبستگی، جذر میانگین مربعات خطأ، ضریب ناشساتکلیف و شاخص توافق ویلموت، طی مراحل اعتبارسنجی گزارش شده است.

نتایج ارائه شده در جدول (۲) نشان داد که برای MLP در ایستگاه تکاب، سناریو ششم مدل MLP با ضریب همبستگی ۰/۸۴، جذر میانگین مربعات خطأ ۲/۱۸ میلی‌متر در روز، ضریب ناشساتکلیف ۰/۷ و شاخص توافق ویلموت ۹۱/۰ کمترین خطأ را نسبت به سایر ترکیبات MLP و نیز تمام مدل‌های مورد استفاده را دارد. با این حال، سناریو اول مدل MLP با ضریب همبستگی ۰/۸۴، جذر میانگین مربعات خطأ ۲/۳۵ میلی‌متر در روز، ضریب ناشساتکلیف ۰/۶۶ و شاخص توافق ویلموت ۹/۰ به‌علت داشتن ورودی‌های کمتر پس از سناریو ششم مدل MLP، دقت پیش‌تری را نسبت به سایر ترکیبات این مدل در برآورد تبخیر روزانه را ارائه کرد. علت این امر را می‌توان در بالهیمت بودن پارامتر دمای میانگین بر مبنای این مدل در مدل MLP افزوده شدن پارامترهای دمای حداقل و حداکثر و نیز میانگین رطوبت نسبی نه تنها باعث کاهش خطای مدل نشد بلکه دقت مدل را با افزایش خطای نسبی کاهش داد. همچنین افزوده شدن پارامترهای حداقل و حداکثر رطوبت نسبی باعث کاهش خطای مدل گردید که این امر نشان از حساسیت مدل به این دو پارامتر می‌باشد. با توجه به اینکه باد مؤلفه مهمی در پیش‌بینی تبخیر می‌باشد اما افزوده شدن این پارامتر باعث افزایش جزئی خطای نسبی کاهش مدل گردید که قابل اغماض است. علت این امر احتمالاً وجود بادهای ملایم و آرام در منطقه با توجه به میانگین حدوداً ۲ متر بر ثانیه بوده که در شکل (۲) نیز نشان داده شده است. لذا این پارامتر تاثیر چندانی در پیش‌بینی تبخیر نداشته است. در نهایت با توجه به شکل (۲) میانگین ساعت آفتابی حدود ۱۰ ساعت بر روز بوده است که این پارامتر سبب کاهش محسوس خطأ گردیده است.

برای مدل SVR در ایستگاه تکاب، سناریو ششم مدل SVR با ضریب همبستگی ۰/۸۴، جذر میانگین مربعات خطأ ۲/۲۷ میلی‌متر در روز، ضریب ناشساتکلیف ۰/۶۸ و شاخص توافق ویلموت ۹/۰ کمترین خطأ را نسبت به سایر ترکیبات SVR دارد. با این حال، سناریو اول مدل SVR با ضریب همبستگی ۰/۸۴، جذر میانگین مربعات خطأ ۲/۲۹ میلی‌متر در روز، ضریب ناشساتکلیف ۰/۶۷ و شاخص توافق ویلموت ۹/۰ پس از سناریو ششم مدل SVR، نیاز کمتری به داده‌های ورودی داشته و دقت بالاتری را در برآورد تبخیر روزانه ارائه کرد. با توجه به جدول (۲) مدل SVR حساسیت بالایی را به ترتیب نسبت به پارامترهای ساعت آفتابی و دمای میانگین دارد. بطوریکه هر دو این پارامترها سبب کاهش خطأ و در نتیجه افزایش دقت مدل می‌شوند. درحالیکه این مدل نسبت به سایر پارامترها حساسیتی نداشته و تغییری در مدل دیده نمی‌شود.

در بین مدل‌های ترکیبی SVR-FFA، سناریو ششم مدل SVR-FFA با ضریب همبستگی ۰/۸۵، جذر میانگین مربعات خطأ ۲/۲ میلی‌متر در روز، ضریب ناشساتکلیف ۷/۰ و شاخص توافق ویلموت ۹۱/۰ کمترین خطأ را نسبت به تمام ترکیبات SVR-FFA دارد. با این حال، سناریو پنجم مدل SVR-FFA با ضریب همبستگی ۰/۸۴، جذر میانگین مربعات خطأ ۲/۲۲ میلی‌متر در روز، ضریب ناشساتکلیف ۰/۶۹ و شاخص توافق ویلموت ۹/۰ پس از سناریو ششم مدل SVR-FFA، دقت بالاتری را داشته و نیاز به داده‌های ورودی کمتری در برآورد تبخیر روزانه دارد. با توجه به جدول (۲) هر سه پارامتر مربوط به رطوبت نسبی سبب افزایش خطای مدل گردیده‌اند علت این امر احتمالاً نوسان بالای رطوبت تسبی با توجه به شکل (۲)

دانست. پارامتر سرعت باد سبب کاهش حدود ۳ درصدی خطای مدل شده است که نشان از حساسیت مدل نسبت به این پارامتر دانست. همچنین پارامتر ساعات آفتابی از مولفه‌های موثر بر پیش‌بینی تبخیر بوده که باعث کاهش خطای حدوداً یک درصدی در آخرین ترکیب مدل گشته است.

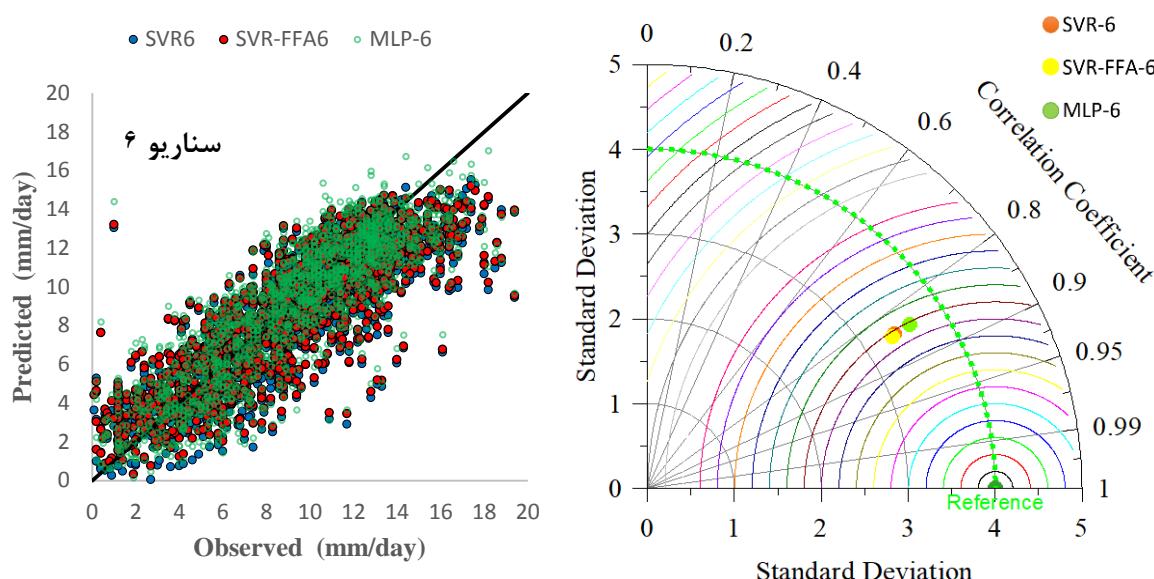
با توجه به نتایج ذکر شده سناریو ششم مدل MLP با داشتن کمترین جذر میانگین مربعات خطای ۰/۱۸ میلی‌متر در روز، به عنوان دقیق‌ترین مدل در میان تمام مدل‌ها و ترکیبات می‌باشد. پس از سناریو ششم مدل MLP، سناریو ششم مدل SVR-FFA با داشتن جذر میانگین مربعات خطای ۰/۲ میلی‌متر در روز دقت بالاتری را در میان تمام مدل‌ها، از خود نشان داد. درنهایت ۲ مدل MLP6 و SVR-FFA6 به ترتیب جزء دقیق‌ترین مدل‌ها بوده و برای انجام مطالعات بیشتر پیشنهاد می‌گردد.

نتایج این تحقیق با نتایج کیشی (Kişi, 2009)، که به مدل‌سازی تبخیر با استفاده از تکنیک‌های مختلف محاسبات عصبی پرداخت و اعلام نمود که تکنیک محاسباتی MLP می‌تواند با موفقیت در مدل‌سازی فرآیند تبخیر مورد استفاده قرار گیرد. همچنین با نتایج مؤذن‌زاده و همکاران (Moazenzadeh et al., 2018) که اعلام نمودند الگوریتم ترکیبی SVR-FFA توانایی بالایی در پیش‌بینی تبخیر ایستگاه‌های رشت و لاهیجان واقع در شمال ایران داشته، مطابقت دارد.

جدول(۲) : پارامترهای ارزیابی مدل‌های مورد مطالعه در دوره آزمون

مدل	پارامترهای آماری			
	R	RMSE	NS	WI
SVR1	۰/۸۴	۲/۲۹	۰/۶۷	۰/۹
SVR2	۰/۸۴	۲/۳	۰/۶۷	۰/۹
SVR3	۰/۸۴	۲/۳	۰/۶۷	۰/۹
SVR4	۰/۸۴	۲/۳	۰/۶۷	۰/۹
SVR5	۰/۸۴	۲/۳	۰/۶۷	۰/۹
SVR6	۰/۸۴	۲/۲۷	۰/۶۸	۰/۹
SVR-FFA1	۰/۸۴	۲/۲۷	۰/۶۸	۰/۹
SVR-FFA2	۰/۸۴	۲/۲۵	۰/۶۹	۰/۹
SVR-FFA3	۰/۸۴	۲/۲۸	۰/۶۸	۰/۹
SVR-FFA4	۰/۸۴	۲/۲۹	۰/۶۷	۰/۹
SVR-FFA5	۰/۸۴	۲/۲۲	۰/۶۹	۰/۹
SVR-FFA6	۰/۸۵	۲/۲	۰/۷	۰/۹۱
MLP-1	۰/۸۴	۲/۳۵	۰/۶۶	۰/۹
MLP-2	۰/۸۳	۲/۳۷	۰/۶۵	۰/۸۹
MLP-3	۰/۸۴	۲/۳۸	۰/۶۵	۰/۸۹
MLP-4	۰/۸۴	۲/۳۶	۰/۶۵	۰/۹
MLP-5	۰/۸۴	۲/۳۷	۰/۶۵	۰/۹
MLP-6	۰/۸۴	۲/۱۸	۰/۷	۰/۹۱

نمودارهای تیلور و پراکنش مقادیر تبخیر روزانه در شکل(۴) که برای بهترین سناریو (سناریو ۶) رسم شده است، نیز به ترتیب نشانگر دقت بالای سناریو ششم مدل MLP6 نسبت به مدل SVR6 و SVR-FFA6 می‌باشد.



شکل (۴) : نمودارهای تیلور و پراکنش مقادیر تبخیر روزانه برای بهترین مدل در میان تمام سناریوها

#### نتیجه‌گیری

پیش‌بینی تبخیر برای محققان از اهمیت خاصی برخوردار است، از این‌رو محققان روش‌های مختلفی جهت بهبود عملکرد مدل‌های پیش‌بینی ارائه نموده‌اند. برای پیش‌بینی تبخیر، علی‌رغم اهمیت فراوان این مؤلفه در درک تعادل آب در حوزه‌های آبخیز، متأسفانه مطالعات کمی در مورد استفاده از الگوریتم‌های ترکیبی مانند SVR-FFA انجام شده است. در این پژوهش با استفاده از روش‌های SVR و MLP، در ایستگاه تکاب مقادیر تبخیر روزانه در طی دوره آماری ۲۰۰۲-۲۰۲۰ برآورد گردید. نتایج بدست آمده با استفاده از پارامترهای آماری مورد مقایسه قرار گرفت و مشخص شد که سناریو ششم مدل MLP بهترین عملکرد را با کمترین خطأ (۲/۱۸) نسبت به تمامی مدل‌ها ارائه داد. همچنین نتیجه گرفته شد که سناریو ششم مدل SVR-FFA خطای کمتری (۲/۲) را نسبت به سایر مدل‌ها داشته و عملکرد بهتری از خود نشان داد. در بین سناریوهای مدل SVR نیز سناریو ششم مدل SVR کمترین خطأ را (۲/۲۷)، نسبت به سایر ترکیبات SVR از خود نشان داد. در حالت کلی سناریو ششم مدل ترکیبی MLP در پیش‌بینی مقادیر تبخیر روزانه نتایج مناسبی را ارائه داد و برای برنامه‌ریزی‌های آبیاری و مدیریت منابع آب پیشنهاد گردید.

#### تشکر و قدردانی

به این وسیله نویسنده‌گان مقاله مراتب تقدیر و تشکر خود را از سازمان هوشناسی کشور در دریافت آمار و اطلاعات دقیق ابراز می‌نمایند.

#### منابع

- Aljanabi Q. A., Chik Z., Allawi M. F., El-Shafie A. H., Ahmed A. N. and El-Shafie A. (2018). *Support vector regression-based model for prediction of behavior stone column parameters in soft clay under highway embankment*. Neural Computing and Applications, 30(8), 2459-2469.
- Allen R. G., Pereira L. S., Raes D. and Smith M. (1998). *Crop evapotranspiration-Guidelines for computing crop water requirements*-FAO Irrigation and drainage paper 56. FaO, Rome, 300(9), D05109 .
- Chau K. W. (2007). *A split-step particle swarm optimization algorithm in river stage forecasting*. Journal of Hydrology, 346(3-4), 131-135 .

4. Chen H., Huang J. J., and McBean E. (2020). *Partitioning of daily evapotranspiration using a modified shuttleworth-wallace model, random Forest and support vector regression*, for a cabbage farmland. Agricultural Water Management, 228, 105923 .
5. Chen J. L., Yang H., Lv M. Q., Xiao Z. L., and Wu S. J. (2019). *Estimation of monthly pan evaporation using support vector machine in Three Gorges Reservoir Area, China*. Theoretical and Applied Climatology, 138(1), 1095-1107 .
6. Chen R., Liang C. Y., Hong W. C., and Gu D. X. (2015). *Forecasting holiday daily tourist flow based on seasonal support vector regression with adaptive genetic algorithm*. Applied Soft Computing, 26, 435-443 .
7. Cheng-Ping Z., Chuan L., and Hai-wei G. (2011) .*Research on Hydrology Time Series Prediction Based on Grey Theory and [epsilon]-Support Vector Regression*. International Conference on Computer Distributed Control and Intelligent Environmental Monitoring.
8. Danandeh Mehr A., Nourani V., Karimi Khosrowshahi V. and Ghorbani M. A. (2019). *A hybrid support vector regression-firefly model for monthly rainfall forecasting*. International Journal of Environmental Science & Technology (IJEST), 16. (1).
9. Dehghani A., Piri M., Hesam M. and Dehghani N. (2010). *Estimation of Daily Pan Evaporation By Using MLP, RBf and Recurrent Neural Networks* .
10. Fan J., Baumgartl T., Scheuermann A. and Lockington D. A. (2015). *Modeling effects of canopy and roots on soil moisture and deep drainage*. Vadose Zone Journal, 14. (2).
11. Feng Y., Cui N., Zhao L., Hu X. and Gong D. (2016). *Comparison of ELM, GANN, WNN and empirical models for estimating reference evapotranspiration in humid region of Southwest China*. Journal of Hydrology, 536, 376-383 .
12. Fister I., Fister Jr I., Yang X. S. and Brest J. (2013). *A comprehensive review of firefly algorithms*. Swarm and Evolutionary Computation, 13, 34-46 .
13. Gardner M. W. and Dorling S. (1998). *Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences*. Atmospheric environment, 32(14-15), 2627-2636 .
14. Gholami V., Chau K. W., Fadaee F., Torkaman J. and Ghaffari A. (2015). *Modeling of groundwater level fluctuations using dendrochronology in alluvial aquifers*. Journal of Hydrology, 529, 1060-1069 .
15. Ghorbani M. A., Shamshirband S., Haghie D. Z., Azani A., Bonakdari H. and Ebtehaj I. (2017). *Application of firefly algorithm-based support vector machines for prediction of field capacity and permanent wilting point*. Soil and Tillage Research, 172, 32-38.
16. Hagan M. T. and Menhaj M .B. (1994). *Training feedforward networks with the Marquardt algorithm*. IEEE transactions on Neural Networks, 5(6), 989-993 .
17. Isazadeh M., Shirzad M. and Rezaei Banafsheh M. (2017). *Evaluation of the Performance of Artificial Neural Network and Support Vector Machine Models in Estimation of Daily Evaporation amounts (Case study: Tabriz and Maragheh Synoptic Stations)*. Physical Geography Research Quarterly. 168-151, 49(1).
18. Keshtegar B., Allawi M. F., Afan H. A. and El-Shafie A. (2016). *Optimized river stream-flow forecasting model utilizing high-order response surface method*. Water Resources Management, 30(11), 3899-3914.
19. Kim I. S., Son J. S., Park C. E., Kim I. and Kim H. (2005). *An investigation into an intelligent system for predicting bead geometry in GMA welding process*. Journal of Materials Processing Technology, 159(1), 113-118 .
20. Kisi O. (2016). *Modeling reference evapotranspiration using three different heuristic regression approaches*. Agricultural Water Management, 169, 162-172 .
21. Kişi O. (2009). *Modeling monthly evaporation using two different neural computing techniques*. Irrigation Science, 27(5), 417-430 .
22. Kisi O., Genc O., Dinc S. and Zounemat-Kermani M. (2016). *Daily pan evaporation modeling using chi-squared automatic interaction detector, neural networks, classification and regression tree*. Computers and Electronics in Agriculture. 117-112, 122.
23. Kisi O., Shiri J., Karimi S., Shamshirband S., Motamed S., Petković D. and Hashim R. (2015). *A survey of water level fluctuation predicting in Urmia Lake using support vector machine with firefly algorithm*. Applied Mathematics and Computation, 270, 731-743 .
24. KumarSrivastava A. and Singh H. (2016). *An enhance firefly algorithm for flexible job shop scheduling*. International Journal of Computer Applications, 6(5), 1-17 .

25. Marichelvam M. and Geetha M. (2014). *Solving tri-objective multistage hybrid flow shop scheduling problems using a discrete firefly algorithm*. International Journal of Intelligent Engineering Informatics, 2(4), 284-303 .
26. Moazenzadeh R., Mohammadi B., Shamshirband S. and Chau K. W. (2018). *Coupling a firefly algorithm with support vector regression to predict evaporation in northern Iran*. Engineering Applications of Computational Fluid Mechanics, 12(1), 584-597 .
27. Mosavi A., Bathla Y. and Varkonyi-Koczy A. (2017). *Predicting the future using web knowledge: state of the art survey*. International conference on global research and education.
28. Nait Amar M. and Zeraibi N. (2019). *A combined support vector regression with firefly algorithm for prediction of bottom hole pressure*. SN Applied Sciences, 2(1), 23. <https://doi.org/10.1007/s42452-019-1835-z>
29. Nasri M. Modarrs R. and Dastoorani M. (2010). *Validation of ANN model of rainfall-runoff relationship in Zaynderood Dam Watershed*. Journal of Watershed Researches, 88, 17-26 .
30. Osaba E., Yang X. S., Diaz F., Onieva E., Masegosa A. D. and Perallos A. (2017). *A discrete firefly algorithm to solve a rich vehicle routing problem modelling a newspaper distribution system with recycling policy*. Soft Computing, 21(18), 5295-5308 .
31. Rahimikhoob A. (2009). *Estimating daily pan evaporation using artificial neural network in a semi-arid environment*. Theoretical and Applied Climatology, 98(1), 101-105 .
32. Sharifi R., Moore F., Mohammadi Z. and Keshavarzi B. (2016). *Estimation of deepwater temperature and hydrogeochemistry of springs in the Takab geothermal field, West Azerbaijan, Iran*. Environmental monitoring and assessment, 188(1), 75 .
33. Shirgure P. S. and Rajput G. (2012). *Prediction of daily pan evaporation using neural networks models*. Scientific Journal of Agricultural, 1(5), 126-137
34. Shirsath P. B. and Singh A. K. (2010). *A comparative study of daily pan evaporation estimation using ANN, regression and climate based models*. Water Resources Management, 24(8), 1571-1581 .
35. Wang S., Lian J., Peng Y., Hu B., and Chen H. (2019). *Generalized reference evapotranspiration models with limited climatic data based on random forest and gene expression programming in Guangxi, China*. Agricultural Water Management, 221, 220-230 .
36. Yang X. S. (2009). *Firefly algorithms for multimodal optimization*. International symposium on stochastic algorithms.
37. Yang X. S. and He X. (2013). *Firefly algorithm: recent advances and applications*. International journal of swarm intelligence, 1(1), 36-50 .
38. Yu T., Cui N., Zhang Q. and Hu X. (2019). *Applicability evaluation of daily reference crop evapotranspiration models in Northwest China*. Journal of Drainage and Irrigation Machinery Engineering, 37(8), 710-717 .
39. Zhang Z., Gong Y. and Wang Z. (2018). *Accessible remote sensing data based reference evapotranspiration estimation modelling*. Agricultural Water Management, 210, 59-69 .

## Prediction of daily evaporation using hybrid support vector regression-firefly optimization algorithm and multilayer perceptron

Milad Sharafi<sup>1</sup>, Saeed Samadianfard<sup>2</sup>

1. \*M.Sc. Student, Department of Water Engineering, Faculty of Agriculture, Urmia University.
2. Associate Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz.

Received: 2021/12

Accepted: 2022/05

### Abstract

Prediction of daily evaporation is a valuable and determinant tool in sustainable agriculture and hydrological issues, especially in the design and management of water resources systems. Therefore, in this study, the ability of artificial intelligence models of multi-layer perceptron (MLP), support vector regression (SVR), and the hybrid model of support vector regression-firefly optimization algorithm (SVR-FFA), to predict daily evaporation at Takab Station during the period 2002-2020 based on four statistical criteria have been assessed. In all three models, the best scenario was the model whose input included the parameters of average temperature, minimum temperature, maximum temperature, average relative humidity, minimum relative humidity, maximum relative humidity, wind speed, and sunny hours. Among the input parameters, the sunny hours was one of the effective components on the evaporation prediction, which reduced the errors in all models. The results showed that the sixth scenario of the MLP model provided the best performance with the least error (2.18) compared to other models. It was also concluded that the sixth scenario of the SVR-FFA model had a lower error (2.20) than the other models. Among the SVR model scenarios, the sixth scenario showed the lowest error (2.27) compared to other SVR combinations. The results of this study showed that the sixth scenario of the MLP model had the best performance and the hybrid firefly algorithm improved the performance of support vector regression in estimating daily evaporation.

**Keywords:** Prediction, Evaporation, Firefly algorithm, Support vector regression

<sup>1</sup> \*Corresponding Author Email: miladsharafi1@gmail.com