



Development of Integrated Meta-heuristic and Analytical Support Vector Models in Predicting Evaporation from Dam Reservoir (Case Study: Dez Dam)

Reza Farzad¹, Ahmad Sharafati^{2*}, Farshad Ahmadi³ and Seyed Abbas Hosseini⁴

1) Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.
2) Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.
3) Department of Hydrology & Water Resources Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.
4) Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.
*Corresponding author emails: asharafati@gmail.com

Abstract:

Introduction: Evaporation from lakes and reservoirs of dams as well as soil is one of the most important processes in hydrological engineering. One of the procedures required for proper and effective management of reservoirs, water resources, basin stability, and agricultural operations is the accurate prediction of evaporation. Weather phenomena that are non-stationary, unpredictable, and non-linear generally have an impact on evaporation. It is evident that these issues hinder the development of precise prediction models. Evaporation is a natural process based on energy supply and air exchange, during which molecules and atoms find the necessary energy to leave the liquid phase and enter the gas phase. On the other hand, climate changes can affect the evaporation parameter, so the prediction of evaporation from the reservoirs of dams is vital in the discussion of water resources management

Methods: This investigation uses the SVR-ABC, Wavelet-SVR, and SVM models with six wavelet functions to predict the amount of evaporation from the Dez dam reservoir in Khuzestan province, Iran. The data series from 1350–1396 for 46 years arises from the Dez dam meteorological station in Iran. The study also uses precipitation, maximum temperature, minimum temperature, average temperature, absolute maximum temperature, and absolute minimum temperature and Using the findings of Shannon's entropy, 5 parameters T_{max} , T_{min} , T_{ave} , T_{amax} , T_{amin} are divided into 5 groups with 1 parameter, 2 parameters, 3 parameters, 4 parameters and 5 parameters respectively as the most effective parameters for scenario planning, which in total 28 scenarios are studied.

Findings: According to modeling results based on RMSE, MAE and WI evaluation indices show that the performance of SVR-ABC meta-heuristic model with $RMSE=82.219$, $MAE=53.977$ and $WI=0.815$ is better than Wavelet-SVR model with $RMSE=93.637$, $MAE=69.360$ and $WI=0.762$. Additionally, based on the violin diagram, the single SVR model with periodic and non-periodic inputs estimated the monthly evaporation lower than the observed values, and as a result, the average data has decreased compared to the observed values.

Conclusion: Furthermore, according to the results of the six wavelet functions that were used in the study, the Wavelet-SVR axis decomposition model with the Haar wavelet function at decomposition level 1 and values of 93.637 mm/month, 69.360 mm/month, and 0.762, respectively, shows the most appropriate result among the six wavelet functions based on the RMSE, MAE, and WI evaluation indices.

Keywords: prediction of evaporation, Dez dam, Meta-heuristic algorithm, wavelet transform, SVR model



شاپا چاپی: ۲۲۵۱-۷۴۸۰
شاپا الکترونیکی: ۲۲۵۰-۷۴۰۰

نشریه حفاظت منابع آب و خاک

آدرس تارنما:

<https://wsrj.srbiau.ac.ir>

پست الکترونیک:

iauwsrj@srbiau.ac.ir
iauwsrj@gmail.com

سال چهاردهم

شماره ۳ (۵۵)

تاریخ دریافت:

۱۴۰۲/۰۹/۱۳

تاریخ پذیرش:

۱۴۰۳/۰۲/۱۸

صفحات: ۷۵-۵۷

توسعه مدل‌های تلفیقی بردار پشتیبان فراابتکاری و تجزیه محور در پیش‌بینی تبخیر از مخزن سد (مطالعه موردی: سد دز)

رضا فرزاد^۱، احمد شرافتی^{۲*}، فرشاد احمدی^۳ و سید عباس حسینی^۴

(۱) گروه عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
(۲) گروه عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
(۳) گروه هیدرولوژی و منابع آب، دانشگاه شهید چمران اهواز، اهواز، ایران.
(۴) گروه عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
* ایمیل نویسنده مسئول: asharafati@gmail.com

چکیده:

مقدمه و هدف پژوهش: تبخیر از دریاچه و مخازن سدها و همچنین خاک، یکی از مهم‌ترین فرآیندها در مهندسی هیدرولوژیکی محسوب می‌شود. پیش‌بینی دقیق تبخیر یکی از فرآیندهای ضروری برای مدیریت صحیح و کارآمد مخازن، منابع آب، پایداری حوضه و فعالیت‌های کشاورزی می‌باشد. تبخیر بطور کلی تحت تاثیر فرآیند آب و هوایی غیرخطی، غیر ثابت و تصادفی است. چنین عواملی به‌وضوح مانع از راه اندازی مدل‌های پیش‌بینی دقیق می‌شود. تبخیر، فرآیندی طبیعی است که بر پایه تامین انرژی و تبادل هوا انجام می‌شود و طی این فرآیند مولکول‌ها و اتم‌ها انرژی لازم برای خارج شدن از فاز سیال و وارد شدن به فاز گاز را پیدا می‌کنند. از طرفی تغییرات اقلیمی می‌تواند بر پارامتر تبخیر تاثیرگذار باشند به همین منظور پیش‌بینی تبخیر از مخازن سدها اهمیت وافری در بحث مدیریت منابع آب دارد.

روش‌ها: در این تحقیق با استفاده از مدل‌های SVM، Wavelet-SVR، SVR-ABC با استفاده از ۶ تابع موجک به پیش‌بینی تبخیر از مخزن سد دز در استان خوزستان، ایران پرداخته شده است. سری داده‌ها از سال ۱۳۹۶-۱۳۵۰ به مدت ۴۶ سال متعلق به ایستگاه هواشناسی سد دز در ایران می‌باشند. همچنین در این تحقیق از پارامترهای هواشناسی بارش، حداکثر درجه حرارت، حداقل درجه حرارت، میانگین درجه حرارت، حداکثر مطلق درجه حرارت و حداقل مطلق درجه حرارت استفاده شده است و بر اساس نتایج آنروپی شانون ۵ پارامتر Tamin، Tamax، Tave، Tmin، Tmax، پارامتر ۱ پارامتر، ۲ پارامتر، ۳ پارامتر، ۴ پارامتر و ۵ پارامتر تقسیم‌بندی می‌شوند که مجموعاً ۲۸ سناریو مورد مطالعه قرار می‌گیرند.

یافته‌ها: نتایج مدلسازی‌ها بر اساس شاخص‌های ارزیابی RMSE، MAE و WI نشان می‌دهد که عملکرد مدل فراابتکاری SVR-ABC با مقدار RMSE برابر ۸۲/۲۱۹، MAE برابر ۵۳/۹۷۷ و WI برابر ۰/۸۱۵ بهتر از مدل Wavelet-SVR با RMSE برابر ۹۳/۶۳۷، MAE برابر ۶۹/۳۶۰ و WI برابر ۰/۷۶۲ می‌باشد. همچنین بر اساس نمودار ویولنی مدل منفرد SVR با ورودی‌های تناوبی و غیر تناوبی تبخیر ماهانه را کمتر از مقادیر مشاهداتی برآورد نموده و در نتیجه میانگین داده‌ها در مقایسه با مقادیر مشاهداتی کاهش یافته است.

نتیجه‌گیری: همچنین نتایج ۶ تابع موجک استفاده شده در تحقیق نشان می‌دهد که مدل تجزیه محور Wavelet-SVR با تابع موجک haar با سطح تجزیه ۱ با شاخص‌های ارزیابی RMSE، MAE و WI به ترتیب ۹۳/۶۳۷ میلیمتر بر ماه، ۶۹/۳۶۰ میلیمتر در ماه و ۰/۷۶۲ مناسبترین نتیجه را در بین توابع موجک ۶ گانه نشان می‌دهد.

واژه‌های کلیدی: پیش‌بینی تبخیر، سد دز، مدل فراابتکاری، تابع موجک، مدل SVR

مقدمه

ای در بسیاری از کشور های در حال توسعه دارد (Ashrafzadeh et al., 2019; Wu et al., 2020)

ارزیابی تاثیر هیدرولوژیکی بر محیط زیست مستلزم داشتن دانش موثر به منظور درک پدیده‌ها و فرآیندها می‌باشد. در طول دهه های گذشته تصور می‌شد که تبخیر سطحی تحت تاثیر شرایط هواشناسی می‌باشد و محققین مختلف در مدت زمان زیادی سعی در شبیه سازی و تخمین تبخیر کرده اند (Lang et al., 1983; Morton, 1990). به عنوان مثال در روش همبستگی گردابی برای سنجش تبخیر از رطوبت مطلق و سرعت عمودی استفاده می‌گردد (Goltz et al., 1970). با توجه به ماهیت پیچیده تبخیر که بررسی آن با معادلات فیزیکی دشوار می‌باشد، استفاده از تکنیک های قوی محاسباتی هوش مصنوعی در تجزیه و تحلیل آن امری مهم بحساب می‌آید (Shirgure & Rajput, 2011). روش های فازی مبتنی بر شبکه عصبی (Moghaddamia et al., 2009)، رگرسیون چند خطی (Baier & Robertson, 1965) و به ویژه مدل های پیشرفته محاسبات نرم، پیشرفت قابل توجهی در شبیه سازی فرآیند تبخیر داشته اند (Adnan et al., 2019; Patle et al., 2020; Qasem et al., 2019b; Sanikhani et al., 2019; Sebbar et al., 2020; Shimi et al., 2020; Yaseen et al., 2020) هاجهاریا و همکاران^۱ (۲۰۰۹) ویژگی های زمانی روند تبخیر تحت شرایط مرطوب شمال شرقی هند را بررسی کردند. نتایج آنها نشان داد که سرعت باد و مدت زمان تابش خورشید بر تغییرات تبخیر در مکان ها، مناطق و فصول مختلف تاثیر گذار می‌باشد (Jhajharia et al., 2009). همچنین ژاکوفسکی^۲ (۲۰۱۹) از شبیه سازی اتمی و حل معادله جنبشی بولتزمن به منظور بررسی انتقال جرم و حرارت بین سطوح تبخیر و تراکم استفاده کردند. آنها تاکید کردند که متغیرهای مهم برای تخمین تبخیر عبارتند از دما، تابش خورشید، رطوبت نسبی، سرعت باد و بارش می‌باشند. همچنین آنها بیان کردند که استفاده از روش های پیشرفته برای بررسی تبخیر در مسائل مختلف مهندسی جهت تجزیه و تحلیل دلایل افزایش و کاهش تغییرات تبخیر برای برآورد دقیق تر و قابل اعتماد تر محدود می‌باشد.

تاکنون روابط و الگوهای مختلفی برای پیش‌بینی تبخیر پیشنهاد شده است که همه آنها در دو دسته مدل های فیزیکی و مدل های داده محور دسته بندی می‌شوند (Lin et al., 2021). مدل های فیزیکی بر اساس روابط ریاضی موجود بین پدیده های مختلف توسعه یافته و نیازمند اطلاعات میدانی می‌باشند و عوامل فیزیکی تاثیرگذار در این مدل‌ها متعدد بوده و هزینه مدلسازی زیادی دارند. همچنین وجود عدم قطعیت بالا در مدل های فیزیکی می‌تواند موجب بروز خطا در پیش‌بینی پارامتر های پیچیده همچون تبخیر شود. برای فائق آمدن به مشکلات مدل های فیزیکی روش های داده محور در سال های

آب یکی از عناصر حیاتی برای زیست بشر می‌باشد و از مهمترین عوامل توسعه صنعت، کشاورزی و شرب به عمل می‌آید (Helfer et al., 2012). تبخیر از دریاچه و مخازن سدها و همچنین خاک، یکی از مهم ترین فرآیندها در مهندسی هیدرولوژیکی محسوب می‌شود (Fan et al., 2018; Jones, 2018). تبخیر، فرآیندی طبیعی است که طی این فرآیند مولکول‌ها و اتم‌ها انرژی لازم برای خارج شدن از فاز سیال و وارد شدن به فاز گاز را پیدا می‌کنند و این سناریو بر پایه تامین انرژی و تبادل هوا انجام می‌شود (Baek et al., 2016; C. A. Chen et al., 2018; Malik et al., 2021). از این رو تلفات ناشی از تبخیر ممکن است در هر سیستم آبی رخ دهد و کمبود آب را تشدید نماید (Fan et al., 2016; Gong et al., 2021). بر اساس روابط پیچیده بین آب، زمین و سیستم جوی، تبخیر جزء دشوارترین چرخه هیدرولوژیکی بحساب می‌آید. از طرفی علاوه بر پیچیدگی روابط، غیرخطی بودن آنها و ماهیت ناپایدار تبخیر، ارائه فرمولی کلی، جامع و ساده که تمام فرایندهای فیزیکی تبخیر را شامل شود، دشوار می‌کند (Bhattarai et al., 2023). چنین عواملی از راه اندازی مدل های پیش بینی دقیق جلوگیری می‌کند (Elbeltagi et al., 2023). همچنین با توجه به تاثیر آن بر بارش، رواناب و سطح مخزن سد در مناطق خشک و نیمه خشک، تبخیر از اهمیت بیشتری برخوردار می‌باشد (Allawi & El-Shafie, 2016; Kim et al., 2012; Kisi, 2016). میزان تبخیر در مناطق خشک و نیمه خشک در فصل تابستان معمولاً بالا می‌باشد از همین رو تلفات آب از مخازن سدها، حوضه‌ها و دریاچه‌ها به سمت اتمسفر تشدید می‌شود و سطح آب پایین می‌آید (Boers et al., 1986; Khan et al., 2019; Sayl et al., 2016). پیش بینی تبخیر نقش اساسی در مدیریت و برنامه ریزی بهتر منابع آبی دارد (Kushwaha et al., 2021). تغییرات آب و هوایی نیز بر تبخیر اثرگذار هستند و در برهم زدن تعادل آب های سطحی موثر می‌باشند (Sartori, 2000). همچنین گرمایش جهانی نیز تاثیر نامطلوب بر رابطه بین تبخیر و مدیریت منابع آب دارد (Eames et al., 1997; Kushwaha et al., 2016).

معمولاً دو روش برای تخمین تبخیر وجود دارد، روش مستقیم و روش غیر مستقیم. روش مستقیم شامل تبخیر تش (PE) و روش های غیر مستقیم مانند انتقال جرم، تعادل آب و انرژی و روش پنمن می‌باشند (Lundberg, 1993; Zhao et al., 2013). روشی که در سطح جهانی از آن استفاده می‌شود، روش تابه کلاس A می‌باشد که سازگاری خوبی در مناطق مختلف آب و هوایی دارد (Masoner et al., 2008) اما ماهیت پرهزینه

Coefficient) دقت پیشبینی مدل را افزایش می‌دهند. در ادامه کار برای پیشبینی تبخیر از تشت، از مدل های LSTM، DL و SVM با استفاده از بهینه سازی های چندگانه استفاده شده است (Ashrafzadeh et al., 2020; Y. Chen et al., 2022; Ferreira et al., 2019; Goyal et al., 2014; Kisi, 2015b; Malik et al., 2020; L. Wang et al., 2017)

با توجه به اینکه رویکرد های DL بدلیل دقت بیشترشان در میان تکنیک های هوش مصنوعی در زمینه های علمی و تجاری برای مدل های سری زمانی از محبوبیت بالایی برخوردار هستند (Hu et al., 2018). یاسینگه^۵ (۲۰۲۲) یک رویکرد مبتنی بر یادگیری عمیق (DL) برای پیشبینی تبخیر توسعه دادند. این رویکردها در سطح جهانی در حال افزایش می‌باشند و در زمینه علوم هیدرولوژیکی نیز مورد توجه محققین (Costache et al., 2022; El Bilali et al., 2023; Liu et al., 2022; X. Yang et al., 2022) واقع شده اند. در ادامه مالیک و همکاران^۶ (۲۰۲۲) به منظور پیش بینی تبخیر از مدل یادگیری عمیق در مقابل دستگاه تقویت گرادیان استفاده کردند. آنها از دو تکنیک نوآورانه یادگیری عمیق (DL) و مدل های ماشین تقویت کننده گرادیان (GBM) بر اساس حداکثر دمای هوا برای مدلسازی فرآیند تبخیر ماهانه استفاده کردند. آنها از دو ایستگاه هواشناسی کیشهر در شمال ایران و Ranichauri در ایالت Uttarakhand هند استفاده نمودند. نتایج آنها نشان داد که هر دو روش در اقلیم خشک ایران قابلیت قابل قبولی در مدلسازی تبخیر ماهانه دارند. اما بطور کلی در دو ایستگاه عملکرد مدل DL را بهتر ارزیابی کردند. استفاده از توابع موجک در پیشبینی تبخیر توسط محققان زیادی مورد ارزیابی قرار گرفته است که به تعدادی از این مطالعات اشاره می‌گردد. همچنین عمادی و همکاران^۷ (۲۰۲۲) به مدلسازی تبخیر ماهانه با استفاده از روش داده محور تک موجک و ترکیبی در حوضه های آبریز ایران در دو اقلیم مختلف پرداختند. در این تحقیق آنها از مدل شبکه عصبی مصنوعی، سیستم استنتاج عصبی فازی تطبیقی و روش های برنامه ریزی بیان ژن و ترکیب این روش‌ها با نظریه موجک استفاده کردند. نتایج آنها نشان داد که برنامه ریزی ژن موجک و شبکه عصبی مصنوعی تک به ترتیب بهترین و ضعیف ترین عملکرد را در میان سایر مدل‌ها داشته اند. در کشور ایران نیز گلابی و همکاران^۸ (۲۰۲۳) جهت پیشبینی تبخیر ماهانه مخزن سد امیرکبیر ایران از تجزیه موجک بر اساس رگرسیون فرآیند گاوسی و رگرسیون خطی چندگانه استفاده کردند. نتایج آنها نشان داد که رگرسیون خطی چندگانه عملکرد بهتری نسبت به رگرسیون فرآیند گاوسی دارد.

بر خلاف مدل های سری زمانی، روش های یادگیری ماشین در توضیح روابط پیچیده از عملکرد مناسبی برخوردار بوده و به عنوان یک روش جایگزین موفق در پیشبینی تبخیر پیشنهاد می‌شوند. از جمله این روش‌ها روش ماشین بردار

آخر توسعه چشمگیری داشته اند. این روش‌ها به ورودی های کمتری نیاز داشته و کاربرد آسانتری دارند (Fang et al., 2019). مطالعات متعددی برای پیشبینی عوامل هیدرولوژیکی با استفاده از هوش مصنوعی که در زمره روش های داده محور قرار دارد، انجام شده است (Ashrafzadeh et al., 2019). از طرفی تکنیک های مختلف مدل سازی مبتنی بر هوش مصنوعی در زمینه های مختلف تحقیقات مهندسی به طور موثر بکار گرفته شده اند. همچنین محققین پیشبینی می‌کنند که شبکه عصبی مصنوعی شبیه سازی های دقیقتری نسبت به رویکرد های سنتی دارد (Pham et al., 2022). از دیگر مدل های داده محور، مدل های سری زمانی می‌باشند که بطور گسترده ای برای پیشبینی جریان رودخانه، بارش، تبخیر و غیره در مناطق مختلف جهان بکار گرفته شده اند (Mehdizadeh et al., 2019). از جمله این مدل‌ها مدل های خود همبسته (AR) و میانگین متحرک (MA) اشاره کرد. مدل های سری زمانی یک رابطه خطی را بین ورودی‌ها و خروجی‌ها در نظر می‌گیرند که در تبخیر نمی‌تواند صحیح باشد. امروزه در میان روش های مختلف مدل سازی، روش یادگیری عمیق به دلیل توانایی بالای این روش‌ها در پیشبینی و مدلسازی پیچیده و غیر خطی بیشتر مورد توجه محققین و پژوهشگران قرار گرفته است. اما یکی از مشکلاتی که در مدل های یادگیری ماشین با آن مواجه هستیم نایست بودن و متغیر بودن داده های ثبت شده می‌باشد که برای حل این مشکل روش های تجزیه پایه توسعه داده شده اند. این روش‌ها می‌توانند سری های تبخیر را به زیر سری های متعدد تجزیه نمایند. در این صورت می‌توان خاصیت پرودییک، روند و نویز را در داده‌ها شناسایی نمود و اطلاعاتی را که قادر به استفاده غیر مستقیم از آنها نیستند را استخراج کرد و عملکرد مدل را به طرز چشمگیری بهبود داد. یکی از روش هایی که می‌تواند نایستایی داده‌ها را شناسایی کند، تبدیل موجک می‌باشد.

در همین راستا قاسم و همکاران^۳ (۲۰۱۹) به مدلسازی تبخیر ماهانه تشت با استفاده از رگرسیون بردار پشتیبان موجک (WSVR) و شبکه عصبی مصنوعی موجک (WANN) در اقلیم های خشک و مرطوب پرداختند. آنها دو ایستگاه در تبریز ایران و آنتالیا ترکیه را مورد ارزیابی قرار دادند. نتایج مطالعه آنها نشان داد که شبکه عصبی مصنوعی روند معقولانه تری را برای مدلسازی تبخیر ارائه می‌دهد. همچنین قائمی و همکاران^۴ (۲۰۱۹) در مورد کاربرد حداکثر همپوشانی تبدیل موجک گسسته (MODWT) ادغام شده با درخت مدل MARS و M5 برای پیشبینی تبخیر ماهانه پرداختند. آنها از پارامتر های ورودی دما، سرعت باد، رطوبت نسبی و تابش خورشیدی استفاده کردند. همچنین آنها از ضریب مالو (Mallows Coefficient) به منظور انتخاب متغیرهای ورودی استفاده کردند. نتایج آنها بر اساس شاخص های ارزیابی نشان داد که استفاده از MODWT و MC (Mallows

ورودی جریان، بارش، معدل حداکثر درجه حرارت، معدل حداقل درجه حرارت، درجه حرارت میانگین، حداکثر مطلق درجه حرارت، حداقل مطلق درجه حرارت و تبخیر برای بازه زمانی سالهای ۱۳۵۰ تا ۱۳۹۶ به مدت ۴۶ سال پرداخته می‌شود. بطور کلی هدف از این مطالعه ۱- پیش‌بینی تبخیر در مخزن سد دز با استفاده از حداقل پارامترهای ورودی ۲- مقایسه مدل‌های SVR، Wavelet-SVR، SVR-ABC در پیش‌بینی تبخیر ۳- مقایسه چندین مدل از توابع موجک با یکدیگر و ارزیابی مناسبترین مدل از توابع موجک برای پیش‌بینی تبخیر منطقه ۴- ارائه رویکردی قابل اعتماد برای پیش‌بینی تبخیر به منظور مدیریت منابع آب در حوضه مورد مطالعه و ۵- مطالعه رویکردی در زمینه تلفات آب تبخیری در مخزن سد دز می‌باشد. روش‌های پیشنهادی به منظور ارزیابی بیشتر تبخیر آموزنده خواهد بود و درک مسائل مختلف مهندسی هیدرولوژی را بهبود می‌بخشد.

مواد و روش‌ها

۱- موقعیت منطقه مورد مطالعه

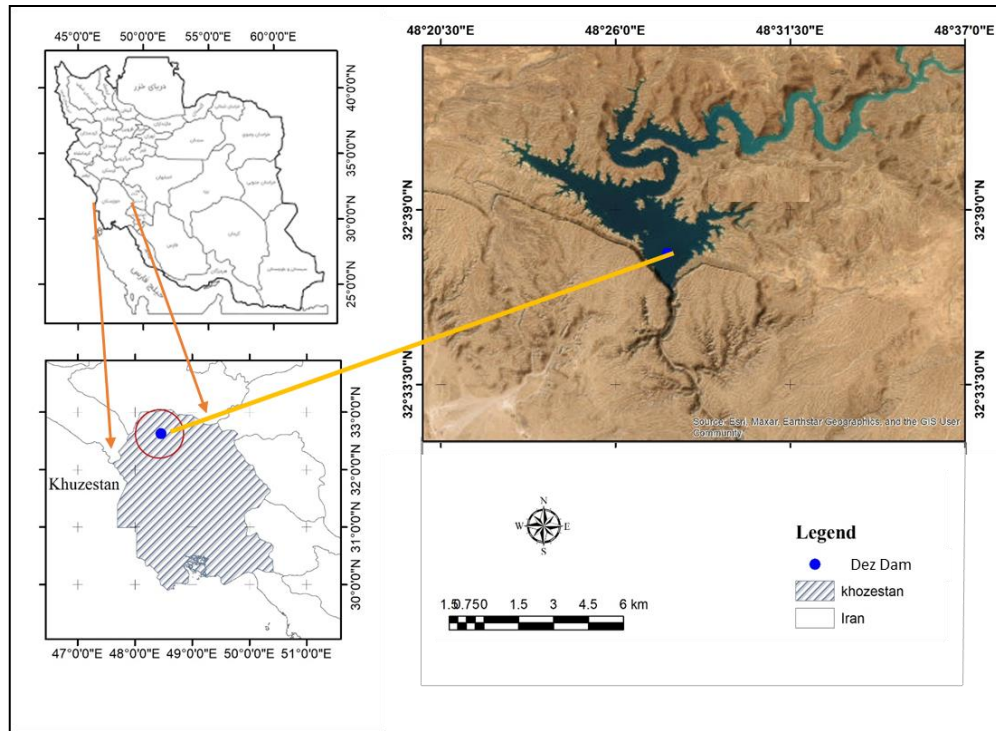
سد دز اولین سد چندمنظوره ایران می‌باشد که با اهداف مدیریت آب، تولید برق، آبیاری و حفاظت مناطق پایین دست در سال ۱۳۳۸ احداث و در سال ۱۳۴۱ مورد بهره‌برداری قرار گرفت. سد دز یک سد بتنی دو قوسی است که در تنگه ای با سازند کنگلومرایی در رودخانه دز واقع شده است. ساختگاه این سد در ۲۲ کیلومتری شهرستان اندیمشک و ۲۵ کیلومتری شهرستان دزفول با مختصات $E 51^{\circ}27'48''$ و $N 32^{\circ}36'20''$ واقع شده است. ارتفاع سد ۲۰۳/۵ متر، طول تاج سد ۲۱۲ متر، طول دریاچه ۶۵ کیلومتر و ظرفیت نهایی مخزن سد ۳/۳ میلیارد متر مکعب آب می‌باشد. سد دز نقش حائز اهمیتی در کنترل سیلاب‌های بالادست دارد و حدود ۱۲۵۰۰۰ هکتار از اراضی پایین دست را آبیاری می‌کند (Ghomeshi et al., 2020; Naderpour et al., 2021). شکل (۱) جانمایی سد دز را نشان می‌دهد. در جدول (۱) مشخصات آماری پارامترهای هواشناسی برگرفته از اطلاعات سازمان مدیریت منابع آب ایران مربوط به سال‌های ۱۳۵۰ الی ۱۳۹۶ مربوط به سد دز آورده شده است.

پشتیبان (SVM)، رگرسیون بایسین، جنگل تصادفی و KSTAR می‌باشد. ماشین بردار پشتیبان (SVR) یک الگوریتم نیمه غیرخطی مبتنی بر مفهوم به حداقل رساندن ریسک ساختاری برای مسائل طبقه بندی و رگرسیون می‌باشد (Cortes C, 1995). تحقیقات زیادی توسط محققان با استفاده از مدل SVR انجام شده است که در ادامه به چندی از آنها در این رابطه اشاره می‌گردد. کشتگر و همکاران^۹ (۲۰۱۹) به مدلسازی تبخیر ماهانه با استفاده از روش سطح پاسخ (RSM) ترکیب شده با رویکرد رگرسیون بردار پشتیبان (SVR) پرداختند. آنها نتایج این مدل را با مدل‌های SVR، RSM و شبکه عصبی پرسپترون چند لایه (MLPNN) مقایسه کردند. نتایج آنها نشان داد که مدل هیبریدی SVR-RSM بهتر از همه مدل‌های پیشنهادی عمل می‌کند. در همین راستا کومار و سینگ^{۱۰} (۲۰۲۲) به مدلسازی سری‌های زمانی هیدرولوژیکی با مقایسه مدل‌های ماشین بردار پشتیبان (SVR)، خطوط رگرسیون تطبیقی چند متغیره (MARS)، رگرسیون خطی چندگانه (MLR) و جنگل تصادفی (RF) به منظور تخمین تبخیر منطقه هیمالیای میانی Uttarakhand در کشور هند پرداختند. نتایج آنها بر اساس شاخص‌های ارزیابی نشان داد که مدل SVR عملکرد بهتری نسبت به دیگر مدل‌های پیشنهادی دارد. همچنین ال‌بیلادی و همکاران^{۱۱} (۲۰۲۳) یک رویکرد ماشین یادگیری قابل تفسیر بر اساس مدل‌های Deep Neural Network (DNN)، SVR، Extra Tree و XGBoost برای پیش‌بینی روزانه تبخیر تحت شرایط پیشنهاد دادند. آنها از ایستگاه هواشناسی Sidi Mohammed Ben Abdallah (SMBA) در کشور مراکش استفاده کردند. نتایج اعتبار سنجی مدل‌های مورد استفاده آنها نشان داد که پارامترهای دمای هوا (TA)، تابش خورشیدی (RS) و رطوبت نسبی (RH) مهمترین متغیرهای اقلیمی می‌باشند. همچنین تفسیر مدل‌های آنها نشان داد که مدل‌ها سازگاری خوبی در یک محیط نیمه خشک دارند.

تبخیر یک فرآیند پویا می‌باشد که تحت تاثیر عوامل اقلیمی متعددی قرار دارد. در مطالعه حاضر به ارزیابی پیش‌بینی تبخیر با استفاده از مدل‌های SVR-ABC، Wavelet-SVR، SVM بر پایه توابع موجک در مخزن سد دز از یک منطقه گرم و خشک در کشور ایران، با استفاده از مجموعه داده‌های هواشناسی دبی

جدول ۱. مشخصات آماری پارامترهای هواشناسی

Parameter	min	max	mean	variance	skewness	kurtosis
Tmin ($^{\circ}C$)	-۱/۷	۲۰/۶	۸/۵۰	۱۴۶/۵۳	۶/۵۶	-۱/۳۰
Tmax ($^{\circ}C$)	۱۰/۹	۴۸/۱	۹/۶۶	۱۱۵	-۰/۰۵	-۱/۴۳
Tave ($^{\circ}C$)	۵/۳	۴۷	۸/۸۰	۹۵/۸۵	۱/۰۲	-۱/۴۱
Tamin ($^{\circ}C$)	۱۰	۵۰	۹/۱۳	۱۰۶/۲۲	-۰/۳۰	-۱/۲۲
Tamax ($^{\circ}C$)	-۶/۵	۳۳/۵	۸/۳۸	۹۱/۹۱	۰/۱۳	-۱/۱۷



شکل ۱. جغرافیایی سد دز در ایران

$$f(x) = w^T x + b \quad (۱)$$

در رابطه (۱) بانگر بایاس و بردار وزن می‌باشد (Cortes, 1995; Fattahi & Babanouri, 2017). مادامی که رابطه زیر به حداقل برسد مقادیر w و b تعیین می‌گردند.

$$R = \frac{1}{2} \|w\|^2 + \frac{c}{n} \sum_{i=1}^n |y_i - f(x_i)|_\epsilon \quad (۲)$$

در رابطه بالا توابع کمکی $(\sum_{i=1}^n |y_i - f(x_i)|_\epsilon)$ توسط کورتس^{۱۲} (۱۹۹۵) صورت زیر ارائه شده است. در رابطه بالا $\frac{1}{2} \|w\|^2$ بردار وزن و C پارامتر مثبت و متوازی است که پیچیدگی مدل را بر حسب بردار وزن و خطای تقریب آن نشان می‌دهد. ϵ مقدار خطای مجاز نقاط آموزشی است (Ansari & Akhoondzadeh, 2020; Fa'al et al., 2020). برای تخمین متغیرهای کمکی و مسئله بهینه سازی درجه دوم از روابط زیر استفاده می‌کنیم (Fattahi & Babanouri, 2017).

$$|y_i - f(x_i)|_\epsilon = \begin{cases} 0 & \text{if } |y_i - f(x_i)|_\epsilon \leq \epsilon \\ |y_i - f(x_i)|_\epsilon - \epsilon & \text{otherwise} \end{cases} \quad (۳)$$

(۴)

$$\text{Maximize } Lp(\alpha_i, \alpha_i^*) = -\frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) x_i^T x_j - \epsilon \sum_{i=1}^n (\alpha_i - \alpha_i^*) + \sum_{i=1}^n (\alpha_i - \alpha_i^*) y_i$$

۲- مدل SVR

ماشین بردار پشتیبان (SVM) یک الگوریتم تعمیم غیر خطی است که در سال ۱۹۹۵ به منظور طبقه بندی و رگرسیون توسط وپنیک پیشنهاد گردید (Cortes C, 1995; Turkey & Demren, 2011). در این روش برای کاهش خطای ناشی از آموزش، از اصل کمینه سازی ریسک ساختاری (ERM) و برای به حداقل رساندن خطای تعمیم از اصل القایی کمینه سازی ریسک ساختاری (SRM) استفاده شده است. (Kavousi- Fard et al., 2014) SVM از متداول ترین و پرکاربردترین مدل های یادگیری داده است که در سال های اخیر مورد توجه محققان قرار گرفته است. این مدل در تشخیص الگوها (Y. Liang et al., 2007), طبقه بندی (Hassan et al., 2011; Oliveira & Sabourin, 2004) و تحلیل رگرسیون (SVR) از مجموعه داده های مشخص کاربرد دارد. هدف از روش SVR پیشبینی یک تابع نامعلوم بر اساس داده های آموزشی محدود می‌باشد (Ansari & Akhoondzadeh, 2020). در این روش برخلاف سایر شبکه های عصبی از ترکیب یک رگرسیون خطی و یک کرنل، یک رگرسیون غیر خطی جهت به حداقل رساندن خطای محاسباتی و تعیین مقدار بهینه انجام می‌شود (W. Wang et al., 2013). با توجه به اینکه هدف نهایی در روش SVR یافتن رابطه ای خطی بین بردار های n بعدی ورودی و پارامتر های خروجی می‌باشد، رابطه زیر تعریف می‌گردد.

در رابطه (۱۱) تابع موجک مادر $\psi(x)$ نشان داده شده است که با دو عمل انتقال و مقیاس ریاضی در طول سیگنال مورد بررسی قرار می‌گیرند.

$$\psi_{a,b}(0) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (11)$$

در هر نقطه سیگنال (b) و هر مقیاس (a) با استفاده از رابطه زیر محاسبه می‌گردند.

$$T(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \psi\left(\frac{t-b}{a}\right) f(t) dt \quad (12)$$

مقدار t به ازای مقادیر مختلف a و b قابل محاسبه می‌باشد و هرچه مقدار t بیشتر باشد، انطباق بهتری ایجاد می‌گردد. برای انتخاب سطح تجزیه مناسب در توابع موجک می‌توان از رابطه زیر استفاده نمود (W. Wang & Ding, 2003).

$$L = \text{Int}[\log(N)] \quad (13)$$

در رابطه (۱۳) به ترتیب L سطح تجزیه، N تعداد داده‌ها و Int عملگر صحیح می‌باشد.

پس از تجزیه سری داده‌ها به زیر سری های تقریب و جزئیات، واریانس سری زمانی اولیه نیز انتقال داده می‌شود و تغییری در اطلاعات سری زمانی اولیه ایجاد نخواهد شد (Nekoeeyan et al., 2022). در این تحقیق از توابع موجک db, haar, sym, coif, dmeyr, Fk استفاده شده است.

۴- الگوریتم فراابتکاری کلونی زنبور عسل(ABC):

Artificial Bee Colony (ABC) این الگوریتم یک راهکار بهینه‌سازی از رفتار یک کلونی زنبور عسل را شبیه سازی می‌کند و برای اولین بار در سال ۲۰۰۵ توسط Karaboga شناسایی گردید (Karaboga & Akay, 2005). در این مدل ریاضی کلونی زنبور عسل، زنبورها به سه دسته تقسیم می‌شوند. دسته اول زنبورهای کارگر هستند که روی گرد آوری غذا و آوردن آن به کندو از یک منبع غذایی خاص کار می‌کنند. دسته دوم زنبورهای ناظر هستند که در میان زنبورهای کارگر گشت زنی می‌کنند و ارزش یک منبع غذایی را بررسی می‌کنند. و دسته سوم زنبورهای دیده بان هستند که به دنبال کشف منابع غذایی جدید هستند. برای اطلاع بیشتر در خصوص روابط مورد استفاده در این الگوریتم به رفرنس (Fattahi & Babanouri, 2017) مراجعه شود.

۵- آنتروپی شانون

مفهوم اطلاعات علمی تحت عنوان آنتروپی شانون توسط (Shannon, 1948) معرفی گردید. آنتروپی معیاری است که میزان آشفتگی یک سیستم را تعریف می‌نماید (Theil, 1972). و

$$\text{Subject to } \begin{cases} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i \leq c \quad i = 1, \dots, n \\ 0 \leq \alpha_i^* \leq c \quad i = 1, \dots, n \end{cases} \quad (5)$$

در رابطه (۴) و (۵) ضرایب لاکرانژ هستند که باید مثبت و غیر از صفر باشند که برای ساخت تابع تصمیم استفاده می‌شوند. تخمین SVR با محاسبه ضرایب لاکرانژ در حالت رگرسیون خطی بصورت زیر نوشته می‌شود.

$$f(x) = w_0^T x + b = \sum_{i=1}^n (\alpha_i - \alpha_i^*) x_i^T x + b \quad (6)$$

$$w_0 = \sum_{i=1}^n (\alpha_i - \alpha_i^*) x_i \quad (7)$$

از تابع کرنل برای حل مسائل غیر خطی استفاده می‌شود. با استفاده از این تابع فضای ورودی به یک فضای چندبعدی با ابعاد بالاتر نگاشت داده می‌شود، یعنی تابع رگرسیون به هایپر صفحه غیر خطی تبدیل می‌شود.

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) k(x_i, x_j) + b \quad (8)$$

در رابطه (۸) $k(x_i, x_j)$ تابع کرنل است که نگاشت غیر خطی را انجام می‌دهد و این تابع بصورت زیر تعریف می‌گردد.

$$k(x_i, x_j) = \phi^T(x_i) \phi(x_j) \quad i, j = 1, \dots, n \quad (9)$$


در رابطه بالا (x_i, x_j) پیش‌بینی فضای ویژگی‌ها هستند. یکی از قدرتمندترین و رایج ترین توابع کرنل، تابع هسته پایه شعاعی (RBF) می‌باشد که بصورت زیر تعریف می‌گردد.

$$k(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (10)$$

در رابطه بالا γ پارامتر تابع کرنل می‌باشد.

۳- توابع موجک:

یکی از شاخصه های مهم تابع موجک فیلتر تقسیم داده‌ها به دو دسته تقریب و جزئیات می‌باشد. همچنین سطح تجزیه تابع موجک تا چندین مرحله می‌تواند انجام گردد (W. Wang & Ding, 2003). مراحل تجزیه موجک در شکل (۲) نشان داده شده است.



شکل ۲. مراحل تجزیه تابع موجک

می‌باشند که بر اساس نتایج آنروپی شانون ۵ پارامتر Tmax، Tmin، Tave، Tamax، Tamin به عنوان تاثیر گذار ترین پارامترها جهت سناریو بندی در ۵ گروه به ترتیب با ۱ پارامتر، ۲ پارامتر، ۳ پارامتر، ۴ پارامتر و ۵ پارامتر تقسیم بندی می‌شوند که مجموعاً ۲۸ سناریو مورد مطالعه قرار می‌گیرند.

جدول ۲. سناریوهای مورد بررسی

ردیف	مدل	الگو	آرایش الگوی ورودی	پارامترها
۱		E1	Tmax	دمای میانگین حداکثر (۱)
۲		E2	Tmin	دمای میانگین حداقل (۲)
۳	۱	E3	Tave	دمای متوسط (۳)
۴		E4	Tamin	دمای مطلق حداقل (۴)
۵		E5	Tamax	دمای مطلق حداکثر (۵)
۶		E6	Tmax, Tmin	(۱) و (۲)
۷		E7	Tmax, Tave	(۱) و (۳)
۸		E8	Tmax, Tamin	(۱) و (۴)
۹		E9	Tmax, Tamax	(۱) و (۵)
۱۰	۲	E10	Tmin, Tave	(۲) و (۳)
۱۱		E11	Tmin, Tamin	(۲) و (۴)
۱۲		E12	Tmin, Tamax	(۲) و (۵)
۱۳		E13	Tave, Tamin	(۳) و (۴)
۱۴		E14	Tave, Tamax	(۳) و (۵)
۱۵		E15	Tamin, Tamax	(۴) و (۵)
۱۶		E16	Tmax-Tmin-Tave	(۱) و (۲) و (۳)
۱۷		E17	Tmax-Tmin-Tamin	(۱) و (۲) و (۴)
۱۸		E18	Tmax-Tmin-Tamax	(۱) و (۲) و (۵)
۱۹		E19	Tave-Tmax-Tamax	(۳) و (۱) و (۵)
۲۰	۳	E20	Tave-Tmax-Tamin	(۳) و (۱) و (۴)
۲۱		E21	Tave-Tmin-Tamax	(۳) و (۲) و (۵)
۲۲		E22	Tave-Tmin-Tamin	(۳) و (۲) و (۴)
۲۳		E23	Tamin-Tamax-Tmax	(۴) و (۵) و (۱)
۲۴		E24	Tamin-Tamax-Tmin	(۴) و (۵) و (۲)
۲۵		E25	Tamin-Tamax-Tave	(۴) و (۵) و (۳)
۲۶	۴	E26	Tmax-Tmin-Tave-Tamin	(۴) و (۳) و (۲) و (۱)
۲۷		E27	Tmax-Tmin-Tave-Tamax	(۵) و (۳) و (۲) و (۱)
۲۸	۵	E28	Tmax-Tmin-Tave-Tamin-Tamax	(۵) و (۴) و (۳) و (۲) و (۱)

به منظور انتقال بهتر اطلاعات و حذف اثر نوفه‌ها در پیش پردازش داده‌ها از ۶ تابع موجک coif2, sym4, db2, haar و dmeyr و Fk4 استفاده شده است و داده‌ها به سه سطح تجزیه شده و بدین ترتیب مدل تلفیقی تجزیه محور Wavelet-SVR ایجاد می‌گردد.

یک رویکرد مدیریتی به منظور برخورد با بی نظمی و بی ثباتی در یک سیستم می‌باشد (Yufeng & Fengxiang, 2009). رابطه شانون برگرفته از اصول بولتزمن اصلاح شده می‌باشد که این اصول، رابطه ای یک به یک بین مقدار آنروپی سیستم، کمیت و درجه بی نظمی می‌باشند (Khoshtinat et al., 2020; A. L. Yang et al., 2010). بطور کلی آنروپی بیان می‌کند چگونه می‌توان از میان عوامل تاثیر گذار بر یک هدف، مهمترین عوامل را پیش بینی و تخمین زد و همچنین پارامترهایی که تاثیر بسزایی در پیش آمد یک واقعه دارند را مشخص نماید (Roustaie et al., 2020). مقادیر آنروپی به منظور محاسبه وزن دهی سیستم شاخص طی مراحل نرمالیزه کردن، محاسبه آنروپی، تعیین عدم قطعیت‌ها و وزن دهی بر اساس روابط زیر مورد استفاده قرار می‌گیرند.

$$f_{ij} = \frac{x_{ij}}{\sum_{j=1}^m x_{ij}} \quad (j=1, \dots, m, i=1, \dots, m) \quad (14)$$

$$E_i = -K \sum_{j=1}^m f_{ij} \ln f_{ij} \quad (15)$$

$$k = \frac{1}{\ln n} \quad (16)$$

$$d_i = 1 - E_i \quad (17)$$

$$w_j^{\wedge} = \frac{d_i}{\sum_{j=1}^m d_i} \quad (18)$$

در روابط بالا x_{ij} بیانگر مرتبه پارامتر i و در مورد ویژگی

های z_i می‌باشد. همچنین f_{ij} فرم نرمالیزه شده x_{ij} می‌باشد. m نشان دهنده تعداد ویژگی‌ها، n نشان دهنده تعداد پارامترها، E_i بیانگر مقدار پراکندگی یا آنروپی و k ثابت آنروپی می‌باشد. در نهایت w_j^{\wedge} وزن بردار کارا کتر j است.

۶- توسعه مدل (ارزیابی الگوهای ورودی)

انتخاب بهینه ترین داده های ورودی به مدل ها، در روند عملکرد بهینه روش‌ها موثر می‌باشد. بطوریکه افزایش تعداد ورودی‌ها در مرحله آموزش نه تنها سبب پیچیدگی و درگیری بیشتر حافظه می‌شود، بلکه در کاهش دقت مدل تاثیرگذار خواهد بود (Nekoeeyan et al., 2022). بنابراین در این مطالعه سعی شده است سناریو های ورودی بر اساس تئوری آنروپی شانون توسعه یابند. در جدول (۲) پارامتر های تاثیرگذار که بر اساس آنروپی شانون وزن دهی و مشخص شده اند و جهت بررسی و ارزیابی سناریو بندی شده اند. پارامتر های ورودی اولیه که شامل بارش (P)، معدل حداکثر درجه حرارت (Tmax)، معدل حداقل درجه حرارت (Tmin)، معدل میانگین درجه حرارت (Tave)، حداکثر مطلق درجه حرارت (Tamax)، حداقل مطلق درجه حرارت (Tamin)

۷- معیارهای ارزیابی

جدول ۳. نتایج آماری الگوهای ورودی مدل SVR در پیش‌بینی تبخیر

Scenario	TRAIN				TEST			
	RMSE	MAE	KGE	WI	RMSE	MAE	KGE	WI
۱	۵۴/۹۱۰	۳۹/۱۰۷	-۰/۸۸۷	-۰/۸۵۱	۸۹/۳۵۴	۶۲/۰۸۰	۰/۷۱۹	۰/۷۸۷
۲	۷۶/۳۹۷	۵۱/۷۳۵	-۰/۷۱۸	-۰/۸۰۳	۹۶/۸۰۳	۶۸/۸۸۵	-۰/۵۴۶	۰/۷۸۷
۳	۶۳/۱۲۲	۴۳/۶۹۵	-۰/۸۱۶	-۰/۸۳۴	۸۵/۴۳۳	۶۱/۰۱۰	۰/۶۸۲	۰/۷۹۱
۴	۷۷/۶۵۳	۵۶/۷۰۶	-۰/۶۹۰	-۰/۷۸۴	۹۸/۱۵۱	۷۴/۲۹۱	-۰/۴۳۸	۰/۷۴۶
۵	۶۱/۳۴۴	۴۴/۱۶۵	-۰/۸۴۵	-۰/۸۳۲	۹۳/۸۸۸	۶۸/۴۳۹	-۰/۷۱۰	۰/۷۶۶
۶	۵۸/۴۳۹	۴۰/۵۴۰	-۰/۸۳۵	-۰/۸۴۶	۹۰/۹۶۲	۶۳/۴۳۱	-۰/۷۱۲	۰/۷۸۳
۷	۵۷/۲۳۱	۴۰/۱۰۸۵	-۰/۸۴۰	-۰/۸۴۷	۹۰/۳۹۱	۶۳/۱۰۶	-۰/۶۹۱	۰/۷۸۴
۸	۵۸/۹۵۵	۴۱/۵۹۰	-۰/۸۰۸	-۰/۸۴۲	۹۶/۳۷۷	۷۰/۲۸۶	-۰/۵۹۶	۰/۷۵۹
۹	۵۷/۴۹۸	۴۰/۷۹۶	-۰/۸۴۵	-۰/۸۴۵	۹۵/۱۴۱	۶۶/۴۲۲	-۰/۶۶۷	۰/۷۷۳
۱۰	۶۰/۶۳۹	۴۲/۳۴۵	-۰/۷۹۴	-۰/۸۳۹	۸۷/۳۳۱	۶۲/۵۳۹	-۰/۶۷۲	۰/۷۸۶
۱۱	۷۴/۸۴۵	۵۲/۰۹۵	-۰/۶۸۸	-۰/۸۰۲	۹۹/۱۱۸	۷۲/۴۰۲	-۰/۴۶۱	۰/۷۵۲
۱۲	۶۲/۷۸۵	۴۴/۹۰۳	-۰/۷۷۱	-۰/۸۲۹	۹۴/۰۸۸	۶۸/۹۰۶	-۰/۶۳۹	۰/۷۶۴
۱۳	۶۰/۶۴۵	۴۲/۸۱۶	-۰/۷۸۵	-۰/۸۳۷	۹۱/۶۴۸	۶۸/۸۶۳	-۰/۵۹۱	۰/۷۶۴
۱۴	۶۱/۴۴۵	۴۳/۷۲۵	-۰/۷۸۹	-۰/۸۳۴	۹۰/۳۹۰	۶۵/۸۸۱	-۰/۶۴۶	۰/۷۷۴
۱۵	۶۴/۴۶۵	۴۶/۴۱۱	-۰/۷۳۰	-۰/۸۲۳	۹۹/۰۸۷	۷۵/۲۳۱	-۰/۵۱۶	۰/۷۴۳
۱۶	۶۰/۱۰۵	۴۱/۳۴۵	-۰/۸۱۹	-۰/۸۴۳	۹۲/۷۹۶	۶۴/۶۸۹	-۰/۶۶۴	۰/۷۶۴
۱۷	۶۲/۲۰۳	۴۳/۵۲۸	-۰/۷۵۸	-۰/۸۳۴	۹۸/۱۸۱	۷۱/۸۴۰	-۰/۵۴۳	۰/۷۵۸
۱۸	۶۳/۵۱۷	۴۴/۳۱۹	-۰/۷۶۴	-۰/۸۳۱	۹۷/۲۵۲	۶۹/۲۱۲	-۰/۶۱۵	۰/۷۶۴
۱۹	۶۱/۴۶۸	۴۳/۲۹۸	-۰/۷۸۳	-۰/۸۳۵	۹۵/۵۹۹	۶۸/۰۸۲	-۰/۶۲۲	۰/۷۶۷
۲۰	۶۱/۳۵۱	۴۲/۱۸۵۰	-۰/۷۷۴	-۰/۸۳۷	۹۸/۰۴۴	۷۲/۱۰۲	-۰/۵۳۷	۰/۷۵۳
۲۱	۶۳/۳۲۳	۴۴/۴۹۴	-۰/۷۵۹	-۰/۸۳۱	۹۴/۸۷۸	۶۸/۹۱۱	-۰/۶۰۹	۰/۷۶۴
۲۲	۶۳/۲۱۳	۴۴/۲۵۸	-۰/۷۴۴	-۰/۸۳۲	۹۵/۰۱۸	۷۱/۱۱۲	-۰/۵۲۵	۰/۷۵۷
۲۳	۶۴/۳۵۲	۴۵/۶۳۴	-۰/۷۲۸	-۰/۸۲۶	۱۰۳/۶۷۱	۷۶/۵۶۴	-۰/۴۷۹	۰/۷۳۸
۲۴	۶۶/۸۹۶	۴۷/۶۸۸	-۰/۶۸۰	-۰/۸۱۹	۱۰۲/۲۶۰	۷۶/۷۹۷	-۰/۴۴۹	۰/۷۳۷
۲۵	۶۵/۹۵۸	۴۶/۷۸۰	-۰/۶۸۹	-۰/۸۲۲	۱۰۰/۷۲۴	۷۵/۷۸۶	-۰/۴۴۶	۰/۷۴۱
۲۶	۶۴/۳۵۵	۴۴/۸۴۵	-۰/۷۲۴	-۰/۸۲۹	۱۰۱/۹۳۹	۷۴/۶۳۹	-۰/۴۶۴	۰/۷۴۴
۲۷	۶۵/۷۸۸	۴۵/۷۹۷	-۰/۷۳۹	-۰/۸۲۶	۹۹/۸۶۰	۷۱/۱۷۰	-۰/۵۵۱	۰/۷۵۶
۲۸	۷۱/۹۲۷	۵۰/۵۵۰	-۰/۶۱۸	-۰/۸۰۸	۱۱۰/۹۶۰	۸۱/۵۶۳	-۰/۲۸۴	۰/۲۸۴

به منظور مقایسه مدل‌ها در هر مرحله و ارزیابی دقت مدل‌ها، از معیارهای آماری ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، شاخص ویلموت (WI) و شاخص کلینگ گوپتا (KGE) استفاده گردیده است.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (o_i - p_i)^2} \quad (19)$$

$$MAE = \frac{1}{N} \sum_{i=0}^N |o_i - p_i| \quad (20)$$

$$WI = 1 - \left[\frac{\sum_{i=1}^N (o_i - p_i)^2}{\sum_{i=1}^N (|p_i - o_i| + |o_i - p_i|)^2} \right] \quad (21)$$

$$KGE = 1 - \sqrt{(cc - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (22)$$

که در روابط ذکر شده O_i مقادیر مشاهداتی (واقعی)، P_i مقادیر محاسباتی (پیش‌بینی شده)، O_i میانگین مشاهداتی، P_i میانگین مقادیر محاسباتی (پیش‌بینی شده)، N تعداد گام‌های زمانی، cc ضریب همبستگی بین داده‌های مشاهداتی و محاسباتی، α نسبت انحراف معیار O_i و P_i ، β نسبت میانگین O_i و P_i می‌باشند.

نتایج و بحث

۸- مدل‌سازی تبخیر ماهانه با استفاده از مدل SVR

در این مطالعه به منظور پیش‌بینی تبخیر ماهانه مخزن سد دز از داده‌های ایستگاه سد دز استفاده شده است. بدین منظور ۷۰ درصد داده‌ها (۳۹۵ ماه) برای آموزش و ۳۰ درصد باقی‌مانده برای تست (۱۶۹ ماه) در نظر گرفته شده است.

در جدول ۳ به ارزیابی مدل SVR برای ۲۸ سناریو در نظر گرفته شده با استفاده از شاخص‌های ارزیابی RMSE، MAE، KGE و WI پرداخته شده است. بر اساس نتایج تست مدل سناریو ۳ (T ave) مناسبترین سناریو از نظر مدل SVR می‌باشد. در این سناریو مقدار RMSE، MAE و WI به ترتیب برابر با ۸۵/۴۳۳، ۶۱/۰۱۰ و ۰/۷۹۱ می‌باشد اما از نظر شاخص ارزیابی KGE سناریو ۱ با مقدار ۰/۷۱۹ نزدیکترین مقدار را دارا می‌باشد که به عنوان وجه غیر اشتراکی بین دیگر شاخص‌ها شناخته می‌شود. اما بر اساس شاخص‌های ارزیابی نتایج آموزش مقادیر مناسبتری را بیان می‌کنند و دلیل این امر فراخوانی ۷۰ درصد داده‌ها در قسمت آموزش می‌باشد. به عنوان مثال شاخص RMSE در سناریو ۳ کاهش ۲۶ درصدی از ۸۵/۴۳۳ به ۶۳/۱۲۲ دارد و برای دیگر شاخص‌ها نیز این تفاوت وجود دارد. بر همین اساس در نتایج قسمت آموزش سناریو ۱ با توجه به شاخص‌های ارزیابی به عنوان سناریو برتر معرفی می‌گردد.

۹- مدل‌سازی تبخیر ماهانه با استفاده از مدل فراابتکاری SVR-ABC

استفاده از الگوریتم فراابتکاری کلونی زنبور عسل (ABC) باعث بهبود نتایج مدل SVR شده است. بر اساس اطلاعات جدول ۴ مشاهده می‌شود که در نتایج Test مقدار خطای شاخص‌های RMSE و MAE به طور قابل ملاحظه‌ای کاهش پیدا کرده است بطوریکه در شاخص RMSE کمترین و بیشترین میزان خطا به مقدار ۸۲/۲۱۹ و ۱۱۶/۰۳۷ مربوط به سناریوهای ۱ و ۲۴ می‌باشد. همچنین اگر مقدار SVR در سناریو ۱ را با مقدار SVR-ABC در سناریو ۱ مقایسه نماییم چیزی در حدود ۹ درصد باعث بهبود نتایج SVR شده است. در شاخص MAE کمترین مقدار خطا مربوط به سناریو شماره ۱ و بیشترین میزان خطا مربوط به سناریو شماره ۲۴ می‌باشد. در شاخص KGW مناسبترین و نامناسبترین سناریو مربوط به شماره ۱۶ و ۲۴ می‌باشد.

جدول ۴. نتایج آماری الگوهای ورودی مدل SVR-ABC در پیش بینی تبخیر

Scenario	TRAIN				TEST			
	RMSE	MAE	KGE	WI	RMSE	MAE	KGE	WI
۱	۵۳/۲۷۰	۳۶/۵۲۷	۰/۹۲۸	۰/۸۶۱	۸۲/۲۱۹	۵۳/۹۷۷	۰/۸۶۰	۰/۸۱۵
۲	۷۲/۳۴۲	۴۷/۰۹۲	۰/۸۳۵	۰/۸۲۱	۹۲/۷۳۳	۶۴/۱۹۴	۰/۶۹۴	۰/۷۸
۳	۶۰/۸۷۸	۴۲/۵۳۲	۰/۸۸۱	۰/۸۳۸	۸۳/۱۳۷	۵۷/۲۷۹	۰/۷۹۷	۰/۸۰۴
۴	۷۵/۶۰۲	۵۴/۰۲۲	۰/۸۱۵	۰/۷۹۴	۸۹/۳۱۴	۶۵/۷۲۷	۰/۶۶۹	۰/۷۷۵
۵	۶۰/۴۵۰	۴۳/۰۳۴	۰/۸۹۱	۰/۸۳۶	۹۲/۵۸۱	۶۲/۶۰۵	۰/۸۲۰	۰/۷۸۶
۶	۴۳/۷۱۴	۲۵/۱۲۸	۰/۹۳۱	۰/۹۰۴	۱۰۷/۶۵۰	۷۳/۳۶۲	۰/۷۲۷	۰/۷۴۹
۷	۵۱/۹۷۹	۳۵/۶۵۵	۰/۹۳۴	۰/۸۶۴	۸۵/۸۰۷	۵۴/۳۵۹	۰/۸۶۱	۰/۸۱۴
۸	۴۹/۹۶۱	۳۳/۵۰۰	۰/۹۳۸	۰/۸۷۳	۸۷/۸۱۶	۵۸/۵۴۵	۰/۸۵۰	۰/۸۰۰
۹	۵۰/۴۴۴	۳۴/۶۳۲	۰/۹۳۲	۰/۸۶۸	۸۳/۴۶۳	۵۴/۵۴۰	۰/۸۵۳	۰/۸۱۴
۱۰	۵۰/۷۳۹	۳۴/۲۵۵	۰/۹۳۳	۰/۸۷۰	۸۷/۷۶۷	۵۵/۸۹۷	۰/۸۵۹	۰/۸۰۹
۱۱	۵۶/۵۴۸	۳۱/۹۵۳	۰/۸۹۰	۰/۸۷۸	۱۰۳/۸۲۸	۷۵/۱۱۲	۰/۶۶۴	۰/۷۴۳
۱۲	۴۹/۵۱۰	۳۴/۰۷۵	۰/۹۲۵	۰/۸۷۰	۹۲/۶۳۶	۶۵/۰۰۲	۰/۸۱۲	۰/۷۷۷
۱۳	۴۶/۲۸۶	۲۷/۲۱۱	۰/۹۳۶	۰/۸۹۶	۹۴/۱۱۳	۷۰/۷۵۲	۰/۷۳۴	۰/۷۵۸
۱۴	۵۱/۴۱۵	۳۶/۱۱۸	۰/۹۲۳	۰/۸۶۳	۸۷/۲۵۱	۵۸/۲۵۲	۰/۸۳۹	۰/۸۰۱
۱۵	۵۲/۲۳۶	۳۷/۱۲۳	۰/۹۱۸	۰/۸۵۹	۹۴/۷۱۵	۶۵/۴۳۴	۰/۸۰۹	۰/۷۷۶
۱۶	۵۲/۱۵۸	۳۶/۲۵۸	۰/۹۲۷	۰/۸۶۲	۸۵/۸۹۶	۵۲/۸۸۵	۰/۸۶۳	۰/۸۱۹
۱۷	۴۰/۸۵۷	۲۳/۲۶۴	۰/۹۳۹	۰/۹۱۱	۱۰۲/۰۴۴	۷۲/۵۱۰	۰/۷۵۶	۰/۷۵۲
۱۸	۴۶/۴۹۲	۳۰/۵۸۵	۰/۹۴۲	۰/۸۸۴	۹۱/۷۷۴	۵۹/۸۲۵	۰/۸۴۸	۰/۷۹۵
۱۹	۴۷/۵۹۷	۳۲/۴۱۸	۰/۹۳۶	۰/۸۷۷	۸۸/۸۷۲	۵۶/۰۹۱	۰/۸۵۴	۰/۸۰۸
۲۰	۴۹/۵۱۵	۳۳/۳۴۸	۰/۹۳۶	۰/۸۷۳	۹۱/۲۰۰	۶۰/۱۸۷	۰/۸۴۰	۰/۷۹۴
۲۱	۴۷/۴۷۰	۳۲/۳۵۴	۰/۹۳۹	۰/۸۷۷	۹۱/۹۳۳	۵۹/۲۷۷	۰/۸۴۶	۰/۷۹۷
۲۲	۴۵/۶۴۶	۲۶/۱۵۶	۰/۹۴۱	۰/۸۸۹	۹۱/۷۸۹	۶۲/۴۸۳	۰/۸۴۱	۰/۷۸۶
۲۳	۴۶/۵۰۳	۳۱/۲۶۹	۰/۹۴۳	۰/۸۸۱	۹۳/۲۷۷	۶۲/۹۳۴	۰/۸۳۸	۰/۷۸۵
۲۴	۳۷/۴۹۲	۱۷/۹۶۲	۰/۹۵۴	۰/۹۳۲	۱۱۶/۰۳۷	۸۸/۴۹۳	۰/۵۶۳	۰/۶۹۷
۲۵	۴۷/۵۶۹	۳۳/۳۳۶	۰/۹۳۳	۰/۸۷۳	۹۴/۸۸۳	۶۵/۰۶۳	۰/۸۲۴	۰/۷۷۷
۲۶	۴۰/۷۳۱	۲۲/۲۵۶	۰/۹۴۱	۰/۹۱۵	۱۰۲/۵۱۰	۷۳/۵۹۷	۰/۷۳۷	۰/۷۴۸
۲۷	۴۶/۴۸۲	۳۰/۷۴۱	۰/۹۴۰	۰/۸۸۳	۹۲/۶۶۰	۶۰/۵۹۰	۰/۸۴۵	۰/۷۹۳
۲۸	۴۵/۹۰۰	۳۱/۰۸۱	۰/۹۴۶	۰/۸۸۲	۵۹/۶۹۹	۶۳/۷۹۲	۰/۸۳۳	۰/۷۸۲

۹۳/۶۳۷ افزایش پیدا کرده است. همچنین از نمودار Heat map برای ارائه نتایج تست مدل Wavelet-SVR در شکل ۳ استفاده شده است. در این شکل با استفاده از پهنه رنگ بندی‌ها متنوع، شاخص های ارزیابی بر اساس مقدار متناظر از کوچک به بزرگ طبقه بندی شده اند که این پهنه بندی کمک شایانی به درک نتایج شاخص‌ها در مدت زمان کوتاه تری برای تحلیلگران می‌باشد. بر اساس ارزیابی ۶ توابع موجک تجزیه و تحلیل سیگنال از مقیاس های مختلف و در دامنه زمان و فرکانس برگرفته از موجک تاثیر قابل توجهی در بهبود نتایج مدل SVR نداشته است. همچنین بر اساس نتایج، تابع موجک Haar علی رغم دارا بودن ساختار ساده و گسسته با داده های تبخیر ماهانه که حالتی پیچیده و تصادفی دارند سازگاری مناسبی داشته و نتایج بهتری را نسبت به دیگر توابع موجک ارائه کرده است. مدل Wavelet-SVR سطح تجزیه (L1) بهترین نتایج را ارائه داده است.

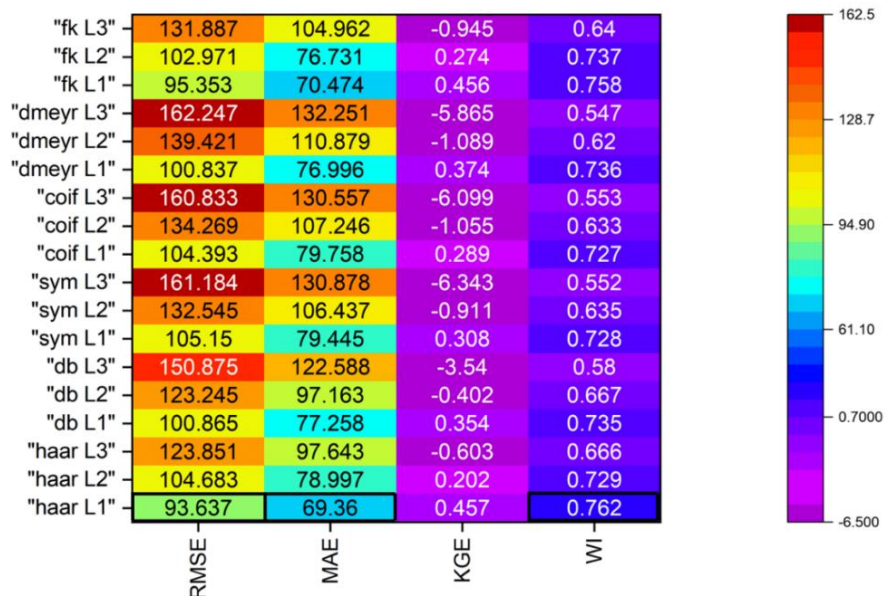
۱۰- مدل سازی تبخیر ماهانه با استفاده از مدل های تلفیقی

تجزیه محور Wavelet-SVR

برای کاربرد مدل ها، سری زمانی تبخیر با توجه به موجک های مادر انتخابی و سطح تجزیه مناسب به زیرسری های تقریب و جزئیات شکسته می‌شوند. برای محاسبه سطح تجزیه مناسب از معادله ۱۶ استفاده شده و برای توابع موجک db2, haar, sym4, coif2, dmeyr و Fk4 تا ۳ سطح تجزیه محاسبات انجام شده است. پس از بدست آوردن ورودی های بهینه که در مدل SVR سناریو ۳ به عنوان داده بهینه شناخته شد از شش تابع موجک برای تجزیه داده‌ها استفاده شده است که در جدول و شکل ۵ و ۳ ارائه شده است. با توجه به این جدول در مدل Wavelet-SVR تاثیر توابع موجک بر عملکرد مدل SVR منفی بوده است بطور مثال در سناریو ۳ (Tave) از مدل SVR مقدار شاخص RMSE برابر ۸۵/۴۳۳ بوده است که بعد از تجزیه داده‌ها این مقدار در بهترین حالت از توابع موجک (haar L1) به

جدول ۵. نتایج آماری Wavelet-SVR

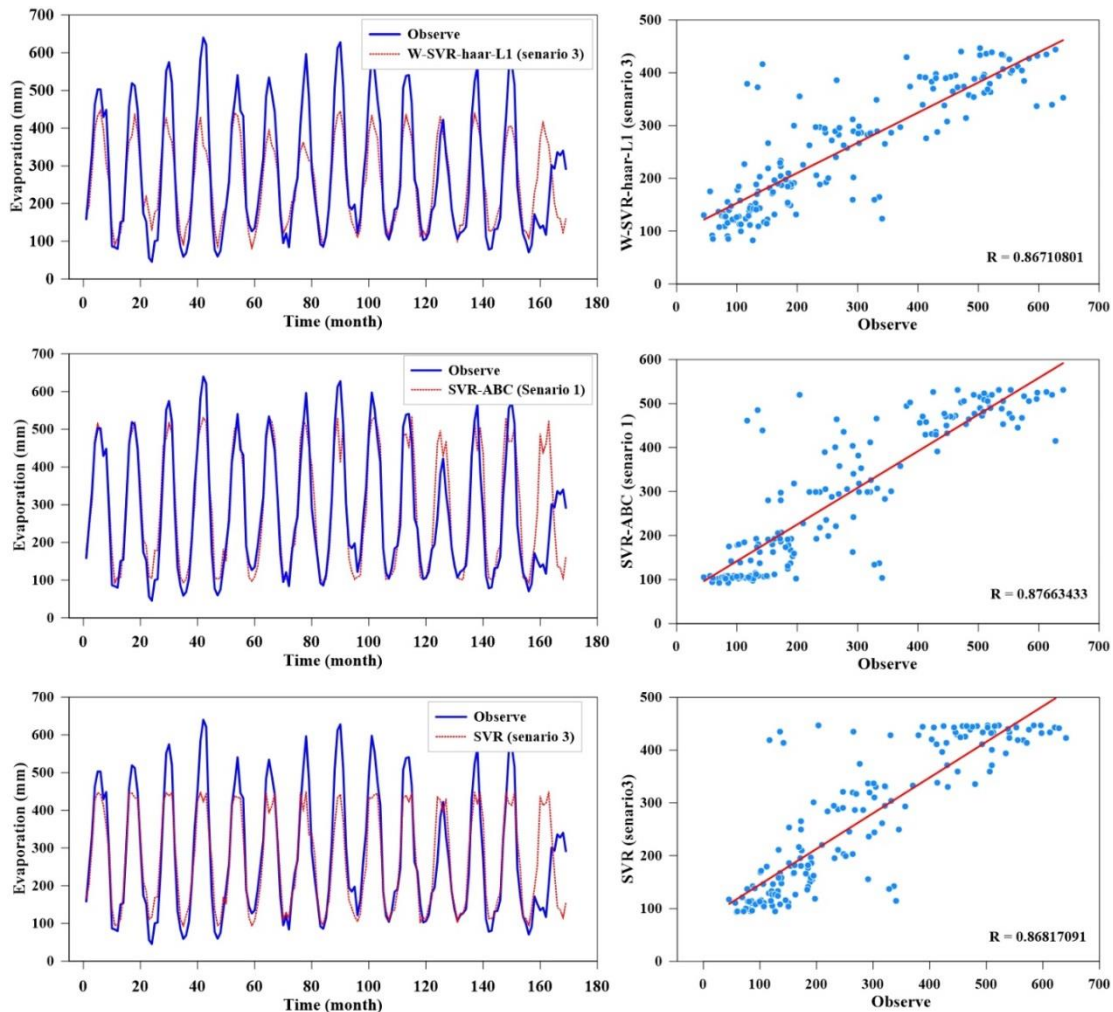
Wavelet Models	DOL	TRAIN				TEST			
		RMSE	MAE	KGE	WI	RMSE	MAE	KGE	WI
haar	L1	۶۴/۰۴۲	۴۴/۸۴۹	-۰/۷۳۹	۰/۸۲۹	۹۳/۶۳۷	۶۹/۳۶۰	-۰/۴۵۷	۰/۷۶۲
	L2	۶۹/۶۹۰	۴۹/۲۲۸	-۰/۶۴۳	۰/۸۱۲	۱۰۴/۶۸۳	۸۷/۹۹۷	-۰/۲۰۲	۰/۷۲۹
	L3	۸۱/۲۰۸	۵۸/۵۹۹	-۰/۳۸۷	۰/۷۷۷	۱۲۳/۸۵۱	۹۷/۶۴۳	-۰/۶۰۳	۰/۶۶۶
db	L1	۶۸/۶۳۴	۴۸/۸۷۸	-۰/۶۲۳	۰/۸۱۴	۱۰۰/۸۶۵	۷۷/۲۵۸	-۰/۳۵۴	۰/۷۳۵
	L2	۸۳/۷۷۲	۶۲/۲۲۲	-۰/۲۶۴	۰/۷۶۳	۱۲۳/۲۴۵	۹۷/۱۶۳	-۰/۴۰۲	۰/۶۶۷
	L3	۱۱۱/۳۰۵	۸۷/۹۸۰	-۰/۹۹۶	۰/۶۶۵	۱۵۰/۸۷۵	۱۲۲/۵۸۸	-۳/۵۴۰	۰/۵۸۰
sym	L1	۷۳/۳۹۳	۵۲/۴۱۹	-۰/۵۹۴	۰/۸۰۰	۱۰۵/۱۵۰	۷۹/۴۴۵	-۰/۳۰۸	۰/۷۲۸
	L2	۹۵/۱۴۴	۷۲/۳۱۳	-۰/۰۴۸	۰/۷۲۵	۱۳۲/۵۴۵	۱۰۶/۴۳۷	-۰/۹۱۱	۰/۶۳۵
	L3	۱۲۱/۸۵۶	۹۸/۱۷۱	-۱/۹۳۳	۰/۶۲۶	۱۶۱/۱۸۴	۱۳۰/۸۷۸	-۶/۳۴۳	۰/۵۵۲
coif	L1	۷۴/۰۱۱	۵۳/۳۲۲	-۰/۵۷۹	۰/۷۹۷	۱۰۴/۳۹۳	۷۹/۷۵۸	-۰/۲۸۹	۰/۷۲۷
	L2	۹۸/۴۷۸	۷۴/۹۶۹	-۰/۱۸۱	۰/۷۱۵	۱۳۴/۲۶۹	۱۰۷/۲۴۶	-۱/۰۵۵	۰/۶۳۳
	L3	۱۲۴/۰۲۰	۹۹/۸۵۵	-۲/۰۵۳	۰/۶۲۰	۱۶۰/۸۳۳	۱۳۰/۵۵۷	-۶/۰۹۹	۰/۵۵۳
dmeyr	L1	۷۰/۵۷۳	۴۹/۱۲۹	-۰/۶۳۸	۰/۸۱۳	۱۰۰/۸۳۷	۷۶/۹۹۶	-۰/۳۷۴	۰/۷۳۶
	L2	۹۷/۴۳۷	۷۳/۵۰۸	-۰/۰۲۶	۰/۷۲۰	۱۳۹/۴۲۱	۱۱۰/۸۷۹	-۱/۰۸۹	۰/۶۲۰
	L3	۱۱۷/۵۲۲	۹۲/۸۷۹	-۱/۱۶۶	۰/۶۴۶	۱۶۲/۲۴۷	۱۳۲/۲۵۱	-۵/۸۶۵	۰/۵۴۷
fk	L1	۶۳/۵۵۶	۴۴/۶۱۹	-۰/۷۲۹	۰/۸۳۰	۹۵/۳۵۳	۷۰/۴۷۴	-۰/۴۵۶	۰/۷۵۸
	L2	۶۹/۰۷۳	۴۹/۲۱۲	-۰/۶۲۵	۰/۸۱۳	۱۰۲/۹۷۱	۷۶/۷۳۱	-۰/۲۷۴	۰/۷۳۷
	L3	۹۱/۹۵۹	۷۱/۲۶۸	-۰/۰۴۴	۰/۷۲۹	۱۳۱/۸۸۷	۱۰۴/۹۶۲	-۰/۹۴۵	۰/۶۴۰



شکل ۳. نمودار Heat map برای نتایج تست مدل Wavelet-SVR

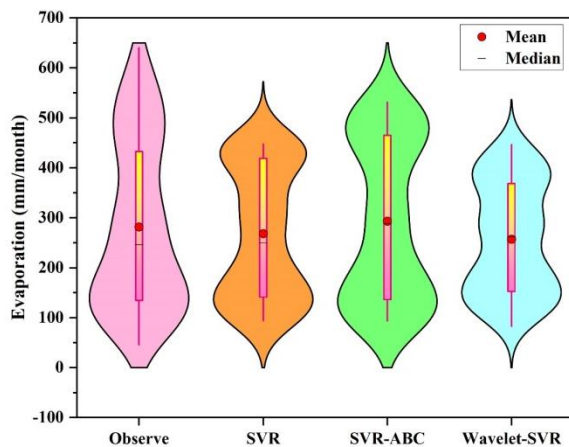
این منطقه مورد مطالعه ارائه کرده است. تلفیق مدل تجزیه محور Wavelet-SVR تأثیری در بهبود نتایج مدل نداشته است اما نتایج تابع موجک haar را بهتر از دیگر توابع موجک پیش بینی کرده است. همچنین با توجه به نمودار پراکنندگی ضریب همبستگی در مدل های مربوطه مقدار این ضریب برای مدل های Wavelet-SVR و SVR-ABC به ترتیب ۰/۸۶۸ ، ۰/۸۷۶ و ۰/۸۶۷ می باشد که با توجه به نتایج بدست آمده نیز قابل قبول می باشد.

در شکل ۴ به مقایسه مقادیر تبخیر از داده های مشاهداتی و پیش بینی شده توسط مدل های SVR، SVR-ABC و Wavelet-SVR برای سناریو های برتر به ترتیب ۳، ۱ و ۳ و رسم نمودار توزیع داده ها پرداخته شده است. بر اساس نتایج تفسیر شده و بر مبنای شاخص های ارزیابی RMSE، MAE، KGE و WI مدل فراابتکاری SVR-ABC در سناریو ۱ مناسبترین نتایج را ارائه داده است. سپس مدل منفرد SVR در سناریو شماره ۳ نتایج بهینه تری نسبت به دیگر سناریوها در



شکل ۴. مقایسه مقادیر تبخیر مشاهداتی با مدل های SVR، SVR-ABC، و Wavelet-SVR

مدل هیبریدی Wavelet-SVR عملکرد مناسبی در این حوضه نداشته است و در نتیجه تابع موجک در عملکرد مدل SVR مطلوب نمی باشد. (Qasem et al., 2019a) در مطالعات خود نتایج مشابهی را گزارش نموده اند.



شکل ۵. نمودار ویولونی مدل ها برای پیش بینی تبخیر

از نمودار ویولونی جهت نحوه توزیع داده های استفاده شده است. در نمودار ویولونی که حالتی دیگر از نمودار جعبه ای می باشد علاوه بر مینیمم، ماکزیمم، میانگین و چارک داده ها از توزیع داده ها و تراکم احتمالی استفاده می گردد. در شکل ۵ نمودار ویولونی تبخیر برای مدل های هیبریدی، منفرد و داده های مشاهداتی رسم شده است. بر اساس شکل ۵ مدل منفرد SVR با ورودی های تناوبی و غیر تناوبی تبخیر ماهانه را کمتر از مقادیر مشاهداتی برآورد نموده و در نتیجه میانگین داده ها در مقایسه با مقادیر مشاهداتی از ۲۸۱/۶۶۲ به ۲۵۶/۹۱ کاهش یافته است. در قسمت هایی که عرض نمودار عریضتر شده است احتمال بیشتری در توزیع داده ها وجود دارد و در محدوده با عرض کمتر احتمال آن کمتر است. اما در مدل ها بیشترین مقادیر تبخیر حول محور میانگین در قسمتی که عرض بیشتر است به خوبی توزیع نشده اند. میانگین داده ها در مدل SVR-ABC نزدیکتر به داده های مشاهداتی بوده و در مدل های SVR و Wavelet-SVR مقدار میانگین داده ها از داده های مشاهداتی کمتر می باشد. بطور کلی می توان نتیجه گرفت که

بحث

در جدول ۹ به مقایسه با تحقیقات دیگر محققین پرداخته شده است. در این مقایسه سعی شده است از مقالاتی استفاده شود که از توابع موجک و مدل SVR استفاده شده است. بر اساس نتایج مقایسه بیشترین تابعی از موجک که در مقالات استفاده شده است در رده اول تابع db و در رده دوم تابع haar می‌باشد که بیانگر این دو تابع مهم موجک می‌باشند و در اکثر مقالات نیز این توابع به عنوان تابع برتر در حوضه مربوطه معرفی شده‌اند. که در این تحقیق نیز تابع haar به عنوان تابع موجک برتر در مدل‌ها شناخته شده است. همچنین پارامتر دما به عنوان یک پارامتر ورودی ثابت در اکثر تحقیقات پیش‌بینی تبخیر، بارش و جریان ماهانه از اهمیت بالایی برخوردار بوده است. در تحقیق پیش رو از ۵ پارامتر مهم و تاثیر گذار دما در قالب ۲۸ سناریو استفاده شده است که پارامتر Tave مناسب ترین و بهینه ترین نتایج شبیه سازی را بر اساس مدل SVR کسب کرده است. بر اساس جدول ۶ مشاهده می‌گردد که استفاده از توابع موجک همیشه باعث افزایش دقت مدت نمی‌گردد و عواملی دیگر در این امر حائز اهمیت می‌باشند به عنوان مثال در تحقیق (Qasem et al., 2019b) که به پیش‌بینی تبخیر با استفاده از مدل SVR و Wavelet-SVR از ایستگاه تبریز و آنتالیا می‌پردازند مشاهده می‌شود که تابع موجک تاثیر نامطلوبی بر بردار پشتیبان رگرسیون دارد و نتایج را بر اساس شاخص ارزیابی RMSE و MAE به ترتیب تا ۱۵ درصد و ۱۴ درصد افزایش می‌دهد و متعاقباً دقت مدل کاهش پیدا می‌کند. در تحقیقی مشابه (Piri et al., 2023) دو حوضه سد پیشین و چاهنیمه در استان سیستان و بلوچستان با مدل Wavelet-SVR با یکدیگر مقایسه می‌کنند که نتایج شاخص ارزیابی RMSE در هر دو منطقه علی‌رغم شرایط آب و هوایی گرم و خشک با یکدیگر متفاوت می‌باشد. ارتفاع از سطح دریا، رطوبت نسبی، سرعت باد و تبخیر جز تفاوت‌های این دو حوضه با یکدیگر می‌باشند که جزء پارامترهای مهم و تاثیر گذار در هر حوضه محسوب می‌شوند. در دیگر تحقیقات گفته شده در جدول ۹ تابع موجک توانسته است بطور موثری در افزایش دقت مدل‌ها تاثیرگذار باشد. بطور مثال (Golabi et al., 2022) پیش‌بینی تبخیر از مخزن سد کرج با دو مدل تلفیقی و منفرد GPR و MLR انجام دادند که تابع موجک db4 از عملکرد مناسبی در این حوضه برخوردار بوده است بطوریکه بر اساس شاخص‌های ارزیابی RMSE و MAE نتایج مدل MLR با استفاده از تابع موجک db4 به ترتیب تا ۲۴ و ۲۸ درصد کاهش پیدا می‌کند و عملکرد مدل را بهبود می‌بخشد.

در این تحقیق به منظور پیش‌بینی تبخیر از مخزن سد در استان خوزستان، ایران از پارامترهای P ، T_{max} ، T_{min} ، T_{ave} ، T_{amax} ، T_{amin} استفاده شده است. بر اساس آنتروپی شانون تاثیرگذارترین پارامترهای ورودی T_{ave} ، T_{min} ، T_{max} ، T_{ave} ، T_{amax} ، T_{amin} برگزیده شده‌اند. همچنین در این تحقیق از مدل منفرد SVR و مدل فراابتکاری SVR-ABC جهت مقایسه و برآورد دقت آنها با یکدیگر و از مدل تجزیه محور Wavelet-SVR به منظور انتقال بهتر اطلاعات در پیش‌پردازش داده‌ها استفاده گردیده است. همچنین از ۶ تابع موجک db2، Haar، sym4، coif2، dmeyr و fk4 تا ۳ سطح تجزیه استفاده شده است. بر اساس جداول ۳ و ۴ شاخص‌های ارزیابی RMSE، MAE و WI مدل فراابتکاری SVR-ABC به ترتیب با ۸۲/۲۱۹ میلیمتر بر ماه، ۵۳/۹۷۷ میلیمتر بر ماه و ۰/۸۱۵ در سناریو ۱ نسبت به مدل SVR به ترتیب با ۸۵/۴۳۳ میلیمتر بر ماه، ۶۱/۰۱۰ میلیمتر بر ماه و ۰/۷۹۱ در سناریو ۳ عملکرد بهتری دارد. اما در شاخص KGE نتایج متفاوت‌تر گزارش شده است. بطور مثال در مدل SVR سناریو ۱ با $KGE=0.719$ و در SVR-ABC سناریو ۷ با اختلاف ۰/۰۰۱ با سناریو ۱ مناسب‌تر می‌باشد. با توجه به نتایج معیارهای آماری مشاهده می‌گردد شاخص‌های ارزیابی RMSE، MAE، KGE و WI با یکدیگر سازگار نبوده و این تفاوت در شاخص‌های ارزیابی می‌تواند باعث اختلال در یافتن مدل بهینه گردد. با توجه به اینکه ۳ معیار ارزیابی RMSE، MAE و WI نسبتاً پایدارتر می‌باشند و برای تعیین ترکیب ورودی بهینه شاخص‌ها، مد نظر قرار می‌گیرند. جدول ۵ نتایج مدل‌سازی تبخیر ماهانه با استفاده از مدل‌های تلفیقی تجزیه محور بر اساس ۶ تابع موجک تا ۳ سطح تجزیه را نشان می‌دهد. شاخص‌های ارزیابی RMSE، MAE و WI برای مدل Wavelet-SVR با تابع موجک Haar با سطح تجزیه ۱ با مقادیر به ترتیب ۹۳/۶۳۷ میلیمتر بر ماه، ۶۹/۳۶۰ میلیمتر بر ماه و ۰/۷۶۲ می‌باشند که بر خلاف تصورات در مدل هیبریدی Wavelet-SVR علاوه بر اینکه هیچکدام از توابع موجک نتایج آن را بهبود نداده‌اند بلکه استفاده از تابع موجک در مدل SVR باعث کاهش دقت مدل شده است بطوریکه بر اساس شاخص ارزیابی RMSE مقدار مدل منفرد SVR نسبت به مدل Wavelet-SVR از ۸۵/۴۳۳ به ۹۳/۶۳۷ افزایش یافته است که نشان دهنده کاهش حدود ۱۰ درصدی دقت مدل می‌باشد.

جدول ۶. مقایسه با دیگر محققین

ردیف	محققین	مدل		تابع موجک	متغیر ها	منطقه	نتایج شاخص های ارزیابی										
		SVR-BBF	SVR-WRBF				RMSE	MAE	WI	KGE	CC	NSE	R	CI	RRMS E	MAP E	
۱	(Pammar & Deka, 2017)	SVR	SVR	Db4, haar	T, W, P, RH, SHLE	هند	۰/۹۰	۰/۷۶۳		۰/۸۳۹							
		W-SVR	W-SVR				۰/۵۲۵	۰/۴۱۰		۰/۹۵۳							
۲	(Shafaei & Kisi, 2016)	SVR	SVR	Db3	Lake level data	Lake Van, Turkey	۰/۲۶۰	۰/۱۹۸				۰/۹۰۴					
		W-SVR	W-SVR				۰/۰۶۹	۰/۰۵۳				۰/۹۹۷					
۳	(Piri et al., 2023)	SVR	SVR		T, U, HS, RS, EP	pishein	۱/۷۴							۰/۷۵			
		W-SVR	W-SVR				۲/۶۴							۰/۸۳			
۴	(Qasem et al., 2019b)	MLR	MLR		W, T, RH, RS	chahmimneh	۰/۷۱۲	۰/۵۴۴				۰/۹۷۷		۰/۹۹۰			
		W-MLR	W-MLR	Db4	RA		۰/۸۲۸	۰/۶۳۳				۰/۹۷۰		۰/۹۸۶			
۵	(Golabi et al., 2022)	SVR	SVR				۳۰/۴۴۶	۲۵/۴۴۸						۰/۹۶۰			
		W-SVR	W-SVR				۲۴/۵۸	۱۹/۸۸						۰/۹۷۴			
۶	(Deo et al., 2016)	LSTM	LSTM	Db2	Tmax, Tmin, U, E, P, P	Cairns Areao	۲/۷۷۸	۲/۱۲۹						۱۵/۲۰۱	۱۵/۶۹۳		
		W-LSTM	W-LSTM				۲/۶۸۱	۲/۰۸۶						۱۴/۶۷۱	۱۵/۶۷۵		
۷	(Z. Liang et al., 2021)	SVR	SVR	meyer	T, E, P, SE	چین	۰/۶۴۷					۰/۵۷۵		۰/۹۳۱			
		Kstar	Kstar				۰/۳۲۵					۰/۸۸۷		۰/۹۴۶			
۸	(Ahmadi & Moadiah, 2021)	SVR	SVR	Haar, db2, db4, sym, coil, fk	P, T	امواز		۰/۵۸۵	۰/۲۰۲	۰/۴۸۲۷							
		W-SVR	W-SVR					۰/۷۵۳	۰/۲۳۷۲	۰/۷۸۴۹							
۹	(Nekoeyan et al., 2022)	SVR	SVR	Haar, db4, sym, coil, fk	R, E, Tave, Tmax, Tmin	سد مارون	۳۰/۴۸۵	۳۳/۵۰۷				۰/۵۰۹					
		W-SVR	W-SVR				۲۲/۹۰۶	۲۰/۲۵۴				۰/۵۴۵					

نتیجه‌گیری

به ترتیب ۹۳/۶۳۷ میلیمتر بر ماه، ۶۹/۳۶۰ میلیمتر در ماه و ۰/۷۶۲ مناسبترین نتیجه را بین توابع موجک ۶ گانه نشان می‌دهد. اما بر خلاف تصورات در مدل Wavelet-SVR علاوه بر اینکه هیچکدام از توابع موجک نتایج مدل SVR را بهبود نداده اند بلکه استفاده از تابع موجک باعث کاهش دقت مدل شده است بطوریکه بر اساس شاخص ارزیابی RMSE مقدار مدل منفرد SVR نسبت به مدل Wavelet-SVR از ۸۵/۴۳۳ به ۹۳/۶۳۷ افزایش یافته است که نشان دهنده کاهش حدود ۱۰ درصدی دقت مدل می‌باشد.

در این تحقیق از سه مدل SVR-ABC، SVR و Wavelet-SVR با ۶ تابع موجک db، haar، sym، coif، dmeyr و fk تا سه سطح تجزیه به منظور پیش‌بینی تبخیر از مخزن سد دز استفاده شده است. بر اساس شاخص‌های ارزیابی RMSE، MAE و WI مدل فراابتکاری SVR-ABC به ترتیب با ۸۲/۲۱۹ میلیمتر بر ماه، ۵۳/۹۷۷ میلیمتر بر ماه و ۰/۸۱۵ در سناریو ۱ نسبت به مدل SVR به ترتیب با ۸۵/۴۳۳ میلیمتر بر ماه، ۶۱/۰۱۰ میلیمتر بر ماه و ۰/۷۹۱ در سناریو ۳ عملکرد بهتری دارد. مدل تجزیه محور Wavelet-SVR با تابع موجک haar با سطح تجزیه ۱ با مقادیر

Reference:

- Adnan, R. M., Malik, A., Kumar, A., Parmar, K. S., & Kisi, O. (2019). Pan evaporation modeling by three different neuro-fuzzy intelligent systems using climatic inputs. *Arabian Journal of Geosciences*, 12(20), 1–14. <https://doi.org/10.1007/S12517-019-4781-6>/METRICS
- Ahmadi, F., & Maddah, M. A. (2021). *Development of Wavelet-Kstar Algorithm Hybrid Model for the Monthly Precipitation Prediction (Case Study: Synoptic Station of Ahvaz* <https://doi.org/10.22059/ijswr.2021.314110.668808>
- Allawi, M. F., & El-Shafie, A. (2016). Utilizing RBF-NN and ANFIS methods for multi-lead ahead prediction model of evaporation from reservoir. *Water Resources Management*, 30, 4773–4788.
- Ansari, M., & Akhoondzadeh, M. (2020). Mapping water salinity using Landsat-8 OLI satellite images (Case study: Karun basin located in Iran). *Advances in Space Research*, 65(5), 1490–1502.
- Ashrafzadeh, A., Ghorbani, M. A., Biazar, S. M., & Yaseen, Z. M. (2019). Evaporation process modelling over northern Iran: application of an integrative data-intelligence model with the krill herd optimization algorithm. *Hydrological Sciences Journal*, 64(15), 1843–1856.
- Ashrafzadeh, A., Malik, A., Jothiprakash, V., Ghorbani, M. A., & Biazar, S. M. (2020). Estimation of daily pan evaporation using neural networks and meta-heuristic approaches. *ISH Journal of Hydraulic Engineering*, 26(4), 421–429.
- Baek, J.-Y., Cho, J.-W., & Kim, S.-H. (2016). Effect of water vapor on evaporation and melt crystallization of mold fluxes. *Metallurgical and Materials Transactions B*, 47, 32–36.
- Baier, W., & Robertson, G. W. (1965). Estimation of latent evaporation from simple weather observations. *Canadian Journal of Plant Science*, 45(3), 276–284.
- Bhattarai, A., Qadir, D., Sunusi, A. M., Getachew, B., & Rahman, A. (2023). *Dynamic Sliding Window-Based Long Short-Term Memory Model Development for Pan Evaporation Forecasting*. 37–54. <https://doi.org/10.51526/kbes.2023.4.1.37-54>
- Boers, T. M., De Graaf, M., Feddes, R. A., & Ben-Asher, J. (1986). A linear regression model combined with a soil water balance model to design micro-catchments for water harvesting in arid zones. *Agricultural Water Management*, 11(3–4), 187–206.
- Chen, C. A., Lin, T. F., Yan, W. M., & Amani, M. (2018). Time periodic evaporation heat transfer of R-134a in a narrow annular duct due to mass flow rate oscillation. *International Journal of Heat and Mass Transfer*, 118, 154–164. <https://doi.org/10.1016/j.ijheatmasstransfer.2017.10.114>
- Chen, Y., Chen, W., Janizadeh, S., Bhunia, G. S., Bera, A., Pham, Q. B., Linh, N. T. T., Balogun, A.-L., & Wang, X. (2022). Deep learning and boosting framework for piping erosion susceptibility modeling: spatial evaluation of agricultural areas in the semi-arid region. *Geocarto International*, 37(16), 4628–4654.
- Cortes C, V. V. (1995). *Support-vector networks*. *Mach Learn*.
- Costache, R., Tin, T. T., Arabameri, A., Crăciun, A., Ajjin, R. S., Costache, I., Islam, A. R. M. T., Abba, S. I., Sahana, M., & Avand, M. (2022). Flash-flood hazard using deep learning based on H2O R package and fuzzy-multicriteria decision-making analysis. *Journal of Hydrology*, 609, 127747.
- Deo, R. C., Wen, X., & Qi, F. (2016). A wavelet-coupled support vector machine model for forecasting global incident solar radiation using limited meteorological dataset. *Applied Energy*, 168, 568–593. <https://doi.org/10.1016/j.apenergy.2016.01.130>
- Eames, I. W., Marr, N. J., & Sabir, H. (1997). The evaporation coefficient of water: a review. *International Journal of Heat and Mass Transfer*, 40(12), 2963–2973.
- El Bilali, A., Abdeslam, T., Ayoub, N., Lamane, H., Ezzaoui, 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(November 2022).

- <https://doi.org/10.1016/j.jenvman.2022.116890>
- Elbeltagi, A., Al-Mukhtar, M., Kushwaha, N. L., Al-Ansari, N., & Vishwakarma, D. K. (2023). Forecasting monthly pan evaporation using hybrid additive regression and data-driven models in a semi-arid environment. *Applied Water Science*, 13(2). <https://doi.org/10.1007/s13201-022-01846-6>
- Emadi, A. R., Zamanzad-Ghavidel, S., Zareie, S., & Rashid-Niaghi, A. (2022). Modeling Of Monthly Evaporation Using Single and Hybrid-Wavelet Data-Driven Methods in Basins of Iran with Climate Variety. *Irrigation and Water Engineering*, 12(4), 354–373.
- Fa'al, F., Ghafouri, H. R., & Ashrafi, S. M. (2020). Predicting Saltwater Intrusion into Coastal Aquifers Using Support Vector Regression Surrogate Models. *Journal of Water and Wastewater*, 31(2), 118–129.
- Fan, J., Chen, B., Wu, L., Zhang, F., Lu, X., & Xiang, Y. (2018). Evaluation and development of temperature-based empirical models for estimating daily global solar radiation in humid regions. *Energy*, 144, 903–914. <https://doi.org/10.1016/j.energy.2017.12.091>
- Fan, J., Wu, L., Zhang, F., Xiang, Y., & Zheng, J. (2016). Climate change effects on reference crop evapotranspiration across different climatic zones of China during 1956–2015. *Journal of Hydrology*, 542, 923–937.
- Fang, W., Huang, S., Ren, K., Huang, Q., Huang, G., Cheng, G., & Li, K. (2019). Examining the applicability of different sampling techniques in the development of decomposition-based streamflow forecasting models. *Journal of Hydrology*, 568, 534–550.
- Fattahi, H., & Babanouri, N. (2017). Applying Optimized Support Vector Regression Models for Prediction of Tunnel Boring Machine Performance. *Geotechnical and Geological Engineering*, 35(5), 2205–2217. <https://doi.org/10.1007/s10706-017-0238-4>
- Ferreira, L. B., da Cunha, F. F., de Oliveira, R. A., & Fernandes Filho, E. I. (2019). Estimation of reference evapotranspiration in Brazil with limited meteorological data using ANN and SVM—A new approach. *Journal of Hydrology*, 572, 556–570.
- Ghaemi, A., Rezaie-Balf, M., Adamowski, J., Kisi, O., & Quilty, J. (2019). On the applicability of maximum overlap discrete wavelet transform integrated with MARS and M5 model tree for monthly pan evaporation prediction. *Agricultural and Forest Meteorology*, 278, 107647. <https://doi.org/https://doi.org/10.1016/j.agrformet.2019.107647>
- Ghomeshi, M., Zayrie, M. R., & Hasounizadeh, H. (2020). Analysis of turbidity currents measured in Dez Reservoir. *Journal of Civil and Environmental Engineering*, 94(1), 77–88.
- Golabi, M. R., Eslamian, S., Geshnigani, F. S., & Farzi, S. (2022). Wavelet decomposition based on Gaussian process regression and multiple linear regression: Monthly reservoir evaporation prediction. *Handbook of Hydroinformatics: Volume II: Advanced Machine Learning Techniques*, 315–325. <https://doi.org/10.1016/B978-0-12-821961-4.00013-0>
- Golabi, M. R., Eslamian, S., Geshnigani, F. S., & Farzi, S. (2023). Chapter 20 - Wavelet decomposition based on Gaussian process regression and multiple linear regression: Monthly reservoir evaporation prediction (S. Eslamian & F. B. T.-H. of H. Eslamian (eds.); pp. 315–325). Elsevier. <https://doi.org/https://doi.org/10.1016/B978-0-12-821961-4.00013-0>
- Goltz, S. M., Tanner, C. B., Thurtell, G. W., & Jones, F. E. (1970). Evaporation measurements by an eddy correlation method. *Water Resources Research*, 6(2), 440–446.
- Gong, D., Hao, W., Gao, L., Feng, Y., & Cui, N. (2021). Extreme learning machine for reference crop evapotranspiration estimation: Model optimization and spatiotemporal assessment across different climates in China. *Computers and Electronics in Agriculture*, 187, 106294.
- Goyal, M. K., Bharti, B., Quilty, J., Adamowski, J., & Pandey, A. (2014). Modeling of daily pan evaporation in sub tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS. *Expert Systems with Applications*, 41(11), 5267–5276.
- Hassan, S., Rafi, M., & Shaikh, M. S. (2011). Comparing SVM and Naïve Bayes classifiers for text categorization with Wikitology as knowledge enrichment. *Proceedings of the 14th IEEE International Multitopic Conference 2011, INMIC 2011*, 31–34. <https://doi.org/10.1109/INMIC.2011.6151495>
- Helfer, F., Lemckert, C., & Zhang, H. (2012). Impacts of climate change on temperature and evaporation from a large reservoir in Australia. *Journal of Hydrology*, 475, 365–378. <https://doi.org/10.1016/J.JHYDROL.2012.10.008>
- Hu, C., Wu, Q., Li, H., Jian, S., Li, N., & Lou, Z. (2018). Deep learning with a long short-term memory networks approach for rainfall-runoff simulation. *Water*, 10(11), 1543.
- Jayasinghe, W. J. M. L. P., Deo, R. C., Ghahramani, A., Ghimire, S., & Raj, N. (2022). Development and evaluation of hybrid deep learning long short-term memory network model for pan evaporation estimation trained with satellite and ground-based data. *Journal of Hydrology*, 607, 127534.
- Jhajharia, D., Shrivastava, S. K., Sarkar, D., & Sarkar, S. (2009). Temporal characteristics of pan evaporation trends under the humid conditions of northeast India. *Agricultural and Forest Meteorology*, 149(5), 763–770.
- Jones, F. E. (2018). *Evaporation of water with emphasis on applications and measurements*. CRC Press.

- Karaboga, D., & Akay, B. B. (2005). An artificial bee colony (abc) algorithm on training artificial neural networks (Technical Report TR06): Erciyes University, Engineering Faculty. *Computer Engineering Department*.
- Kavousi-Fard, A., Samet, H., & Marzbani, F. (2014). A new hybrid Modified Firefly Algorithm and Support Vector Regression model for accurate Short Term Load Forecasting. *Expert Systems with Applications*, 41(13), 6047–6056. <https://doi.org/10.1016/j.eswa.2014.03.053>
- Keshtegar, B., Heddami, S., Sebbar, A., Zhu, S.-P., & Trung, N.-T. (2019). SVR-RSM: a hybrid heuristic method for modeling monthly pan evaporation. *Environmental Science and Pollution Research*, 26(35), 35807–35826. <https://doi.org/10.1007/s11356-019-06596-8>
- Khan, N., Shahid, S., Juneng, L., Ahmed, K., Ismail, T., & Nawaz, N. (2019). Prediction of heat waves in Pakistan using quantile regression forests. *Atmospheric Research*, 221, 1–11.
- Khoshtinat, S., Aminnejad, B., Hassanzadeh, Y., & Ahmadi, H. (2020). Potential Detection of Groundwater Resources of Sero Plain: Applications of Shannon's Entropy and Frequency Ratio (FR) Models. *Irrigation Sciences and Engineering*, 43(2), 123–137.
- Kim, S., Shiri, J., & Kisi, O. (2012). Pan evaporation modeling using neural computing approach for different climatic zones. *Water Resources Management*, 26, 3231–3249.
- Kisi, O. (2015a). Pan evaporation modeling using least square support vector machine, multivariate adaptive regression splines and M5 model tree. *Journal of Hydrology*, 528, 312–320. <https://doi.org/10.1016/j.jhydrol.2015.06.052>
- Kisi, O. (2015b). Pan evaporation modeling using least square support vector machine, multivariate adaptive regression splines and M5 model tree. *Journal of Hydrology*, 528, 312–320.
- Kumar, P., & 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), 90–98.
- Kushwaha, N. L., Bhardwaj, A., & Verma, V. K. (2016). Hydrologic response of Takarla-Ballowal watershed in Shivalik foot-hills based on morphometric analysis using remote sensing and GIS. *J Indian Water Resour Soc*, 36(1), 17–25.
- Kushwaha, N. L., Rajput, J., Elbeltagi, A., Elnaggar, A. Y., Sena, D. R., Vishwakarma, D. K., Mani, I., & Hussein, E. E. (2021). Data intelligence model and meta-heuristic algorithms-based pan evaporation modelling in two different agro-climatic zones: a case study from Northern India. *Atmosphere*, 12(12), 1654.
- Lang, A. R. G., McNaughton, K. G., Fazu, C., Bradley, E. F., & Ohtaki, E. (1983). Inequality of eddy transfer coefficients for vertical transport of sensible and latent heats during advective inversions. *Boundary-Layer Meteorology*, 25, 25–41.
- Liang, Y., Reyes, M. L., & Lee, J. D. (2007). Real-time detection of driver cognitive distraction using support vector machines. *IEEE Transactions on Intelligent Transportation Systems*, 8(2), 340–350. <https://doi.org/10.1109/TITS.2007.895298>
- Liang, Z., Liu, Y., Hu, H., Li, H., Ma, Y., & Khan, M. Y. A. (2021). Combined Wavelet Transform With Long Short-Term Memory Neural Network for Water Table Depth Prediction in Baoding City, North China Plain. *Frontiers in Environmental Science*, 9(December), 1–17. <https://doi.org/10.3389/fenvs.2021.780434>
- Lin, Y., Wang, D., Wang, G., Qiu, J., Long, K., Du, Y., Xie, H., Wei, Z., Shangguan, W., & Dai, Y. (2021). A hybrid deep learning algorithm and its application to streamflow prediction. *Journal of Hydrology*, 601, 126636.
- Liu, Y., Hou, G., Huang, F., Qin, H., Wang, B., & Yi, L. (2022). Directed graph deep neural network for multi-step daily streamflow forecasting. *Journal of Hydrology*, 607, 127515.
- Lundberg, A. (1993). Evaporation of intercepted snow—review of existing and new measurement methods. *Journal of Hydrology*, 151(2–4), 267–290.
- Malik, A., Kumar, A., Kim, S., Kashani, M. H., Karimi, V., Sharafati, A., Ghorbani, M. A., Al-Ansari, N., Salih, S. Q., & Yaseen, Z. M. (2020). Modeling monthly pan evaporation process over the Indian central Himalayas: Application of multiple learning artificial intelligence model. *Engineering Applications of Computational Fluid Mechanics*, 14(1), 323–338.
- Malik, A., Saggi, M. K., Rehman, S., Sajjad, H., Inyurt, S., Bhatia, A. S., Farooque, A. A., Oudah, A. Y., & Yaseen, Z. M. (2022). Deep learning versus gradient boosting machine for pan evaporation prediction. *Engineering Applications of Computational Fluid Mechanics*, 16(1), 570–587. <https://doi.org/10.1080/19942060.2022.2027273>
- 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), 1075–1094.
- Masoner, J. R., Stannard, D. I., & Christenson, S. C. (2008). Differences in evaporation between a floating pan and class a pan on land 1. *JAWRA Journal of the American Water Resources Association*, 44(3), 552–561.
- Mehdizadeh, S., Fathian, F., & Adamowski, J. F. (2019). Hybrid artificial intelligence-time series models for

- monthly streamflow modeling. *Applied Soft Computing*, 80, 873–887.
- Moghaddamnia, A., Ghafari Gousheh, M., Piri, J., Amin, S., & Han, D. (2009). Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*, 32(1), 88–97. <https://doi.org/10.1016/J.ADVWATRES.2008.10.005>
- Morton, F. I. (1990). Studies in evaporation and their lessons for the environmental sciences. *Canadian Water Resources Journal*, 15(3), 261–286.
- Naderpour, H., Hoseini Vaez, S. R., & Malekshahi, N. (2021). Predicting the Behavior of Concrete Dams Using Artificial Neural Networks (Case study of Dez Dam). *Civil Infrastructure Researches*, 6(2), 123–132. <https://doi.org/10.22091/cer.2021.6898.1242>
- Nekoeyan, M. A., Radmanesh, F., & Ahmadi, F. (2022). Prediction of Monthly Streamflow Using Shannon Entropy and Wavelet Theory Approaches (Case study: Maroon River). *Water and Irrigation Management*, 12(1), 15–31.
- Oliveira, L. S., & Sabourin, R. (2004). Support vector machines for handwritten numerical string recognition. *Proceedings - International Workshop on Frontiers in Handwriting Recognition, IWFHR*, 39–44. <https://doi.org/10.1109/IWFHR.2004.99>
- Pammar, L., & Deka, P. C. (2017). Daily pan evaporation modeling in climatically contrasting zones with hybridization of wavelet transform and support vector machines. *Paddy and Water Environment*, 15(4), 711–722. <https://doi.org/10.1007/s10333-016-0571-x>
- Patle, G. T., Chettri, M., & Jhajharia, D. (2020). Monthly pan evaporation modelling using multiple linear regression and artificial neural network techniques. *Water Supply*, 20(3), 800–808. <https://doi.org/10.2166/WS.2019.189>
- Pham, Q. B., Kumar, M., Di Nunno, F., Elbeltagi, A., Granata, F., Islam, A. R. M. T., Talukdar, S., Nguyen, X. C., Ahmed, A. N., & Anh, D. T. (2022). Groundwater level prediction using machine learning algorithms in a drought-prone area. *Neural Computing and Applications*, 34(13), 10751–10773.
- Piri, J., Mollaeinia, M., & Mostafaie, A. (2023). Assessment of response surface method and hybrid models to predict evaporation (case study: Chahnimeh and Pishein reservoirs in Sistan and Baluchestan Province of Iran). *Arabian Journal of Geosciences*, 16(5). <https://doi.org/10.1007/s12517-023-11330-3>
- Qasem, S. N., Samadianfard, S., Kheshtgar, S., Jarhan, S., Kisi, O., Shamshirband, S., & Chau, K.-W. (2019a). Modeling monthly pan evaporation using wavelet support vector regression and wavelet artificial neural networks in arid and humid climates. *Engineering Applications of Computational Fluid Mechanics*, 13(1), 177–187. <https://doi.org/10.1080/19942060.2018.1564702>
- Qasem, S. N., Samadianfard, S., Kheshtgar, S., Jarhan, S., Kisi, O., Shamshirband, S., & Chau, K. W. (2019b). Modeling monthly pan evaporation using wavelet support vector regression and wavelet artificial neural networks in arid and humid climates. <http://www.tandfonline.com/action/authorSubmission?JournalCode=tcfm20&page=instructions>, 13(1), 177–187. <https://doi.org/10.1080/19942060.2018.1564702>
- Roustaie, S., Mokhtari, D., & Ashrafi Fini, Z. (2020). Landslide hazard zonation in Taleghan watershed using Shannon entropy index. *Geography and Planning*, 24(71), 125–150.
- Sanikhani, H., Kisi, O., Maroufpoor, E., & Yaseen, Z. M. (2019). Temperature-based modeling of reference evapotranspiration using several artificial intelligence models: application of different modeling scenarios. *Theoretical and Applied Climatology*, 135, 449–462.
- Sartori, E. (2000). A critical review on equations employed for the calculation of the evaporation rate from free water surfaces. *Solar Energy*, 68(1), 77–89.
- Sayl, K. N., Muhammad, N. S., Yaseen, Z. M., & El-shafie, A. (2016). Estimation the physical variables of rainwater harvesting system using integrated GIS-based remote sensing approach. *Water Resources Management*, 30, 3299–3313.
- Sebbar, A., Heddami, S., & Djemili, L. (2020). Kernel extreme learning machines (KELM): a new approach for modeling monthly evaporation (EP) from dams reservoirs. <https://doi.org/10.1080/02723646.2020.1776087>, 42(4), 351–373.
- Shafaei, M., & Kisi, O. (2016). Lake Level Forecasting Using Wavelet-SVR, Wavelet-ANFIS and Wavelet-ARMA Conjunction Models. *Water Resources Management*, 30(1), 79–97. <https://doi.org/10.1007/s11269-015-1147-z>
- Shannon, C. E. (1948). A mathematical theory of communication, *Bell Systems Tech. J.*, 27, 379–423.
- Shimi, M., Najjarchi, M., Khalili, K., Hezavei, E., & Mirhoseyni, S. M. (2020). Investigation of the accuracy of linear and nonlinear time series models in modeling and forecasting of pan evaporation in IRAN. *Arabian Journal of Geosciences*, 13(2), 1–16. <https://doi.org/10.1007/S12517-019-5031-7/METRICS>
- Shirgure, P. S., & Rajput, G. S. (2011). Evaporation modeling with neural networks—A Research review. *Int J Res Rev Soft Intell Comput*, 1(2), 37–47.
- Tezel, G., & Buyukyildiz, M. (2016). Monthly evaporation forecasting using artificial neural networks and

- support vector machines. *Theoretical and Applied Climatology*, 124, 69–80.
- Theil, H. (1972). *Statistical decomposition analysis, vol. 14, Edited by H. Theil*. Amsterdam: North-Holland Publishing Company.
- Türkay, B. E., & Demren, D. (2011). Electrical load forecasting using support vector machines. *ELECO 2011 - 7th International Conference on Electrical and Electronics Engineering*, 1–49.
- Wang, L., Kisi, O., Zounemat-Kermani, M., & Li, H. (2017). Pan evaporation modeling using six different heuristic computing methods in different climates of China. *Journal of Hydrology*, 544, 407–427.
- Wang, W., & Ding, J. (2003). Wavelet network model and its application to the prediction of hydrology. *Nature and Science*, 1(1), 67–71.
- Wang, W., Xu, D., Chau, K., & Chen, S. (2013). Improved annual rainfall-runoff forecasting using PSO–SVM model based on EEMD. *Journal of Hydroinformatics*, 15(4), 1377–1390.
- Wu, L., Huang, G., Fan, J., Ma, X., Zhou, H., & Zeng, W. (2020). Hybrid extreme learning machine with meta-heuristic algorithms for monthly pan evaporation prediction. *Computers and Electronics in Agriculture*, 168, 105115.
- Yang, A. L., Huang, G. H., & Qin, X. S. (2010). An integrated simulation-assessment approach for evaluating health risks of groundwater contamination under multiple uncertainties. *Water Resources Management*, 24, 3349–3369.
- Yang, X., Yang, S., Tan, M. L., Pan, H., Zhang, H., Wang, G., He, R., & Wang, Z. (2022). Correcting the bias of daily satellite precipitation estimates in tropical regions using deep neural network. *Journal of Hydrology*, 608, 127656.
- Yaseen, Z. M., Al-Juboori, A. M., Beyaztas, U., Al-Ansari, N., Chau, K.-W., Qi, C., Ali, M., Salih, S. Q., & Shahid, S. (2020). Prediction of evaporation in arid and semi-arid regions: A comparative study using different machine learning models. *Engineering Applications of Computational Fluid Mechanics*, 14(1), 70–89.
- Yufeng, S., & Fengxiang, J. (2009). Landslide stability analysis based on generalized information entropy. *2009 International Conference on Environmental Science and Information Application Technology*, 2, 83–85.
- Zhao, L., Xia, J., Xu, C., Wang, Z., Sobkowiak, L., & Long, C. (2013). Evapotranspiration estimation methods in hydrological models. *Journal of Geographical Sciences*, 23, 359–369.

یادداشت‌ها

- ¹ Jhajharia et al. (2009)
- ² Zhakhovsky et al. (2019)
- ³ Qasem et al. (2019)
- ⁴ Ghaemi et al. (2019)
- ⁵ Jayasinghe et al. (2022)
- ⁶ Malik et al. (2022)
- ⁷ Emadi et al. (2022)
- ⁸ Golabi et al. (2023)
- ⁹ Keshtegar et al. (2019)
- ¹⁰ Kumar and Singh (2022)
- ¹¹ El Bilali et al. (2023)
- ¹² Cortes C. (1995)

Abbreviations

ANFIS	مدل عصبی فازی تطبیقی	MLR	رگرسیون خطی چندگانه
ANN	شبکه عصبی مصنوعی	MODWT	تبدیل موجک گسسته
Baggin	بسته بندی	P	بارش
CA	الگوریتم فراابتکاری جستجو کلاغ	PSO	ازدحام ذرات بهینه
Coif	کویفلت	REPTree	درخت هرس با خطای کاهش یافته
Db	دابچیز	RF	مدل جنگل تصادفی
DL	یادگیری عمیق	Rh	رطوبت نسبی
Dmeyer	میر	RMSE	ریشه میانگین مربعات خطا
DOL	سطح تجزیه	RNN	شبکه عصبی مکرر
E,Ep	تبخیر	RSS	مدل زیر فضای تصادفی
FFA	الگوریتم فراابتکاری کرم شب تاب	SOA	الگوریتم فراابتکاری مرغ دریایی
Fk	فجر کورکین	SVR	بردار پشتیبان رگرسیون
GBM	مدل ماشین تقویت کننده گرادیان	Sym	سیملت
GPR	رگرسیون فرآیند گوسی	T	دما
Haar	هار	Tamax	حداکثر مطلق درجه حرارت
Hs, Sh	ساعت خورشیدی	Tamin	حداقل مطلق درجه حرارت
KGE	شاخص کلینگ گوپتا	Tave	معدل میانگین درجه حرارت
LSTM	حافظه کوتاه مدت طولانی	Tmax	معدل حداکثر درجه حرارت
M5P	یادگیری ماشین هرس شده	Tmin	معدل حداقل درجه حرارت
MAE	میانگین قدر مطلق خطا	W,U	سرعت باد
MARS	خطوط رگرسیون تطبیقی چندمتغیره	Wavelet	تابع موجک
MLP	شبکه پرسپترون	WI	شاخص ویلموت
MLPNN	شبکه عصبی پرسپترون چندلایه	WNN	شبکه عصبی موجک