

Research Article

Estimation of Daily Reference Evapotranspiration Without the Need for Wind Speed Using Machine Learning and Hybrid Models in Tabriz and Urmia Synoptic Stations

H Aghamohammadpoor Garebagh¹, J Behmanesh^{2*}, S Besharat³

Received: August 14, 2023

Accepted: May 8, 2024

Revised: May 7, 2024

Published online: September 22, 2024

1- Ph.D. student of Water Engineering, Urmia University, Urmia, Iran

2- Prof., Dept. of Water Engineering, Urmia University, Urmia, Iran

3- Prof., Dept. of Water Engineering, Urmia University, Urmia, Iran

*Corresponding Author, E-mail: j.behmanesh@urmia.ac.ir

Abstract

Background and Objectives

Evapotranspiration is considered the water requirement of plants. Therefore, its measurement is necessary for all agricultural and irrigation projects. Reference evapotranspiration (ET₀) is one of the main components of the hydrological cycle associated with agricultural systems. Accurate estimation and prediction of ET₀ is essential in managing water resources, planning irrigation, and determining the water requirement of plants. Prediction of the ET₀ by providing information about the future state in different time scales can help to make appropriate decisions, plan, and apply water resources management methods. Also, assessing agricultural drought conditions by well-known indices such as the Standardized Precipitation-Evaporation Index (SPEI) and Palmer Drought Severity Index (PDSI) directly requires ET₀ of the region. The sharp decrease in the level of Lake Urmia and the threat to the region's ecosystem have also made the need for accurate calculation of ET₀ more significant than in the past. One of the solutions to calculate ET₀ is to use the FAO-56 Penman-Mantis equation (FAO-56 PM), an acceptable alternative for the scarce lysimeter data. However, the Penman-Mantis equation is highly dependent on the wind speed parameter, so a small error in the wind speed measurement causes a significant error. Therefore, this study aims to provide an innovative and reliable model for estimating ET₀ without the need for wind speed parameters in Tabriz and Urmia stations.

Methodology

In this study, to predict daily ET₀ from intelligent models including multi-layer perceptron neural network (ANN-MLP), support vector regression (SVR), and support vector regression combined with firefly algorithm (SVR-FFA) in Urmia and Tabriz stations during the period 2002-2022 was used. The input parameters of the models include minimum relative humidity (RH_{min}), maximum relative humidity (RH_{max}), average relative humidity (RH_{avg}), sunshine hours (SSH), minimum temperature (T_{min}), maximum temperature (T_{max}), average temperature (T_{avg}), and average soil temperature (T_{soil}) was obtained from Iran Meteorological Organization (IRIMO). Also, four different scenarios were used to run the models. The selection of different input combinations was based on the correlation coefficient, so the first combination had the lowest correlation and the last combination had the highest correlation concerning ET₀. Also, data from 2002-2015 for 14 years were considered for model training and from 2016-2022 for 6 years for model testing. Correlation coefficient (R), mean absolute error (MAE), root mean square error (RMSE), and normalized root mean square error (NRMSE) indices were used to evaluate the used models.

Findings

The comparison and evaluation of the models used in Tabriz station showed that the SVR-FFA-4 model was the best model in this station with the RMSE of 1.23 mm day⁻¹. Among the SVR models, the SVR-4 model showed a good performance with the RMSE of 1.95 mm day⁻¹ after the combined model. Finally, the ANN-4 model also obtained an acceptable accuracy compared to other ANN combinations by having the RMSE of



1.99 mm day⁻¹. Finally, the evaluation of the results used for the Urmia station shows that the SVR-FFA-3 model has made the best predictions compared to other models with a RMSE of 1.16mm day⁻¹. The SVR-3 and SVR-4 models had a higher accuracy than other SVR combinations with a RMSE of 1.78 mm day⁻¹, but the third scenario was chosen as the appropriate model in the SVR model due to having less input. Among the ANN combinations, the ANN-3 model has a good performance compared to the other combinations of this model with the RMSE of 1.81 mm day⁻¹.

Conclusion

The results of this study revealed that in both stations, the hybrid model showed higher accuracy than the individual models. Therefore, in Tabriz station, the SVR-FFA-4 model had the best performance with an error rate of 1.23 mm day⁻¹. In the Urmia station, the SVR-FFA-3 model showed good accuracy with an error rate of 1.16 mm day⁻¹. Finally, it is suggested to use the hybrid model to predict the daily reference evapotranspiration in the northwest of the country. One of the limitations of this research is the lack of access to the parameters of dew point temperature and solar radiation. Therefore, it is suggested to use these parameters in the subsequent studies.

Keywords: Correlation, Evapotranspiration, Intelligent models, Water demand, Water resources.

مقاله پژوهشی

تخمین تبخیر-تعرق مرجع روزانه بدون نیاز به سرعت باد با استفاده از مدل‌های یادگیری ماشین و

هیبریدی در ایستگاه‌های سینوپتیک تبریز و ارومیه

حسین آقامحمدپور قره باغ^۱، جواد بهمنش^{۲*}، سینا بشارت^۳

تاریخ دریافت: ۱۴۰۲/۰۶/۲۰

تاریخ پذیرش: ۱۴۰۲/۱۱/۱۴

تاریخ ویرایش: ۱۴۰۲/۱۱/۰۸

تاریخ انتشار آنلاین: ۱۴۰۳/۰۷/۰۱

۱- دانشجوی دکتری مهندسی آب، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه

۲- استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه

۳- استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه

*مسئول مکاتبات، پست الکترونیکی: j.behmanesh@urmia.ac.ir

چکیده

تبخیر-تعرق مرجع روزانه (ET_0) یک عامل کلیدی برای تخمین نیاز آبی محصولات کشاورزی بوده که تعیین‌کننده عمق مورد نیاز جهت آبیاری است. یکی از روش‌های متداول برای محاسبه ET_0 استفاده از معادله پنمن-مونتیث (FAO-PM) است. با این حال، معادله پنمن-مونتیث به شدت به پارامتر سرعت باد وابسته است، به طوری که خطای اندک در اندازه‌گیری سرعت باد سبب خطای قابل توجهی در دقت معادله می‌گردد. لذا برای بهبود دقت پیش‌بینی ET_0 در مناطق مختلف آب‌وهوایی کشور که فاقد پارامتر سرعت باد هستند، مقدار ET_0 بر اساس مدل‌های هوشمند شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان و رگرسیون بردار پشتیبان ترکیب شده با الگوریتم کرم شبتاب در ایستگاه‌های ارومیه و تبریز طی دوره ۲۰۲۲-۲۰۰۲ تخمین زده شد. پارامترهای ورودی هواشناسی شامل حداقل رطوبت نسبی، حداکثر رطوبت نسبی، رطوبت نسبی متوسط، ساعات آفتابی، حداقل دما، حداکثر دما، میانگین دما و متوسط دمای خاک بوده و مدل‌ها با استفاده از معیارهای ارزیابی مورد سنجش قرار گرفتند. ارزیابی نتایج حاصل از مدل‌ها نشان داد که سناریو چهارم مدل هیبریدی در ایستگاه تبریز با داشتن جذر میانگین مربعات خطای ۱/۲۳ میلی‌متر در روز و ضریب تبیین ۰/۹۶ و همچنین سناریو سوم در ایستگاه ارومیه با داشتن جذر میانگین مربعات خطای ۱/۱۶ میلی‌متر در روز و ضریب تبیین ۰/۹۲ بهترین عملکرد را در بین تمام مدل‌های به کار رفته داشتند.

واژه‌های کلیدی: تبخیر-تعرق، مدل‌های هوشمند، منابع آب، نیاز آبی، همبستگی

مقدمه

در سراسر جهان برای سطح مرجع شناخته می‌شود (زومر و همکاران ۲۰۲۲). خواص یک محصول در سطح مرجع شامل ارتفاع یکنواخت، خواص خاک، مقدار مشخصی از آب مصرفی و رشد کامل محصول در رابطه با یک دوره معین تحت شرایط استاندارد هواشناسی و زراعی تعریف می‌شود (پیرا ۲۰۲۱). توانایی تخمین دقیق ET_0 با استفاده از پارامترهای هواشناسی، سبب بهبود مدیریت و طراحی سیستم‌های آبیاری شده و همچنین در تهیه نیاز آبی برای تحویل حجمی آب بسیار مهم است (احمد و همکاران ۲۰۲۲؛ بوامبال و همکاران ۲۰۲۲). در سال‌های اخیر مدل‌های ریاضی به‌علت داشتن دقت بالا به‌عنوان جایگزین مناسبی برای مدل‌های تجربی شده‌اند (موسوی و همکاران ۲۰۱۹). از جمله پرکاربردترین مدل‌های ریاضی می‌توان به مدل‌های کلاس‌بندی اشاره کرد که به‌علت عملکرد مناسب در مطالعات مختلفی به‌کار برده شده‌اند.

یو و همکاران (۲۰۲۰) در مطالعه‌ای به تحلیل عدم قطعیت هوش مصنوعی در مدل‌سازی تبخیر-تعرق مرجع روزانه در شمال غربی چین با استفاده از مدل‌های شبکه عصبی مصنوعی (ANN^2)، رگرسیون بردار پشتیبان (SVR^3) و مدل یادگیری ماشین افراطی (ELM^4) پرداختند. بر اساس نتایج این مطالعه، هر دو مدل ELM و SVR به دلیل توانایی بالا در شبیه‌سازی و عدم قطعیت کمتر برای تخمین ET_0 ، توصیه شدند. کریشنشتی و همکاران (۲۰۲۱) در یک مطالعه مروری به مقایسه پرکاربردترین مدل‌های محاسباتی در مطالعات مختلف برای تخمین تبخیر-تعرق مرجع در نقاط مختلف پرداختند. نتایج این تحقیق نشان داد که شبکه عصبی مصنوعی با داشتن ضریب تبیین ۰/۹۹ عملکرد بهتری نسبت به ماشین بردار پشتیبان و برنامه‌ریزی ژنتیک (GP^5) داشت. موکاری و همکاران (۲۰۲۲) در مطالعه‌ای به بررسی پتانسیل چهار مدل یادگیری ماشین شامل

کاهش دسترسی به آب در قرن بیست‌ویکم به یکی از مسائل اساسی در سطح جهانی تبدیل شده است (البلتگی و همکاران ۲۰۲۱). بخش اعظمی از آب شیرین موجود در سطح زمین توسط بخش کشاورزی مصرف می‌شود. میزان برداشت آب از سطح زمین در کشورهای در حال توسعه ۸۱ درصد تخمین زده شده است، در حالی که این میزان در سطح جهان ۷۱ درصد است (لیو و همکاران ۲۰۰۹). علاوه بر این، آبیاری نقش مهمی در مصرف حداقل ۵۵ درصد از ذخایر آب شیرین جهان ایفا می‌کند (عباسوف و همکاران ۲۰۲۲). توانایی تأمین غذا برای جمعیت جهان در میان کمبود آب شیرین به معنایی جدی تبدیل شده است (شوکل و همکاران ۲۰۲۱). افزایش تقاضا برای منابع آبی محدود تحت تأثیرات فزاینده تغییرات آب و هوایی به‌طور مداوم نیاز به ارائه راهکارهای مؤثری جهت استفاده کارآمد از منابع آبی موجود دارد (اسکلون و همکاران ۲۰۲۳). بخش کشاورزی بیش از ۹۰ درصد آب کشور را مصرف می‌کند که این میزان مصرف، ۲۲ درصد بیشتر از متوسط مصرف جهانی آب در این بخش می‌باشد (ظریفیان و همکاران ۲۰۲۰). یکی از راهکارهای مؤثر، کسب دانش در مورد رابطه پیچیده آب-خاک-گیاه شامل فرآیندهای بیوفیزیکی می‌باشد (کارلس رودریگز و همکاران ۲۰۲۳). لذا، توسعه مدل‌ها برای تعیین مقدار دقیق نیاز آبی برای یک برنامه آبیاری مؤثر بیش از پیش ضرورت می‌یابد (گنگ و همکاران ۲۰۲۰).

تبخیر-تعرق مرجع (ET_0^1) به‌عنوان مؤلفه اصلی چرخه هیدرولوژیکی جهانی در نظر گرفته می‌شود، به طوری که تأثیر مستقیمی بر عملکرد محصولات، نیاز آبی، برنامه‌ریزی‌های آبی و همچنین مدیریت منابع آب دارد (ژائو و همکاران ۲۰۲۳). یک زمین کاملاً یکنواخت چمن

⁴ Extreme learning machine

⁵ Genetic programming

¹ Reference evapotranspiration

² Artificial neural network

³ Support vector regression

گردید. هو و همکاران (۲۰۲۳) به منظور بهبود تخمین تبخیر-تعرق روزانه ذرت بهاره از مدل جنگل تصادفی ترکیب شده با رگرسیون بردار پشتیبان و بهینه‌سازی ازدحام استفاده کردند. نتایج این ارزیابی نشان داد که مدل ترکیبی با داشتن ضریب تعیین ۰/۹۵ عملکرد مناسبی داشته و برای تخمین تبخیر-تعرق روزانه ذرت بهاره در مناطق نیمه خشک پیشنهاد گردید. میرزانی و همکاران (۲۰۲۳) در مطالعه‌ای به ارزیابی مدل رگرسیون بردار پشتیبان و رگرسیون بردار پشتیبان ترکیب شده با الگوریتم توپچی ابتکاری (AIG⁴) در دو شرایط اقلیمی مختلف جهت برآورد ET₀ روزانه پرداختند. ایستگاه‌های مورد مطالعه شامل یک ایستگاه در منطقه خشک (Marree Aero) و یک ایستگاه در منطقه مرطوب (St Helen Aerodrome) در استرالیا بود. نتایج این مطالعه نشان داد که مدل ترکیبی با داشتن ضریب تعیین ۰/۹ دقت بالاتری نسبت به مدل منفرد داشته و در هر دو ایستگاه سبب بهبود دقت پیش‌بینی مدل منفرد گردید.

یکی از الگوریتم‌های فراابتکاری قابل اطمینان، الگوریتم کرم شب‌تاب (FFA⁵) است که به علت داشتن عملکرد مناسب در مطالعات مختلفی به کار رفته است (بالاجی و همکاران ۲۰۲۳؛ چائو و ژانگ ۲۰۲۳). وانگ و همکاران (۲۰۱۸) در مطالعه‌ای با استفاده از یک الگوریتم ترکیبی کرم شب‌تاب (NDFA⁶) به برآورد تقاضای منابع آب در شهر نانچانگ چین طی دوره ۱۳۹۳-۱۳۸۱ پرداختند. ارزیابی نتایج این بررسی نشان داد که مدل پیشنهادی عملکرد بهتری نسبت به مدل‌های منفرد کرم شب‌تاب داشته به طوری که دقت پیش‌بینی آن تا ۹۷/۹۱٪ افزایش یافته است. کیشی و همکاران (۲۰۱۵) در تحقیقی به پیش‌بینی نوسانات روزانه سطح آب دریاچه ارومیه با استفاده از ماشین بردار پشتیبان ترکیب شده با الگوریتم کرم شب‌تاب پرداختند. نتایج پیش‌بینی مدل ترکیبی با

یادگیری ماشین افراطی، برنامه‌ریزی ژنتیک، جنگل تصادفی (RF¹) و رگرسیون بردار پشتیبان برای تخمین ET₀ روزانه پرداختند. برای انجام این مطالعه از داده‌های اقلیمی در طول دوره ۱۳۸۷-۱۳۹۷ از شش ایستگاه هواشناسی در مناطق مختلف استفاده شد. بررسی نتایج این مطالعه نشان داد که مدل‌های SVR و ELM بهترین مدل‌های یادگیری ماشین برای همه سناریوهای مورد استفاده بودند به طوری که این مدل‌ها بهترین پایداری را در مراحل آزمون نشان دادند. کایا و همکاران (۲۰۲۱) در تحقیقی قابلیت مدل‌های محاسباتی پرسپترون چندلایه (MLP²)، رگرسیون بردار پشتیبان و رگرسیون چند خطی (MLR³) برای تخمین تبخیر-تعرق روزانه در کوشیسه (اسلوآکی) را مورد بررسی قرار دادند. پارامترهای هواشناسی شامل تابش خورشیدی، رطوبت نسبی، دمای هوا و سرعت باد به عنوان ورودی مدل‌ها در نظر گرفته شد. ارزیابی نتایج مدل‌ها نشان داد که مدل MLP با داشتن ضریب تعیین ۰/۹۹ بهتر از سایر مدل‌ها عمل کرد.

الگوریتم‌های فراابتکاری، یکی از انواع الگوریتم‌های بهینه‌سازی تقریبی هستند که دارای راهکارهای برون-رفت از نقاط بهینه محلی هستند و قابلیت کاربرد در طیف گسترده‌ای از مسائل را دارند. تیخمارین و همکاران (۲۰۲۰) در تحقیقی به بررسی رگرسیون بردار پشتیبان ادغام شده با الگوریتم‌های گرگ خاکستری، ژنتیک و ازدحام ذرات در تخمین ET₀ ماهانه در ایستگاه‌های الجزایر، تلمسان و آنابا واقع در شمال الجزایر پرداختند. نتایج این بررسی نشان داد که مدل رگرسیون بردار پشتیبان ترکیب شده با گرگ خاکستری با داشتن میزان خطای ۰/۰۷۷۶، ۰/۰۶۱۳ و ۰/۰۳۷۴ mm month⁻¹ به ترتیب در ایستگاه‌های الجزایر، تلمسان و آنابا به عنوان مناسب-ترین مدل انتخاب شده و برای شمال الجزایر پیشنهاد

⁴ Algorithm of innovative gunner

⁵ Firefly algorithm

⁶ New dynamic firefly algorithm

¹ Random forest

² Multilayer perceptron

³ Multilinear regression

تعرق مرجع در ایستگاه‌های ارومیه و تبریز با استفاده از مدل‌های هوشمند شبکه عصبی مصنوعی (ANN) و رگرسیون بردار پشتیبان (SVR) و مدل هیبریدی رگرسیون بردار پشتیبان ترکیب‌شده با الگوریتم کرم شبتاب (SVR-FFA) بدون استفاده از پارامتر سرعت باد انجام گرفت.

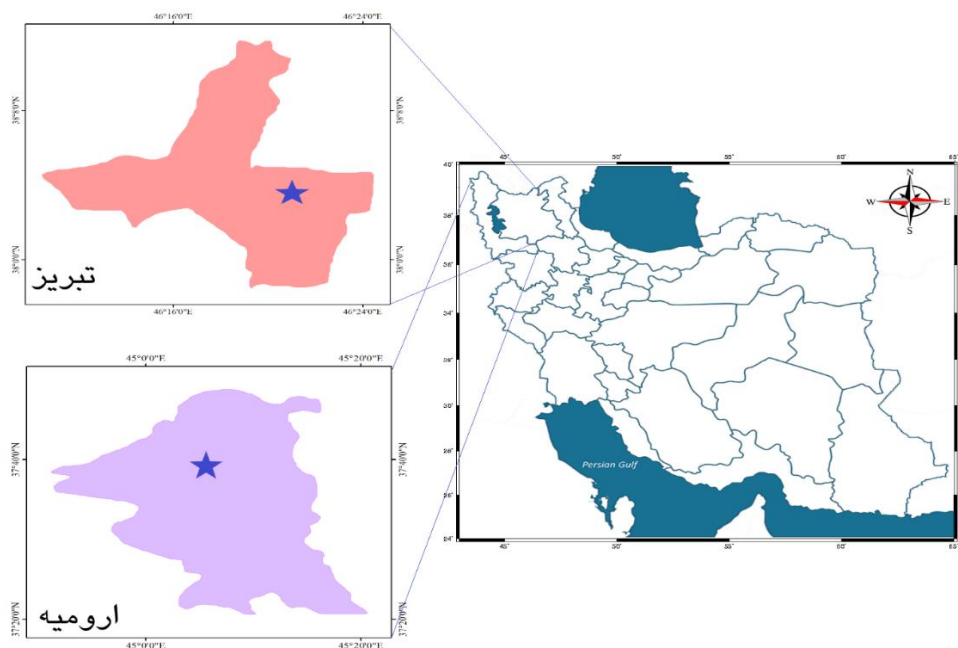
مواد و روش‌ها

منطقه مورد مطالعه

در تحقیق حاضر مقادیر تبخیر-تعرق روزانه در طی دوره آماری ۲۰ ساله در سال‌های ۲۰۰۲-۲۰۲۲ در ایستگاه‌های ارومیه و تبریز گردآوری شد. هر دو ایستگاه در شمال غرب کشور واقع شده‌اند. ایستگاه ارومیه دارای مختصات $37^{\circ} 32' 50''$ شمالی و $45^{\circ} 4' 3''$ شرقی بوده و دارای میانگین بارش سالانه حدود ۳۳۰ میلی‌متر و میانگین تبخیر سالانه حدود ۲۴۰ میلی‌متر است (محمدی و همکاران ۲۰۲۲). ایستگاه تبریز دارای مختصات 38° شمالی و $46^{\circ} 16' 6''$ شرقی بوده و دارای میانگین بارش سالانه حدود ۲۸۰ میلی‌متر و میانگین تبخیر سالانه حدود ۲۲۰ میلی‌متر است (قاضی و جیحونی ۲۰۲۲). با توجه به اینکه معیشت اغلب مردم حوزه دریاچه از بخش کشاورزی است، لذا پیش‌بینی صحیح تبخیر-تعرق باعث بهبود مدیریت بر منابع آب و کشاورزی خواهد گردید. شکل ۱ نقشه موقعیت جغرافیایی ایستگاه‌های مورد مطالعه را نشان می‌دهد. موقعیت ایستگاه‌ها در شکل ۱ با علامت ستاره مشخص شده است. همچنین جدول ۱ نیز مشخصات و پارامترهای آماری روزانه داده‌های مورد استفاده در طی دوره آماری را نشان می‌دهد.

مدل‌های برنامه‌ریزی ژنتیک و شبکه عصبی مصنوعی مقایسه شد. نتایج تجربی نشان داد که بهبود در دقت پیش‌بینی و قابلیت تعمیم را می‌توان با رویکرد مدل ترکیبی در مقایسه با GP و ANN در پیش‌بینی سطح دریاچه یک روز قبل به دست آورد. علاوه بر این، یافته‌ها نشان داد که مدل ترکیبی توانست با قابلیت اطمینان بالایی برای پیش‌بینی سطح دریاچه استفاده شود. قربانی و همکاران (۲۰۱۸) در مطالعه‌ای با استفاده از الگوریتم ترکیبی پرسپترون چند لایه ادغام‌شده با کرم شبتاب به پیش‌بینی تبخیر روزانه در دو ایستگاه هواشناسی تالش و منجیل واقع در شمال ایران بین سال‌های ۲۰۱۴-۲۰۱۲ پرداختند. نتایج این مطالعه نشان داد که مدل ترکیبی با داشتن خطای 1 mm day^{-1} دقت مناسبی داشته و سبب بهبود عملکرد مدل منفرد گردید.

یکی از راه‌های معمول جهت محاسبه تبخیر-تعرق استفاده از معادله پنمن-مونتیث بوده که توسط سازمان خواربار و کشاورزی ملل متحد (فائو) پیشنهاد شده است. با این حال این معادله به شدت به پارامتر سرعت باد حساس بوده و خطا در اندازه‌گیری این متغیر سبب خطای قابل توجه در معادله می‌شود. لذا ارائه مدلی قابل اطمینان که بتواند مقدار تبخیر-تعرق مرجع را با دقت بالا تخمین بزند، ارزشمند خواهد بود. از طرف دیگر کاهش شدید سطح دریاچه ارومیه در سال‌های اخیر به علت برداشت بی‌رویه از منابع آب سطحی و آب زیرزمینی جهت مصرف به‌ویژه در بخش پرمصرف کشاورزی، نیاز به صرفه‌جویی در بخش آب را دوچندان کرده است. دانستن نیاز دقیق محصولات، جهت آبیاری دقیق، سبب احیای دریاچه ارومیه و در نهایت نجات اکوسیستم منطقه خواهد شد. لذا این مطالعه با هدف بهبود پیش‌بینی تبخیر-



شکل ۱- موقعیت جغرافیایی ایستگاه‌های مورد مطالعه.

خواهد کرد. نحوه انتخاب ترکیبات مختلف ورودی، براساس ضریب تبیین بوده بطوریکه ترکیب اول کمترین تبیین و ترکیب آخر بیش‌ترین تبیین را نسبت به ET_0 داشته‌اند. همچنین داده‌ها از سال‌های ۲۰۱۵-۲۰۲۰ به مدت ۱۴ سال برای آموزش مدل‌ها (۷۰ درصد داده‌ها برای آموزش مدل‌ها) و از سال‌های ۲۰۱۶-۲۰۲۲ به مدت ۶ سال برای آزمایش مدل‌ها (۳۰ درصد داده‌ها برای آزمون مدل‌ها) در نظر گرفته شدند. در نهایت جدول ۲ نیز پارامترهای آماری را برای متغیرهای مورد استفاده در دوره آزمون را نشان می‌دهد. لازم به ذکر است که داده‌های تبخیر-تعرق مرجع در مطالعه حاضر با استفاده از معادله پنمن-مونتیت محاسبه گردیده‌اند.

جدول ۱ ترکیبات مختلفی که به عنوان ورودی و خروجی مدل‌ها در نظر گرفته شدند را نشان می‌دهد. پارامترهای حداقل رطوبت نسبی (RH_{min})، حداکثر رطوبت نسبی (RH_{max})، رطوبت نسبی متوسط (RH_{avg})، ساعات آفتابی (SSH)، حداقل دما (T_{min})، حداکثر دما (T_{max})، میانگین دما (T_{avg}) و متوسط دمای خاک در عمق ۵۰ سانتی‌متری (T_{soil}) به عنوان پارامترهای ورودی و تبخیر-تعرق روزانه (ET_0) به عنوان پارامتر خروجی بود. لازم به ذکر است که پارامتر متوسط دمای خاک به علت عدم اندازه‌گیری در اکثر نقاط کشور به ندرت در دسترس بوده و مطالعات اندکی به استفاده از این پارامتر پرداخته‌اند. لذا استفاده از این پارامتر در تحقیق حاضر میزان اثربخشی آن را بر مقدار تبخیر-تعرق مرجع تعیین

جدول ۱- ترکیبات مختلف ورودی برای مدل‌های مورد مطالعه

ترکیب	پارامترهای ورودی							خروجی
1	RH_{min}	RH_{ave}	RH_{max}					ET_0
2	RH_{min}	Rh_{ave}	RH_{max}	SSH				ET_0
3	RH_{min}	Rh_{ave}	RH_{max}	SSH	T_{min}	T_{ave}	T_{max}	ET_0
4	RH_{min}	Rh_{ave}	RH_{max}	SSH	T_{min}	T_{ave}	T_{max}	T_{soil}

جدول ۲- پارامترهای آماری برای متغیرهای مورد استفاده.

ایستگاه	ارتفاع (m)	پارامترهای آماری	داده‌های آزمون		
			دما (°C)	رطوبت نسبی (%)	ساعات آفتابی (h)
تبریز	۱۳۶۱	مینیم	-۲/۴	۱۰/۵	۰
		ماکزیم	۳۵/۱	۹۴/۴	۱۳/۹
		میانگین	۱۹/۶	۴۲/۴	۹/۸
		انحراف معیار	۶/۷	۱۴/۴	۳/۱
ارومیه	۱۳۲۸	مینیم	۲/۷	۱۵/۴	۰
		ماکزیم	۳۰	۹۶/۸	۱۴/۵
		میانگین	۱۸	۵۱/۶	۹/۸
		انحراف معیار	۵/۷	۱۳	۳/۲

معادله پنمن-مونتیث

موسسه منابع آب و محیط‌زیست و انجمن مهندسان عمران آمریکا در سال ۲۰۰۵ چمن را به‌عنوان محصول مرجع پیشنهاد کردند. معادله پنمن-مانتیث با گام زمانی روزانه به‌صورت معادله زیر آورده شده است:

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T_{min} + 273} U_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34U_2)}$$


که در آن ET_0 تبخیر-تعرق گیاه مرجع (mm day^{-1})، Δ شیب منحنی فشار بخار ($\text{kPa } ^\circ\text{C}^{-1}$)، R_n تابش ورودی خالص در سطح زمین ($\text{MJ m}^{-2} \text{ day}^{-1}$)، G چگالی شار حرارتی در سطح خاک ($\text{MJ m}^{-2} \text{ day}^{-1}$)، γ ثابت سایکرومتری (kPa)، T متوسط دمای روزانه ($^\circ\text{C}$)، U_2 متوسط روزانه سرعت باد در ارتفاع دو متری (m s^{-1})، e_s متوسط فشار بخار واقعی در ارتفاع دو متری (kPa) و e_a متوسط فشار بخار اشباع در ارتفاع دو متری (kPa) است (آلن و همکاران ۱۹۹۸).

شبکه عصبی مصنوعی-پرسپترون چندلایه (ANN-MLP¹)

شبکه‌های عصبی مصنوعی اساساً مجموعه‌ای از عناصر پردازشی ساده (PE^2) هستند که در ورودی، خروجی و معمولاً یک یا چند لایه پنهان مرتب شده‌اند. توابع انتقال پاسخ PE را به ورودی خالص آن تعیین می‌کنند. پرسپترون‌ها معمولاً از یک تابع نوع سیگموئید برای هر PE استفاده می‌کنند. توابع نوع سیگموئید توابعی محدود، یکنواخت و غیر کاهشی با پاسخ غیرخطی هستند و شبکه را قادر می‌سازد تا هر فرآیند غیرخطی را شبیه‌سازی کند (رائو ۲۰۰۰).

در مطالعه حاضر از الگوریتم پس انتشار^۲، رایج‌ترین و محبوب‌ترین شبکه‌های عصبی مصنوعی پیش‌خور استفاده شده است. همچنین از چهار لایه ورودی، پنج لایه پنهان و یک لایه خروجی بر اساس آزمون و خطا برای مدل استفاده شد. شکل ۲ نمای مدل MLP مورد استفاده و لایه‌های بکار رفته را نشان می‌دهد.

³ Feed-forward¹ Artificial neural network-Multilayer perceptron² Processing elements



شکل ۲- نمای مدل پرسپترون چندلایه.

رگرسیون بردار پشتیبان (SVR)


رگرسیون بردار پشتیبان (SVR) یک روش رگرسیونی مبتنی بر مفهوم ماشین بردار پشتیبان (SVM) است که توسط دراکر و همکاران (۱۹۹۶) معرفی شده است. SVR از یک تابع خطای حساس به اسیلون استفاده می‌کند که در آن خطای بین مقادیر مشاهداتی و پیش‌بینی شده در صورتی که از ξ کمتر باشند قابل صرف نظر هستند. خطاهای بزرگتر از ξ که در اینجا به عنوان ξ_i^* نامیده می‌شود، در تابع بهینه‌سازی در یک عبارت منظم‌سازی، C ضرب می‌شوند. شکل ۳ تجسم SVR برای یک مورد خطی در یک بعد است. در حالت خطی، پیش‌بینی‌های (y) را می‌توان به عنوان تابعی از ویژگی‌های ورودی (x) مانند رابطه ۱ نوشت، که d بعد فضای ویژگی می‌باشد. قیود مربوط به آن در رابطه ۲ تابع خطا در رابطه ۳ و آورده شده است. راه‌حل بهینه را فقط تعداد محدودی از نقاط خواهند داشت که ابرصفحه رگرسیون را تعریف می‌کنند. این نقاط داده به عنوان بردارهای پشتیبانی شناخته می‌شوند و تعداد آن‌ها تحت تأثیر پارامتر ξ است که حاشیه تلورانس است (آواد و همکاران ۲۰۱۵). همچنین برای بهبود نتایج مدل SVR از کرنل RBF^1 استفاده شد (ایزونین و همکاران ۲۰۲۱).

$$y = f(x) = w^T x, w, x \in R^{d+1} \quad [1]$$

$$Error\ function = \min \frac{1}{2} w^2 + C \sum_{i=1}^N \xi_i + \xi_i^* \quad [2]$$

$$\begin{cases} y_i - w^T x_i \leq f + \xi_i^* \\ w^T x_i - y_i \leq \epsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad [3]$$

¹ Radial basis function



شکل ۳- رگرسیون بردار پشتیبان یک بعدی.

الگوریتم کرم شب‌تاب (FFA)

الگوریتم کرم شب‌تاب یک الگوریتم مبتنی بر ازدحام هوشمند است که توسط یانگ (۲۰۰۹) برای حل مسائل بهینه‌سازی توسعه داده شده است. الهام و فرمول اساسی FA بر اساس رفتار طبیعی کرم شب‌تاب است که از فلاش نورها به عنوان یک استراتژی ارتباطی تقلید می‌کند. بر این اساس، در صورتی که کرم شب‌تاب دوم شدت نور بیشتری را از خود ساطع کند، کرم شب‌تاب اول به سمت دیگری جذب می‌شود (یانگ ۲۰۰۹). شایان ذکر است که روشنایی هر کرم شب‌تاب از کیفیت راه‌حل‌ها تقلید می‌کند، به طوری که با بهبود راه‌حل‌ها مدل به جواب بهینه دست می‌یابد.

وظیفه حرکت یک کرم شب‌تاب "i" به سمت یک کرم شب‌تاب جذاب تر (دارای نور بیشتر) "j" بر اساس معادله ۴ انجام می‌شود:

$$x_i = x_i + \beta_0 e^{-\gamma r_{ij}^2} (x_i - x_j) + \alpha \left(\text{rand} - \frac{1}{2} \right) \quad [4]$$

در معادله بالا، عبارت $\beta_0 e^{-\gamma r_{ij}^2} (x_i - x_j)$ مربوط به اثر جاذبه است. و عبارت $\alpha (\text{rand} - \frac{1}{2})$ یک عبارت تصادفی است و اساساً یک علامت یا جهت تصادفی را ارائه می‌دهد که α با ضریب تصادفی‌سازی مطابقت دارد. β_0 شدت نور در فاصله $r=0$ است. γ ضریب جذب است که مقدار آن بین $[0, \infty]$ قرار دارد. همچنین

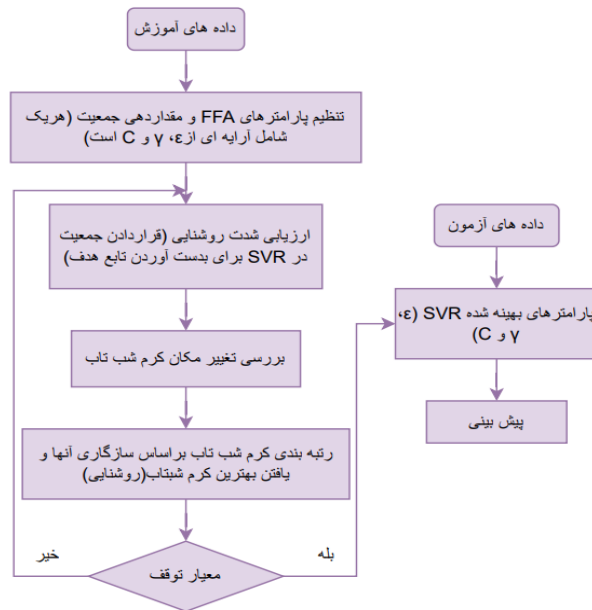
دکاری برای محاسبه فاصله بین هر دو کرم شب‌تاب i و j در رابطه ۵ ارائه شده است.

$$r_{i,j} = \sqrt{\sum_{k=1}^D (x_{i,k} - x_{j,k})^2} \quad [5]$$

مکانیسم حرکت کرم شب‌تاب به طور مکرر تکرار می‌شود تا زمانی که یک شرط توقف برآورده شود. مناسب‌ترین کرم شب‌تاب نشان‌دهنده بهترین راه حل است.

یکی از اصلی‌ترین علل انتخاب الگوریتم کرم شب‌تاب در مطالعه حاضر، استفاده از اعداد تصادفی واقعی توسط مدل است که این انتخاب مبتنی بر ارتباط بین ذرات ازدحام شده (یعنی کرم شب‌تاب) بوده که سبب می‌شود مدل در بهینه‌سازی چند هدفه موثرتر باشد.

شکل ۴ فلوچارت مدل ترکیبی SVR-FFA را نشان می‌دهد. در این فلوچارت γ به عنوان پهنای باند تابع هسته ε ، γ و C سه پارامتر از پیش تعیین شده، تعریف می‌شود. در این تحقیق مقادیر 0.001 ، 0.1 و 1 به ترتیب برای هر سه پارامتر ε ، γ و C بر اساس آنالیز حساسیت انتخاب شدند. روش‌های مورد مطالعه، از جمله توسعه مدل‌های SVR، MLP، SVR-FFA و SVR، در محیط MATLAB، پیاده‌سازی شدند و پارامترهای تابع هسته از طریق آزمون و خطا بهینه‌سازی شدند.



شکل ۴- فلوچارت مدل ترکیبی SVR-FFA

$$NRMSE = \frac{RMSE}{\max(O_i) - \min(O_i)} \quad [9]$$

در روابط ۶ تا ۹، P_a و O_a به ترتیب مقدار مشاهداتی، پیش‌بینی شده، میانگین مشاهداتی و میانگین پیش‌بینی شده بوده و N نیز تعداد کل داده‌ها می‌باشد.

نتایج و بحث

تطابق بین مقادیر مشاهداتی و پیش‌بینی شده تخبیر- تعرق مرجع در جدول ۳ از نظر ضریب تبیین، جذر میانگین مربعات خطا، میانگین خطای مطلق و جذر میانگین مربعات خطای نرمال‌شده، طی مراحل آزمون گزارش شده است.

ارزیابی نتایج جدول ۳ برای مدل ANN در ایستگاه تبریز نشان می‌دهد که سناریو سوم و چهارم با داشتن ضریب تبیین ۰/۸۹ و جذر میانگین مربعات خطای نرمال- شده ۰/۰۹ دقت بالاتری نسبت به ترکیبات اول و دوم ANN داشته، با این تفاوت که سناریو چهارم در شاخص‌های خطا اندکی بهتر از سناریو سوم عمل کرده

معیارهای ارزیابی مدل

در این پژوهش برای ارزیابی ترکیبات مختلف تعریف‌شده برای مدل‌های مورد مطالعه، از معیارهای ضریب تبیین (R^2) ، میانگین خطای مطلق (MAE^2) ، جذر میانگین مربعات خطا $(RMSE^2)$ و جذر میانگین مربعات خطای نرمال‌شده $(NRMSE^2)$ استفاده گردید. شاخص ضریب تبیین بین بازه -۱ تا ۱ متغیر بوده و هرچه به یک نزدیک‌تر باشد دقت مدل افزایش می‌یابد. معیارهای خطا نیز هرچه به صفر نزدیک‌تر باشند، خطای پیش‌بینی مدل کاهش می‌یابد.

$$R^2 = \left(\frac{\sum_{i=1}^N (O_i - O_a)(P_i - P_a)}{\sum_{i=1}^N (O_i - O_a)^2 - \sum_{i=1}^N (P_i - P_a)^2} \right)^2 \quad [6]$$

$$MAE = \frac{|O_i - P_i|}{N} \quad [7]$$

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

³ Root mean squared error

⁴ Normalized root mean squared error

¹ Correlation coefficient

² Mean absolute error

خطا $1/99 \text{ mm day}^{-1}$ دقت قابل قبولی را نسبت به سایر ترکیبات ANN به دست آورد.

نتایج این مطالعه با نتایج محمدی (۲۰۱۸) که به پیش‌بینی تبخیر روزانه در ایستگاه رودسر با استفاده از مدل هیبریدی کرم شب‌تاب پرداختند و نشان دادند که مدل ترکیبی با داشتن ضریب همبستگی $0/93$ توانایی بالایی در پیش‌بینی تبخیر روزانه داشته، مطابقت دارد.

مقایسه نتایج ارزیابی مدل‌های بکار رفته در ایستگاه ارومیه برای مدل‌های ANN-1 و ANN-2 نشان می‌دهد که سناریو دوم با داشتن ضریب تبیین $0/69$ ، میانگین خطای مطلق $1/71 \text{ mm day}^{-1}$ ، جذر میانگین مربعات خطا $2/12$ و جذر میانگین مربعات خطای نرمال شده $0/15$ دقت بالاتری نسبت به سناریو اول داشته است. برای سناریوهای سوم و چهارم نیز مقایسه نتایج نشان می‌دهد که سناریو سوم با داشتن ضریب تبیین $0/79$ ، میانگین خطای مطلق $1/39 \text{ mm day}^{-1}$ ، جذر میانگین مربعات خطای مطلق $1/81 \text{ mm day}^{-1}$ و جذر میانگین مربعات خطای نرمال شده $0/13$ خطای کمتری نسبت به سناریو چهارم این مدل داشته است. برای مدل SVR نیز مقایسه سناریو اول و دوم نشان می‌دهد که سناریو دوم سبب بهبود دقت پیش‌بینی سناریو اول گردیده است بطوریکه مقدار شاخص‌های میانگین خطای مطلق و جذر میانگین مربعات خطا به ترتیب از $1/75$ به $1/68$ و از $2/18$ به $2/13$ کاهش یافته است. سناریوهای سوم و چهارم با اینکه دقت بهتری نسبت به سناریوهای اول و دوم داشته‌اند اما مقدار شاخص‌ها در دو سناریو آخر تغییری نداشته است. مقایسه سناریوهای اول و دوم برای مدل هیبریدی نیز نشان می‌دهد که سناریو دوم سبب بهبود میزان شاخص‌های ارزیابی ضریب تبیین، میانگین خطای مطلق، جذر میانگین مربعات خطا و جذر میانگین مربعات خطای نرمال شده به ترتیب به میزان 7 ، $10/7$ ، $7/5$ و $6/9$ درصد نسبت به سناریو اول شده است. سناریو سوم نیز سبب افزایش دقت پیش‌بینی مدل نسبت به سناریو دوم شده است به طوری که مقدار معیارهای ضریب تبیین،

است. پس از مدل ANN-3، مدل ANN-2 نیز با داشتن ضریب تبیین $0/76$ ، میانگین خطای مطلق $2/38 \text{ mm day}^{-1}$ ، جذر میانگین مربعات خطا $3/02 \text{ mm day}^{-1}$ و جذر میانگین مربعات خطای نرمال شده $0/13$ دقت بالاتری نسبت به ANN-1 داشته است. مقایسه ترکیبات مدل SVR نیز نشان می‌دهد که سناریوهای سوم و چهارم با داشتن میانگین خطای مطلق $1/5 \text{ mm day}^{-1}$ ، جذر میانگین مربعات خطا $1/9 \text{ mm day}^{-1}$ عملکرد تقریباً مشابهی را داشتند اما سناریو چهارم اندکی بهتر از سناریو سوم عمل کرد. سناریو دوم نیز با داشتن ضریب تبیین $0/74$ ، میانگین خطای مطلق $2/34 \text{ mm day}^{-1}$ ، جذر میانگین مربعات خطا $2/89 \text{ mm day}^{-1}$ و جذر میانگین مربعات خطای نرمال شده $0/13$ عملکرد بهتری نسبت به SVR-1 داشته است. مقایسه ترکیبات مدل ANN با مدل SVR نشان می‌دهد که مدل رگرسیون بردار پشتیبان در تمام ترکیبات خطای کمتری نسبت به مدل شبکه عصبی مصنوعی داشته است. ارزیابی نتایج برای مدل ترکیبی نیز نشان می‌دهد که SVR-FFA-4 با داشتن ضریب تبیین $0/96$ ، میانگین خطای مطلق $0/95 \text{ mm day}^{-1}$ ، جذر میانگین مربعات خطا $1/23 \text{ mm day}^{-1}$ و جذر میانگین مربعات خطای نرمال شده $0/05$ دقت بالاتری نسبت به SVR-FFA-3 داشته است. مدل SVR-FFA-2 نیز با داشتن ضریب تبیین $0/8$ ، میانگین خطای مطلق $2/05 \text{ mm day}^{-1}$ ، جذر میانگین مربعات خطا $2/59 \text{ mm day}^{-1}$ و جذر میانگین مربعات خطای نرمال شده $0/11$ دقت بالاتری نسبت به SVR-FFA-1 داشته است.

مقایسه و ارزیابی مدل‌های مورد استفاده در ایستگاه تبریز نشان می‌دهد که مدل SVR-FFA-4 با داشتن جذر میانگین مربعات خطا $1/23 \text{ mm day}^{-1}$ به عنوان مدل برتر در این ایستگاه انتخاب شده و بهترین پیش‌بینی‌ها را نشان داد. در میان مدل‌های SVR نیز مدل SVR-4 با داشتن جذر میانگین مربعات خطا $1/23 \text{ mm day}^{-1}$ پس از مدل ترکیبی عملکرد مناسبی را نشان داد. در نهایت مدل ANN-4 نیز با داشتن جذر میانگین مربعات

هواشناسی (رشت و لاهیجان) واقع در استان گیلان در شمال ایران طی دوره زمانی ۱۳۸۵ تا ۱۳۹۵ بود. برای مجموعه داده‌های تبخیر، میزان کاهش RMSE از SVR1 به SVR7 در لاهیجان حدود ۲۷ درصد و در ایستگاه رشت حدود ۱۸ درصد بود. درحالی‌که کاهش RMSE از SVR-FFA1 به SVR-FFA7 در ایستگاه‌های لاهیجان و رشت به ترتیب ۱۸ و ۲۶ درصد بود. در نهایت مدل ترکیبی عملکرد مناسبی داشته و سبب بهبود دقت پیش‌بینی مدل SVR گردید که با نتایج این مطالعه در تطابق است. در مطالعه‌ای دیگر نیز لی و همکاران (۲۰۱۹) نیز با استفاده از رگرسیون بردار پشتیبان ادغام‌شده با الگوریتم کرم شب‌تاب به پیش‌بینی شاخص کیفیت آب رودخانه فرات، عراق طی یک دوره ۱۰ ساله پرداختند و نشان دادند که مدل هیبریدی میزان معیار جذر میانگین مربعات خطای مدل منفرد را به میزان ۴۲ درصد کاهش داده و به‌عنوان مدل برتر شناخته شد. همچنین اثبات گردید که عملکرد مدل ترکیبی در شناخت ویژگی‌های الگوی دینامیکی و غیرخطی نسبت به مدل منفرد بالا و قابل توجه بود که در تطابق با این مطالعه می‌باشد.

جدول ۳- نتایج ارزیابی مدل‌های مورد استفاده در دوره آزمون.

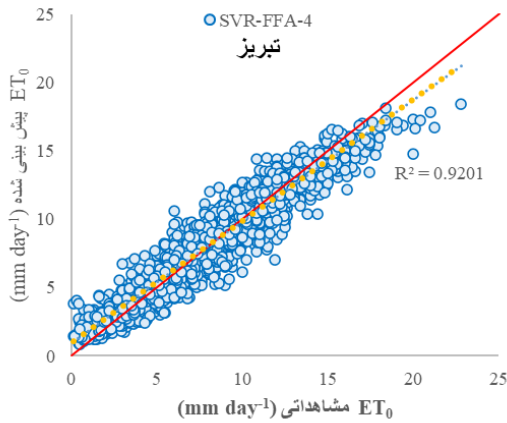
ایستگاه	تیریز				ارومیه				
	مدل	R	MAE (mm day ⁻¹)	RMSE (mm day ⁻¹)	NRMSE	R	MAE (mm day ⁻¹)	RMSE (mm day ⁻¹)	NRMSE
ANN-1		۰/۷۲	۲/۵۴	۳/۱۲	۰/۱۴	۰/۶۵	۱/۸۹	۲/۳۰	۰/۱۶
ANN-2		۰/۷۶	۲/۳۸	۳/۰۲	۰/۱۳	۰/۶۹	۱/۷۱	۲/۱۲	۰/۱۵
ANN-3		۰/۸۹	۱/۵۷	۲	۰/۰۹	۰/۷۹	۱/۳۹	۱/۸۱	۰/۱۳
ANN-4		۰/۸۹	۱/۵۶	۱/۹۹	۰/۰۹	۰/۷۸	۱/۴۲	۱/۸۷	۰/۱۳
SVR-1		۰/۷۳	۲/۳۴	۲/۹۳	۰/۱۳	۰/۶۶	۱/۷۵	۲/۱۸	۰/۱۶
SVR-2		۰/۷۴	۲/۳۴	۲/۸۹	۰/۱۳	۰/۶۷	۱/۶۸	۲/۱۳	۰/۱۵
SVR-3		۰/۸۹	۱/۵۴	۱/۹۶	۰/۰۹	۰/۷۹	۱/۳۸	۱/۷۸	۰/۱۳
SVR-4		۰/۸۹	۱/۵۲	۱/۹۵	۰/۰۹	۰/۷۹	۱/۳۸	۱/۷۸	۰/۱۳
SVR-FFA-1		۰/۷۷	۲/۱۹	۲/۷۵	۰/۱۲	۰/۶۹	۱/۶۷	۲/۰۸	۰/۱۵
SVR-FFA-2		۰/۸۰	۲/۰۵	۲/۵۹	۰/۱۱	۰/۷۴	۱/۵۰	۱/۹۳	۰/۱۴
SVR-FFA-3		۰/۹۶	۰/۹۷	۱/۲۴	۰/۰۶	۰/۹۲	۰/۸۹	۱/۱۶	۰/۰۸
SVR-FFA-4		۰/۹۶	۰/۹۵	۱/۲۳	۰/۰۵	۰/۹۲	۰/۸۹	۱/۱۷	۰/۰۸

میانگین خطای مطلق و جذر میانگین مربعات خطا به- ترتیب به میزان ۲۱/۷، ۵۱/۱ و ۴۹/۸ درصد بهبود یافته- اند.

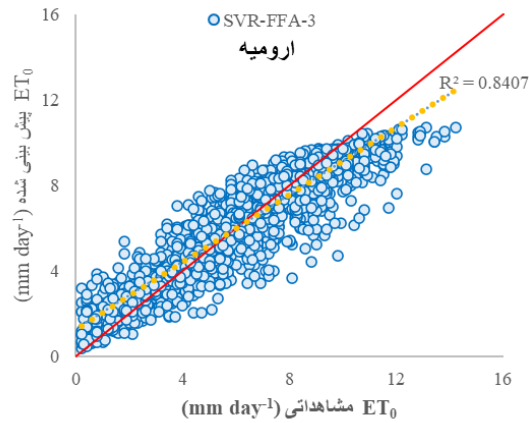
در نهایت ارزیابی نتایج به‌کار رفته برای ایستگاه ارومیه نشان می‌دهد که مدل SVR-FFA-3 با داشتن جذر میانگین مربعات خطا $1/16 \text{ mm day}^{-1}$ بهترین پیش‌بینی‌ها را نسبت به سایر مدل‌ها انجام داده است. پس از مدل SVR-FFA-3، مدل‌های SVR-3 و SVR-4 با داشتن جذر میانگین مربعات خطا $1/78 \text{ mm day}^{-1}$ دقت بالاتری نسبت به سایر ترکیبات SVR داشتند اما سناریو سوم به‌علت داشتن ورودی کمتر به‌عنوان مدل مناسب در مدل SVR انتخاب گردید. در میان ترکیبات ANN نیز مدل ANN-3 با داشتن جذر میانگین مربعات خطا $1/81 \text{ mm day}^{-1}$ عملکرد مناسبی نسبت به سایر ترکیبات این مدل داشته است.

موزن‌زاده و همکاران (۲۰۱۸) در مطالعه‌ای به ترکیب الگوریتم کرم شب‌تاب با رگرسیون بردار پشتیبان برای پیش‌بینی تبخیر در شمال ایران پرداختند. هدف اصلی این کار پیش‌بینی مؤلفه تبخیر در دو ایستگاه

تبیین بالاتری نسبت به ایستگاه ارومیه بوده‌اند. با این حال بالا بودن مقدار ضریب تعیین در هر دو ایستگاه نشان‌دهنده عملکرد مناسب مدل هیبریدی بوده است.



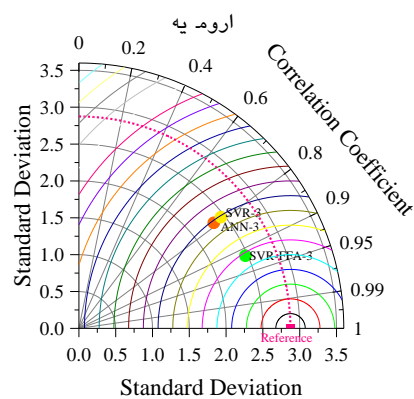
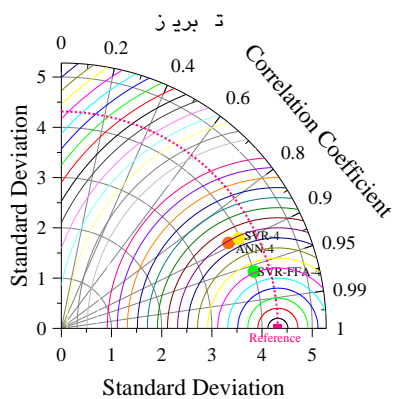
شکل ۵ نمودارهای پراکنش برای بهترین سناریو در مدل ترکیبی برای هر دو ایستگاه تبریز و ارومیه را نشان می‌دهد. مقایسه بین نمودارها نشان می‌دهد که برای ایستگاه تبریز مقادیر مشاهداتی و پیش‌بینی شده دارای



شکل ۵- نمودارهای پراکنش برای بهترین سناریو.

عملکرد را داشتند. با این حال مقایسه بین مدل‌های به‌کار رفته در هر دو ایستگاه نشان می‌دهد که مدل ترکیبی با داشتن نزدیک‌ترین مقدار به خط مشاهداتی (رفرنس) دقت بالاتری نسبت به سایر مدل‌های منفرد داشته است.

شکل ۶ نمودارهای تیلور را برای بهترین سناریو در ایستگاه‌های ارومیه و تبریز نشان می‌دهد. ارزیابی نمودارها نشان می‌دهد که برای ایستگاه ارومیه سناریو سوم و برای ایستگاه تبریز سناریو چهارم بهترین



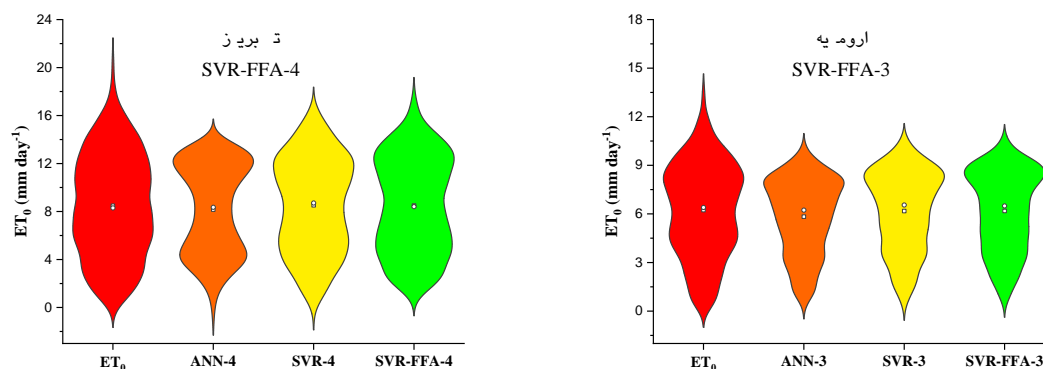
شکل ۶- نمودارهای تیلور برای بهترین سناریو در هر مدل.

بیش‌تری نسبت به ایستگاه ارومیه هستند. به‌طوری‌که در ایستگاه تبریز بیش‌ترین پراکنندگی داده‌ها بین بازه ۱۳-۴ بوده و در ایستگاه ارومیه بین بازه ۱۰-۳ بوده است. مقایسه نمودارها برای ایستگاه تبریز نشان می‌دهد که به‌جز مدل ANN‌های مدل‌های SVR-FFA و دارای پلات

شکل ۷ نمودارهای ویولن پلات را برای بهترین سناریو نشان می‌دهد. مربع و دایره‌های سفیدرنگ در هر پلات به‌ترتیب نشانگر میانگین و میانه برای هر مدل می‌باشند. ارزیابی پلات‌ها در هر دو ایستگاه نشان می‌دهد که در ایستگاه تبریز داده‌های مشاهداتی دارای بازه

قادر به پیش‌بینی مقدار مشاهداتی نبوده و دارای کم-برآورد بوده‌اند. با این حال مدل‌های SVR و SVR-FFA عملکرد بهتری نسبت به ANN داشته‌اند.

مشابهی نسبت به داده‌های مشاهداتی بودند، هرچند که مدل ترکیبی دارای میانگین و میانه نزدیک‌تری نسبت به ET_0 بوده است. برای ایستگاه ارومیه نیز مقایسه نمودارها نشان می‌دهد که هر سه مدل در بازه ۱۵-۱۰



شکل ۷- نمودارهای ویولون پلات برای بهترین سناریو.

تخمین ET_0 در ایستگاه‌های ارومیه و تبریز انجام گرفته است. مدل‌های مورد استفاده شامل شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان و رگرسیون بردار پشتیبان ترکیب‌شده با الگوریتم کرم شب‌تاب بوده که با استفاده از معیارهای ارزیابی مختلف مورد ارزیابی قرار گرفتند. مقایسه تاثیر ورودی‌های مختلف بر مقدار تبخیر-تعرق مرجع نشان داد که پارامتر دمای هوا تاثیر زیادی بر دقت پیش‌بینی مدل‌ها داشته و در تمام سناریوها سبب کاهش خطای مدل‌سازی گردید. نتایج حاصل از این مطالعه نشان داد که در هر دو ایستگاه مدل هیبریدی دقت بالاتری را نسبت به مدل‌های منفرد نشان داد به طوری که در ایستگاه تبریز مدل SVR-FFA-4 بهترین عملکرد را با داشتن میزان خطای $1/23 \text{ mm day}^{-1}$ داشته و در ایستگاه ارومیه نیز مدل SVR-FFA-3 با داشتن میزان خطای $1/16 \text{ mm day}^{-1}$ دقت مناسبی را نشان داد. تحقیقات آتی می‌تواند بین نتایج حاصل از روش‌های تجربی مختلف توصیف‌شده در ادبیات با نتایج الگوریتم‌های مورد استفاده در مطالعه حاضر و همچنین با سایر الگوریتم‌های بهینه‌سازی ترکیبی، به منظور

مقایسه بین نتایج ایستگاه‌های تبریز و ارومیه نشان می‌دهد که در تمام سناریوها مقدار خطا برای ایستگاه تبریز بیش‌تر از ایستگاه ارومیه بوده است. با توجه به جدول ۲ در پارامترهای دما، رطوبت نسبی و دمای خاک مقدار محدوده بین مینیمم و ماکزیمم هر پارامتر در ایستگاه تبریز بیشتر از ایستگاه ارومیه بوده است. از طرفی با افزایش بازه داده‌ها شاخص ضریب تعیین دارای مقدار بیشتر و شاخص جذر میانگین مربعات خطا به طور بالعکس دارای مقدار کمتری خواهد بود (منارد ۲۰۰۰). لذا علت کاهش ضریب تعیین و میزان خطا در ایستگاه ارومیه را می‌توان به محدود بودن بازه پارامترهای مورد استفاده نسبت داد.

نتیجه‌گیری کلی

یکی از مهم‌ترین بخش‌های چرخه هیدرولوژیکی تبخیر-تعرق مرجع می‌باشد، به طوری که برآوردهای دقیق ET_0 در مناطق آبی برای برنامه‌ریزی، کنترل و مدیریت منابع طبیعی حیاتی است. لذا این مطالعه با هدف ارائه مدلی بدون وابستگی به متغیر سرعت باد جهت

بررسی دقیق عملکرد آن‌ها در مدیریت منابع آبی مورد

تشکر و قدردانی

بدین وسیله نویسندگان از سازمان هواشناسی

مقایسه قرار گیرد.

کشور جهت ارائه داده‌ها کمال تشکر را دارند.

منابع مورد استفاده

- Abbasov R, Karimov R and Jafarova N, 2022. Ecosystem and socioeconomic values of clean water. Pp. 71-121. Ecosystem Services in Azerbaijan: Value and Losses, Springer-Verlag, Germany.
- Ahmad U, Alvino A and Marino S, 2022. Solar fertigation: A sustainable and smart IoT-based irrigation and fertilization system for efficient water and nutrient management. *Agronomy*: 12, 1012.
- Allen RG, Pereira LS, Raes D and Smith M, 1998. Crop evapotranspiration-guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. FAO, Rome 300(9):112-142.
- Rao S, 2000. Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering* 5: 115-123.
- Awad M, Khanna R, Awad M and Khanna R, 2015. Support vector regression. *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, 67-80.
- Balaji K, Sai Kiran P and Sunil Kumar M, 2023. Power aware virtual machine placement in IaaS cloud using discrete firefly algorithm. *Applied Nanoscience* 13: 2003-2011.
- Cárceles Rodríguez B, Durán Zuazo VH, Franco Tarifa D, Cuadros Tavira S, Sacristan PC and García-Tejero IF, 2023. Irrigation alternatives for avocado (*Persea americana* Mill.) in the mediterranean subtropical region in the context of climate change: A Review. *Agriculture* 13, 1049.
- Dervisoglu A, 2021. Analysis of the temporal changes of inland Ramsar Sites in Turkey using Google Earth Engine. *ISPRS International Journal of Geo-Information* 10, 521.
- Drucker H, Burges C, Kaufman L, Smola A and Vapnik V, 1996. Support vector regression machines. Pp.155-161. In: *Proceedings of the 9th International Conference on Neural Information Processing Systems, NIPS'96*. Cambridge, MA, MIT Press, USA.
- Elbeltagi A, Aslam MR, Mokhtar A, Deb P, Abubakar GA, Kushwaha N, Venancio LP, Malik A, Kumar N and Deng J, 2021. Spatial and temporal variability analysis of green and blue evapotranspiration of wheat in the Egyptian Nile Delta from 1997 to 2017. *Journal of Hydrology* 594, 125662.
- Ghazi B and Jeihouni E, 2022. Projection of temperature and precipitation under climate change in Tabriz, Iran. *Arabian Journal of Geosciences* 15, 621.
- Ghorbani M, Deo RC, Yaseen ZM, Kashani M, Mohammadi B, (2018). Pan evaporation prediction using a hybrid multilayer perceptron-firefly algorithm (MLP-FFA) model: case study in North Iran. *Theoretical and applied climatology* 133: 1119-1131.
- Gong X, Zhang H, Ren C, Sun D and Yang J, 2020. Optimization allocation of irrigation water resources based on crop water requirement under considering effective precipitation and uncertainty. *Agricultural Water Management* 239, 106264.
- Hou W, Yin G, Gu J and Ma N, (2023). Estimation of spring maize evapotranspiration in semi-arid regions of northeast China using machine learning: An improved SVR model based on PSO and RF algorithms. *Water* 15, 1503.
- Kati V, Selva N and Sjögren-Gulve P, 2022. Greek roadless policy: A model for Europe. *Science* 375: 984-984.
- Kaya YZ, Zelenakova M, Üneş F, Demirci M, Hlavata H and Mesáros P, 2021. Estimation of daily evapotranspiration in Košice City (Slovakia) using several soft computing techniques. *Theoretical and Applied Climatology* 144: 287-298.
- Kisi O, Shiri J, Karimi S, Shamshirband S, Motamedi S, Petković D and Hashim R, 2015. A survey of water level fluctuation predicting in Urmia Lake using support vector machine with firefly algorithm. *Applied Mathematics and Computation* 270: 731-743.
- Krishnashetty PH, Balasangameshwara J, Sreeman S, Desai S and Kantharaju AB, 2021. Cognitive computing models for estimation of reference evapotranspiration: A review. *Cognitive Systems Research* 70: 109-116.

- Li J, Abdulmohsin HA, Hasan SS, Kaiming L, Al-Khateeb B, Ghareb MI and Mohammed MN, 2019. Hybrid soft computing approach for determining water quality indicator: Euphrates River. *Neural Computing and Applications* 31: 827-837.
- Liu J, Zehnder AJ and Yang H, 2009. Global consumptive water use for crop production: The importance of green water and virtual water. *Water Resources Research* 45 (1).
- Menard S, 2000. Coefficients of determination for multiple logistic regression analysis. *The American Statistician* 54(1): 17-24.
- Mirzania E, Vishwakarma DK, Bui Q-AT, Band SS and Dehghani R, 2023. A novel hybrid AIG-SVR model for estimating daily reference evapotranspiration. *Arabian Journal of Geosciences* 16: 1-14.
- Moazenzadeh R, Mohammadi B, Shamshirband S and Chau KW, 2018. Coupling a firefly algorithm with support vector regression to predict evaporation in northern Iran. *Engineering Applications of Computational Fluid Mechanics*, 12(1): 584-597.
- Mohammadi B, 2018. Study performance of the hybrid Firefly algorithm and artificial neural network in simulation of the daily evaporation values. *Nivar*, 42(100-101): 21-34. (In Persian with English abstract)
- Mohammadi M, Safaie A, Nejatian A, Irajizad A and Tajrishy M, 2022. Lake Urmia water evaporation suppression using self-assembled coating: case study of pools near the Lake. *Journal of Hydrologic Engineering* 27, 05022001.
- Mokari E, DuBois D, Samani Z, Mohebzadeh H and Djaman K, 2022. Estimation of daily reference evapotranspiration with limited climatic data using machine learning approaches across different climate zones in New Mexico. *Theoretical and Applied Climatology* 147: 575-587.
- Mousavi N, Kothapalli G, Habibi D, Khiadani M and Das CK, 2019. An improved mathematical model for a pumped hydro storage system considering electrical, mechanical, and hydraulic losses. *Applied Energy* 247: 228-236.
- Pereira LS, Paredes P, López-Urrea D and Jovanovic N, 2021. Updates and advances to the FAO56 crop water requirements method. *Agricultural Water Management* 110(4): 58-72.
- Scanlon BR, Fakhreddine S, Rateb A, de Graaf I, Famiglietti J, Gleeson T, Grafton RQ, Jobbagy E, Kebede S and Kolusu SR, (2023). Global water resources and the role of groundwater in a resilient water future. *Nature Reviews Earth & Environment* 4: 87-101.
- Shukla R, Kumar P, Vishwakarma DK, Ali R, Kumar R and Kuriqi A, 2021. Modeling of stage-discharge using back propagation ANN-, ANFIS-, and WANN-based computing techniques. *Theoretical and Applied Climatology* 1-23.
- Tikhmarine Y, Malik A, Souag-Gamane D and Kisi O, 2020. Artificial intelligence models versus empirical equations for modeling monthly reference evapotranspiration. *Environmental Science and Pollution Research* 27: 30001-30019.
- Wang H, Wang W, Cui Z, Zhou X, Zhao J and Li Y, 2018. A new dynamic firefly algorithm for demand estimation of water resources. *Information Sciences* 438: 95-106.
- Yang XS, 2009. Firefly algorithms for multimodal optimization. Pp.169-178. *International symposium on stochastic algorithms*. Springer.
- Yu H, Wen X, Li B, Yang Z, Wu M and Ma Y, 2020. Uncertainty analysis of artificial intelligence modeling daily reference evapotranspiration in the northwest end of China. *Computers and Electronics in Agriculture* 176, 105653.
- Zarenistanak M, Dhorde AG and Kripalani R, 2014. Trend analysis and change point detection of annual and seasonal precipitation and temperature series over southwest Iran. *Journal of Earth System Science* 123: 281-295.
- Zhao B, An D, Yan C, Yan H, Kong R and Su J, 2023. Spatiotemporal variations of reference evapotranspiration and its climatic driving factors in Guangdong, a humid subtropical province of South China. *Agronomy* 13, 1446.
- Zomer RJ, Xu J and Trabucco A, 2022. Version 3 of the global aridity index and potential evapotranspiration database. *Scientific Data* 9, 409.
- Zarifian S, Rostami J and Pishbahar E, 2020. Factors affecting the use of modern irrigation systems for Sustainable Agricultural Development (Case study: Rural Areas of Bostan Abad City of East-Azerbaijan Province-Iran). *Journal of Agricultural Science and Sustainable Production* 30(3): 217-229. (In Persian with English abstract)