

Research Article

Prediction of Daily Reference Evapotranspiration with M5P, Gaussian Process Regression and Support Vector Regression Methods

S Samadianfard^{1*}, Z Rousta², M Sharafi³

Received: October 30, 2023

Accepted: May 12, 2024

Revised: April 24, 2024

Published online: June 21, 2024

1- Assoc. Prof., Water Engineering Dept., Faculty of Agriculture, University of Tabriz, Iran

2- MSc student, Water Engineering Dept., Faculty of Agriculture, University of Tabriz, Iran

3- PhD candidate, Water Engineering Dept., Faculty of Agriculture, Urmia University, Iran

*Corresponding Author, Email: s.samadian@tabrizu.ac.ir

Abstract

Background and Objectives

Indiscriminate use of water resources and the occurrence of drought in recent years have caused many problems in the country's water resources. The increasing shortage of water resources and high irrigation costs require developing new irrigation methods for optimal water consumption, which can minimize the amount of water used to produce yields. Evapotranspiration is one of the most important parameters needed to estimate the water balance in any ecosystem. Evapotranspiration is an essential parameter in the hydrological cycle process in natural ecosystems, which links the water and energy balance of the earth's surface with the atmosphere. Reference evapotranspiration (ET_0) plays an important role in the availability of water resources and stimulating the hydrological effect of climate change. Accurate estimation of ET_0 is necessary for forecasting climate changes, predicting and monitoring droughts, assessing the lack of availability of water resources, assessing crop water needs, and planning irrigation. FAO's Penman-Monteith method is known as a standard reference method for estimating ET_0 . However, this model and, in general, water balance-based assessment methods require accurate and long-term meteorological data, which are not always and everywhere available. Therefore, alternative methods for predicting ET_0 at different temporal and spatial scales should be developed, which are easily applied and require fewer input data without compromising the estimation accuracy. Also, due to the high rate of evapotranspiration in the coastal and central stations of the country, so far, few studies have predicted the ET_0 parameter. Therefore, this study was carried out to predict daily reference evapotranspiration in Isfahan and Astara stations.

Methodology

The current study is forecasting daily reference evapotranspiration in two stations of Astara and Isfahan using Gaussian Process Regression (GPR), Support Vector Regression (SVR), M5P tree model, and M5Rules linear regression. For this purpose, the daily meteorological data of the stations including average temperature, minimum temperature, maximum temperature, average relative humidity, minimum relative humidity, maximum relative humidity, wind speed, and sunshine hours during the period of 1990-2021 as inputs to the models was used. Also, to evaluate the effectiveness of the models, the evaluation criteria of determination coefficient (R^2), root mean square error (RMSE), Nash-Sutcliffe coefficient (NS), and Wilmott's index of agreement (WI) were used.

Findings

The evaluation of the results of different scenarios of the GPR model in Astara station showed that the fifth scenario was recognized as the best scenario of this model due to having a lower error value (RMSE=1.52 mm day⁻¹). For the M5Rules model, the fifth scenario has performed better than the other scenarios of the M5Rules model due to having fewer inputs and similar errors compared to the sixth to eighth scenarios (RMSE=1.42 mm day⁻¹).



In the M5P model, the fifth scenario has a higher accuracy than the other scenarios due to having a lower error value (RMSE=1.42 mm day⁻¹). For the SVR model, the sixth scenario with the least error (RMSE=1.58 mm day⁻¹) was selected as the best scenario compared to other scenarios of the SVR model. For the Isfahan station, for the GPR model, the fifth scenario has performed better than the other scenarios due to having fewer inputs. The comparison of M5Rules model scenarios also showed that the eighth scenario with RMSE=1.86 (mm day⁻¹), had higher accuracy than other scenarios. The eighth scenario of the M5P model has performed better than other scenarios due to its RMSE=1.86 (mm day⁻¹). Finally, the evaluation of SVR model scenarios showed that the eighth scenario with RMSE=1.88 (mm day⁻¹) had a better performance than other scenarios.

Conclusion

The comparison of the models used to predict daily reference evapotranspiration in Astara station showed that the fifth scenario of M5P and M5Rules models having evaluation criteria of $R^2=0.76$, RMSE=1.42 (mm day⁻¹), NS=0.7 and WI=0.89 had the highest accuracy compared to other models and showed the best performance. Also, the evaluation of the results of the models in Isfahan station showed that the eighth scenario of the M5Rules model, having the evaluation criteria of $R^2=0.8$, RMSE=1.85 (mm day⁻¹), NS=0.8 and WI=0.94 had the best performance compared to other models and the M5Rules model was selected as the best model. Also, the seventh scenario of the M5P model had almost the same performance as the eighth scenario of the M5Rules model and showed a good performance. Therefore, M5P and M5Rules models successfully predicted reference evapotranspiration.

Keywords: Astara, Evapotranspiration, Forecasting, Support vector regression, Water resources

مقاله پژوهشی

پیش‌بینی تبخیر-تعرق مرجع روزانه با روش‌های مدل درختی، رگرسیون بردار پشتیبان و رگرسیون فرآیند گاوسی

سعید صمدیان فرد^{۱*}، زهرا روستا^۲، میلاد شرفی^۳

تاریخ پذیرش: ۱۴۰۳/۰۲/۲۳

تاریخ دریافت: ۱۴۰۲/۰۸/۰۸

تاریخ انتشار آنلاین: ۱۴۰۳/۰۴/۰۱

تاریخ ویرایش: ۱۴۰۳/۰۲/۰۵

۱- دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، ایران

۲- دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، ایران

۳- دانشجوی دکتری، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ایران

* مسئول مکاتبات، پست الکترونیکی: s.samadian@tabrizu.ac.ir

چکیده

استفاده بی‌رویه از منابع آب و بروز خشکسالی در سال‌های اخیر سبب ایجاد مشکلات متعددی در منابع آبی کشور شده است. یکی از پارامترهای مهم در این راستا محاسبه تبخیر-تعرق می‌باشد. تبخیر-تعرق یکی از مهم‌ترین عوامل محدود کننده توسعه کشاورزی در مناطق خشک و نیمه‌خشک می‌باشد. به دلیل محدودیت‌های اقتصادی و سایر محدودیت‌ها همواره جمع‌آوری داده‌های تبخیر-تعرق چالش‌های فراوانی را برای محققان در پی داشته است. لذا هدف از مطالعه حاضر پیش‌بینی تبخیر-تعرق مرجع روزانه در دو ایستگاه آستارا و اصفهان با استفاده از مدل‌های رگرسیون فرآیند گاوسی، رگرسیون بردار پشتیبان، مدل درختی M5P و رگرسیون خطی M5Rules است. برای این منظور داده‌های هواشناسی روزانه ایستگاه‌ها شامل دما، رطوبت نسبی، سرعت باد و ساعات آفتابی طی دوره ۲۰۲۱-۱۹۹۰ به‌عنوان ورودی مدل‌ها به‌کار برده شد. بررسی پارامترهای ورودی نشان داد که رطوبت نسبی بیش‌ترین تاثیر را بر دقت پیش‌بینی مدل‌ها داشته است. همچنین جهت ارزیابی کارایی مدل‌ها از معیارهای ارزیابی مختلفی استفاده شد. ارزیابی مدل‌های به‌کار رفته در ایستگاه آستارا نشان داد که سناریو پنجم با کاربرد پارامترهای حداکثر دما، حداقل دما، میانگین دما، رطوبت نسبی حداکثر و رطوبت نسبی میانگین مدل‌های M5P و M5Rules با داشتن مقدار خطای $(1/42 \text{ mm day}^{-1})$ ، بالاترین دقت را نسبت به سایر مدل‌ها داشته‌اند. در ایستگاه اصفهان نیز سناریو هشتم مدل M5P و M5Rules با کاربرد پارامترهای حداکثر دما، حداقل دما، میانگین دما، رطوبت نسبی حداکثر و رطوبت نسبی میانگین، رطوبت نسبی حداکثر، ساعات آفتابی و سرعت باد با داشتن مقدار خطای $(1/86 \text{ mm day}^{-1})$ ، بهترین عملکرد را نسبت به سایر مدل‌ها داشتند. لذا مدل‌های M5P و M5Rules با موفقیت تبخیر-تعرق مرجع را پیش‌بینی کرده و روابط ریاضی ساده مستخرج از آنها برای استفاده در تعیین نیاز آبی گیاهان توصیه می‌گردد.

واژه‌های کلیدی: آستارا، پیش‌بینی، تبخیر-تعرق، رگرسیون بردار پشتیبان، منابع آب

مقدمه

تنوع و در دسترس بودن آب است (گیسولو و همکاران ۲۰۲۲). روش‌های زیادی برای تخمین ET_0 مانند تعادل آب و تعادل انرژی وجود دارد (ابیسیریوآردانا و همکاران ۲۰۲۲). روش‌های برآورد ET_0 را می‌توان به پنج دسته اصلی تقسیم کرد: مبتنی بر تبخیر تشت، مبتنی بر انتقال جرم، مبتنی بر دما، مبتنی بر تشعشع و ترکیبی (وانیاریچ و ساروکالیچ ۲۰۲۲). روش بیلان آب به‌عنوان یک روش مرجع برای برآورد ET_0 استفاده شده است. شایان ذکر است که روش پنمن-مانتیث فائو به‌عنوان یک روش مرجع استاندارد برای تخمین ET_0 شناخته شده است. با این وجود، این مدل و به‌طور کلی، روش‌های ارزیابی مبتنی بر تعادل آب به داده‌های دقیق و بلندمدت هواشناسی نیاز دارند که همیشه و در همه‌جا در دسترس نیستند (ابیسیریوآردانا و همکاران ۲۰۲۲). بنابراین، روش‌های جایگزین برای پیش‌بینی ET_0 در مقیاس‌های زمانی و مکانی مختلف باید توسعه داده شوند، که به راحتی اعمال می‌شوند و به داده‌های ورودی کمتری نیاز دارند بدون اینکه دقت تخمین را به خطر بیندازند. در این راستا، به‌ویژه در دهه‌های گذشته، رویکردهای هوش مصنوعی در برآورد ET_0 بسیار محبوب شده‌اند (عابدی کوپایی و همکاران ۲۰۲۲).

بسیاری از محققان تلاش کردند تا روش‌هایی را توسعه دهند که به‌طور مداوم ET_0 را با استفاده از داده‌های مختلف هواشناسی تخمین بزنند (شاه و همکاران ۲۰۲۱). تجادا و همکاران (۲۰۲۲) مدل‌هایی را بر اساس ماشین

صرفه‌جویی در مصرف آب در بخش کشاورزی و افزایش بهره‌وری مصرف آب در مناطق خشک و نیمه-خشک حیاتی است (میردشتوان و همکاران ۲۰۲۱). کمبود روزافزون منابع آب و هزینه‌های بالای آبیاری مستلزم توسعه روش‌های نوین آبیاری جهت مصرف بهینه آب است که می‌تواند میزان آب مورد استفاده در تولید محصولات را به حداقل برساند (النشر و الیامانی ۲۰۲۳). یکی از مهم‌ترین پارامترهای مورد نیاز برای تخمین تعادل آب در هر اکوسیستم تبخیر-تعرق است. تبخیر-تعرق یک پارامتر ضروری در فرآیند چرخه هیدرولوژیکی در اکوسیستم‌های طبیعی است که تعادل آب و انرژی سطح زمین را با جو پیوند می‌دهد (کوبی و همکاران ۲۰۲۱). تبخیر-تعرق مرجع (ET_0) به‌عنوان نرخ تبخیر-تعرق از سطح محصول مرجع یونجه بیان می‌شود (مارین و همکاران ۲۰۱۶). ET_0 نقش مهمی در دسترس بودن منابع آب و تحریک اثر هیدرولوژیکی تغییرات آب و هوا دارد (ستاری و همکاران ۲۰۱۴، شرافتمندراد و ماشیزی ۲۰۲۱). تخمین دقیق ET_0 برای پیش‌بینی تغییرات آب‌وهوا، پیش‌بینی و پایش خشکسالی، ارزیابی کمبود یا در دسترس بودن منابع آب، ارزیابی نیاز آبی محصول و برنامه‌ریزی آبیاری ضروری است (طالب مراد و همکاران ۲۰۲۱). نرخ و کمیت ET_0 از منطقه‌ای به منطقه دیگر بسته به عوامل هواشناسی مانند دما، تابش خورشیدی، رطوبت هوا و سرعت باد تغییر می‌کند (خو و همکاران ۲۰۱۷).

زمانی که مشاهدات میدانی مداوم به دلیل هزینه زیاد، نصب پیچیده ابزارها و یا تعمیر و نگهداری امکان‌پذیر نباشد، تخمین ET_0 یک روش امکان‌پذیر برای توصیف

استان اردبیل مدل مناسب‌تری بوده است. شرفی و صمدیان فرد (۲۰۲۱) در مطالعه‌ای به نقش توابع کرنل در افزایش دقت پیش‌بینی تبخیر روزانه در مناطق مرطوب و خشک کشور پرداختند. در این تحقیق، عملکرد مدل‌های رگرسیون فرآیند گاوسی (GPR⁶) و رگرسیون ماشین بردار پشتیبان (SVR) در تخمین تبخیر روزانه ایستگاه‌های آمل و بم در دوره زمانی ۱۳۹۹-۱۳۹۵ مورد ارزیابی قرار گرفت. نتایج مدل‌های مذکور نشان داد که هر دو مدل GPR و SVR عملکرد قابل قبولی در برآورد تبخیر داشتند. همچنین با توجه به ارزیابی مدل‌ها مشخص شد که مدل GPR عملکرد بهتری نسبت به مدل SVR داشته است (جزر میانگین مربعات خطا به ترتیب $1/56$ (mm day^{-1}) و $1/62$ (mm day^{-1}). الجنابی (۲۰۱۷) در تحقیقی به مدل‌سازی تبخیر ماهانه با استفاده از مدل درختی M5P در ایستگاه عماره واقع در جنوب عراق پرداخت. نتایج نشان داد مدل M5P که شامل ورودی‌های سرعت باد، رطوبت نسبی و دما بود، بهترین عملکرد را در میان تمام ترکیب در این مطالعه داشت. در نهایت M5P توانست با موفقیت در مدل‌سازی فرآیند تبخیر از داده‌های آب‌وهوایی موجود به‌کار گرفته شود. الدوسری و همکاران (۲۰۲۳) در مطالعه‌ای با استفاده از الگوریتم‌های داده‌کاوی و مدل‌های تجربی ریاضی به پیش‌بینی رانش باد و تلفات تبخیر برای آبیاری بارانی پرداختند. نتایج این بررسی نشان داد که مدل‌های REPTree و MLP خطاهای کوچک‌تری را برای مجموعه داده‌های آزمایشی ارائه کردند و با توجه به مقادیر شاخص اطمینان آنها به ترتیب $0/956$ و $0/966$ به‌عنوان مدل‌های کارآمد شناخته شدند.

بردار پشتیبان (SVM¹) و یادگیری ماشین شدید (ELM²) برای تخمین ET_0 روزانه با استفاده از ترکیب‌های ورودی مختلف داده‌های هواشناسی توسعه دادند. یافته‌های آنها نشان می‌دهد که مدل‌های SVM و ELM با حداقل T_{max} ، T_{min} و R_s به عنوان ورودی، بهترین تخمین ET_0 روزانه را ارائه می‌دهند. بایداراولو و کچاک (۲۰۱۴) در تحقیقی به پیش‌بینی تبخیر با استفاده از مدل مبتنی بر رگرسیون بردار پشتیبان پرداختند. نتایج این تحقیق نشان داد که پیش‌بینی‌های مبتنی بر رگرسیون بردار پشتیبان با داشتن ضرایب تعیین به ترتیب ۸۳ و ۹۷ درصد برای سری زمانی تک متغیره و چند متغیره بسیار موفق بوده است. تزل و بیوک ییلدیز (۲۰۱۶) در مطالعه‌ای به بررسی قابلیت استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه (MLP³)، شبکه تابع پایه شعاعی (RBFN⁴) و رگرسیون بردار پشتیبان (SVR⁵) جهت تخمین تبخیر ماهانه پرداختند. نتایج این بررسی نشان داد که الگوریتم‌های MLP و SVR با داشتن ضریب تعیین ۰/۹۵ نتایج مشابهی داشتند. شرفی و همکاران (۲۰۲۱) در تحقیقی مدل‌های هوشمند برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان را برای پیش‌بینی بارش ماهانه استان اردبیل به‌کار بردند. نتایج این تحقیق نشان داد که عملکرد هر دو مدل خوب و تقریباً یکسان بوده میانگین خطای مطلق به ترتیب $0/8$ (mm day^{-1}) و $0/721$ ، اما بر اساس ارزیابی‌های انجام شده، مدل رگرسیون بردار پشتیبان عملکرد نسبتاً بهتری نسبت به مدل دیگر داشته است. به‌طور کلی مدل رگرسیون بردار پشتیبان برای مدل‌سازی و پیش‌بینی بارش ماهانه در

⁵ Support vector regression

⁶ Gaussian process regression

¹ Support vector regression

² Extreme learning machine

³ Multilayer perceptron

⁴ Radial basis function network

ایستگاه سینوپتیک آستارا و اصفهان به ترتیب واقع در استان‌های گیلان و اصفهان طی بازه زمانی ۳۱ ساله بین سال‌های ۱۹۹۰-۲۰۲۱ مورد استفاده قرار گرفت. شکل ۱ موقعیت جغرافیایی ایستگاه‌های مورد مطالعه را نشان می‌دهد. همچنین جدول ۱ نیز مختصات و میزان بارش و تبخیر سالیانه را در هر دو ایستگاه نشان می‌دهد.

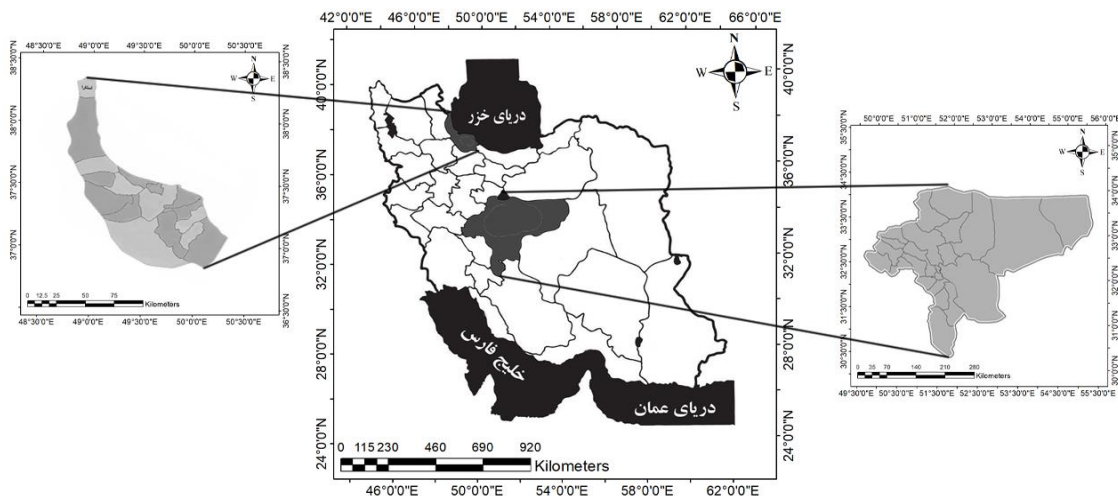
در مطالعه حاضر، داده‌های اقلیمی شامل حداکثر دما روزانه، حداقل دما روزانه، متوسط دما روزانه، رطوبت نسبی، سرعت باد در ارتفاع دو متری و ساعات آفتابی مربوط به ایستگاه تبخیرسنجی شهر آستارا و شهر اصفهان مورد استفاده قرار گرفت. با توجه به موقعیت جغرافیایی آستارا، ارتفاع آن از سطح دریا، نزدیکی این شهر به دره حیران و دارا بودن اقلیم کوهستانی و آب‌وهوای مرطوب و معتدل، این شهر اندکی خنک‌تر از دیگر مناطق پست جلگه‌ای استان است. علاوه بر این استان اصفهان در مرکز فلات ایران است و به علت گستردگی زیاد، شامل بخش‌های متعدد کوهستانی و جلگه‌ای است.

در دستیابی به اهداف مدیریت منابع آب مانند برنامه‌ریزی آبیاری، برآورد دقیق تبخیر-تعرق مرجع روزانه امری ضروری است. همچنین با توجه به نرخ بالای تبخیر در ایستگاه‌های ساحلی و مرکزی، به علت قرارگرفتن کشور بر روی کمربند خشکی جهان، تاکنون مطالعات اندکی به پیش‌بینی پارامتر تبخیر-تعرق با استفاده از روابط ریاضی ساده و خطی با دقت قابل قبولی پرداخته است. در این راستا مدل‌های رگرسیون فرآیند گاوسی، رگرسیون بردار پشتیبان، مدل درختی M5P و رگرسیون خطی M5Rules برای مدل‌سازی تبخیر-تعرق مرجع روزانه در ایستگاه‌های هواشناسی آستارا و اصفهان در دوره زمانی ۲۰۲۱-۱۹۹۰ استفاده گردید و نتایج حاصله به صورت روابط ریاضی کاربردی در تعیین نیاز آبی گیاهان ارائه شده‌اند.

مواد و روش‌ها

منطقه مورد مطالعه

در این مطالعه برای بررسی و برآورد مقادیر تبخیر-تعرق مرجع در مقیاس روزانه، داده‌های هواشناسی دو



شکل ۱- نقشه جغرافیایی ایستگاه‌های آستارا و اصفهان.

جدول ۱- مشخصات جغرافیایی ایستگاه‌های آستارا و اصفهان.

ایستگاه	طول جغرافیایی (°N)	عرض جغرافیایی (°E)	ارتفاع از سطح دریا (m)	میانگین بارندگی سالانه (mm)	میانگین تبخیر سالانه (mm)
آستارا	۴۸/۵۱	۳۸/۲۱	-۲۱،۱	۱۳۴۵	۱۱۰۰
اصفهان	۵۱/۴۰	۳۲/۳۹	۱۵۷۵	۱۲۰	۳۵۰۰

مدل سری زمانی رگرسیون فرآیند گاوسی (GPR)

GPR به صورت رابطه ۲ نوشته می‌شود (کوپرنیک و پفاف ۲۰۲۱).

$$f(t) = GPR(m(t) = 0, k(t, t')) \quad [2]$$

رگرسیون خطی (M5Rules)

M5Rules یکی از تکنیک‌های مبتنی بر قوانین در یادگیری ماشین برای پیش‌بینی مقادیر عددی و اسمی است. این مدل بر اساس مدل درختی M5P به وجود آمد که توسط کوینلان (۱۹۹۲) پیشنهاد شده و قوانین با هم ترکیب شده‌اند. برای ساختن مدل درختی M5P، الگوریتم درخت تصمیم برای ساختن درخت مدل به عنوان اولین گام مورد استفاده قرار می‌گیرد. سپس، می‌توان آن را به روش‌های مختلف هرس کرد، که توسط بریمن و همکاران (۱۹۸۴) و کوینلان (۱۹۸۷) معرفی شده است. برای تولید قوانین، الگوریتم درخت رگرسیون جزئی اعمال می‌شود (فرانک و ویتن ۱۹۹۸). در هر قاعده، یک اکتشافی بر اساس قاعده IF-THEN ایجاد می‌شود (شفیع الله و همکاران ۲۰۰۸)، و بهترین برگ در هر قاعده ایجاد می‌شود. از مجموعه داده مورد استفاده، تمام نمونه‌ها حذف شده و توسط قانون تولید شده در مرحله سوم پوشش داده می‌شوند. سپس، نمونه‌های باقی‌مانده توسط فرآیند بازگشتی در مرحله چهارم اعمال می‌شوند. سپس یک درخت کامل به جای درخت تا حدی کاوش شده ساخته می‌شود. در نهایت، مدل درختی M5P بهترین قانون را در هر الگو برای هر

راسموسن و ویلیامز (۲۰۰۶) اولین کسانی بودند که رگرسیون فرآیند گاوسی (GPR) را معرفی کردند. این رویکرد یک روش شناخته شده و ناپارامتریک برای حل مسائل طبقه‌بندی و رگرسیون است. علاوه بر این، مدل GPR به طور معمول برای پیش‌بینی متغیرهای موجود در بخش منابع آب مورد استفاده قرار گرفته است (دیو و سامویی ۲۰۱۷، روشنگر و شهنازی ۲۰۲۰). GPR یادگیری بیزین و ماشین‌های کرنل را ترکیب می‌کند تا یک رویکرد اصولی و احتمالی برای ایجاد یک مدل رگرسیون ایجاد کند. همچنین عدم قطعیت پیش‌بینی مدل می‌تواند مستقیماً در کنار مقدار پیش‌بینی شده خروجی قرار گیرد (فام و همکاران ۲۰۲۱).

به طور کلی می‌توان از میانگین و تابع کرنل برای محاسبه GPR استفاده کرد (کوپرنیک و پفاف ۲۰۲۱). طبق این تعریف، GPR مجموعه‌ای از متغیرهای تصادفی است که مقدار تابع $f(t)$ را در موقعیت t نشان می‌دهد. لذا می‌توان تابع را به صورت رابطه ۱ بیان کرد:

$$\begin{cases} f(t) = GPR(m(t), k(t, t')) \\ m(t) = E[f(t)] \\ k(t, t') = E[(f(t) - m(t))(f(t') - m(t'))] \end{cases} \quad [1]$$

$f(t)$ توزیع اولیه تابع رگرسیون بوده و $k(t)$ و $m(t)$ به ترتیب کرنل و تابع مدل هستند. باتوجه به اینکه مجموعه آموزشی T شامل اعداد محدود ورودی به صورت ماتریسی از t و t' می‌باشد، در نهایت، توزیع مشترک

مدل رگرسیون بردار پشتیبان (SVR)

مفهوم یادگیری SVM توسط کورتس و واپنیک (1995) معرفی شد. این مدل رویکرد رضایت‌بخشی را به مشکلات حاصل از طبقه‌بندی، تشخیص الگو، رگرسیون و پیش‌بینی ارائه می‌دهد. روش‌های مبتنی بر SVM مانند SVR با بسیاری از روش‌های دیگر متفاوت معنی‌داری دارند، به گونه‌ای که به جای به حداقل رساندن خطا بین مقادیر پیش‌بینی شده و مشاهده شده، ریسک عملیاتی به عنوان تابع هدف در نظر گرفته می‌شود که بایستی حداقل گردد. یک رگرسیون خطی ابتدا بر روی داده‌ها در SVR قرار می‌گیرد و سپس برای گرفتن الگوی داده‌های غیرخطی، خروجی از یک کرنل غیرخطی عبور می‌کند.

با توجه به مجموعه‌ای از داده‌های آموزشی $\{(d_i, x_i)\}$ مقدار واقعی است، x_i بردار ورودی و N تعداد کل الگوهای داده می‌باشد، تابع عمومی SVR در رابطه ۳ آورده شده است (وانگ و همکاران، ۲۰۱۳):

$$y = f(x) = w\phi(x_i) + b \quad [3]$$

که در آن $\phi(x_i)$ به صورت غیرخطی از بردار ورودی x نگاشت شده است که دلالت بر فضاهای ویژگی دارد. b و w نیز پارامترهای رگرسیون مدل هستند (وانگ و همکاران، ۲۰۱۳).

معیارهای ارزیابی مدل

در این پژوهش برای ارزیابی سناریوهای مختلف از معیارهای ضریب تعیین (R^{2V})، جذر میانگین مربعات خطا ($RMSE^A$)، ضریب کارایی نش-ساتکلیف (NS^9)، شاخص توافق ویلموت (WI^{10}) و شاخص خطای نسبی

درخت به نام M5Rules انتخاب می‌کند (آیاز و همکاران ۲۰۱۵).

مدل درختی (M5P)

درخت M5P یک مدل پیشرفته بوده و از نظر محاسباتی سرعت و کارایی بالایی را در میان یادگیرندگان درخت تصمیم دارد که بر اساس وظایف رگرسیونی که ابعاد بسیار بالایی دارند عمل می‌کند. این مدل برای اولین بار توسط کوینلان (۱۹۹۳) توسعه داده شد. M5P به جای تخصیص یک مقدار ثابت به هر گره از برگ، یک مدل رگرسیون خطی چند متغیره را در هر برگ برای پیش-بینی مقادیر عددی اختصاص می‌دهد. بنابراین، عملکرد یک مدل درختی M5P به شدت به مدل‌های خطی انتخاب شده وابسته است. در بین مدل‌ها درختی، M5P یک درخت رگرسیون باینری است که ویژگی‌های عددی پیوسته را ایجاد می‌کند. همچنین، برای انجام هرس درخت، تخلیه و جایگزینی درخت توسط یک تقریب تابع خطی انجام می‌شود، که واریانس در سلول‌ها را کاهش داده و گره‌های کوچک‌تری با ساختار درختی ایجاد می‌کند (نهو و همکاران ۲۰۲۰). مدل M5P قادر به مدیریت مجموعه داده‌های بزرگ، همراه با داده‌های از دست رفته است که با تقسیم فضاهای ورودی به فضاهای فرعی مختلف کوچکتر بازیابی می‌شوند. به طور کلی، حداقل تعداد نمونه‌ها، اندازه دسته‌ای، درختان رگرسیون ساخته شده، تعداد ارقام اعشاری و قابلیت‌های هرس نشده و بررسی نشده همگی از مزایای مدل‌های M5P هستند (فام و همکاران ۲۰۲۱).

⁹ Nash-Sutcliffe coefficient

¹⁰ Willmott's index of agreement

⁷ Correlation coefficient

⁸ Root mean squared error

نتایج و بحث

در این پژوهش پارامتر تبخیر-تعرق برای ایستگاه‌های اصفهان و آستارا توسط مدل‌های رگرسیون فرآیند گاوسی، رگرسیون بردار پشتیبان، مدل درختی M5P و رگرسیون خطی M5Rules پیش‌بینی شد. به طوری که ۷۰ درصد داده‌ها برای مرحله آموزش و ۳۰ درصد داده‌ها برای مرحله آزمون اختصاص یافت. همچنین، داده‌های هواشناسی حداقل دما (T_{min})، حداکثر دما (T_{max})، میانگین دما (T_m)، حداقل رطوبت نسبی (RH_{min})، حداکثر رطوبت نسبی (RH_{max})، میانگین رطوبت نسبی (RH_m)، میانگین سرعت باد (U_2) و ساعات آفتابی (SSH) جهت پیش‌بینی تبخیر-تعرق مرجع روزانه (ET_0) مورد استفاده قرار گرفت. جدول ۲ پارامترهای آماری داده‌های مورد استفاده در مطالعه حاضر و جدول ۳ نیز ترکیب سناریوهای مورد استفاده جهت پیش‌بینی تبخیر-تعرق مرجع روزانه را نشان می‌دهد. ترتیب پارامترها بر اساس ضریب همبستگی پیرسون و نقشه‌های گرمایشی ارائه شده در شکل ۲ تعیین شده است، به طوری که سناریو اول کم‌ترین همبستگی و سناریو هشتم بیش‌ترین همبستگی را با ET_0 داشته است.

($NRMSE^{11}$) برای پیش‌بینی مقادیر عملکرد مدل‌ها استفاده شده است. مقدار شاخص‌های ضریب نش-ساتکلیف و شاخص توافق ویلموت از ۱- تا ۱ متغیر است. به طوری که مقدار ۱ نشان‌دهنده‌ی بالاترین دقت و مقدار ۱- نشان‌دهنده‌ی کم‌ترین دقت مدل‌ها می‌باشد. برای شاخص ضریب تعیین، جذر میانگین مربعات خطا و خطای نسبی نیز هرچه مقدار این شاخص‌ها به ترتیب به یک، صفر و صفر نزدیک‌تر باشد، نشانگر همبستگی بالاتر و خطای کمتر مدل‌ها می‌باشد.

$$R^2 = \left(\frac{\sum_{i=1}^N O_i P_i - \frac{1}{N} \sum_{i=1}^N O_i \sum_{i=1}^N P_i}{\left(\left(\sum_{i=1}^N O_i^2 - \frac{1}{N} \left(\sum_{i=1}^N O_i \right)^2 \right) \left(\sum_{i=1}^N P_i^2 - \frac{1}{N} \left(\sum_{i=1}^N P_i \right)^2 \right) \right)^{1/2}} \right)^2 \quad [4]$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad [5]$$

$$NS = 1 - \left[\frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2} \right] \quad [6]$$

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

$$NRMSE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2}}{\bar{O}} \quad [8]$$


در روابط بالا، N تعداد کل داده‌ها، \bar{O}_i میانگین مقادیر مشاهداتی و پارامترهای P_i و O_i به ترتیب مقادیر پیش‌بینی شده و مشاهداتی می‌باشند.

جدول ۲- پارامترهای آماری داده‌های مورد استفاده.

Csx	Cv	Sx	Xmax	Xmin	Xmean	واحد	
۱/۶۴	۰/۷۳	۰/۹۱	۱۲/۷۵	۰/۰۰	۱/۲۵	m/s	ffm
-۰/۱۰	۰/۳۹	۸/۰۶	۳۶/۸۰	۲/۰۰	۲۰/۶۱	°C	Tmax
-۰/۱۳	۰/۵۳	۶/۸۹	۲۸/۰۰	-۲/۲۰	۱۳/۱۲	°C	Tmin
-۰/۰۸	۰/۴۴	۷/۳۹	۳۰/۹۰	۰/۸۰	۱۶/۷۳	°C	Tm
-۲/۰۹	۰/۰۰	۵/۹۲	۱۰۰/۰۰	۴۲/۰۰	۹۲/۵۸	%	Umax
۰/۰۰	۰/۰۰	۱۵/۴۶	۹۹/۰۰	۷/۰۰	۶۴/۳۴	%	Umin
-۱/۰۴	۰/۱۳	۱۰/۰۸	۹۹/۶۳	۲۴/۵۰	۸۰/۰۳	%	Um
۰/۰۷	۰/۷۸	۴/۳۹	۱۳/۵۰	۰/۰۰	۵/۶۴	h	Sshn
۱/۸۱	۰/۸۶	۲/۳۰	۵۰/۲۰	۰/۱۰	۲/۶۷	mm	evt
۱/۲۵	۰/۷۲	۱/۲۶	۱۰/۱۳	۰/۰۰	۱/۷۴	m/s	ffm
-۰/۵۴	۰/۲۷	۷/۷۹	۴۳/۰۰	۳/۲۰	۲۹/۰۱	°C	Tmax
-۰/۳۷	۰/۴۹	۶/۸۰	۲۸/۸۰	-۴/۸۰	۱۳/۷۷	°C	Tmin
-۰/۴۵	۰/۳۴	۷/۴۶	۳۵/۲۰	۰/۹۰	۲۱/۶۷	°C	Tm

¹¹ Normalized Root mean squared error

۰/۹۳	۰/۰۰	۲۰/۴۶	۱۰۰/۰۰	۹/۰۰	۴۵/۲۴	%	Umax
۲/۳۲	۰/۰۰	۱۰/۶۳	۸۹/۰۰	۲/۰۰	۱۶/۱۴	%	Umin
۱/۴۸	-۰/۵۲	۱۵/۰۰	۹۵/۸۸	۳/۶۳	۲۸/۷۸	%	Um
-۱/۶۳	۰/۲۸	۲/۷۸	۱۴/۰۰	۰/۰۰	۹/۹۵	H	Sshn
-۰/۰۲	۰/۴۸	۳/۹۷	۳۰/۰۰	۰/۱۰	۸/۳۴	Mm	Evt



شکل ۲- نقشه ی گرمایشی ایستگاه‌های آستارا (راست) و اصفهان (چپ).

جدول ۳- ترتیب سناریوهای مورد استفاده.

شماره	سناریو
۱	T_m
۲	T_m, T_{min}
۳	T_m, T_{min}, T_{max}
۴	$T_m, T_{min}, T_{max}, RH_{max}$
۵	$T_m, T_{min}, T_{max}, RH_{max}, RH_m$
۶	$T_m, T_{min}, T_{max}, RH_{max}, RH_m, RH_{min}$
۷	$T_m, T_{min}, T_{max}, RH_{max}, RH_m, RH_{min}, SSH$
۸	$T_m, T_{min}, T_{max}, RH_{max}, RH_m, RH_{min}, SSH, U_2$

شاخص توافق ویلموت (WI) و شاخص درصد میانگین نسبی (NRMSE) در جدول‌های ۴ و ۵ به‌ترتیب برای ایستگاه آستارا و اصفهان گزارش شده است.

در نهایت، خطای بین داده‌های اندازه‌گیری شده و پیش‌بینی شده از نظر ضریب تعیین (R^2), جذر میانگین مربعات خطا (RMSE), ضریب نش-ساتکلیف (NS),

جدول ۴- نتایج ارزیابی مدل‌های مورد استفاده در ایستگاه آستارا.

مدل	معیارهای ارزیابی					مدل	معیارهای ارزیابی				
	R^2	RMSE (mm day ⁻¹)	WI	NS	NRMSE (mm day ⁻¹)		R^2	RMSE (mm day ⁻¹)	WI	NS	NRMSE (mm day ⁻¹)
GPR-1	۰/۶۸	۲/۳۸	۰/۲۹	۰/۱۵	۰/۸۹	M5Rules-1	۰/۷۴	۱/۴۵	۰/۸۹	۰/۶۹	۰/۵۴
GPR-2	۰/۳۲	۲/۳۴	۰/۳۸	۰/۱۸	۰/۸۸	M5Rules-2	۰/۷۴	۱/۴۵	۰/۸۹	۰/۶۹	۰/۵۴

GPR-3	۰/۴۱	۲/۱۳	۰/۶۰	۰/۳۳	۰/۸۰	M5Rules-3	۰/۷۵	۱/۴۴	۰/۸۹	۰/۶۹	۰/۵۴
GPR-4	۰/۷۱	۱/۵۶	۰/۸۷	۰/۶۴	۰/۵۸	M5Rules-4	۰/۷۵	۱/۴۵	۰/۸۹	۰/۶۹	۰/۵۴
GPR-5	۰/۷۳	۱/۵۲	۰/۸۷	۰/۶۶	۰/۵۷	M5Rules-5	۰/۷۶	۱/۴۲	۰/۸۹	۰/۷۰	۰/۵۳
GPR-6	۰/۷۳	۱/۵۲	۰/۸۷	۰/۶۶	۰/۵۷	M5Rules-6	۰/۷۶	۱/۴۲	۰/۸۹	۰/۷۰	۰/۵۳
GPR-7	۰/۷۴	۱/۵۲	۰/۸۷	۰/۶۶	۰/۵۷	M5Rules-7	۰/۷۶	۱/۴۲	۰/۸۹	۰/۷۰	۰/۵۳
GPR-8	۰/۷۴	۱/۵۲	۰/۸۷	۰/۶۶	۰/۵۷	M5Rules-8	۰/۷۶	۱/۴۲	۰/۸۹	۰/۷۰	۰/۵۳
M5P-1	۰/۷۴	۱/۴۵	۰/۸۹	۰/۶۹	۰/۵۴	SVR-1	۰/۶۸	۱/۶۹	۰/۸۳	۰/۵۸	۰/۶۳
M5P-2	۰/۷۴	۱/۴۵	۰/۸۹	۰/۶۹	۰/۵۴	SVR-2	۰/۶۹	۱/۶۹	۰/۸۳	۰/۵۸	۰/۶۳
M5P-3	۰/۷۵	۱/۴۴	۰/۸۹	۰/۶۹	۰/۵۴	SVR-3	۰/۷۰	۱/۶۷	۰/۸۳	۰/۵۹	۰/۶۲
M5P-4	۰/۷۵	۱/۴۵	۰/۸۹	۰/۶۹	۰/۵۴	SVR-4	۰/۷۲	۱/۶۱	۰/۸۵	۰/۶۱	۰/۶۰
M5P-5	۰/۷۶	۱/۴۲	۰/۸۹	۰/۷۰	۰/۵۳	SVR-5	۰/۷۳	۱/۶۰	۰/۸۶	۰/۶۲	۰/۶۰
M5P-6	۰/۷۵	۱/۴۳	۰/۸۹	۰/۷۰	۰/۵۴	SVR-6	۰/۷۳	۱/۵۸	۰/۸۶	۰/۶۳	۰/۵۹
M5P-7	۰/۷۵	۱/۴۳	۰/۸۹	۰/۶۹	۰/۵۴	SVR-7	۰/۷۴	۱/۵۹	۰/۸۶	۰/۶۳	۰/۵۹
M5P-8	۰/۷۵	۱/۴۴	۰/۸۹	۰/۶۹	۰/۵۴	SVR-8	۰/۷۴	۱/۵۹	۰/۸۶	۰/۶۳	۰/۵۹

سرعت باد و ساعات آفتابی بر روی دقت مدل GPR می- باشد. در نهایت سناریو پنجم به دلیل داشتن ورودی‌های کمتر و دقت مشابه نسبت به سناریوهای ششم تا هشتم به عنوان سناریو برتر شناخته می‌شود.

برای مدل M5Rules سناریوهای اول تا چهارم به دلیل داشتن معیارهای ضریب تعیین $0/74$ ، جذر میانگین مربعات خطا $(mm\ day^{-1})$ $1/45$ ، ضریب نش-ساتکلیف $0/69$ ، شاخص توفیق ویلموت $0/89$ و شاخص درصد میانگین نسبی $0/54$ عملکرد تقریباً مشابهی را نسبت به یکدیگر داشته و تفاوت فاحشی در عملکرد سناریوها مشاهده نمی‌شود. در سناریو پنجم مقدار شاخص جذر میانگین مربعات خطا حدوداً $2/1$ درصد بهبود یافته و سایر معیارها تغییر محسوسی نداشته‌اند. لذا پارامتر میانگین رطوبت نسبی را می‌توان علت این بهبود در عملکرد مدل دانست. از سناریوهای ششم تا هشتم تغییری در دقت مدل مشاهده نمی‌شود و لذا پارامترهای ورودی تأثیری بر افزایش یا کاهش دقت مدل نداشته‌اند. در نهایت سناریو پنجم به دلیل داشتن ورودی‌های کمتر و در نتیجه صرفه‌جویی در زمان مدل‌سازی به عنوان

برای مدل GPR سناریو اول با داشتن ضریب تعیین $0/68$ ، جذر میانگین مربعات خطا $(mm\ day^{-1})$ $2/38$ ، ضریب نش-ساتکلیف $0/15$ ، شاخص توفیق ویلموت $0/29$ و شاخص درصد میانگین نسبی $0/89$ بیشترین خطا را نسبت به سایر سناریوهای این مدل داشته است. اما سناریو دوم با داشتن ضریب تعیین $0/32$ کمترین همبستگی را بین داده‌های مشاهداتی و پیش‌بینی شده داشته است. در سناریو سوم عملکرد مدل بهبود یافته به طوری که معیارهای R^2 ، NS و WI افزایش یافته و معیارهای RMSE و NRMSE کاهش جزئی داشته‌اند. سناریو چهارم نیز همانند سناریو سوم با افزایش دقت مدل همراه بوده است. دلیل افزایش دقت مدل در سناریو سوم و چهارم را می‌توان به ترتیب در افزودن پارامترهای حداکثر دما و حداکثر رطوبت نسبی دانست. مقایسه سناریو پنجم با سناریو چهارم نشان می‌دهد که شاخص‌های ضریب تعیین و جذر میانگین مربعات خطا به ترتیب به میزان $2/8$ و $2/6$ درصد بهبود یافته‌اند. از سناریو ششم تا هشتم تغییر محسوسی در مقدار شاخص‌های ارزیابی صورت نگرفته است. لذا معیارها به صورت تقریباً ثابتی باقی مانده‌اند. این عدم تغییر بیانگر عدم تأثیر پارامترهای حداقل و میانگین رطوبت نسبی،

نیز با افزوده شدن پارامتر حداکثر رطوبت نسبی میزان خطا نسبت به سناریو قبلی حدوداً ۳/۷ درصد بهبود یافته است. برای سناریو پنجم مقایسه معیارها نشان می‌دهد که عملکرد مدل به‌طور جزئی کاهش یافته است. همچنین سناریو ششم نیز با کاهش خطا به مقدار ۱/۳ درصد نسبت به سناریو پنجم عملکرد بهتری داشته است. دو سناریو آخر نیز با افزایش نسبی خطا به مقدار 1 mm day^{-1} نسبت به سناریو ششم عملکرد ضعیف‌تری را داشته‌اند. در نهایت سناریو ششم با داشتن کم‌ترین خطا نسبت به سایر سناریوهای مدل SVR به‌عنوان سناریو برتر انتخاب گردید. مقایسه مدل‌های به‌کار رفته جهت پیش‌بینی تبخیر-تعرق مرجع روزانه در ایستگاه آستارا نشان داد که سناریو پنجم مدل‌های M5P و M5Rules با داشتن معیارهای ارزیابی ضریب تعیین 0.76 ، جذر میانگین مربعات خطا $(1.42 \text{ mm day}^{-1})$ ، ضریب نش-سانکلیف 0.7 ، شاخص توافق و یلموت 0.89 و شاخص درصد میانگین نسبی 0.53 بالاترین دقت را نسبت به سایر مدل‌ها داشته و بهترین عملکرد را نشان داد. همچنین بررسی پارامترهای آماری در جدول ۴ نشان می‌دهد که مقدار ET_0 را می‌توان با سناریو اول مدل M5P و استفاده از پارامتر دمای میانگین با دقت قابل قبولی تخمین زد.

مدل برتر نسبت به سایر سناریوهای مدل M5Rules شناخته شد.

مقایسه سناریوهای مختلف برای مدل M5P نشان می‌دهد که از سناریوهای اول تا چهارم عملکرد مدل‌ها تغییر محسوسی نداشته است. با این حال افزوده شدن پارامتر میانگین رطوبت نسبی به سناریو پنجم سبب افزایش دقت مدل شده است. به طوری که میزان جذر میانگین مربعات خطا حدود $(0.3 \text{ mm day}^{-1})$ کاهش یافته است و باقی معیارها تقریباً بدون تغییر باقی مانده‌اند. از سناریو ششم تا هشتم مدل با داشتن معیارهای ضریب تعیین 0.75 ، جذر میانگین مربعات خطا $(1.43 \text{ mm day}^{-1})$ ، ضریب نش-سانکلیف 0.69 ، شاخص توافق و یلموت 0.89 و شاخص درصد میانگین نسبی 0.54 عملکرد نسبتاً ضعیفی نسبت به سناریو پنجم داشته است. در نهایت سناریو پنجم به‌علت داشتن مقدار خطای کمتر نسبت به سایر سناریوها عملکرد مناسب‌تری را داشته است.

ارزیابی نتایج مدل SVR نشان می‌دهد که سناریوهای اول و دوم با داشتن میزان خطای $(1.69 \text{ mm day}^{-1})$ ضعیف‌ترین عملکرد را نسبت به سایر سناریوهای این مدل داشته‌اند. سناریو سوم با بهبود شاخص خطا به مقدار $(0.2 \text{ mm day}^{-1})$ عملکرد بهتری نسبت به سناریوهای اول و دوم داشته است. در سناریو چهارم

جدول ۵- نتایج ارزیابی مدل‌های مورد استفاده در ایستگاه اصفهان.

مدل	معیارهای ارزیابی					مدل	معیارهای ارزیابی				
	R ²	RMSE (mm day ⁻¹)	WI	NS	NRMSE (mm day ⁻¹)		R ²	RMSE (mm day ⁻¹)	WI	NS	NRMSE (mm day ⁻¹)
GPR-1	0.75	2.88	0.34	0.11	0.46	M5Rules-1	0.76	2.05	0.92	0.75	0.25
GPR-2	0.58	3.89	0.35	0.11	0.47	M5Rules-2	0.77	2.01	0.93	0.76	0.24
GPR-3	0.62	2.73	0.81	0.56	0.33	M5Rules-3	0.77	2.00	0.93	0.76	0.24
GPR-4	0.76	2.03	0.92	0.76	0.24	M5Rules-4	0.78	1.92	0.93	0.78	0.23
GPR-5	0.76	2.00	0.93	0.76	0.24	M5Rules-5	0.76	1.92	0.93	0.78	0.23
GPR-6	0.76	2.00	0.93	0.76	0.24	M5Rules-6	0.78	1.92	0.93	0.78	0.23
GPR-7	0.76	2.00	0.93	0.76	0.24	M5Rules-7	0.79	1.87	0.94	0.79	0.22
GPR-8	0.76	2.00	0.93	0.76	0.24	M5Rules-8	0.80	1.85	0.94	0.8	0.22
M5P-1	0.76	2.05	0.92	0.75	0.25	SVR-1	0.75	2.09	0.92	0.74	0.25

ادامه جدول ۵

M5P-2	۰/۷۷	۲/۰۱	۰/۹۳	۰/۷۶	۰/۲۴	SVR-2	۰/۷۶	۲/۰۵	۰/۹۲	۰/۷۵	۰/۲۴
M5P-3	۰/۷۷	۲/۰۰	۰/۹۳	۰/۷۶	۰/۲۴	SVR-3	۰/۷۶	۲/۰۴	۰/۹۲	۰/۷۵	۰/۲۴
M5P-4	۰/۷۸	۱/۹۲	۰/۹۳	۰/۷۸	۰/۲۳	SVR-4	۰/۷۸	۱/۹۴	۰/۹۳	۰/۷۸	۰/۲۳
M5P-5	۰/۷۹	۱/۹۱	۰/۹۴	۰/۷۸	۰/۲۳	SVR-5	۰/۷۸	۱/۹۲	۰/۹۳	۰/۷۸	۰/۲۳
M5P-6	۰/۷۹	۱/۹۱	۰/۹۳	۰/۷۸	۰/۲۳	SVR-6	۰/۷۸	۱/۹۲	۰/۹۳	۰/۷۸	۰/۲۳
M5P-7	۰/۸۰	۱/۸۶	۰/۹۴	۰/۸۰	۰/۲۲	SVR-7	۰/۷۹	۱/۹۰	۰/۹۴	۰/۷۹	۰/۲۲
M5P-8	۰/۸۰	۱/۸۶	۰/۹۴	۰/۷۹	۰/۲۲	SVR-8	۰/۷۹	۱/۸۸	۰/۹۴	۰/۷۹	۰/۲۲

ششم در مقایسه با سناریوی سوم بدون تغییر باقی مانده است. همچنین مقایسه سناریوهای هفتم و هشتم نشان می‌دهد که شاخص جذر میانگین مربعات خطا حدود ۱/۱ درصد کاهش یافته و لذا عملکرد مدل در آخرین سناریو بهبود یافته است. در نهایت مقایسه سناریوهای مدل M5Rules نشان داد که سناریو هشتم با داشتن ضریب تعیین ۰/۸، جذر میانگین مربعات خطا (mm day^{-1}) ۱/۸۵، ضریب نش-ساتکلیف ۰/۸، شاخص توافق و یلموت ۰/۹۴ و شاخص درصد میانگین نسبی ۰/۲۲ دقت بالاتری را نسبت به سایر سناریوها داشته است.

برای مدل M5P ارزیابی سناریوهای اول و دوم نشان می‌دهد که معیار جذر میانگین مربعات خطا حدود ۲ درصد کاهش یافته و سایر معیارها به صورت جزئی بهبود یافته‌اند. همچنین در سناریو چهارم با افزوده شدن پارامتر حداکثر رطوبت نسبی مقدار شاخص جذر میانگین مربعات خطا تقریباً ۴/۱ درصد کاهش یافته که نشان از افزایش دقت مدل می‌باشد. برای سناریوهای پنجم و ششم مقدار شاخص‌های ارزیابی بدون تغییر باقی مانده-اند. در دو سناریو آخر با اینکه تغییری در عملکرد مدل مشاهده نمی‌شود، اما سناریو هفتم نسبت به سناریو ششم سبب کاهش ۲/۶ درصدی معیار خطا شده است. در نهایت سناریو هشتم مدل M5P به علت داشتن معیارهای ضریب تعیین ۰/۸، جذر میانگین مربعات خطا (mm day^{-1}) ۱/۸۶، ضریب نش-ساتکلیف ۰/۸، شاخص توافق و یلموت ۰/۹۴ و شاخص درصد میانگین

همچنین در ایستگاه اصفهان (جدول ۵) و برای مدل GPR، مقایسه سناریوهای اول و دوم نشان می‌دهد که معیار ضریب تعیین به شکل چشمگیری کاهش یافته (۲۵/۶ درصد) و معیارهای جذر میانگین مربعات خطا، شاخص توافق و یلموت و شاخص درصد میانگین نسبی در حد جزئی افزایش یافته‌اند. مقایسه دو سناریو بعدی (سوم و چهارم) نشان می‌دهد که شاخص‌های ضریب تعیین، ضریب نش-ساتکلیف و شاخص توافق و یلموت به ترتیب به میزان ۲۰/۳، ۳۰/۳ و ۱۲/۷ درصد افزایش یافته و شاخص جذر میانگین مربعات خطا حدود ۲۹/۴ درصد کاهش یافته‌اند. لذا عملکرد سناریو چهارم نسبت به سناریو سوم به علت افزوده شدن پارامتر حداکثر رطوبت نسبی به شکل موثری افزایش یافته است. از سناریو پنجم تا هفتم نیز با این که میزان شاخص‌ها ثابت باقی مانده‌اند، اما نسبت به سناریو چهارم مقدار خطا حدوداً ۱/۵ درصد بهبود یافته است. لذا سناریو پنجم به علت داشتن ورودی‌های کم‌تر عملکرد مناسب‌تری نسبت به سایر سناریوها داشته است.



مقایسه سناریوهای اول و دوم مدل M5Rules نشان می‌دهد که جذر میانگین مربعات خطا حدود ۲ درصد کاهش یافته در حالی که سایر معیارها تغییر محسوسی نداشته‌اند. ارزیابی سناریوهای سوم و چهارم نشان می‌دهد که مقدار خطا حدود ۴/۱ درصد کاهش یافته و شاخص نش-ساتکلیف ۲/۶ درصد افزایش یافته و سایر معیارها تغییر چشمگیری نداشته‌اند. میزان خطای سناریوهای پنجم و

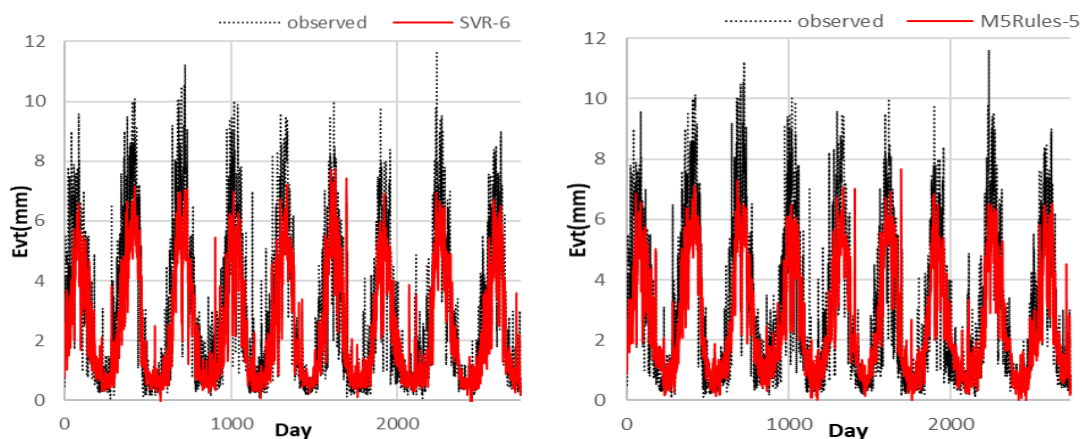
ارزیابی نتایج مدل‌های به‌کار رفته جهت پیش‌بینی تبخیر-تعرق مرجع روزانه در ایستگاه اصفهان نشان داد که سناریو هشتم مدل M5P و M5Rules با داشتن معیارهای ارزیابی ضریب تعیین $0/8$ ، جذر میانگین مربعات خطا (mm day^{-1}) $1/86$ ، ضریب نش-ساتکلیف $0/8$ ، شاخص توافق ویلموت $0/94$ و شاخص درصد میانگین نسبی $0/22$ بهترین عملکرد را نسبت به سایر مدل‌ها داشته‌اند. لذا در صورتی که پارامتر سرعت باد در دسترس نباشد مدل M5P می‌تواند به‌عنوان جایگزین امیدوارکننده‌ای به‌کار رود. بنابراین مدل M5P به‌عنوان مدل برتر در این مقاله انتخاب شد. علاوه‌براین، روند مشابهی همانند ایستگاه آستارا در تخمین تبخیر-تعرق مرجع در ایستگاه اصفهان مشاهده می‌گردد. به‌عبارت دیگر در این ایستگاه نیز می‌توان مقدار ET_0 را با سناریو اول مدل M5P و استفاده از پارامتر دمای میانگین با دقت قابل قبولی تخمین زد.

علاوه‌براین، نمودارهای تغییرات مقدار تبخیر-تعرق برای هر دو ایستگاه مورد مطالعه در شکل‌های ۳ و ۴، نمودارهای راداری مقادیر خطا در شکل‌های ۵ و ۶ و نمودارهای پراکنش در شکل‌های ۷ و ۸ ارائه شده‌اند.

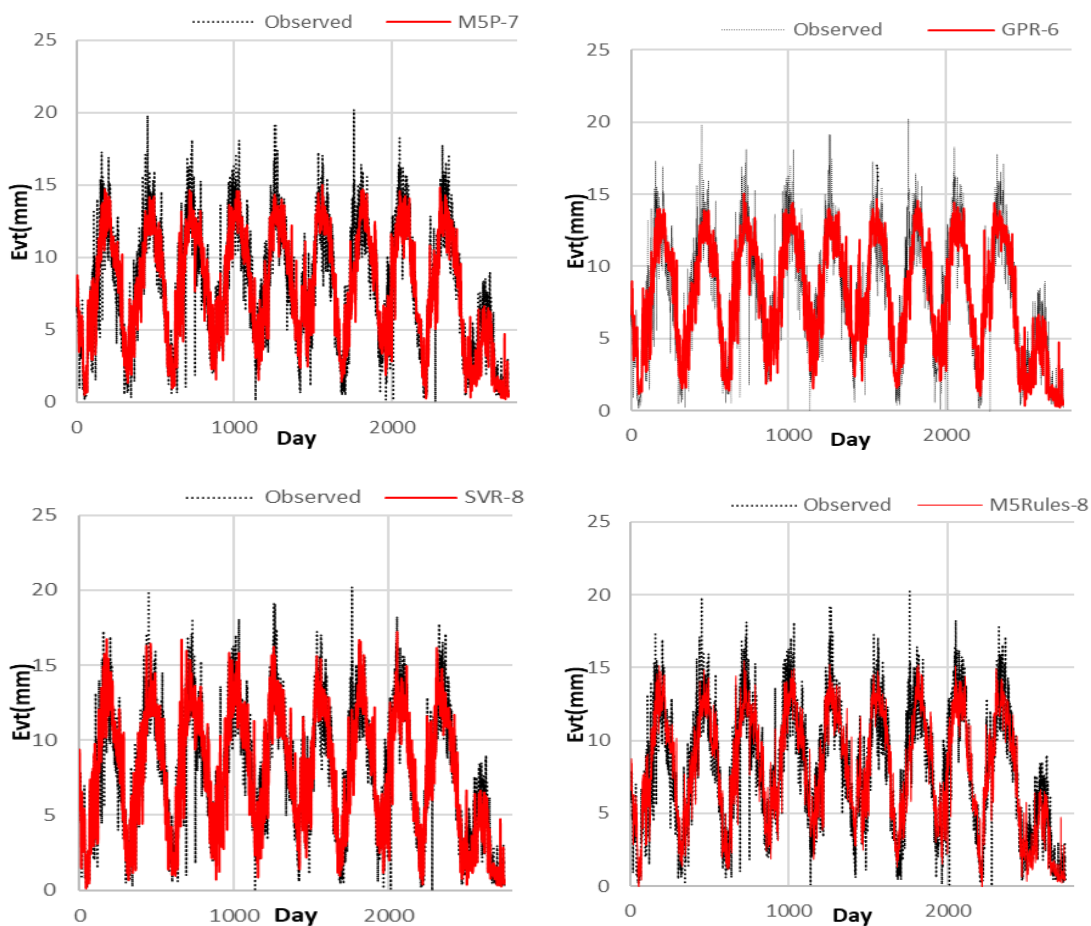
نسبی $0/22$ عملکرد بهتری را نسبت به سایر سناریوها داشته است.

مقایسه نتایج دو سناریو اول مدل SVR نشان می‌دهد که سناریو دوم سبب بهبود شاخص خطا به میزان ۲ درصد شده است در حالی که سایر معیارها تغییر محسوسی نداشته‌اند. برای دو سناریو بعدی (سوم و چهارم) معیار جذر میانگین مربعات خطا حدود ۵ درصد کاهش یافته و معیارهای ضریب تعیین، ضریب نش-ساتکلیف و شاخص توافق ویلموت به ترتیب حدود $2/6$ ، $3/9$ و $1/1$ درصد نسبت به سناریو سوم افزایش یافته‌اند. مقایسه سناریوهای پنجم و ششم حاکی از آن است که تغییری در عملکرد مدل رخ نداده است. لذا افزودن پارامتر حداقل رطوبت نسبی سبب افزایش یا کاهش دقت مدل نشده است. برای دو سناریو آخر مقدار شاخص خطا حدود $1/1$ درصد کاهش یافته و سایر معیارها نسبت به سناریو هفتم بدون تغییر باقی‌مانده‌اند. در نهایت ارزیابی سناریوهای مدل SVR نشان داد که سناریو هشتم با داشتن معیارهای ضریب تعیین $0/79$ ، جذر میانگین مربعات خطا (mm day^{-1}) $1/88$ ، ضریب نش-ساتکلیف $0/79$ ، شاخص توافق ویلموت $0/94$ و شاخص درصد میانگین نسبی $0/22$ کارایی بهتری نسبت به سایر سناریوها داشته است.

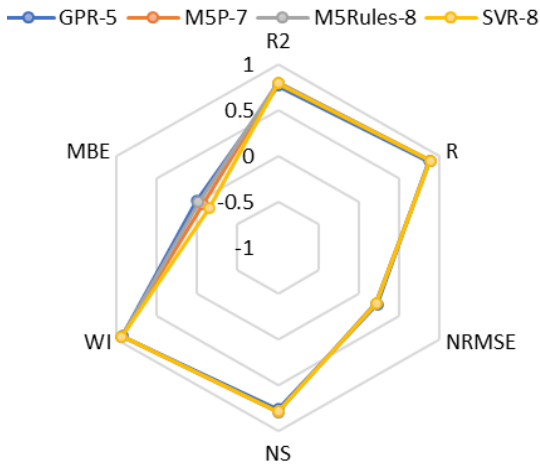




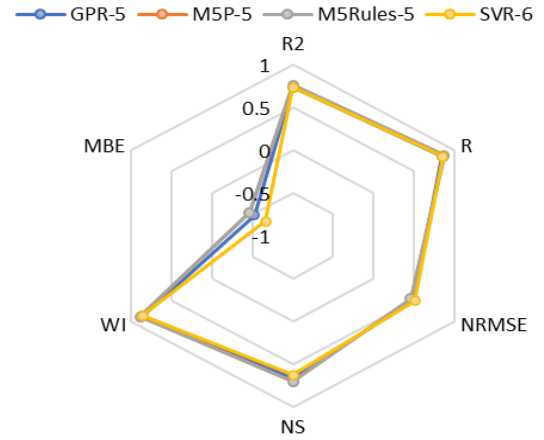
شکل ۳- نمودار سری زمانی برای بهترین سناریو در ایستگاه آستارا.





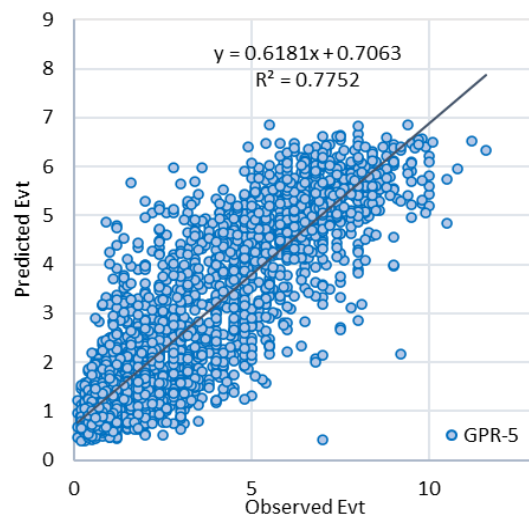

شکل ۴- نمودار سری زمانی برای بهترین سناریو در ایستگاه اصفهان.



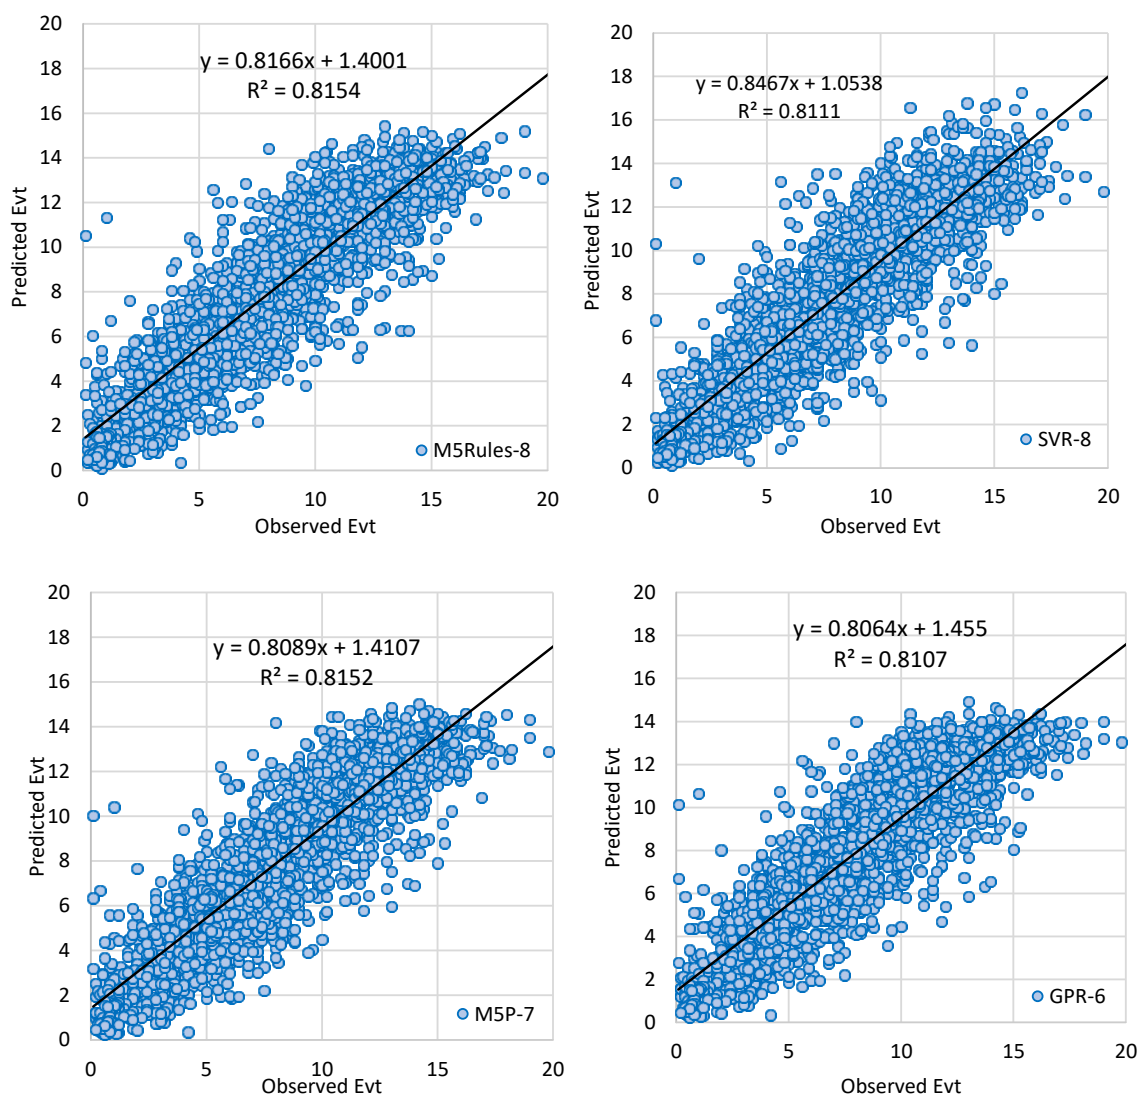
شکل ۶- نمودار راداری برای ایستگاه اصفهان.



شکل ۵- نمودار راداری برای ایستگاه آستارا.



شکل ۷- نمودار پراکنش ایستگاه آستارا.



شکل ۸- نمودار پراکنش ایستگاه اصفهان.

بنابراین براساس تحلیل‌های انجام یافته، مدل M5P به- عنوان مدل برتر در این مطالعه انتخاب گردید. در نهایت نتایج ریاضی استخراج شده از سناریوهای پنجم و هشتم به ترتیب در ایستگاه‌های آستارا و اصفهان در جدول‌های ۶ و ۷ ارائه شده‌اند.

همان‌طوری که از شکل‌های ۳ تا ۸ مشخص است، که سناریو پنجم مدل‌های M5P و M5Rules در ایستگاه آستارا و سناریو هشتم مدل M5P و M5Rules در ایستگاه اصفهان توافق بیشتری با داده‌های مشاهده‌ای داشته و بهترین عملکرد را نسبت به سایر مدل‌ها نشان داده‌اند.

جدول ۶- نتایج ریاضی استخراج شده از سناریو پنجم در ایستگاه آستارا.

معادله استخراج شده	شرط ورودی
$ET_0 = -0.0001 \times T_{max} + 0.0318 \times T_m + 0.074 \times T_{min} - 0.0226 \times U_m + 0.0545 \times sshn + 1.9809$	$T_{max} \leq 24.7$
$ET_0 = 0.0022 \times T_{max} + 0.1784 \times T_m + 0.0017 \times T_{min} - 0.0009 \times U_m + 0.0512 \times sshn - 0.9862$	$T_{max} > 24.7, T_m \leq 22.65$
$ET_0 = 0.0019 \times T_{max} + 0.2419 \times T_m + 0.0015 \times T_{min} - 0.0318 \times U_m + 0.1034 \times sshn - 0.0949$	$T_{max} > 24.7, 22.65 < T_m < 24.95$
$ET_0 = 0.0005 \times T_{max} + 0.274 \times T_m - 0.1286 \times T_{min} - 0.0344 \times U_m + 0.0272 \times sshn + 2.8684$	$T_{max} > 24.7, T_m > 24.95$

جدول ۷- نتایج ریاضی استخراج شده از سناریو هشتم در ایستگاه اصفهان.

معادله استخراج شده	شرط ورودی
$ET_0 = 0.0834 \times T_m + 0.0202 \times T_{min} - 0.0611 \times T_{max} - 0.004 \times U_{max} - 0.0095 \times U_m + 0.3176 \times sshn + 0.1168 \times ffm + 2.7464$	$T_{min} \leq 4, U_m \leq 21.938, sshn \leq 10.75$
$ET_0 = 0.0834 \times T_m + 0.0202 \times T_{min} - 0.0611 \times T_{max} - 0.004 \times U_{max} + 0.1354 \times U_m + 0.3176 \times sshn + 0.1168 \times ffm - 1.2462$	$T_{min} \leq 4, U_m \leq 21.936, 21.938 \leq U_m \leq 41.438, sshn \leq 10.75$
$ET_0 = 0.038 \times T_m + 0.0202 \times T_{min} - 0.0324 \times T_{max} - 0.004 \times U_{max} - 0.0095 \times U_m + 0.49 \times sshn + 0.2257 \times ffm + 1.2211$	$4 < T_{min} < 8.5, U_m \leq 27.188, sshn \leq 10.75$
$ET_0 = 0.0099 \times T_m + 0.217 \times T_{min} - 0.0146 \times T_{max} - 0.1076 \times U_{max} + 0.2238 \times U_m - 0.1261 \times umin + 0.141 \times sshn - 0.3581 \times ffm + 5.9036$	$T_{min} \leq 5.1, U_m \leq 23.813, sshn > 10.75$
$ET_0 = 0.0099 \times T_m + 0.0202 \times T_{min} - 0.3736 \times T_{max} - 0.1463 \times U_{max} + 0.399 \times U_m - 0.1735 \times umin + 0.141 \times sshn - 1.5122 \times ffm + 14.9912$	$T_{min} \leq 5.1, 23.813 < U_m \leq 27.188, sshn > 10.75$
$ET_0 = -0.2453 \times T_m + 0.0202 \times T_{min} + 0.1797 \times T_{max} - 0.0046 \times U_{max} - 0.0516 \times U_m + 1.1184 \times sshn + 0.135 \times ffm - 4.4626$	$5.1 < T_{min} \leq 8.5, U_m \leq 27.188, U_{max} \leq 31.5, sshn > 10.75$
$ET_0 = -0.2067 \times T_m + 0.0202 \times T_{min} + 0.1606 \times T_{max} - 0.0046 \times U_{max} - 0.0351 \times U_m + 0.5744 \times sshn + 0.1699 \times ffm + 0.4822$	$5.1 < T_{min} \leq 8.5, U_m \leq 27.188, U_{max} > 31.5, 10.75 < sshn \leq 12.3$
$ET_0 = -0.2529 \times T_m + 0.0202 \times T_{min} + 0.2034 \times T_{max} - 0.0046 \times U_{max} - 0.0351 \times U_m + 0.7228 \times sshn + 0.3423 \times ffm - 1.4049$	$5.1 < T_{min} \leq 8.5, U_m \leq 27.188, U_{max} > 31.5, sshn > 12.3$
$ET_0 = 0.0099 \times T_m + 0.2361 \times T_{min} - 0.018 \times T_{max} - 0.0003 \times U_{max} - 0.0088 \times U_m + 0.1917 \times sshn + 0.0286 \times ffm + 2.0057$	$T_{min} \leq 8.5, 27.188 < U_m \leq 41.438, FF_m \leq 0.688$
$ET_0 = 0.0099 \times T_m + 0.1576 \times T_{min} - 0.1562 \times T_{max} - 0.0003 \times U_{max} - 0.0081 \times U_m + 0.2242 \times sshn + 0.0255 \times ffm + 5.6155$	$T_{min} \leq 8.5, 27.188 < U_m \leq 41.438, FF_m > 0.688$
$ET_0 = 0.5835 \times T_m + 0.0054 \times T_{min} - 0.3453 \times T_{max} - 0.0003 \times U_{max} - 0.0792 \times U_m + 0.1484 \times sshn + 0.2058 \times ffm + 5.3075$	$8.5 < T_{min} \leq 13.3, U_m < 41.438$
$ET_0 = 0.1363 \times T_m + 0.0092 \times T_{min} - 0.0015 \times T_{max} - 0.0183 \times U_{max} - 0.002 \times U_m - 0.0079 \times umin + 0.0033 \times sshn + 0.3874 \times ffm + 2.673$	$T_{min} \leq 13.3, U_m > 41.438, T_m \leq 11.95$
$ET_0 = -0.26 \times T_m + 0.3797 \times T_{min} + 0.2282 \times T_{max} - 0.0004 \times U_{max} - 0.0512 \times U_m + 0.0033 \times sshn + 0.0121 \times ffm + 2.6269$	$T_{min} \leq 13.3, U_m > 41.438, T_m > 11.95$
$ET_0 = 0.0007 \times T_m + 0.4006 \times T_{min} - 0.0005 \times T_{max} + 0.0274 \times U_{max} - 0.0902 \times U_m + 0.0003 \times umin + 0.0055 \times sshn + 0.2633 \times ffm + 3.1714$	$13.3 < T_{min} \leq 18.45, sshn \leq 11.85$
$ET_0 = -0.4263 \times T_m + 0.3756 \times T_{min} + 0.2263 \times T_{max} - 0.0655 \times U_{max} - 0.0026 \times U_m + 0.0003 \times umin + 0.6454 \times sshn + 0.3748 \times ffm + 1.388$	$13.3 < T_{min} \leq 18.45, sshn > 11.85$
$ET_0 = -0.1124 \times T_m + 0.4517 \times T_{min} - 0.0005 \times T_{max} + 0.0264 \times U_{max} - 0.1712 \times U_m + 0.0562 \times umin + 0.2569 \times sshn + 0.2538 \times ffm + 4.1509$	$T_{min} > 18.45$

ضریب همبستگی ۰/۹۲ و جذر میانگین خطای ۰/۲۵ دارای عملکرد مناسبی در پیش‌بینی تبخیر-تعرق پتانسیل بوده است، مطابقت دارد. همچنین نتایج به‌دست آمده در تحقیق حاضر تطابق کاملی با نتایج ستاری و اسمعیل زاده (۲۰۱۷) دارد. به‌طوری‌که مقدار جذر میانگین

نتایج این مطالعه با نتایج میرهاشمی و همکاران (۲۰۲۰) که به ارزیابی الگوریتم MSP در برآورد تبخیر-تعرق پتانسیل، دمای کمینه و بیشینه طی دوره ۳۰ ساله از سال ۱۳۶۷ تا ۱۳۹۷ به‌صورت ماهانه در ایستگاه هواشناسی ساری پرداختند و نشان دادند که مدل MSP با داشتن

پارامترهای هواشناسی بر دقت مدل‌ها از هشت سناریو مختلف با در نظر گرفتن ضریب همبستگی پارامترهای ورودی استفاده شد. ارزیابی مدل‌های به کار رفته در ایستگاه آستارا نشان داد که سناریو پنجم مدل‌های M5P و M5Rules با داشتن معیارهای ارزیابی ضریب تعیین ۰/۷۶ و شاخص توافق و یلموت ۰/۸۹ بالاترین دقت را نسبت به سایر مدل‌ها داشته‌اند. در ایستگاه اصفهان نیز سناریو هشتم مدل M5P و M5Rules با داشتن معیارهای ارزیابی ضریب تعیین ۰/۸ و شاخص توافق و یلموت ۰/۹۴ بهترین عملکرد را نسبت به سایر مدل‌ها داشتند. لذا مدل‌های M5P با موفقیت تبخیر-تعرق مرجع روزانه را در ایستگاه‌های آستارا و اصفهان پیش‌بینی کردند. در نهایت استفاده از روابط ریاضی ساده مستخرج از مدل‌های درختی جهت برآورد تبخیر-تعرق مرجع با دقت قابل قبول برای کاربرد در تعیین نیاز آبی گیاهان توصیه می‌گردد.

مربعات خطا در تحقیق حاضر و در منطقه نیمه خشک اصفهان تقریباً برابر با مقدار متناظر در پژوهش ستاری و اسمعیل زاده می‌باشد، در حالی که توانایی مدل‌های درختی در پیش‌بینی تبخیر-تعرق مرجع و در منطقه مرطوب بالاتر بود.

نتیجه‌گیری کلی

تبخیر-تعرق پدیده‌ای غیرخطی و پیچیده بوده که به پارامترهای اقلیمی متفاوتی نیاز دارد. از طرفی، پیش‌بینی دقیق تبخیر-تعرق به صرفه‌جویی در مصرف آب و مدیریت بهینه کشاورزی کمک می‌کند. لذا در مطالعه حاضر جهت پیش‌بینی هرچه دقیق‌تر ET_0 با استفاده از پارامترهای هواشناسی از مدل‌های رگرسیون فرآیند گاوسی (GPR)، رگرسیون بردار پشتیبان (SVR)، مدل درختی M5P و رگرسیون خطی M5Rules در ایستگاه‌های هواشناسی آستارا و اصفهان طی دوره زمانی ۲۰۲۱-۱۹۹۰ استفاده گردید. همچنین جهت ارزیابی تاثیر

منابع مورد استفاده

- Abedi-Koupai J, Dorafshan MM, Javadi A and Ostad-Ali-Askari K, 2022. Estimating potential reference evapotranspiration using time series models (Case study: synoptic station of Tabriz in northwestern Iran). *Applied Water Science* 12(9): 212-224.
- Abeyisiriwardana HD, Muttill N and Rathnayake U, 2022. A Comparative study of potential evapotranspiration estimation by three methods with FAO Penman-Monteith method across Sri Lanka. *Hydrology* 9(11): 206-218.
- Al-Dosary NMN, Maray SA, Al-Hamed SA and Aboukarima AM, 2023. Employing data mining algorithms and mathematical empirical models for predicting wind drift and evaporation losses of a sprinkler irrigation method. *Water* 15(5): 922-939.
- AL-Janabi MAHJ, 2017. Modeling of monthly pan evaporation using M5P machine learning technique. *Journal of Kufa-Physics* 9(1): 21-38.
- Ayaz Y, Kocamaz AF and Karakoç MB, 2015. Modeling of compressive strength and UPV of high-volume mineral-admixed concrete using rule-based M5 rule and tree model M5P classifiers. *Construction and Building Materials* 94: 235-240.
- Baydaroğlu Ö and Koçak K, 2014. SVR-based prediction of evaporation combined with chaotic approach. *Journal of Hydrology* 508: 356-363.
- Breiman L, Friedman JH, Olshen RA and Stone CJ, 1984. *Classification and Regression Trees*. Taylor & Francis, New York.
- Cortes C and Vapnik V, 1995. Support-vector networks. *Machine Learning* 20: 273-297.

- Cui Y, Song L and Fan W, 2021. Generation of spatio-temporally continuous evapotranspiration and its components by coupling a two-source energy balance model and a deep neural network over the Heihe River Basin. *Journal of Hydrology* 597: 126-139.
- Deo RC and Samui P, 2017. Forecasting evaporative loss by least-square support-vector regression and evaluation with genetic programming, Gaussian process, and minimax probability machine regression: case study of Brisbane City. *Journal of Hydrologic Engineering* 22(6): 50-64.
- El-Nashar W and Elyamany A, 2023. Adapting irrigation strategies to mitigate climate change impacts: a value engineering approach. *Water Resources Management* 37(6-7): 2369-2386.
- Frank E and Witten IH, 1998. Generating accurate rule sets without global optimization. 1-18.
- Gisolo D, Previati M, Bevilacqua I, Canone D, Boetti M, Dematteis N, Balocco J, Ferrari S, Gentile A and N'sassila M, 2022. A calibration free radiation driven model for estimating actual evapotranspiration of mountain grasslands (CLIME-MG). *Journal of Hydrology* 610: 127-138.
- Koepf P and Pfaff F, 2021. Consistency of Gaussian process regression in metric spaces. *The Journal of Machine Learning Research* 22(1): 11066-11092.
- Marin FR, Angelocci LR, Nassif DS, Costa LG, Vianna MS and Carvalho KS, 2016. Crop coefficient changes with reference evapotranspiration for highly canopy-atmosphere coupled crops. *Agricultural Water Management* 163: 139-145.
- Mirdashtvan M, Najafinejad A, Malekian A and Sa'doddin A, 2021. Sustainable water supply and demand management in semi-arid regions: optimizing water resources allocation based on RCPs scenarios. *Water Resources Management* 35: 5307-5324.
- Mirhashemi S, Panahi M and Zareei L, 2020. Evaluation of M5P algorithm for estimation of potential evapotranspiration, minimum and maximum temperature (Case study: Sari Weather Station). *Journal of Meteorology and Atmospheric Science* 2(4): 287-295.
- Nhu VH, Shahabi H, Nohani E, Shirzadi A, Al-Ansari N, Bahrami S, Miraki S, Geertsema M and Nguyen H, 2020. Daily water level prediction of Zrebar Lake (Iran): a comparison between M5P, random forest, random tree and reduced error pruning trees algorithms. *ISPRS International Journal of Geo-Information* 9(8): 479-491.
- Pham BT, Ly H-B, Al-Ansari N and Ho LS, 2021. A comparison of Gaussian process and M5P for prediction of soil permeability coefficient. *Scientific Programming* 2021: 1-13.
- Quinlan JR, 1987. Simplifying decision trees. *International Journal of Man-Machine Studies* 27(3): 221-234.
- Quinlan JR, 1992. Learning with continuous classes. 5th Australian joint conference on artificial intelligence, 6-18 November, Hobart, Australia.
- Quinlan JR, 1993. Combining instance-based and model-based learning. *Proceedings of the Tenth International Conference on Machine Learning*.
- Rasmussen CE and Williams CK, 2006. *Gaussian Processes for Machine Learning*. Springer.
- Roushangar K and Shahnazi S, 2020. Prediction of sediment transport rates in gravel-bed rivers using Gaussian process regression. *Journal of Hydroinformatics* 22(2): 249-262.
- Sattari MT and Esmailzadeh B, 2017. Performance assessment of M5 tree model and genetic Programming in Tabriz station reference evapotranspiration modeling. *Journal of Water Resources Engineering* 9(31): 11-20 (In Persian with English abstract).
- Sattari MT, Ahmadifar V and Pashapour Kholif Ansar R, 2014. M5 tree model based modeling of evaporation losses in Elevisyan reservoir and comparison with empirical equations. *Journal of Irrigation And Water Engineering* 5(1): 107-121(In Persian with English abstract).
- Shafiullah G, Simson S, Thompson A, Wolfs PJ and Ali A. 2008. Forecasting vertical acceleration railway wagons-A comparative study. 4th International Conference on Data Mining (DMIN'08), 11(2): 290-299.
- Shah S, Duan Z, Song X, Li R, Mao H, Liu J, Ma T and Wang M, 2021. Evaluating the added value of multi-variable calibration of SWAT with remotely sensed evapotranspiration data for improving hydrological modeling. *Journal of Hydrology* 603: 127-146.
- Sharafatmandrad M and Khosravi Mashizi A, 2021. Temporal and spatial assessment of supply and demand of the water-yield ecosystem service for water scarcity management in arid to semi-arid ecosystems. *Water Resources Management* 35(1): 63-82.

- Sharafi M and Samadian Fard S, 2021. The role of kernel functions in increasing the accuracy of daily evaporation prediction in wet and dry regions of Iran. *Journal of Auifer and Qanat* 3(1): 147-157 (In Persian with English abstract).
- Sharafi M, Samadian Fard S and Hashemi S, 2021. Monthly rainfall Forecasting using genetic programming and support vector machine. *Journal of Rainwater Catchment Systems* 8(4): 63-71 (In Persian with English abstract).
- Talebmorad H, Abedi-Koupai J, Eslamian S, Mousavi SF, Akhavan S, Ostad-Ali-Askari K and Singh VP, 2021. Evaluation of the impact of climate change on reference crop evapotranspiration in Hamedan-Bahar plain. *International Journal of Hydrology Science and Technology* 11(3): 333-347.
- Tejada Jr AT, Ella VB, Lampayan RM and Reaño CE, 2022. Modeling reference crop evapotranspiration using support vector machine (SVM) and extreme learning machine (ELM) in region IV-A, Philippines. *Water* 14(5): 754-766.
- Tezel G and Buyukyildiz M, 2016. Monthly evaporation forecasting using artificial neural networks and support vector machines. *Theoretical and Applied Climatology* 124: 69-80.
- Wang WC, Xu DM, Chau KW and Chen S, 2013. Improved annual rainfall-runoff forecasting using PSO-SVM model based on EEMD. *Journal of Hydroinformatics* 15(4): 1377-1390.
- Wanniarachchi S and Sarukkalige R, 2022. A review on evapotranspiration estimation in agricultural water management: Past, present, and future. *Hydrology* 9(7): 123-142.
- Xu Y, Xu Y, Wang Y, Wu L, Li G and Song S, 2017. Spatial and temporal trends of reference crop evapotranspiration and its influential variables in Yangtze River Delta, eastern China. *Theoretical and Applied Climatology* 130: 945-958.