

مطالعه مقایسه‌ای با استفاده از روش داده‌محور در مقابل رویکرد ترکیبی در جهت برآورد تبخیر-تعرق مرجع روزانه در اهواز

میلاذ شرفی^{۱*}، سینا بشارت^۲ و کامران زینال زاده^۳

*۱- نویسنده مسئول، دانشجوی دکتری تخصصی، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، st_m.sharafi@urmia.ac.ir

۲- دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه.

۳- دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه.

دریافت:

بازنگری:

پذیرش:

چکیده

پیش‌بینی تبخیر-تعرق مرجع روزانه یک ابزار تعیین‌کننده و مفید در کشاورزی پایدار و مسائل هیدرولوژیک، به‌ویژه در طراحی و مدیریت سیستم‌های منابع آب می‌باشد. استفاده از مدل‌های هیبریدی با کمک عوامل اقلیمی روشی مؤثر در فرآیند پیش‌بینی تبخیر-تعرق مرجع روزانه است. بنابراین، در این مطالعه توانایی مدل رگرسیون بردار پشتیبان (SVR) و مدل ترکیبی رگرسیون بردار پشتیبان با الگوریتم مگس میوه (SVR-FOA) در برآورد تبخیر-تعرق مرجع روزانه در ایستگاه اهواز، طی دوره ۲۰۲۲-۲۰۰۰ با استفاده از چهار معیار آماری مورد ارزیابی قرار گرفت. ورودی‌های مورد استفاده شامل پارامترهای میانگین دما، حداقل دما، حداکثر دما، متوسط رطوبت نسبی، حداقل رطوبت نسبی، حداکثر رطوبت نسبی، سرعت باد و ساعات آفتابی بود. آنالیز حساسیت پارامترهای ورودی با استفاده از ضریب همبستگی پیرسون نیز نشان داد که در میان پارامترهای ورودی، پارامتر ساعات آفتابی و رطوبت نسبی از مؤلفه‌های مؤثر بر پیش‌بینی تبخیر بودند به طوری که تأثیر مستقیمی روی مقدار تبخیر روزانه داشته و باعث کاهش خطا در تمام مدل‌ها گردیدند. نتایج به‌دست آمده نشان داد که سناریو ششم مدل SVR-FOA بهترین عملکرد را با کمترین خطا ($1/24$ mm/day) نسبت به تمامی مدل‌ها ارائه داد. در بین سناریوهای مدل SVR نیز سناریو سوم مدل SVR کمترین خطا را ($1/45$ mm/day)، نسبت به سایر ترکیبات SVR از خود نشان داد. نتایج حاصل از این پژوهش نشان داد که سناریو ششم مدل SVR-FOA بهترین عملکرد را داشته و نیز الگوریتم هیبریدی مگس میوه باعث بهبود عملکرد رگرسیون بردار پشتیبان در برآورد تبخیر-تعرق مرجع روزانه گردید.

کلید واژه‌ها: پیش‌بینی، بهینه‌سازی، الگوریتم مگس میوه، رگرسیون بردار پشتیبان، اهواز.

مقدمه

لذا، توسعه روش‌های مختلف بهبود یافته برای پیش‌بینی این متغیر بسیار مهم برای محققان از اهمیت ویژه‌ای برخوردار است (Ghumman et al., 2021). تخمین تبخیر-تعرق مرجع با استفاده از مدل‌سازی، در مطالعه‌های پیشین به کار رفته و نتایج مناسبی را ارائه کرده است (Allawi et al., 2019). به عبارت دیگر، تخمین دقیق تبخیر-تعرق مرجع به بسیاری از جنبه‌ها از جمله مسائل آبیاری و زهکشی، به‌ویژه در مناطق خشک کمک می‌کند (Huang et al., 2019).

با توجه به پیچیدگی سیستم‌های هیدرولوژیک، مدل‌سازی کامل سیستم‌های هیدرولوژیک بسیار پیچیده است (Eslamian and Eslamian, 2022; Mashaly and Fernald, 2020). علاوه بر این، وجود عدم قطعیت در تغییرات اقلیمی آبی، مدل‌سازی و دست‌یابی به تغییرات احتمالی آینده را مهم می‌سازد. در چنین شرایطی، استفاده از مدل‌سازی مبتنی بر روابط ریاضی و مدل‌های مبتنی بر داده سودمند است (Kisi et al., 2016). یکی از مدل‌های قابل دسترس، رگرسیون بردار پشتیبان (Support vector regresion) است که در مطالعه‌های مختلفی استفاده شده است (El Bilali et al., 2023; Shabani et

تبخیر-تعرق به‌عنوان یکی از مهم‌ترین پارامترها در علم هواشناسی و منابع آب محسوب می‌شود (Sun et al., 2021b). نرخ تبخیر-تعرق مرجع یک معیار اساسی است که می‌تواند برای استخراج پارامترهای مختلف هواشناسی مورد استفاده قرار گیرد (Allen et al., 2011). بنابراین برآورد دقیق تبخیر-تعرق مرجع یکی از مهم‌ترین کارهایی است که منجر به مدیریت بهتر منابع آب و رفع بسیاری از چالش‌های مهندسی آب می‌شود (Wanniarachchi and Sarukkalige, 2022). با توجه به اهمیت تبخیر-تعرق مرجع و میزان تأثیرگذاری زیاد آن بر منابع آب شیرین کشور و تغییرات اقلیمی که سبب افزایش گرما و در نهایت موجب افزایش تبخیر-تعرق مرجع شده و کاهش منابع آب شیرین اعم از ذخایر زیرزمینی و سطحی را به‌دنبال داشته است، پیش‌بینی دقیق میزان تبخیر-تعرق مرجع امری ضروری به‌نظر می‌رسد. متغیرهای مختلف هواشناسی، مانند تابش خورشیدی، دمای هوا، رطوبت نسبی و سرعت باد، می‌توانند به طور تعاملی بر مؤلفه تبخیر-تعرق مرجع تأثیر بگذارند (Yan et al., 2019).

(al., 2020)، در مطالعه‌ای (Chen et al., 2019)، به برآورد تبخیر-تعرق با استفاده از ماشین بردار پشتیبان در منطقه‌ای در چین پرداختند، نتایج نشان داد که روش SVR جایگزینی امیدوارکننده، برای رویکردهای سنتی در برآورد تبخیر-تعرق از متغیرهای اندازه‌گیری شده هواشناسی خواهد بود. Baydaroğlu و Koçak (2014) در تحقیقی به پیش‌بینی تبخیر-تعرق با استفاده از رویکردهای مبتنی بر داده پرداختند. نتایج این بررسی نشان داد که مدل SVR به دلیل قابلیت تعمیم خوب و با ضرایب تعیین بالا به ترتیب ۸۳ و ۹۷ درصد برای پیش‌بینی مقادیر تبخیر-تعرق انتخاب شد. Guan et al. (2020) در مطالعه‌ای با استفاده از مدل رگرسیون بردار پشتیبان ترکیب شده با الگوریتم گله کرپل (Krill Herd) به پیش‌بینی تبخیر-تعرق روزانه در مناطق ساحلی ایران پرداختند. برای انجام این مطالعه داده‌های هواشناسی از سه ایستگاه ساحلی در بازه زمانی ۱۳۸۷-۱۳۹۷ جمع‌آوری و مورد استفاده قرار گرفت. نتایج این مطالعه نشان داد که عملکرد مدل‌های SVR و SVR-KHA (با داشتن ضریب تعیین به ترتیب ۰/۸۲ و ۰/۸۴ در ایستگاه بندرعباس و ۰/۸۸ و ۰/۹ در ایستگاه رودسر) در ایستگاه‌های بندرعباس و رودسر مشابه یکدیگر بودند. Singh و Kumar (2022) در مطالعه‌ای به مدل‌سازی هفتگی تبخیر مرجع با استفاده از مدل‌های رگرسیونی و روش‌های مبتنی بر درخت برای ایستگاه Ranichauri واقع در منطقه هیمالیا، هند پرداختند. نتایج این مطالعه نشان داد که بالاترین مقدار ضریب تعیین به میزان ۰/۹ برای مدل SVR برای دوره آزمون بوده و لذا مدل SVR بهترین پیش‌بینی تبخیر مرجع را برای منطقه Ranichauri ارائه داد.

در سال‌های اخیر الگوریتم‌های هیبریدی به‌علت داشتن دقت بالا در مطالعه‌های متعددی بکار برده شده‌اند. Arya Azar et al. (2021) در تحقیقی به پیش‌بینی تبخیر ماهانه از مخازن سد درودزن واقع در استان فارس با استفاده از رگرسیون بردار پشتیبان حداقل مربعات و سیستم استنتاج عصبی فازی تطبیقی بهینه‌سازی شده با الگوریتم هریس‌هاکس (Harris hawk) پرداختند. نتایج این تحقیق نشان داد که الگوریتم هیبریدی با داشتن مقدار خطای ۲/۳۵ میلی‌متر برترین عملکرد را نسبت به سایر مدل‌ها داشته است. Malik et al. (2021) در مطالعه‌ای تبخیر-تعرق روزانه را در مناطق مختلف زراعی واقع در شمال هند با استفاده از رگرسیون بردار پشتیبان بهینه‌سازی شده توسط الگوریتم ازدحام سالپ (Salp swarm algorithm) با آزمون گاما پیش‌بینی کردند. نتایج این مطالعه نشان داد که مدل هیبریدی با داشتن مقدار خطای ۱/۱۲ میلی‌متر به عنوان مدلی قابل اعتماد برای پیش‌بینی تبخیر-تعرق روزانه در شمال هند انتخاب شد. Tikhmarine et al. (2020) در تحقیقی به تخمین تبخیر-تعرق مرجع ماهانه با استفاده از رگرسیون بردار پشتیبان ترکیب شده با الگوریتم بهینه‌سازی نهنگ (Whale optimization algorithm) در ایستگاه‌های هواشناسی الجزایر و تلمسان واقع در

شمال الجزایر پرداختند. نتایج این تحقیق نشان داد که مدل ترکیبی به‌کار رفته کمترین میزان خطا را داشته و با داشتن عملکرد مناسب در شمال الجزایر به‌عنوان کارآمدترین مدل شناخته شد. Mirzania et al. (2023) در مطالعه‌ای به پیش‌بینی تبخیر-تعرق مرجع با استفاده از الگوریتم ترکیبی مدل رگرسیون برداری نوآورانه پشتیبانی توپچی (Innovative gunner) ترکیب شده با رگرسیون بردار پشتیبان در دو شرایط اقلیمی مرطوب و خشک در استرالیا پرداختند. نتایج این مطالعه نشان داد که مدل ترکیبی با داشتن ضریب همبستگی ۰/۹ پیش‌بینی‌های دقیقی را در هر دو ایستگاه ارائه کرد.

الگوریتم بهینه‌سازی مگس میوه (Fruit fly) به‌عنوان یکی از الگوریتم‌های ابداعی برای بهینه‌سازی استفاده می‌شود و به دلیل دقت بالا در کاربردهای مختلف بهینه‌سازی، مانند مسائل بهینه‌سازی پیوسته جهانی، توانسته است توجه بسیاری را به خود جلب کند (Wu et al., 2020). در مطالعه‌ای برای ارزیابی دقت SVR بهینه‌شده با FOA در پیش‌بینی جریان رودخانه در دو ایستگاه حوضه دریاچه ارومیه، SVR-FOA به‌عنوان روشی دقیق برای تخمین جریان رودخانه پیشنهاد شد (Samadianfard et al., 2019). در مطالعه دیگری، FOA برای بهینه‌سازی پیش‌بینی‌های داده‌های هواشناسی در جبهه النصره انجام شد و نتایج نشان داد که مدل‌های پیشنهادی در فصول مختلف با دقت بالایی انجام می‌شوند و به‌خوبی با شرایط اقلیمی پیچیده سازگار هستند (Ruiming and Shijie, 2020). لذا، استفاده از الگوریتم‌های بهینه‌سازی به جهت دقت بالای آن‌ها برای تخمین تبخیر-تعرق مرجع بیش از پیش ضرورت می‌یابد. زیرا تبخیر-تعرق مرجع یکی از اصلی‌ترین پارامترهای هواشناسی به‌ویژه در مناطق خشک و نیمه‌خشک مانند ایران است و بنابراین پیش‌بینی دقیق آن از اهمیت بالایی برخوردار است.

هدف این تحقیق ارزیابی عملکرد SVR بهینه شده با FOA در برآورد تبخیر-تعرق مرجع روزانه ایستگاه اهواز واقع در استان خوزستان می‌باشد. با توجه به اقلیم گرم و نیمه‌بیابانی اهواز و کمبود روزافزون منابع آبی پیش‌بینی دقیق تبخیر-تعرق مرجع روزانه در این ایستگاه بیش از پیش اهمیت پیدا می‌کند. نکته قابل توجه اینست که مدل هیبریدی SVR-FOA برای اولین بار در این تحقیق برای پیش‌بینی مقادیر تبخیر-تعرق مرجع روزانه مورد استفاده قرار می‌گیرد. بررسی مطالعه مطالعه‌های پیشین نشان داده که مدل SVR-FOA تاکنون برای تخمین تبخیر-تعرق مرجع روزانه استفاده نشده است. همچنین از محدودیت‌های مطالعه حاضر می‌توان به عدم دسترسی به داده‌های دمای نقطه شبنم برای به‌کارگیری در ورودی مدل‌ها اشاره کرد.

مواد و روش‌ها

منطقه مورد مطالعه

مدیریت بر منابع و کشاورزی خواهد گردید. شکل (۱) نقشه موقعیت جغرافیایی ایستگاه اهواز را نشان می‌دهد.

در این مطالعه برای ایجاد مدل‌هایی برای پیش‌بینی تبخیر-تعرق، از ۷۰ درصد داده‌ها (۱۳۸۰ داده) برای آموزش و ۳۰ درصد از [داده] (۵۶۷ داده) برای مرحله آزمون به‌طور تصادفی استفاده گردید. همچنین داده‌های پرت نیز به‌علت ایجاد خطا در صحت نتایج، از مجموع داده‌های مورد استفاده حذف گردید. جدول (۱) پارامترهای آماری روزانه داده‌های آموزش و آزمون مورد استفاده در طی دوره آماری را نشان می‌دهد. همچنین جدول (۲) نیز سناریوهای مختلفی را که به‌عنوان 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 حداقل (RH_{avg})، حداقل رطوبت نسبی (RH_{min})، حداکثر رطوبت نسبی (RH_{max})، سرعت باد (U)، ساعات آفتابی (SSH) به‌عنوان پارامترهای ورودی و تبخیر-تعرق مرجع روزانه (E) به‌عنوان پارامتر هدف می‌باشند. نحوه انتخاب ترکیبات مختلف ورودی، برای تخمین مقدار تبخیر-تعرق مرجع روزانه در مدل‌های مورد مطالعه براساس داشتن همبستگی بالاتر نسبت به سایر ترکیبات، صورت گرفته است.

در تحقیق حاضر مقادیر تبخیر-تعرق مرجع روزانه در طی دوره آماری ۲۲ ساله در سال‌های ۲۰۰۰-۲۰۲۲ در ایستگاه اهواز در نظر گرفته شد. این ایستگاه در موقعیت جغرافیایی ۳۱ درجه و ۲۰ دقیقه عرض شمالی و ۴۸ درجه و ۴۴ دقیقه طول شرقی، در بخش جلگه‌ای خوزستان و با ارتفاع ۱۲ متر از سطح دریا، در جنوب غربی کشور و مرکز استان خوزستان واقع شده‌است. میانگین بارش سالانه در این شهرستان حدود ۲۳۰ میلی‌متر است (Asadifard and Masoudi, 2018). با در نظر گرفتن میانگین بارش سالانه، با توجه به روش طبقه‌بندی اقلیمی دومارتن، اهواز در گروه رژیم بارانی نیمه‌بیابانی یا نیمه‌خشک قرار می‌گیرد. در حالی که افزایش بارندگی و سیل، خسارت‌های فراوان در پی دارد، اما این کاهش بارندگی و خشکسالی است که بحران خوانده می‌شود و بیش از خسارت‌های سیل، نگاه‌ها را به خود معطوف می‌کند تا جایی که در سال جاری، کم‌آبی خوزستان که میزبان بزرگ‌ترین رودخانه‌های ایران است، به موضوعی ملی تبدیل شد تا به تصمیم‌گیری‌های کلان بینجامد. این در حالی است که در خوزستان به روش‌های آبخیزداری نیز چندان توجهی نشده و همین امر، پتانسیل لازم را برای مدیریت کم‌آبی ایجاد نکرده است. لذا پیش‌بینی صحیح تبخیر-تعرق مرجع باعث بهبود

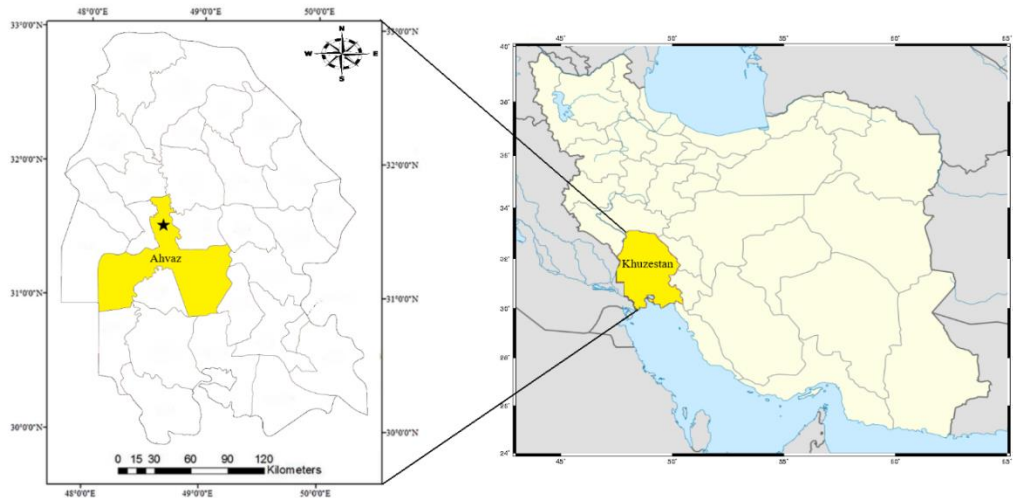


Fig. 1- Map of the geographical location of Ahvaz station (black star)

شکل ۱- نقشه موقعیت جغرافیایی ایستگاه اهواز (ستاره سیاه رنگ)

جدول ۱- پارامترهای آماری روزانه داده‌های مورد استفاده در دوره آزمون

Table 1- Daily statistical parameters of the data used in the test period

Parameter	U2	SSH	RH	T_{avg}	E
Unit	(m/s)	(hr)	(%)	($^{\circ}C$)	(mm)
Average	1.99	7.18	54.81	17.07	3.54
Minimum	0.25	0	19	5.3	0.2
Maximum	6.5	11.4	91.25	29.7	10.8
Standard deviation	0.97	3.29	13.51	4.01	1.76

جدول ۲- ترکیب‌های مختلف ورودی، برای تخمین مقدار تبخیر-تعرق مرجع روزانه در مدل‌های مورد مطالعه
 Table 2- Different input combinations to estimate the amount of daily evaporation in the studied models

Scenario	parameters Input							Output
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}	U2	E
6	T_{avg}	T_{min}	T_{max}	RH_{avg}	RH_{min}	RH_{max}	U2 SSH	E

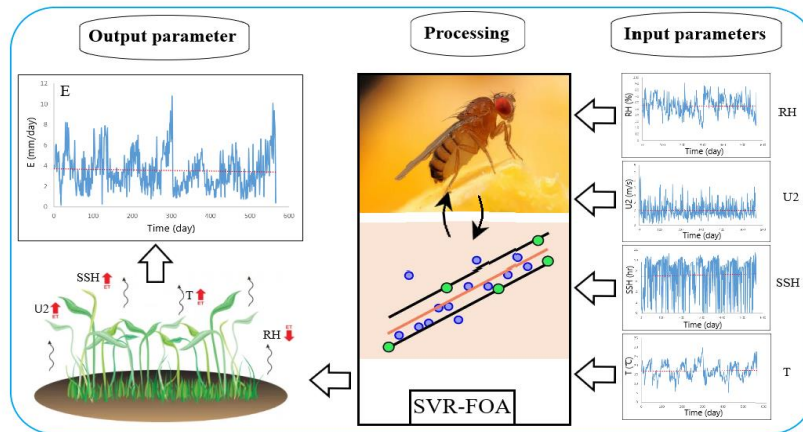


Fig. 2- Schematic of the research

شکل ۲- نمای کلی تحقیق




Fig 3- The heat map of the used parameters

شکل ۳- نقشه گرمایی پارامترهای مورد استفاده

شکل (۳) نقشه گرمایی پارامترهای مورد استفاده را بر اساس ضریب همبستگی پیرسون نشان می‌دهد. با توجه به شکل (۳) سفیدتر شدن رنگ نقشه نشان از همبستگی بالای پارامترها بوده و سیاه‌تر شدن رنگ نقشه نشان‌دهنده کاهش همبستگی پارامترها می‌باشد. مقایسه همبستگی بین پارامترهای ورودی نشان می‌دهد که پارامتر دما بیش‌ترین همبستگی را با مقدار تبخیر-تعرق مرجع روزانه داشته است. پارامتر T_{ave} مقدار 0.61 همبستگی را با مقدار تبخیر-تعرق مرجع روزانه داشته است.

آنالیز حساسیت با استفاده از ضریب همبستگی پیرسون بین پارامترهای مورد استفاده به‌عنوان یکی از روش‌های تعیین همبستگی پارامترها نسبت به یکدیگر بوده و در مطالعه‌های (Ahmadi et al., 2020; Saltelli et al., 2019). شکل (۲) نمای کلی مطالعه حاضر را بر اساس پارامترهای ورودی و خروجی نشان می‌دهد. خط نقطه چین قرمز رنگ نیز نشانگر میانگین هر پارامتر می‌باشد.

رگرسیون بردار پشتیبان (SVR)

SVR برای طبقه‌بندی و تجزیه و تحلیل مشکلات رگرسیون استفاده می‌شود. این روش توسط Vapnik و Chervonenkis (1974) ارائه شد. SVR بر اساس طبقه‌بندی مضاعف در فضای ویژگی‌های مورد نظر استفاده می‌شود و به‌طور گسترده در مسائل پیش‌بینی استفاده می‌شود (Jha and Hayashi, 2014; Yoon et al., 2011). روش SVR می‌تواند مقادیر را با توجه به مجموعه داده‌های داده‌شده $(x_i, y_i) \times n$ پیش‌بینی کند، جایی که x_i نشان‌دهنده داده‌های ورودی، y_i نشان‌دهنده مقدار خروجی (تبخیر-تعرق)، و n مقدار کل داده‌های مورد استفاده بود. معادله رگرسیون خطی به‌صورت زیر است:

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

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

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

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

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

الگوریتم بهینه‌سازی مگس میوه (FOA)

Pan (2012) برای اولین بار الگوریتم بهینه‌سازی مگس میوه (FOA) را ارائه نمود. این الگوریتم ساده و روان، بخشی از چالش‌های مرتبط با دشواری‌های الگوریتم‌های پیشین را برطرف نموده است. این الگوریتم مشابه بسیاری از الگوریتم‌های فراابتکاری دیگر که بر اساس الهام از طبیعت طراحی شده‌اند، مبتنی بر رفتار طبیعی موجودات است. مگس میوه پس از اینکه بوی میوه را در هوا احساس کرد به موقعیت میوه نزدیک می‌شود. این حشره با استفاده از حس بینایی خود، موقعیت دقیق میوه را می‌یابد. این الگوریتم از چندین مرحله تشکیل شده که در زیر به شرح آن پرداخته می‌شود (Pan, 2012; Shan et al., 2013).

الف- فرض می‌شود که موقعیت مگس میوه به‌صورت تصادفی مقداردهی می‌شود.

ب- جهتی تصادفی و مسافتی برای جستجوی غذا با استفاده از حس بویایی مگس تعریف می‌شود:

$$X_1 = X_{axis} + \text{Random value} \quad (4)$$

$$Y_1 = Y_{axis} + \text{Random value} \quad (5)$$

ج- فاصله تا مبدا ($Dist$) و شدت بو (S) محاسبه شده، به طوری که این دو مقدار نسبت عکس با هم دارند.

$$Dist = \sqrt{X_i^2 + Y_i^2} \quad (6)$$

$$S_i = \frac{1}{Dist} \quad (7)$$

د- مقدار شدت بو در تابع برازندگی جایگزین گردیده و سپس شدت بوی موقعیت موجود ($Smell_i$) به‌دست می‌آید.

$$Smell_i = \text{Function}(S_i) \quad (8)$$

ه- یافتن مگس میوه با بیش‌ترین شدت بو (یافتن بیش‌ترین مقدار) صورت می‌پذیرد.

$$(bestSmell \ bestIndex) = \max(Smell) \quad (9)$$

و- اگر شدت بو در هر تکرار بیشتر از مقدار کنونی باشد (رابطه ۱۰)، آنگاه بیش‌ترین مقدار شدت بو و مختصات مگس میوه‌ای که آن شدت بو را حس کرده است ($bestIndex$) نگه داشته شده و در این زمان است که حشره می‌تواند با توجه به قدرت بینایی خود به سمت میوه حرکت کند (روابط ۱۱ و ۱۲).

$$Smell_{best} = bestSmell \quad (10)$$

$$X_{axis} = X(bestIndex) \quad (11)$$

$$Y_{axis} = Y(bestIndex) \quad (12)$$

ز- مراحل "ب" تا "و" از بهینه‌سازی تا رسیدن به شرط توقف تکرار می‌شود.

شکل (۴)، فلوجارت مدل ترکیبی SVR-FOA را نشان می‌دهد. در شکل (۴) پارامتر LR نشانگر ازدحام اولیه مگس میوه، پارامتر FR نشان‌دهنده محدوده پرواز تصادفی هر مگس میوه، $maxgen$ حداکثر تعداد مگس میوه و $sizepop$ بیانگر اندازه جمعیت مگس میوه می‌باشد. در این فلوجارت برای بهینه‌سازی

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

$$NS = 1 - \left[\frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \right] \quad (15)$$

$$WI = 1 - \left[\frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \right] \quad (16)$$

در روابط (۱۳) تا (۱۶)، پارامترهای P_i و O_i به ترتیب مقادیر پیش‌بینی و مشاهداتی می‌باشند.

نتایج و بحث

در این مطالعه، شش ترکیب مختلف از متغیرهای پیش‌بینی کننده 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_2) و ساعات آفتابی (SSH)، به عنوان ورودی مدل‌ها در جدول (۲) در نظر گرفته شد. در این بخش، الگوریتم‌های SVR-FOA و SVR روی شش مجموعه داده برای پیش‌بینی مقادیر تبخیر-تعرق مرجع روزانه استفاده شده است. تطابق بین مقادیر اندازه‌گیری شده و پیش‌بینی شده تبخیر-تعرق مرجع در جدول (۳) از نظر ضریب همبستگی، جذر میانگین مربعات خطا، ضریب نش‌ساتکیف و شاخص توافقی ویلموت، طی مراحل اعتبارسنجی گزارش شده است.

بهتر مقادیر LR بین ۰ تا ۱۰، مقادیر FR بین ۱ تا ۱، مقدار maxgen برابر ۱۰۰ و مقدار sizepop برابر ۲۰ بر اساس آزمون خطا در نظر گرفته شدند.

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

معیارهای ارزیابی مدل

در این پژوهش برای ارزیابی عملکرد سناریوهای مختلف تعریف شده برای روش‌های مورد مطالعه از پارامترهای آماری ضریب همبستگی، **Correlation coefficient**، جذر میانگین مربعات خطا **Root mean squared error**، ضریب نش‌ساتکیف **Nash-Sutcliffe coefficient** و شاخص توافقی ویلموت **Willmott's index of agreement** استفاده شده است. مقدار ضریب همبستگی از بازه ۱ تا -۱ بوده و هرچه این مقدار به یک نزدیک‌تر باشد نشان‌دهنده بالا بودن دقت مدل می‌باشد. مقدار شاخص جذر میانگین مربعات خطا نیز هر چه کمتر باشد نشان از خطای کم مدل و در نتیجه دقت بالای آن می‌باشد. مقدار شاخص‌های ضریب نش‌ساتکیف و شاخص توافقی ویلموت نیز بین یک تا یک منفی بوده و هرچه به یک نزدیک‌تر باشند نشان از دقت بالای مدل خواهد بود.

$$R = \frac{(\sum_{i=1}^N (O_i - \bar{O}) - \frac{1}{N} (P_i - \bar{P}))}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2 \sum_{i=1}^N (P_i - \bar{P})^2}} \quad (13)$$

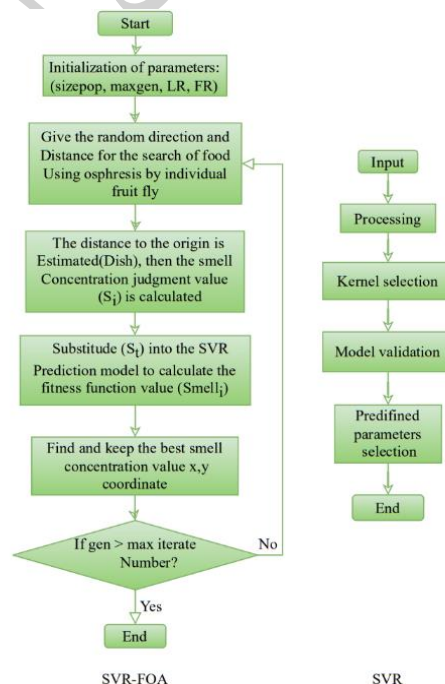


Fig 4- Flowchart used model
شکل ۴- فلوچارت مدل‌های مورد استفاده

مقایسه بین مدل‌های SVR-1 و SVR-FOA-1 (سناریو اول هر مدل) نشان می‌دهد با اینکه مقدار شاخص‌های R، NS و WI در مدل هیبریدی کاهش یافته است اما مقدار شاخص RMSE به میزان ۱۰ درصد کاهش یافته است. همچنین مقایسه بین سناریوهای دوم هر دو مدل حاکی از آنست که مقدار معیار NS از ۰/۱۸ به ۰/۳۸ افزایش یافته است در حالی که سایر معیارها کاهش یافته‌اند. مقایسه بین میزان خطای سناریوهای اول و دوم نشان داد که با افزوده شدن پارامتر T_{min} و T_{max} به ورودی‌ها، در مدل منفرد این پارامتر نه تنها باعث کاهش خطا نشده بلکه سبب افزایش میزان خطا نیز گردید و در مدل هیبریدی نیز میزان خطا ثابت ماند. ارزیابی مدل‌ها در سناریو سوم نیز نشان داد که معیار خطا به میزان ۹/۴ درصد در مدل ترکیبی نسبت به مدل منفرد کاهش یافته است. همچنین ارزیابی بین سناریو دوم و سوم نشان می‌دهد که در هر دو مدل مقدار شاخص خطا کاهش یافته و لذا افزودن پارامتر RH_{avg} سبب افزایش دقت مدل‌ها شده است. برای سناریو چهارم با اینکه مقدار شاخص‌های R و WI تغییر محسوسی نداشتند اما شاخص NS به مقدار ۵۵/۶ درصد افزایش و شاخص RMSE به مقدار ۱۵/۶ درصد کاهش یافته‌اند. مقایسه بین سناریو سوم و چهارم نیز نشان داد که با افزودن پارامتر RH_{min} و RH_{max} در مدل منفرد میزان خطا از ۱/۴۵ به ۱/۵۲ افزایش و در مدل هیبریدی از ۱/۳۲ به ۱/۳ کاهش یافته است. در سناریو پنجم نیز همانند سناریو چهارم مقدار شاخص‌های R و WI تغییر محسوسی نداشتند اما شاخص از ۰/۲۲ در مدل منفرد به ۰/۵ در مدل ترکیبی افزایش یافته و شاخص RMSE از ۱/۵۶ به ۱/۲۵ کاهش یافته است. ارزیابی بین سناریوهای چهارم و پنجم نیز نشان داد که افزودن پارامتر U2 سبب افزایش جزئی در میزان خطا مدل منفرد شده و سبب کاهش جزئی خطا در مدل ترکیبی گردید. در نهایت در سناریو ششم مقدار خطا مدل هیبریدی به میزان ۲۰/۳ درصد نسبت به مدل منفرد کاهش یافته و افزودن پارامتر SSH سبب کاهش مقدار خطا در هر دو مدل گردید.

ارزیابی نتایج نشان داد که سناریو سوم مدل SVR با ضریب همبستگی ۰/۷۱، جذر میانگین مربعات خطا ۱/۴۵ میلی‌متر، ضریب نش‌ساتکلیف ۰/۳۳ و شاخص توافق ویلموت ۰/۸۲ کمترین خطا را نسبت به سایر ترکیبات SVR داراست. دقت بالای این مدل نشان از اهمیت بالای پارامتر رطوبت نسبی در افزایش دقت پیش‌بینی پارامتر تبخیر-تعرق مرجع است. با این حال، سناریو ششم مدل SVR با ضریب همبستگی ۰/۶۹، جذر میانگین مربعات خطا ۱/۵۲ میلی‌متر در روز، ضریب نش‌ساتکلیف ۰/۲۶ و

شاخص توافق ویلموت ۰/۸۲ پس از سناریو سوم مدل SVR، دقت بیش‌تری را نسبت به سایر ترکیبات این مدل در برآورد تبخیر-تعرق مرجع روزانه را ارائه کرد. در میان مدل‌های ترکیبی SVR-FOA نیز سناریو ششم با داشتن ضریب همبستگی ۰/۷۱، جذر میانگین مربعات خطا ۱/۲۴ میلی‌متر در روز، ضریب نش‌ساتکلیف ۰/۵۱ و شاخص توافق ویلموت ۰/۸۲ بالاترین دقت را نسبت به سایر ترکیبات SVR-FOA و تمام سناریوها داراست. علت این امر اضافه‌شدن پارامتر ساعات آفتابی و ورودی‌های مدل می‌باشد. زیرا شهر اهواز به علت ساعات آفتابی زیاد و شدت تابش بالا دارای اقلیم نیمه‌بیابانی بوده و در نتیجه ساعات آفتابی نقشی مؤثر در دقت پیش‌بینی پارامتر تبخیر-تعرق مرجع روزانه دارد. سناریو پنجم مدل SVR-FOA نیز با ضریب همبستگی ۰/۷۲، جذر میانگین مربعات خطا ۱/۲۵ میلی‌متر در روز، ضریب نش‌ساتکلیف ۰/۵ و شاخص توافق ویلموت ۰/۸۱ پس از سناریو ششم مدل SVR-FOA، دقت بیش‌تری را نسبت به سایر ترکیبات این مدل در برآورد تبخیر-تعرق مرجع روزانه ارائه کرد.

در نهایت نتایج این تحقیق با نتایج Sattari et al. (2021) که به برآورد بارندگی ماهانه و فصلی با استفاده از روش‌های داده‌محور و ترکیبی پرداخته و نشان دادند که مدل SVR-FOA با داشتن جذر میانگین مربعات خطا ۱۳/۵۸ میلی‌متر در طول تخمین بارش ماهانه و با داشتن جذر میانگین مربعات خطا ۶/۳۷ میلی‌متر در طول بارش فصلی قادر به تخمین دقیق بارش در منطقه مورد مطالعه است، همچنین نتایج این مطالعه با نتایج Sun et al. (2021) که با استفاده از مدل ترکیبی رگرسیون بردار پشتیبان و الگوریتم بهینه‌سازی مگس میوه به پیش‌بینی هندسه آبستنگی سرریز پرداختند و نشان دادند که مدل SVR-FOA با داشتن ضریب همبستگی ۰/۹۹ به‌طور قابل‌توجهی نتایج رگرسیون بردار پشتیبان را بهبود بخشیده و دقت بالایی را از خود نشان داد، مطابقت دارد.

نمودارهای تیلور و پراکنش مقادیر تبخیر-تعرق مرجع روزانه در شکل (۵) که برای بهترین سناریو برای هر مدل رسم شده است. در نمودار تیلور مقایسه بین دو مدل نشان می‌دهد که مدل SVR-3 ضریب همبستگی یکسانی را با مدل SVR-FOA-6 داشته اما مدل SVR-FOA-6 انحراف از معیار کمتری نسبت به مدل SVR-3 داشته و لذا دارای دقت بیشتری است. همچنین مقایسه مدل‌ها در نمودار پراکنش نیز نشان می‌دهد که هر دو مدل منفرد و هیبریدی مقدار پراکنندگی تقریباً یکسانی را داشته‌اند و ضریب تعیین بین مدل‌ها دارای تغییرات معنی‌دار نمی‌باشد.

جدول ۳- پارامترهای ارزیابی مدل‌های مورد مطالعه در دوره آزمون

Table 3- Evaluation parameters of the studied models in the test period

Model	Evaluation criteria			
	R	RMSE (mm/day)	NS	WI
SVR-1	0.65	1.53	0.25	0.78
SVR-2	0.64	1.60	0.18	0.77
SVR-3	0.71	1.45	0.33	0.82
SVR-4	0.69	1.52	0.26	0.81
SVR-5	0.70	1.56	0.22	0.81
SVR-6	0.69	1.52	0.26	0.82
SVR-FOA-1	0.61	1.39	0.38	0.73
SVR-FOA-2	0.62	1.39	0.38	0.73
SVR-FOA-3	0.68	1.32	0.44	0.79
SVR-FOA-4	0.72	1.30	0.46	0.81
SVR-FOA-5	0.72	1.25	0.50	0.81
SVR-FOA-6	0.71	1.24	0.51	0.82

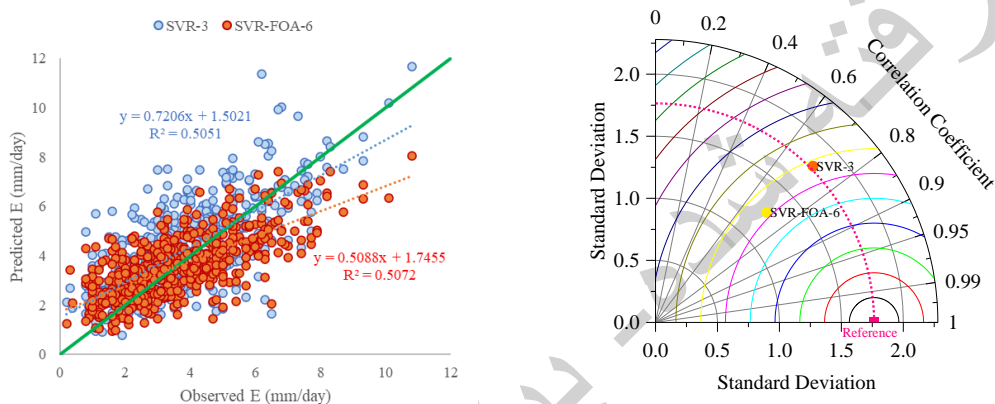


Fig. 5- Taylor diagrams and scatter plots of daily evaporation values for the best scenario in each model

شکل ۵- نمودارهای تیلور و پراکنش مقادیر تبخیر-تعرق مرجع روزانه برای بهترین سناریو در هر مدل

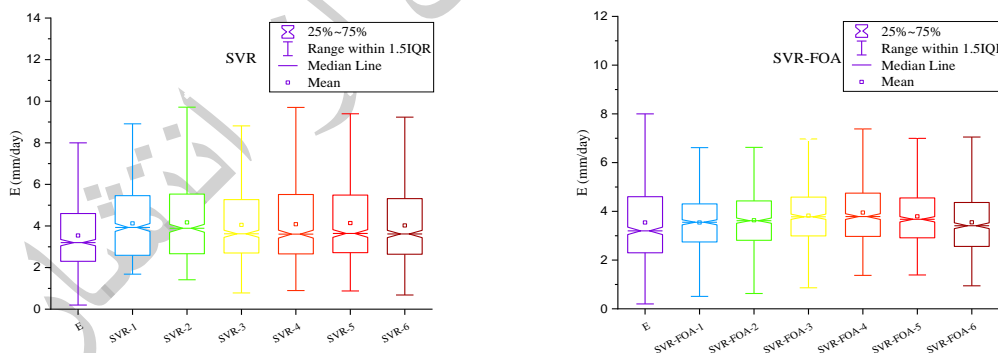


Fig 6- Box plot diagrams of daily evaporation during the test period

شکل ۶- نمودارهای جعبه‌ای تبخیر-تعرق مرجع روزانه در دوره آزمون

سوم بوده و لذا سناریو سوم دقت بالاتری را نسبت به سایر سناریوها داشته است. در مدل SVR-FOA نیز ارزیابی سناریوها نشان می‌دهد که سناریوهای پنجم و ششم عملکرد بهتری نسبت به سایر سناریوها داشته‌اند اما سناریو پنجم دارای بازه کوچک‌تری نسبت به سناریو ششم بوده و لذا سناریو ششم بالاترین دقت را نسبت به سایر سناریوها داشته است.

شکل (۶) نمودارهای جعبه‌ای را برای هر دو مدل SVR و SVR-FOA در تمام سناریوها را نشان می‌دهد. در مدل SVR سناریوهای سوم و ششم، میانگین و بازه مشابه‌تری را نسبت به مقدار واقعی تبخیر-تعرق مرجع در مقایسه با سایر سناریوها داشته‌اند. همچنین مقایسه بین سناریو سوم و ششم نیز نشان داد با اینکه هر دو سناریو دارای بیش برآزش نسبت به مقدار مشاهداتی بودند اما سناریو ششم دارای بیش برآزش بیشتری نسبت به سناریو




Fig 7- Radar charts of the studied models
شکل ۷- نمودارهای راداری مدل‌های مورد مطالعه

شکل (۷) نمودارهای راداری مدل‌های SVR و SVR-FOA در دوره آزمون نشان می‌دهد. برای مدل SVR-3 شاخص‌های R و WI بیشترین مقدار را نسبت به سایر سناریوها دارند در حالیکه شاخص RMSE مقدار کمتری را داشته و در نهایت شاخص NS نیز تقریباً بدون تغییر باقی‌مانده است. همچنین کمترین مقدار شاخص NS نیز مربوط به SVR-2 می‌باشد که نشان می‌دهد این سناریو عملکرد مطلوبی را نداشته است. برای مدل SVR-FOA نیز مقدار معیارهای R، NS و WI در سناریو ششم به بیشترین مقدار رسیده است و معیار خطا نیز کاهش جزئی نسبت به سایر سناریوها داشته است. در مقابل سناریوهای اول و دوم مدل هیبریدی بیشترین مقدار خطا را نسبت به سایر سناریوها داشته و عملکرد ضعیف‌تری را از خود نشان دادند.

نتیجه‌گیری

پیش‌بینی تبخیر-تعرق مرجع برای محققان از اهمیت خاصی برخوردار است، از این‌رو محققان روش‌های مختلفی برای بهبود عملکرد مدل‌های پیش‌بینی ارائه نموده‌اند. برای پیش‌بینی تبخیر-تعرق، علی‌رغم اهمیت فراوان این مؤلفه در درک تعادل آب در حوزه‌های آبخیز، متأسفانه مطالعه‌های کمی در مورد استفاده از الگوریتم‌های ترکیبی مانند SVR-FOA انجام شده است. این

موضوع در مناطق با نرخ تبخیر-تعرق مرجع بالایی مانند اهواز بیش از پیش اهمیت پیدا می‌کند. در این پژوهش با استفاده از روش‌های SVR و SVR-FOA، در ایستگاه اهواز مقادیر تبخیر-تعرق مرجع روزانه در طی دوره آماری ۲۰۲۲-۲۰۰۰ برآورد گردید. نتایج به‌دست آمده با استفاده از پارامترهای آماری مورد مقایسه قرار گرفت و مشخص شد که سناریو ششم مدل SVR-FOA بهترین عملکرد را با کمترین خطا ($1/24$ mm/day) نسبت به تمامی مدل‌ها ارائه داد. در بین سناریوهای مدل SVR نیز سناریو سوم مدل SVR کمترین خطا را ($1/45$ mm/day)، نسبت به سایر ترکیبات SVR از خود نشان داد. در حالت کلی سناریو ششم مدل ترکیبی SVR-FOA در پیش‌بینی مقادیر تبخیر-تعرق مرجع روزانه نتایج مناسبی را ارائه داد و برای پیش‌بینی تبخیر-تعرق مرجع روزانه پیشنهاد گردید.

تشکر و قدردانی

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

References

- 1- **Ahmadi**, M., Sharifi, A., Dorosti, S., Ghoushchi, S.J., Ghanbari, N., 2020. Investigation of effective climatology parameters on COVID-19 outbreak in Iran. *Science of the total environment*, 729, pp. 138705.
- 2- **Aljanabi**, Q., Chik, Z., Allawi, M.F., El-Shafie, A.H., Ahmed, A.N., 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, pp. 2459-2469.
- 3- **Allawi**, M.F., Binti Othman, F., Afan, H.A., Ahmed, A.N., Hossain, M.S., Fai, C.M., El-Shafie, A., 2019. Reservoir evaporation prediction modeling based on artificial intelligence methods. *Water*, 11(6), pp. 1226.
- 4- **Allen**, R.G., Pereira, L.S., Howell, T.A., Jensen, M.E., 2011. Evapotranspiration information reporting: II. Recommended documentation. *Agricultural Water Management*, 98(6), pp. 921-929.

- 5- **Arya** Azar, N., Ghordoyee Milan, S., Kayhomayoon, Z., 2021. Predicting monthly evaporation from dam reservoirs using LS-SVR and ANFIS optimized by Harris hawks optimization algorithm. *Environmental Monitoring and Assessment*, 193, pp. 1-14.
- 6- **Asadifard**, E. and Masoudi, M., 2018. Status and prediction of carbon monoxide as an air pollutant in Ahvaz City, Iran. *Caspian Journal of Environmental Sciences*, 16(3), pp. 203-21.†
- 7- **Baydaroğlu**, Ö. and Koçak, K., 2014. SVR-based prediction of evaporation combined with chaotic approach. *Journal of Hydrology*, 508, pp. 356-363.
- 8- **Chen**, J.-L., Yang, H., Lv, M.-Q., Xiao, Z.-L., 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), pp. 1095-1107.
- 9- **El Bilali**, A., Abdeslam, T., Ayoub, N., Lamane, H., Ezzaouini, M.A., Elbeltagi, A., 2023. An interpretable machine learning approach based on DNN, SVR, Extra Tree, and XGBoost models for predicting daily pan evaporation. *Journal of Environmental Management*, 327, pp. 116890.
- 10- **Eslamian**, S. and Eslamian, F., 2022. Handbook of HydroInformatics: Volume I: Classic Soft-Computing Techniques. Elsevier .
- 11- **Ghumman**, A.R., Jamaan, M., Ahmad, A., Shafiquzzaman, M., Haider, H., Al Salamah, I.S., Ghazaw, Y.M., 2021. Simulation of pan-evaporation using penman and hamon equations and artificial intelligence techniques. *Water*, 13(6), 793.
- 12- **Guan**, Y., Mohammadi, B., Pham, Q.B., Adarsh, S., Balkhair, K.S., Rahman, K.U., Linh, N.T.T., Tri, D.Q., 2020. A novel approach for predicting daily pan evaporation in the coastal regions of Iran using support vector regression coupled with krill herd algorithm model. *Theoretical and Applied Climatology*, 142, pp. 349-367.
- 13- **Huang**, G., Wu, L., Ma, X., Zhang, W., Fan, J., Yu, X., Zeng, W., Zhou, H., 2019. Evaluation of CatBoost method for prediction of reference evapotranspiration in humid regions. *Journal of Hydrology*, 574, pp. 1029-1041.
- 14- **Jha**, S.K. and Hayashi, K., 2014. A novel odor filtering and sensing system combined with regression analysis for chemical vapor quantification. *Sensors and Actuators B: Chemical*, 200, pp. 269-287.
- 15- **Kisi**, O., Genc, O., Dinc, S., 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*, 122, pp. 112-117.
- 16- **Kumar**, P. and Singh, A.K., 2022. A comparison between MLR, MARS, SVR and RF techniques: hydrological time-series modeling. *Journal of Human, Earth, and Future*, 3(1), pp. 90-98.
- 17- **Malik**, A., Tikhamarine, Y., Al-Ansari, N., Shahid, S., Sekhon, H.S., Pal, R.K., Rai, P., Pandey, K., Singh, P., Elbeltagi, A., 2021. Daily pan-evaporation estimation in different agro-climatic zones using novel hybrid support vector regression optimized by Salp swarm algorithm in conjunction with gamma test. *Engineering Applications of Computational Fluid Mechanics*, 15(1), pp. 1075-1094.
- 18- **Mashaly**, A.F. and Fernald, A.G., 2020. Identifying capabilities and potentials of system dynamics in hydrology and water resources as a promising modeling approach for water management. *Water*, 12(5), pp. 1432.
- 19- **Mirzania**, E., Vishwakarma, D.K., Bui, Q.-A.T., Band, S.S., Dehghani, R., 2023. A novel hybrid AIG-SVR model for estimating daily reference evapotranspiration. *Arabian Journal of Geosciences*, 16(5), pp. 1-14.
- 20- **Pan**, W.-T., 2012. A new fruit fly optimization algorithm: taking the financial distress model as an example. *Knowledge-Based Systems*, 26, pp. 69-74.

- 21- **Poluru**, R.K. and Kumar R, L., 2021. An Improved Fruit Fly Optimization (IFFOA) based Cluster Head Selection Algorithm for Internet of Things. *International Journal of Computers and Applications*, 43(7), pp. 623-631.
- 22- **Ruiming**, F. and Shijie, S .,2020 .Daily reference evapotranspiration prediction of Tieguanyin tea plants based on mathematical morphology clustering and improved generalized regression neural network. *Agricultural Water Management*, 236, pp. 106177.
- 23- **Saltelli**, A.,Aleksankina, K.,Becker, W.,Fennell, P.,Ferretti, F.,Holst, N.,Li, S., Wu, Q., 2019. Why so many published sensitivity analyses are false: A systematic review of sensitivity analysis practices. *Environmental modelling & software*, 114, pp. 29-39.
- 24- **Samadianfard**, S.,Jarhan, S.,Salwana, E.,Mosavi, A.,Shamshirband, S., Akib, S., 2019. Support vector regression integrated with fruit fly optimization algorithm for river flow forecasting in Lake Urmia Basin. *Water*, 11(9), pp. 1934.
- 25- **Sattari**, M.T.,Feizi, H.,Samadianfard, S.,Falsafian ,K., Salwana, E., 2021. Estimation of monthly and seasonal precipitation: A comparative study using data-driven methods versus hybrid approach. *Measurement*, 173, pp. 108512.
- 26- **Shabani**, S.,Samadianfard, S.,Sattari, M.T.,Mosavi, A.,Shamshirband, S.,Kmet, T., Várkonyi-Kóczy, A.R., 2020. Modeling pan evaporation using Gaussian process regression K-nearest neighbors random forest and support vector machines; comparative analysis. *Atmosphere*, 11(1), pp. 66.
- 27- **Shan**, D.,Cao, G., Dong, H., 2013. LGMS-FOA: an improved fruit fly optimization algorithm for solving optimization problems. *Mathematical problems in engineering*, 2013, pp .
- 28- Sun, X.,Bi, Y.,Karami, H.,Naini, S.,Band, S.S., Mosavi, A., 2021a. Hybrid model of support vector regression and fruitfly optimization algorithm for predicting ski-jump spillway scour geometry. *Engineering Applications of Computational Fluid Mechanics*, 15(1), pp. 272-291.
- 29- **Sun**, Z.,Zhu, G.,Zhang, Z.,Xu, Y.,Yong, L.,Wan, Q.,Ma, H.,Sang, L., Liu, Y., 2021b. Identifying surface water evaporation loss of inland river basin based on evaporation enrichment model. *Hydrological Processes*, 35(3), pp. e14093.
- 30- **Tikhamarine**, Y.,Malik, A.,Pandey, K.,Sammen, S.S.,Souag-Gamane, D.,Heddam, S., Kisi, O., 2020. Monthly evapotranspiration estimation using optimal climatic parameters: efficacy of hybrid support vector regression integrated with whale optimization algorithm. *Environmental Monitoring and Assessment*, 192, pp. 1-19.
- 31- **Vapnik**, V. and Chervonenkis, A., 1974. Theory of pattern recognition. Nauka, Moscow, pp .
- 32- Wanniarachchi, S. and Sarukkalgige, R., 2022. A review on evapotranspiration estimation in agricultural water management: Past, present, and future. *Hydrology*, 9(7), pp. 123.
- 33- **Wu**, J.,Wang, Y.-G.,Burrage, K.,Tian, Y.-C.,Lawson, B., Ding, Z., 2020. An improved firefly algorithm for global continuous optimization problems. *Expert Systems with Applications*, 149, pp. 113340.
- 34- Yan, Z.,Wang, S.,Ma, D.,Liu, B.,Lin, H., Li, S., 2019. Meteorological factors affecting pan evaporation in the Haihe River Basin, China. *Water*, 11(2), pp. 317.
- 35- **Yoon**, H.,Jun, S.-C.,Hyun, Y.,Bae, G.-O., Lee, K.-K., 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of hydrology*, 396(1-2), pp. 128-138.

EXTENDED ABSTRACT

A comparative study using a data-driven method versus a hybrid approach to estimate daily reference evapotranspiration in Ahvaz

M. Sharafi^{1*}, S. Besharat² and K. Zeinalzadeh³

1* - PhD student, Department of Water Engineering, Faculty of Agriculture, Urmia University, Urmia, Iran. (st_m.sharafi@urmia.ac.ir)

2- Associate Professor, Department of Water Engineering, Faculty of Agriculture, Urmia University, Urmia, Iran.

3- Associate Professor, Department of Water Engineering, Faculty of Agriculture, Urmia University, Urmia, Iran.

Keywords: Prediction, Optimization, Fruit fly Algorithm, Support Vector Regression, Ahvaz.

Introduction

Evapotranspiration is considered one of the most essential parameters in meteorology and water resources (Sun et al., 2021b). Therefore, accurate estimation of reference evapotranspiration is one of the most important tasks that lead to better management of water resources and solving many water engineering challenges (Wanniarachchi and Sarukkalige, 2022). Various meteorological variables, such as solar radiation, air temperature, relative humidity, and wind speed, can interactively affect the reference evapotranspiration component (Yan et al., 2019). Therefore, the development of various improved methods to predict this very important variable is of particular importance for researchers (Ghumman et al., 2021). Due to the complexity of hydrological systems, complete modeling of hydrological systems is very complicated (Eslamian and Eslamian, 2022). In addition, the existence of uncertainty in future climate changes makes it important to model and achieve possible future changes. In such a situation, it is beneficial to use modeling based on mathematical relationships and data-based models (Kisi et al., 2016). One of the available models is Support Vector Regression (SVR), which has been used in various studies (El Bilali et al., 2023; Shabani et al., 2020). The fruit fly optimization algorithm (FOA) is used as one of the innovative algorithms for optimization, and due to its high accuracy in various optimization applications, such as global continuous optimization problems, it has been able to attract a lot of attention (Wu et al., 2020). The aim of this research is to evaluate the performance of SVR optimized with FOA in estimating daily reference evapotranspiration of Ahvaz station located in Khuzestan province. Due to the hot and semi-desert climate of Ahvaz and the growing shortage of water resources, accurate forecasting of daily reference evapotranspiration becomes more important in this station. It is noteworthy that the SVR-FOA hybrid model is used for the first time in this research to predict daily reference evapotranspiration values. The review of previous studies has shown that the SVR-FOA model has not been used to estimate daily reference evapotranspiration.

Methodology

Study area

In the current research, daily reference evapotranspiration values were considered during the statistical period of 22 years in 2000-2022 at Ahvaz station. This city is located in the geographical position of 31° 30' N and 48° 65' E, in the plains of Khuzestan and with a height of 12 m above sea level, in the southwest of Iran and the center of Khuzestan province.

Table (1) shows the different scenarios considered as input and output of the models. Parameters of average temperature (T_{avg}), minimum temperature (T_{min}), maximum temperature (T_{max}), average relative humidity (RH_{avg}), minimum relative humidity (RH_{min}), maximum relative humidity (RH_{max}), wind speed (U), and sunshine hours (SSH) as input parameters and daily reference evapotranspiration (E) as the target parameter. The way of choosing different input compounds to estimate daily reference evapotranspiration in the studied models is based on having a higher correlation than other compounds.

Table 1. Different input combinations to estimate the amount of daily evapotranspiration in the studied models

Scenario	parameters Input							Output
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}	U2	E
6	T _{avg}	T _{min}	T _{max}	RH _{avg}	RH _{min}	RH _{max}	U2 SSH	E

Support Vector Regression (SVR)

SVR is used to classify and analyze regression problems. This method was proposed by Vapnik and Chervonenkis (1974). SVR is based on the dual classification in the desired feature space and is widely used in prediction problems (Jha and Hayashi, 2014; Yoon et al., 2011).

Fruit fly optimization algorithm (FOA)

Pan (2012) presented the fruit fly optimization algorithm (FOA) for the first time. This simple and fluent algorithm has solved part of the challenges related to the difficulties of previous algorithms. This algorithm is similar to many other meta-heuristic algorithms that are designed based on the inspiration of nature, based on the natural behavior of organisms. The fruit fly approaches the location of the fruit after smelling the fruit in the air. This insect finds the exact position of the fruit by using its sense of sight (Poluru and Kumar R, 2021).

In this research, the statistical parameters of correlation coefficient (*R*), root mean square error (*RMSE*), Nash-Satcliff coefficient (*NS*), and Willmott's index of agreement (*WI*) were used to evaluate the performance of different scenarios defined for the studied methods.

Findings

The evaluation of the results according to Table (2) showed that the third scenario of the SVR model with *R*=0.71, *RMSE*= 1.45 mm/day, *NS*=0.33, and *WI*=0.82 has the lowest error compared to other SVR combinations. The high accuracy of this model shows the high importance of the relative humidity parameter in increasing the prediction accuracy of the reference evapotranspiration parameter. Among the combined SVR-FOA models, the sixth scenario with *R*=0.71, *RMSE*=1.24 mm/day, *NS*=0.51, and *WI*=0.82 has the highest accuracy compared to all scenarios. The reason for this is the addition of the sunshine hour's parameter to the model inputs. Because the city of Ahvaz has a semi-desert climate due to long sunshine hours, and as a result, sunshine hours have an effective role in predicting the accuracy of the daily reference evapotranspiration parameter.

Table 2- Evaluation parameters of the studied models in the test period

Model	Evaluation criteria			
	R	RMSE (mm/day)	NS	WI
SVR-1	0.65	1.53	0.25	0.78
SVR-2	0.64	1.60	0.18	0.77
SVR-3	0.71	1.45	0.33	0.82
SVR-4	0.69	1.52	0.26	0.81
SVR-5	0.70	1.56	0.22	0.81
SVR-6	0.69	1.52	0.26	0.82
SVR-FOA-1	0.61	1.39	0.38	0.73
SVR-FOA-2	0.62	1.39	0.38	0.73
SVR-FOA-3	0.68	1.32	0.44	0.79
SVR-FOA-4	0.72	1.30	0.46	0.81
SVR-FOA-5	0.72	1.25	0.50	0.81
SVR-FOA-6	0.71	1.24	0.51	0.82

Conclusion

Forecasting reference evapotranspiration is of particular importance for researchers, therefore researchers have provided various methods to improve the performance of forecasting models. In this research, using SVR and SVR-FOA methods, daily reference evapotranspiration values were estimated in Ahvaz station during the statistical period of 2000-2022. The obtained results were compared using statistical parameters and it was found that the sixth scenario of the SVR-FOA model provided the best performance with the lowest error (1.24 mm/day) compared to all models. Among the scenarios of the SVR model, the third scenario of the SVR model showed the lowest error (1.45 mm/day) compared to other SVR combinations. In the general situation of the sixth scenario, the combined SVR-FOA model provided good results in predicting daily reference evapotranspiration values and was suggested for daily reference evapotranspiration prediction.

Acknowledgments

The authors of the article express their gratitude to the Meteorological Organization of Iran for receiving accurate statistics and information.

References

- 1- **El Bilali**, A., Abdeslam, T., Ayoub, N., Lamane, H., Ezzaouini, M.A., Elbeltagi, A., 2023. An interpretable machine learning approach based on DNN, SVR, Extra Tree, and XGBoost models for predicting daily pan evaporation. *Journal of Environmental Management*, 327, pp.116-890.
- 2- **Eslamian**, S. and Eslamian, F., 2022. Handbook of HydroInformatics: Volume I: Classic *Soft-Computing Techniques*. Elsevier.
- 3- **Ghumman**, A.R., Jamaan, M., Ahmad, A., Shafiquzzaman, M., Haider, H., Al Salamah, I.S., Ghazaw, Y.M., 2021. Simulation of pan-evaporation using penman and hamon equations and artificial intelligence techniques. *Water*, 13, pp.793-809.
- 4- **Jha**, S.K. and Hayashi, K., 2014. A novel odor filtering and sensing system combined with regression analysis for chemical vapor quantification. *Sensors and Actuators*, 200, pp.269-287.
- 5- **Kisi**, O., Genc, O., Dinc, S., 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*, 122, pp.112-117.
- 6- **Pan**, W.-T., 2012. A new fruit fly optimization algorithm: taking the financial distress model as an example. *Knowledge-Based Systems* 26, pp.69-74.
- 7- **Poluru**, R.K. and Kumar R, L., 2021. An Improved Fruit Fly Optimization (IFFOA) based Cluster Head Selection Algorithm for Internet of Things. *International Journal of Computers and Applications*, 43, pp.623-631.
- 8- **Shabani**, S., Samadianfard, S., Sattari, M.T., Mosavi, A., Shamshirband, S., Kmet, T., Várkonyi-Kóczy, A.R., 2020. Modeling pan evaporation using Gaussian process regression K-nearest neighbors random forest and support vector machines; comparative analysis. *Atmosphere*, 11, pp.66-78.
- 9- **Sun**, Z., Zhu, G., Zhang, Z., Xu, Y., Yong, L., Wan, Q., Ma, H., Sang, L., Liu, Y., 2021. Identifying surface water evaporation loss of inland river basin based on evaporation enrichment model. *Hydrological Processes*, 35, 14093.
- 10- **Vapnik**, V. and Chervonenkis, A., 1974. Theory of pattern recognition. Nauka, Moscow.
- 11- **Wanniarachchi**, S. and Sarukkalgige, R., 2022. A review on evapotranspiration estimation in agricultural water management: Past, present, and future. *Hydrology*, 9, pp.123-137.

- 12- **Wu**, J., Wang, Y.-G., Burrage, K., Tian, Y.-C., Lawson, B., Ding, Z., 2020. An improved firefly algorithm for global continuous optimization problems. *Expert Systems with Applications*, 149, 113340.
- 13- **Yan**, Z., Wang, S., Ma, D., Liu, B., Lin, H., Li, S., 2019. Meteorological factors affecting pan evaporation in the Haihe River Basin, China. *Water*, 11, pp.317-330.
- 14- **Yoon**, H., Jun, S.-C., Hyun, Y., Bae, G.-O., Lee, K.-K., 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrology*, 396, pp.128-138.

پاییز فتنه شده - پیش از انتشار