

A comparative analysis using soft computing in predicting reference evapotranspiration in Shiraz Bajgah

Jasem Bavi¹, Aslan Egdernezhad^{1*}, Arash Tafteh²

¹ Department of Water Sciences and Engineering, Ahvaz Branch, Islamic Azad University, Ahvaz, Iran.

² Department of irrigation and soil physics, Soil and Water Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran.

Article Info

Article type:

Research Article

Article history:

Received 07May2024

Revised 06August2024

Accepted 21September2024

Published online29March2026

Keywords:

Climate

Prediction

Artificial intelligence

Sensitivity analysis

Performance assessment

ABSTRACT

Objective: Accurate prediction of hydrological cycle components is essential for effective water-resource management. This study applies three machine learning models-SVM, GEP and ANN- to estimate potential evapotranspiration at the Bajgah station in Fars Province using climatic variables.

Methods: Daily climatic data from 01/01/1378 to 12/29/1398 (7670 records) were collected for model development. The Gamma test was applied to identify the most influential input variables, showing that temperature, humidity, wind speed, sunshine duration, and precipitation all significantly affect potential evapotranspiration. Therefore, all five variables were used as inputs for the SVM, GEP, and ANN models. The dataset was divided into 70% training (5370 points) and 30% testing (2300 points). Model parameters were tuned using the training set to achieve optimal performance. The accuracy of each model was evaluated using four criteria: RMSE, Mean Square Error, Mean Absolute Error, coefficient of determination, and the Developed Difference Ratio.

Results: The analysis of the results indicates that all three models exhibit varying degrees of accuracy in predicting the ET_0 values, with the Gene Expression Programming (GEP) model demonstrating the highest accuracy and lowest error. Specifically, for the GEP model with a three-gene structure, the performance evaluation indices (RMSE, MAE, R^2 , and $ET_{0(DDR)MAX}$) during the training phase were determined as (4.42, 0.98167, 0.2219, 2752), while during the testing phase, they were recorded as (8.54, 0.9907, 0.1515, 0.1985). Following the GEP model, the Support Vector Machine (SVM) and Artificial Neural Network (ANN) models ranked subsequently in the simulation process.

Conclusions: This research work aimed to assess the predictive capabilities of three MLMs, namely SVM, GEP, and ANN, in forecasting ET_0 . The statistical metrics affirmed the proficiency of all three data-driven models. However, the GEP exhibited notably superior accuracy compared to its counterparts, SVM and ANN.

*Corresponding author: Email: a_eigder@ymail.com

Cite this article: Bavi, J., Egdernezhad, A., Tafteh, A. (2026). A comparative analysis using soft computing in predicting reference evapotranspiration in Shiraz Bajgah. *Journal of New Approaches in Water Engineering and Environment*. <http://doi.org/10.22034/nawee.2025.556274.1176>.



© The Author(s).

Publisher: Gonbad Kavous University.

DOI: <http://doi.org/10.22034/nawee.2025.556274.1176>.



تحلیل مقایسه‌ای با استفاده از محاسبات نرم در پیش‌بینی تبخیر تعرق مرجع در باجگاه شیراز

جاسم باوی^۱، اصلان اگدرنژاد^{۱*}، آرش تافته^۲

^۱ گروه علوم و مهندسی آب، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران.

^۲ بخش آبیاری و فیزیک خاک، موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران.

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	هدف: پیش‌بینی دقیق مؤلفه‌های چرخه هیدرولوژیکی برای مدیریت مؤثر منابع آب ضروری است. در این پژوهش، سه مدل یادگیری ماشین SVM، GEP و ANN برای برآورد تبخیر و تعرق پتانسیل در ایستگاه بجگاه واقع در استان فارس، با استفاده از متغیرهای اقلیمی به کار گرفته شده‌اند.
تاریخ دریافت: ۱۴۰۳/۰۲/۱۸	مواد و روش‌ها: داده‌های اقلیمی روزانه از تاریخ ۱۳۷۸/۰۱/۰۱ تا ۱۳۹۸/۱۲/۲۹ (شامل ۷۶۷۰ رکورد) برای توسعه مدل‌ها گردآوری شد. برای شناسایی مهم‌ترین متغیرهای ورودی، از آزمون گاما استفاده شد که نشان داد دما، رطوبت، سرعت باد، مدت‌زمان تابش خورشید و بارش همگی اثر قابل‌توجهی بر تبخیر و تعرق پتانسیل دارند. بنابراین، هر پنج متغیر به‌عنوان ورودی مدل‌های SVM، GEP و ANN در نظر گرفته شدند. مجموعه داده به دو بخش آموزش (۷۰ درصد معادل ۵۳۷۰ داده) و آزمون (۳۰ درصد معادل ۲۳۰۰ داده) تقسیم شد. پارامترهای هر مدل با استفاده از داده‌های آموزشی برای دستیابی به بهترین عملکرد تنظیم شدند. برای ارزیابی دقت مدل‌ها، چهار معیار شامل میانگین مربعات خطا، میانگین قدر مطلق خطا، ضریب تعیین و نسبت اختلاف توسعه‌یافته به کار گرفته شد.
تاریخ بازنگری: ۱۴۰۳/۰۵/۱۶	نتایج: برطبق نتایج به‌دست‌آمده مشخص شد که هر سه مدل قادر به پیش‌بینی مقدار ET_0 با مقادیر دقت نسبی مختلف هستند، اما در این میان مدل GEP بیشترین دقت و کمترین خطا را به خود اختصاص داد. برای مدل GEP با ساختار سه ژن، مقدار شاخص‌های ارزیابی عملکرد (RMSE, MAE, R^2 , $ET_{0(DDR)MAX}$) در گام آموزش برابر با (۰/۹۸۱۶۷, ۰/۲۲۱۹, ۰/۲۷۵۲) و در گام آزمون (۰/۹۹۰۷, ۰/۱۵۱۵, ۰/۱۹۸۵) به دست آمدند. مدل‌های SVM و ANN در رتبه‌های بعدی شبیه‌سازی قرار گرفتند.
تاریخ پذیرش: ۱۴۰۳/۰۶/۳۱	نتیجه‌گیری: هدف این پژوهش، ارزیابی توان پیش‌بینی سه مدل یادگیری ماشین SVM، GEP و ANN در برآورد ET_0 بود. شاخص‌های آماری، کارایی هر سه مدل داده‌محور را تأیید کردند؛ با این حال، مدل GEP در مقایسه با دو مدل SVM و ANN دقت به مراتب بالاتری از خود نشان داد.
تاریخ انتشار: ۱۴۰۵/۰۱/۰۹	
کلیدواژه‌ها: اقلیم، پیش‌بینی، هوش مصنوعی، تحلیل حساسیت، ارزیابی عملکرد	

* نویسنده مسئول، Email: a_eigder@gmail.com

استناد: باوی، ج.، اگدرنژاد، ا.، تافته، آ. ۱۴۰۳. تحلیل مقایسه‌ای با استفاده از محاسبات نرم در پیش‌بینی تبخیر تعرق مرجع در باجگاه شیراز.

رویکردهای نوین در مهندسی آب و محیط زیست.

<http://doi.org/10.22034/nawee.2025.556274.1176>



مقدمه

پیش‌بینی دقیق تبخیر و تعرق از اهمیت به‌سزایی برخوردار است؛ زیرا این فرایندها مستقیماً توسط شرایط اقلیمی، پارامترهای محیطی و تغییرات اقلیمی تحت تأثیر قرار می‌گیرند. از جمله پارامترهای مؤثر در تبخیر و تعرق می‌توان به درجه حرارت، رطوبت هوا، شدت و جهت باد، تشعشع خورشیدی و نوع و تراکم گیاهان اشاره کرد. تغییرات اقلیمی، از جمله افزایش دما و کاهش الگوی بارندگی، می‌تواند الگوی تبخیر و تعرق را تغییر دهد و به تبع آن، بر روی منابع آبی و کشاورزی تأثیر گذار باشد. تبخیر به‌عنوان فرایندی اساسی، آب را از سطح اقیانوس‌ها، دریاچه‌ها و توده‌های خشک به اتمسفر انتقال می‌دهد. با توجه به اهمیت چالش‌های مربوط به کمبود آب، ارزیابی دقیق میزان تبخیر و تعریق بسیار حیاتی است؛ به‌ویژه در مناطقی که منابع آب محدودی دارند. مطابق با پیش‌بینی‌ها، حدود ۶۱ درصد از مجموع بارش‌های جهانی به‌وسیله فرایند تبخیر و تعرق از بین می‌رود. بنابراین، پیش‌بینی دقیق مقدار تبخیر و تعرق، اساسی برای مدیریت منابع آب و کشاورزی در دوره‌های آینده است (زارع‌ایبانه، ورکشی و معروفی، ۱۳۹۰؛ Chow et al., 1988؛ Tabari et al., 2010؛ Liu et al., 2010؛ Kisi, 2016).

روش‌های مستقیم و غیرمستقیم دو گروه عمده برای پیش‌بینی و برآورد شدت تبخیر است. استفاده از تشت تبخیر کلاس A مرکز هواشناسی آمریکا یکی از متداول‌ترین روش‌های مستقیم اندازه‌گیری تبخیر است که دارای مشکلات و محدودیت‌هایی از قبیل: دقت و هماهنگی زیاد برای نصب، خطای اندازه‌گیری، کدورت آب و تأثیرپذیری از عواملی محیطی مانند باد، نور خورشید و رطوبت هوا است. استفاده از داده‌های هواشناسی و فرمول‌های مبتنی بر موازنه جرم و انرژی از جمله روش‌های غیرمستقیم برآورد تبخیر و تعرق است که عدم دقت در اندازه‌گیری داده‌های هواشناسی، عدم دقت در به‌کارگیری معادلات مربوط، استفاده از فرمول‌های ناکارآمد و نامناسب از جمله محدودیت‌ها و مشکلات این گروه از روش‌ها است. از طرف دیگر، عوامل اقلیمی متأثر از یکدیگر بوده و ارائه مدل ریاضی با لحاظ کردن همه عوامل اقلیمی بسیار مشکل و زمان‌بر است (Kim & Jain et al., 1999؛ Wang et al., 2017 and Kim, 2008).

برای غلبه بر این محدودیت‌ها و مشکلات، مدل‌های گوناگونی برای پیش‌بینی تبخیر و تعرق با کمترین مقدار خطا و بیشترین دقت توسط پژوهشگران ارائه شده است. مدل‌های یادگیری ماشینی، به‌عنوان یکی از روش‌های پیشرفته و مؤثر در این زمینه در دهه‌های اخیر مورد توجه دانشمندان و پژوهشگران قرار گرفته است. مدل‌های یادگیری ماشینی قادرند که الگوهای پیچیده و غیرخطی موجود در داده‌های هواشناسی را شناسایی کرده و بهبود دقت پیش‌بینی تبخیر و تعرق را فراهم کنند. این مدل‌ها قابلیت تطبیق خوبی با متغیرهای محیطی مختلف مانند دما، رطوبت، باد و تشعشع خورشیدی را دارند و می‌توانند اثرات این متغیرها را در پیش‌بینی تبخیر و تعرق در نظر بگیرند. این مدل‌ها از الگوریتم‌های خودکار سازی برای انتخاب و تنظیم بهترین پارامترها و متغیرهای ورودی برای مدل‌سازی استفاده می‌کنند، که این امر باعث بهبود دقت و کارایی مدل می‌شود. مدل‌های یادگیری ماشینی قادرند به طور سریع و با دقت زیاد پیش‌بینی‌های مبتنی بر داده‌های هواشناسی را ارائه کنند که این امر به تصمیم‌گیری‌های سریع‌تر و بهتر در زمینه مدیریت منابع آب کمک می‌کند. در نهایت، این مدل‌ها قادرند به‌طور انعطاف‌پذیر با متغیرهای ورودی مختلف مانند داده‌های هواشناسی، ویژگی‌های اقلیمی و متغیرهای زمانی متفاوت، هماهنگ شوند و پیش‌بینی دقیقی را ارائه کنند (حق‌زاده و همکاران، ۱۳۹۸؛ برزکار و همکاران، ۱۴۰۰؛ ماجدی‌اصل و همکاران، ۱۴۰۰؛ فولادی‌پناه و ماجدی‌اصل، ۱۴۰۱؛ Jain et al., 1999). از جمله این مدل‌ها می‌توان به ANN، GEP، SVM، Classification and Regression، Adaptive Neuro-Fuzzy Inference System (ANFIS)، Genetic Programing (GP)، Trees (CART)، Multivariate Adaptive Regression Splines (MARS) اشاره نمود. این مدل‌ها در پژوهش‌های مختلف توسط پژوهشگران مورد استفاده قرار گرفته‌اند که در جدول ۱ خلاصه‌ای از آنها ارائه شده است.

جدول ۱- خلاصه مرور منابع کاربرد مدل‌های یادگیری ماشین در پیش‌بینی عناصر اقلیمی

منبع	مدل‌های مورد استفاده	مطالعه موردی	نتیجه
محبوبی و همکاران (۱۴۰۲)	ANN-MLP, ANN-RBF, CART, M5P, SVM	ایستگاه سینوپتیک بندرعباس در ایران	SVM و M5P نتایج بهتری داشتند
باقری، قاسمی و نصرافهانی (۱۴۰۲)	GEP, Time series	ایستگاه اهواز، آبادان و دزفول در ایران	مدل GEP کارایی بیشتر و بهتری دارد.
ملک‌احمدی و همکاران (۱۴۰۱)	SVM, ANN, WAVELETE-ANN, MLR, TREE DECISION	ایستگاه اسکاتسلوف در ایالت نبراسکا آمریکا	برتری مدل‌های یادگیری ماشین نسبت به روش‌های رگرسیونی
حقی‌زاده، بیات و ارشیا (۱۳۹۸)	GP	سیستان و بلوچستان در ایران	استفاده از GP منجر به جواب‌های دقیق‌تری می‌شود.
امیرآبادی‌زاده، ناظری‌تهرودی و زینلی (۱۳۹۷)	ANFIS, SVR, ANN, SVM, GP	ایستگاه همدیدی ارومیه در ایران	برترین عملکرد متعلق به GP بود.
طباطبایی، ناظری‌تهروی و دستورانی (۱۳۹۷)	SVM, GP, ANN, BCSD	ایستگاه سینوپتیک اهواز در ایران	مدل SVM عملکرد برتری نسبت به دیگر مدل‌ها داشت
عیسی‌زاده، شیرزاد و رضایی-بنفشه (۱۳۹۶)	ANN, SVM	ایستگاه هواشناسی تبریز و مراغه در ایران	مدل SVM دارای خروجی‌های دقیق‌تری هستند.
محمدرضایپور (۱۳۹۵)	ANFIS, GP, SVM	زابل، چابهار و ایرانشهر در ایران	مدل ANFIS به‌عنوان مدل برتر انتخاب شد.
شادمانی و معروفی (۱۳۹۰)	ANN, ANFIS, Empirical models	ایستگاه کرمان در ایران	روش ANFIS به‌عنوان مدل برتر انتخاب شد.
Achite et al. (2008)	ANN, GEP	شمال غرب الجزایر	مدل ANN دقت بهتری در برآورد تبخیر و تعرق داشت.
Majhi and Naidu (2021)	FALNN, MLANN, Empirical models	سه منطقه آب و هوایی ایالت چاتیسگار هند	مدل پیشنهادی FALNN عملکرد بهتری داشت
Patle et al. (2020)	MLR, ANN	ایستگاه‌های گنگتوک و ایمفال در هند	برتری عملکرد مدل ANN
Qasem et al. (2019)	WT-SVM, WT-ANN, SVR, ANN	ایستگاه تبریز (ایران) و ایستگاه آنتالیا (ترکیه)	SVR و ANN نسبت به مدل‌های هیبریدی عملکرد بهتری داشتند
Nourani et al. (2019)	FFNN, ANFIS, SVR, Empirical Models	چندین منطقه آب‌وهوایی در ترکیه، قبرس، عراق، ایران و لیبی	مدل‌های مبتنی بر هوش مصنوعی از نظر عملکرد از مدل‌های دیگر برتر هستند.
Ghorbani et al. (2018)	MLP, SVM, MLP-FFA	ایستگاه‌های تالش و منجیل در ایران	مدل هیبریدی MLP-FFA خروجی دقیق‌تری داشت
Wang et al. (2017)	FG, TREE5M, MARS, LSSVR, MLR	حوضه دریاچه دونگتینگ در چین	مدل LSSVR و FG نتایج بهتری داشتند
Deo et al. (2017)	MARS, LSSVM, M5P	شرق استرالیا	مدل M5P و MARS نتایج بهتری داشتند.
Kisi (2015)	LSSVM, MARS, TREE5M	ایستگاه‌های مرسین و آنتالیا در ترکیه	مدل LSSVM نتایج برتری دارد


همان‌طور که مشاهده می‌شود، استفاده از روش‌های یادگیری ماشین برای ارزیابی عناصر اقلیمی توسط پژوهشگران در نقاط مناطق با اقلیم‌های مختلف مورد استفاده قرار می‌گیرد. ضمن اینکه در مقایسه با معادلات و مدل‌های تجربی منجر به جواب‌های

دقیق تر می‌شود. هدف اصلی این مقاله، کاربرد سه مدل یادگیری ماشین شامل SVM، GEP و ANN برای شبیه‌سازی و پیش‌بینی مقدار تبخیر و تعرق پتانسیل در ایستگاه باجگاه در استان فارس است. به کمک تحلیل حساسیت با استفاده از گاما تست، ضمن بررسی اثرگذاری ترکیب‌های مختلف ورودی (شامل عناصر اقلیمی)، بهترین ترکیب استخراج و با استفاده از آن، شبیه‌سازی مقدار تبخیر و تعرق پتانسیل به کمک مدل‌های یادگیری ماشین انجام شده است.

مواد و روش‌ها

منطقه مورد مطالعه


در این پژوهش، از داده‌های آماری روزانه ثبت‌شده در ایستگاه باجگاه از تاریخ ۱۳۸۷/۰۱/۰۱ تا ۱۳۹۸/۱۲/۲۹ شامل دمای میانگین، رطوبت میانگین، سرعت باد، ساعات آفتابی و بارش (در مجموع مشتمل بر ۷۷۶۷۰ داده) برای شبیه‌سازی مقدار تبخیر و تعرق پتانسیل استفاده شده است. شکل ۱ موقعیت منطقه مورد بررسی در دشت باجگاه استان فارس را نشان می‌دهد. مشخصات آماری هر یک از متغیرهای مستقل در جدول ۲ ارائه شده‌اند. تغییرات مقدار ET_0 طی بازه زمانی مورد نظر در شکل نشان داده شده است. استقلال خطی هر یک از پنج متغیر مستقل در شکل به نمایش درآمده است. برطبق این نمودار، هیچکدام از متغیرهای مستقل دارای وابستگی خطی با یکدیگر نیستند.



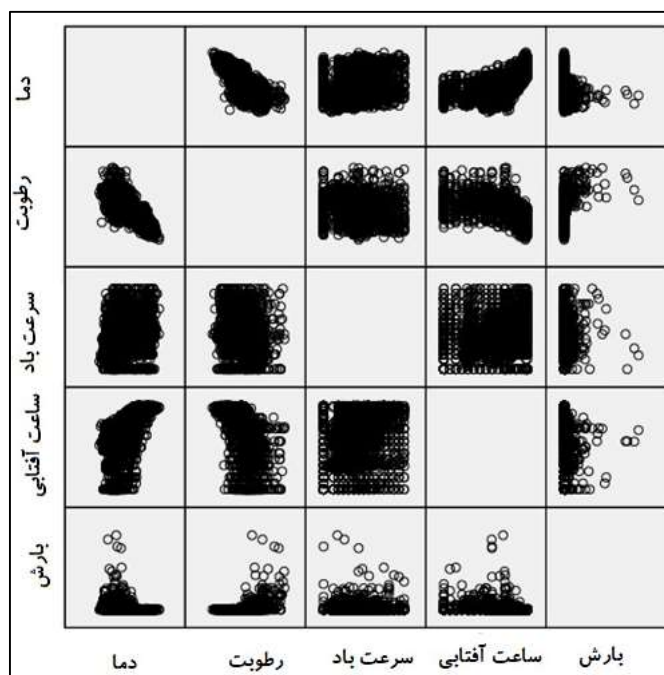
شکل ۱- موقعیت منطقه مورد مطالعه در این پژوهش

جدول ۲- مقادیر شاخص‌های آماری متغیرهای مستقل مورد استفاده در این پژوهش

ردیف	متغیر	نماد	بیشینه	کمینه	میانگین	انحراف معیار
۱	دما	T	۳۵/۲۵	-۰/۳۰	۱۵/۱۶	۷/۸۴
۲	رطوبت	H	۹۶/۵۰	۱۱/۰۰	۵۳/۲۱	۱۰/۴۱
۳	ساعات آفتابی	SH	۲/۴۰	۰/۰۰	۱/۰۰	۰/۴۲
۴	سرعت باد	WS	۱۳/۹۲	۰/۰۰	۱۰/۲۰	۳/۱۹
۵	بارش	P	۵۳/۰۰	۰/۰۰	۰/۹۳	۲/۱۶
۶	تبخیر و تعرق پتانسیل	ET_0	۹/۱۲	۰/۶۶	۳/۸۶	۱/۹۴



شکل ۲- تغییرات ET_0 طی بازه زمانی مورد مطالعه



شکل ۳- استقلال خطی متغیرهای مستقل مورد استفاده در این پژوهش

مروری بر مدل SVM

مدل SVM یک روش یادگیری ماشینی است که برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شود. این روش ابتدا توسط وپینیک (۱۹۸۸) معرفی شد و از آن زمان تاکنون، به عنوان یکی از روش‌های محبوب در حوزه یادگیری ماشینی شناخته شده است. یکی از ویژگی‌های برجسته SVM این است که با استفاده از یک تابع هسته^۱ می‌تواند داده‌هایی که غیر قابل تفکیک خطی هستند را به یک فضای ویژگی بالاتر نگاشت کند و در این فضا، آن‌ها را به راحتی از یکدیگر جدا کند. اگر داده‌های $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ موجود باشند که در آن x_i ها بردارهای ویژگی مربوط به نمونه‌ها و y_i ها برچسب‌های آن‌ها

^۱. Kernel function

هستند. هدف اصلی در SVM، پیدا کردن یک مرز تصمیم است که بتواند داده‌ها را به صورت بهینه تفکیک کند. در حالت ساده، این مرز تصمیم به عنوان یک صفحه (برای مسائل دو کلاسه) یا یک فضای برای مسائل چند کلاسه (با استفاده از روش‌های تبدیل به مسئله دو کلاسه) تعریف می‌شود. اگر معادله مرز تصمیم برای مسئله دو کلاسه به صورت رابطه (۱) باشد:

$$x\omega^T + b = 0 \quad \text{رابطه (۱)}$$

که در آن ω برداری است که به عنوان بردار وزن مربوط به ویژگی‌ها عمل می‌کند و b یک عدد حقیقی است که به عنوان یک تعیین‌کننده ثابت عمل می‌کند. در SVM، انتخاب مرز تصمیم به گونه‌ای صورت می‌گیرد که حاشیه بین مرز و داده‌های نزدیک به آن، حداکثر شود. حاشیه میان مرز تصمیم و نمونه‌ها به صورت عمودی بر روی مرز تصمیم تعریف می‌شود. برای پیدا کردن این مرز تصمیم به صورت بهینه، یک مسئله بهینه‌سازی ریاضی حل می‌شود. مسئله بهینه‌سازی SVM به صورت زیر است:

$$\text{minimize } \frac{1}{2} \|\omega\|^2 \quad \text{رابطه (۲)}$$

که باید قید زیر برقرار باشد:

$$y_i(\omega^T x_i + b) \geq 1 \quad \text{for } i=1, 2, \dots, n \quad \text{رابطه (۳)}$$

در این معادلات $\|\omega\|^2$ نشان‌دهنده نرم دوم بردار وزن ω است. شرط ارائه شده در معادله (۲) نشان‌دهنده صحت تمام نقاط نمونه‌ها نسبت به مرز تصمیم است. به علاوه، برای مواردی که داده‌ها به صورت غیر خطی قابل جداسازی نیستند، از توابع هسته استفاده می‌شود تا داده‌ها را به یک فضای ویژگی بالاتر نگاشت کرده، سپس مرز تصمیم را در این فضا پیدا کند. لیست توابع کرنل مورد استفاده در مدل SVM به قرار جدول ۳ است. در این مقاله برای به کارگیری مدل SVM از نرم‌افزار MATLAB استفاده شده است (Shaker yousefi et al., 2024).

جدول ۳- لیست توابع کرنل در مدل SVM

معادله کرنل	نام تابع کرنل	ردیف
$K(x_i, x_j) = (x_i, x_j)$	خطی	۱
$K(x_i, x_j) = [(x_i, x_j) + 1]^d$	چند جمله‌ای	۲
$K(x_i, x_j) = \exp\left[-\frac{\ x_i - x_j\ ^2}{2\sigma^2}\right]$	گوسین	۳
$K(x_i, x_j) = \tanh[-\alpha(x_i, x_j) + c]$	سیگموئید	۴

مروری بر مدل GEP

برنامه‌ریزی بیان ژن یا GEP یک روش قدرتمند در حوزه یادگیری ماشینی و به ویژه یادگیری تکاملی است که برای مسائل متنوعی از جمله طبقه‌بندی، پیش‌بینی، و بهینه‌سازی مورد استفاده قرار می‌گیرد. این روش بر اساس تلاش برای شبیه‌سازی فرایندهای تکاملی در طبیعت، به ویژه تکامل ژنتیکی، طراحی شده است (Ferreira, 2006). مراحل اصلی مدل‌سازی در GEP عبارتند از:

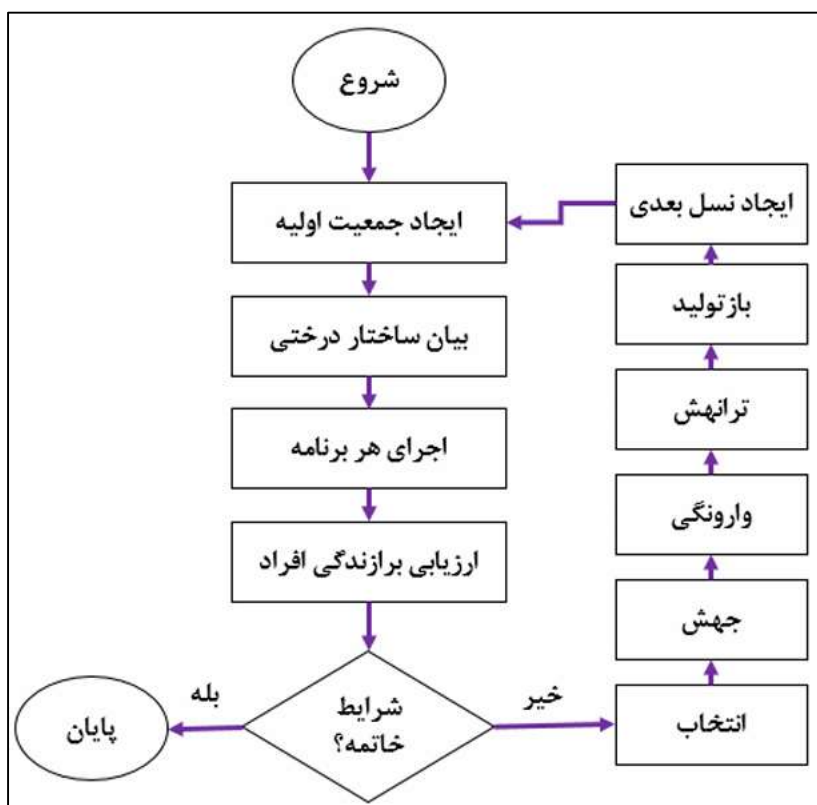
- تعریف مسئله: در این مرحله، مسئله مورد نظر برای حل با استفاده از GEP تعریف می‌شود. این مسئله می‌تواند یک مسئله طبقه‌بندی، پیش‌بینی یا بهینه‌سازی باشد.
- تعریف ترمینال‌ها و توابع: ترمینال‌ها نشانگر ورودی‌های مسئله (مثلاً متغیرها) و توابع مورد استفاده برای پردازش داده‌ها (مثلاً عملیات جمع و ضرب) هستند. این انتخاب باید با توجه به نوع مسئله و داده‌های ورودی صورت گیرد.
- تعریف ژنوم: ژنوم یک کروموزوم مصنوعی است که شامل یک یا چند عبارت ژنتیکی است. هر ژن شامل یک رشته از ترمینال‌ها و توابع است که با یکدیگر ترکیب شده‌اند و یک نتیجه می‌دهند.

¹. Decision boundary

². Bias

³. Margin

- انتخاب و ترکیب: در این مرحله، از روش‌های تکاملی مانند انتخاب رولت، انتخاب رومب، یا انتخاب تورنومنت برای انتخاب فرزندان استفاده می‌شود. سپس عملیات ترکیب برای ترکیب ژنوم‌های انتخاب شده انجام می‌شود.
 - مطابقت و ارزیابی: ژنوم‌های تولیدشده به سیستم معیاری که برای ارزیابی عملکرد آن‌ها تعیین شده است، وارد می‌شوند. عملکرد هر ژنوم با استفاده از معیارهایی مانند دقت، خطای میانگین و یا سایر معیارهای مشخص شده ارزیابی می‌شود.
 - انتخاب نسل بعدی: بر اساس عملکرد ژنوم‌ها، نسل بعدی انتخاب می‌شود تا فرایند تکاملی ادامه یابد. این انتخاب می‌تواند با استفاده از روش‌های مختلفی مثل انتخاب الیتیمی که ژنوم‌های با بهترین عملکرد را حفظ می‌کند و یا روش‌های دیگری مانند انتخاب تورنومنت انجام شود.
 - پایان الگوریتم: فرایند تکامل تا زمانی ادامه می‌یابد که شرایط پایانی مانند تکرار تعداد مشخصی نسل‌ها یا دستیابی به عملکرد مطلوب برآورده شود. در این صورت، بهترین ژنوم به عنوان جواب نهایی انتخاب می‌شود (Moradinejad et al., 2025).
- الگوریتم مورد استفاده در مدل GEP در شکل ارائه شده است. برای اجرای مدل GEP، از محیط نرم‌افزاری MATLAB استفاده شده است.



شکل ۴-فلوچارت مدل GEP

مروری بر مدل ANN

مدل ANN به عنوان یکی از پیشرفته‌ترین مدل‌های یادگیری ماشینی شناخته می‌شوند. این شبکه‌ها الهام گرفته از ساختار و عملکرد سیستم عصبی حیوانات و انسان‌ها هستند. یک شبکه عصبی مصنوعی معمولاً از سه لایه اصلی تشکیل شده است: (۱)

لایه ورودی^۱ در این لایه، ورودی‌های مختلفی که باید وارد شبکه شوند دریافت می‌شوند. هر ورودی می‌تواند یک ویژگی یا ورودی مرتبط با مسئله مورد نظر باشد؛ (۲) لایه مخفی یا لایه‌های میانی^۲: این لایه‌ها وظیفه پردازش اطلاعات و استخراج ویژگی‌های مهم از ورودی‌های دریافتی را دارند. این لایه‌ها معمولاً شامل تعداد زیادی نورون است که با هم ارتباط برقرار می‌کنند (۳) لایه خروجی^۳: در این لایه، خروجی نهایی شبکه تولید می‌شود. این خروجی می‌تواند یک پیش‌بینی، تصمیم یا کلاس برچسب‌گذاری شده باشد. در شبکه‌های عصبی، هر اتصال بین دو نورون با یک وزن مشخص نشان داده می‌شود. این وزن‌ها نشان‌دهنده اهمیت نورون‌های ورودی در تولید خروجی‌های شبکه هستند. هنگامی که شبکه آموزش می‌بیند، این وزن‌ها به‌طور خودکار تنظیم می‌شوند تا خروجی شبکه با داده‌های ورودی مطابقت بهتری داشته باشد. توابع فعال‌سازی در شبکه‌های عصبی مصنوعی وظیفه ایجاد غیرخطیت در خروجی نورون‌ها دارند. این توابع به شبکه کمک می‌کنند تا الگوها و ارتباطات پیچیده‌تری را در داده‌ها شناسایی کند. برخی از توابع فعال‌سازی معروف شامل سیگموئید، تانژانت هایپربولیک و تابع ReLU هستند (Kisi et al., 2024). در این کار پژوهشی، مدل ANN با استفاده از کدنویسی در محیط نرم‌افزار MATLAB اجرا شده است.

متغیرهای ورودی به مدل‌ها

برطبق جدول ۱، پنج متغیر ورودی در ایستگاه باجگاه در طی بازه زمانی مورد مطالعه به‌صورت روزانه ثبت و اندازه‌گیری شده است. برای شبیه‌سازی مقدار تبخیر و تعرق پتانسیل با استفاده از مدل‌های یادگیری ماشین، لازم است آنالیز حساسیت برای تعیین متغیرهای موثر بر آن انجام شود. بدین منظور از آزمون گاما-تست استفاده شده است. این آزمون یک ابزار برای مدل‌سازی-های غیرخطی است که توسط Koncar (1997) و Stefánsson, Končar and Jones (1997) برای مدل‌سازی پارامتر هدف با برقراری مدل هموار معرفی شد. زمانی که تعداد متغیرهای مستقل متعدد باشند با استفاده از این تست می‌توان میزان تاثیرگذاری ترکیب‌های مختلف از متغیرهای مستقل روی خروجی را بررسی و بهترین ترکیب را به دست آورد. معادله بنیادین این تست به قرار زیر است:

$$y=f(x_1, x_2, \dots, x_n)+r \quad \text{رابطه ۴}$$

که در آن x_i ها متغیرهای مستقل، y متغیر وابسته یا خروجی مدل، f نشان‌دهنده تابع هموار برای مدل‌سازی داده‌ها و r نشان‌دهنده متغیر تصادفی برای اعمال میزان خطا یا نویز هستند. آماره گاما (Γ) بیانگر عرض از مبدأ خط برازش‌یافته‌ای است که معادله آن به قرار زیر است:

$$y=A\delta+\Gamma \quad \text{رابطه ۵}$$

که در آن Γ واریانس خروجی مدل و پارامتر A ، شیب خط برازشی است. پارامتر دیگری در این آزمون برای اثرگذاری ترکیب‌های مختلف روی متغیر خروجی مورد استفاده قرار می‌گیرد که رابطه آن به قرار زیر است:

$$V\text{-Ratio}=\frac{\Gamma}{\sigma^2(y)} \quad \text{رابطه ۶}$$

که در آن $\sigma^2(y)$ واریانس پارامتر وابسته (y) است که توصیف‌گر قضاوت مستقل از دامنه متغیر خروجی در چگونگی مدل‌سازی پارامتر خروجی توسط تابع هموار f است. هر چه میزان V-Ratio نزدیک به صفر باشد، نشان‌دهنده آن خواهد بود که درجه زیادی از پیش‌بینی متغیر وابسته y توسط داده‌های مستقل منتخب انجام شده است. در این مقاله برای انجام گاما تست از نرم‌افزار WinGamma استفاده شده است تا بهترین ترکیب ورودی برای پیش‌بینی تبخیر و تعرق پتانسیل تعیین شود. کم‌بودن مقادیر خطای استاندارد، مقدار پارامتر Γ و پارامتر V-Ratio دلالت بر ترکیب بهینه برای شمول متغیر خروجی خواهد بود. خلاصه محاسبات مربوط به گاما تست در جدول ۴ ارائه شده است. در این پژوهش پنج متغیر T ، H ، WS ، SH و P به‌عنوان پنج متغیر مستقل برای پیش‌بینی ET_0 مورد استفاده قرار گرفته‌اند. اعداد ۱ و ۰ به ترتیب برای شمول و عدم شمول متغیرهای مستقل برای تحلیل حساسیت مورد استفاده قرار می‌گیرند. به عنوان مثال ترکیب «۱۱۱۱۱» نشان‌دهنده دخیل بودن هر پنج پارامتر و

1. Input layers

2. Hidden layers

3. Output layers

ترکیب «۰۱۱۱۱» به معنی حذف پارامتر T برای آنالیز حساسیت ترکیب ورودی روی پیش‌بینی ET_0 است. طبق ردیف شماره ۱ جدول ۴، لازم است هر پنج متغیر در تحلیل و شبیه‌سازی تبخیر و تعرق پتانسیل توسط مدل‌های یادگیری ماشین مورد استفاده قرار گیرند؛ زیرا کمترین مقادیر مربوط به خطای استاندارد، Γ و V-Ratio مربوط به این ترکیب است.

جدول ۴- نتایج حاصل از تحلیل حساسیت با استفاده از گاما-تست

V-RATIO	خطای استاندارد	گرادیان (A)	Γ	ماسک	ردیف
۰/۰۱۳۷۳۹	۰/۰۰۸۷۶۹	۰/۰۳۱۱۱۷	۰/۰۵۱۷۷۸	۱۱۱۱۱	۱
۰/۰۱۷۱۵۸	۰/۰۰۸۷۴۷	۰/۰۵۶۷۲۳	۰/۰۶۴۶۶۳	۱۰۱۱۱	۲
۰/۰۳۳۵۳۴	۰/۰۰۸۳۴۵	۰/۰۲۱۸۳۶	۰/۱۲۶۳۸۲	۱۱۰۱۱	۳
۰/۰۳۹۸۷۲	۰/۰۲۴۶۴۹	۰/۰۶۰۷۳۳	۰/۱۵۰۲۷۱	۱۱۱۰۱	۴
۰/۰۱۲۳۲۸	۰/۰۰۹۲۶۶	۰/۰۶۲۵۱۵	۰/۰۴۶۴۶۲	۱۱۱۱۰	۵
۰/۰۷۴۰۹	۰/۰۱۵۸۵۷	۰/۰۷۸۶۵۶	۰/۲۷۹۲۳۲	۰۰۱۱۱	۶
۰/۰۶۵۳۵	۰/۰۱۶۵۲۲	۰/۰۶۴۷۳۹	۰/۲۴۶۲۹۱	۰۱۰۱۱	۷
۰/۲۴۰۳۶۳	۰/۰۵۰۲۳۲	۰/۱۱۸۱۰۷	۰/۹۰۵۸۸	۰۱۱۰۱	۸
۰/۰۴۲۴۵۹	۰/۰۱۱۴۹۵	۰/۱۷۶۱۵۹	۰/۱۶۰۰۱۹	۰۱۱۱۰	۹
۰/۰۴۵۹۶۱	۰/۰۰۹۹۰۸	۰/۰۵۱۴۵۱	۰/۱۷۳۳۲	۱۰۰۱۱	۱۰
۰/۰۶۹۶۷۴	۰/۰۱۳۸۰۹	۰/۰۶۴۷۲۷	۰/۲۶۲۵۸۹	۱۰۱۰۱	۱۱
۰/۰۱۵۴۵۶	۰/۰۰۴۰۱۴	۰/۲۲۱۰۷۳	۰/۰۵۸۲۵	۱۰۱۱۰	۱۲
۰/۰۸۳۸۴	۰/۰۲۸۲۵۹	۰/۰۳۶۶۰۵	۰/۳۱۵۹۷۸	۱۱۰۰۱	۱۳
۰/۰۳۶۳۷	۰/۰۰۷۲۹۲	۰/۰۳۹۹۲۶	۰/۱۳۷۰۷۳	۱۱۰۱۰	۱۴
۰/۰۴۵۳۰۴	۰/۰۱۳۴۳۳	۰/۱۳۳۰۶۷	۰/۱۷۰۷۴۳	۱۱۱۰۰	۱۵
۰/۱۱۸۹۴۸	۰/۰۳۱۴۹۲	۰/۰۲۳۴۱۷	۰/۴۴۸۲۹۱	۰۰۰۱۱	۱۶
۰/۴۲۹۲۱۷	۰/۰۸۰۵۷۸	-۰/۰۶۹۳۴	۱/۶۱۷۶۳۳	۰۰۱۰۱	۱۷
۰/۰۹۷۷۰۳	۰/۰۲۷۹۳۶	۰/۷۹۸۱۰۱	۰/۳۶۸۲۲۳	۰۰۱۱۰	۱۸
۰/۲۸۴۵۲۱	۰/۰۲۷۱۱۱	۰/۰۵۳۲۵۲	۱/۰۷۲۳۰۴	۰۱۰۰۱	۱۹
۰/۲۸۹۷۹۱	۰/۰۵۱۴۲۵	۰/۱۹۶۷۵۱	۱/۰۹۲۱۶۵	۰۱۱۰۰	۲۰
۰/۱۲۵۵۳۲	۰/۰۲۱۲۴۸	۰/۰۰۹۵۹۱	۰/۴۷۳۱۰۵	۱۰۰۰۱	۲۱
۰/۰۵۵۴۰۳	۰/۰۱۲۳۵۲	۰/۱۳۳۶۹	۰/۲۰۸۸۰۴	۱۰۰۱۰	۲۲
۰/۰۹۵۲۷۸	۰/۰۲۱۶۴۸	۰/۰۶۷۴۳۷	۰/۳۵۹۰۸۳	۱۱۰۰۰	۲۳
۰/۱۲۸۶۷	۰/۰۲۹۰۷۶	۰/۸۶۱۸۹۷	۰/۴۸۴۹۳	۱۰۰۰۰	۲۴
۰/۳۴۷۱۷۵	۰/۰۷۳۹۳۵	-۰/۰۴۹۰۹	۱/۳۰۸۴۳۴	۰۱۰۰۰	۲۵
۰/۷۵۸۲۶۶	۰/۰۶۸۴۲	۲/۴۰۵۴۵	۲/۸۵۷۷۵۷	۰۰۱۰۰	۲۶
۰/۱۳۸۴۰۶	۰/۰۳۰۰۵۳	-۰/۱۰۰۱	۰/۵۲۱۶۲۷	۰۰۰۱۰	۲۷
۰/۶۷۴۵۷۲	۰/۹۰۶۲۰۱	۰/۱۰۶۵۵	۰/۵۴۲۳۲۹	۰۰۰۰۱	۲۸

شاخص‌های ارزیابی عملکرد

ارزیابی عملکرد مدل‌ها با استفاده از یک سری شاخص‌های آماری انجام می‌شود. میانگین مربعات خطا (RMSE)، میانگین مطلق خطا (MAE) و ضریب تبیین (R^2) به عنوان سه معیار ارزیابی خطا در این مقاله مورد استفاده قرار گرفته‌اند. شاخص RMSE دقت مدل در پیش‌بینی مقادیر واقعی است به طوری که مقدار کمتر RMSE نشان‌دهنده دقت بیشتر مدل است. معادله RMSE به صورت زیر است:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \text{رابطه (۷)}$$

که در آن، n تعداد نمونه‌ها، y_i مقدار واقعی متغیر وابسته برای نمونه i و \hat{y}_i مقدار پیش‌بینی شده برای نمونه i ام هستند. شاخص MAE نیز یک شاخص ارزیابی خطا است که میزان میانگین خطای مدل را نشان می‌دهد. معمولاً در واحد واقعی متغیر وابسته است. معادله MAE به صورت زیر است:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \text{رابطه ۸}$$

شاخص R^2 شاخصی از توضیح داده‌ها توسط مدل است. این شاخص از صفر تا یک متغیر بوده که یک مقدار نزدیک به یک نشان‌دهنده توانایی مدل در توضیح تغییرات داده‌ها است. معادله آن به قرار زیر است:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad \text{رابطه ۹}$$

که در آن \bar{y} میانگین مقادیر واقعی متغیر وابسته است. سه شاخص فوق‌الذکر برای ارزیابی عملکرد مدل‌ها براساس متوسط خطا استوار هستند. به عبارت دیگر، از روی مقادیر عددی آنها نمی‌توان قضاوت صحیح و درستی روی توزیع خطا در خروجی مدل‌ها داشت. در راستای نیل به این هدف؛ شاخص DDR (نسبت تفاوت توسعه داده شده) به قرار زیر استفاده می‌شود (Noori et al., 2010):

$$DDR = \frac{\text{Predicted Value}}{\text{Measured Value}} - 1 \quad \text{رابطه ۱۰}$$

مقدار DDR برابر با صفر نشان‌دهنده معادل بودن مقدار محاسباتی و مشاهداتی، مقدار DDR مثبت بیانگر بیشتر بودن مقدار محاسباتی از مشاهداتی و مقدار DDR منفی حاکی از کمتر بودن مقدار محاسباتی از مشاهداتی است. علاوه بر این مقادیر کمی، محاسبه تابع گوسی شاخص DDR و رسم توزیع نرمال استاندارد آن به عنوان معیار کیفی و گرافیکی برای ارزیابی عملکرد مدل‌ها قابل استفاده است. باریک بودن منحنی توزیع شاخص DDR و دارا بودن نقطه اکسترمم بیشتر روی محور عمودی دلالت بر عملکرد برتر مدل دارد.

نتایج و بحث

با مشخص شدن این که هر پنج متغیر ورودی شامل: دما، رطوبت، تعداد ساعات آفتابی، سرعت باد و بارش باید در محاسبات و شبیه‌سازی مقدار تبخیر و تعرق پتانسیل نقش داشته باشند، با اجرای هر یک از سه مدل، خلاصه نتایج آنها مشخص و مقدار تحلیل خطای آنها در جدول ۵ ارائه شده است. در اجرای هر یک از مدل‌ها، سهم گام‌های آموزش و آزمون از ۷۶۷۰ داده در دسترس به ترتیب ۷۰ درصد (۵۳۷۰ داده) و ۳۰ درصد (۲۳۰۰ داده) بودند.

جدول ۵- خلاصه ارزیابی عملکرد مدل‌های یادگیری ماشین براساس شاخص‌های آماری


ردیف	نام مدل	گام آموزش				گام آزمون			
		ET _{0(DDR)MAX}	R ²	MAE	RMSE	ET _{0(DDR)MAX}	R ²	MAE	RMSE
۱	GEP	۴/۴۲	۰/۹۸۱۶۷	۰/۲۲۱۸۸	۰/۲۷۵۲۴	۸/۵۴	۰/۹۹۰۷	۰/۱۵۱۵	۰/۱۹۸۵
۲	SVM	۴/۱۴	۰/۹۸۸۷۶	۰/۱۷۸۱۷	۰/۲۱۶۷۵	۴/۲۷	۰/۹۶۵۰	۰/۳۱۱۵	۰/۴۱۰۰
۳	ANN	۳/۲۱	۰/۹۳۶۵۶	۰/۴۹۴۰۱	۰/۶۵۹۹۷۷	۳/۱۹	۰/۹۴۵۶	۰/۴۶۸۹	۰/۶۴۳۲

در رتبه اول شبیه‌سازی قرار دارد. نتایج به دست آمده برای این مدل با لحاظ مقادیر GEP همان‌طور که مشخص است مدل پارامترهای تنظیمی گفته شده در

جدول ۶ به دست آمده‌اند. مقدار شاخص‌های (RMSE, MAE, R², ET_{0(DDR)MAX}) برای گام آموزش و آزمون به ترتیب (۴/۴۲، ۰/۹۸۱۶۷، ۰/۲۲۱۸۸، ۰/۲۷۵۲۴) و (۸/۵۴، ۰/۹۹۰۷، ۰/۱۵۱۵، ۰/۱۹۸۵) به دست آمده‌اند. با مقایسه نتایج می‌توان مشاهده کرد کمترین مقادیر مربوط به MAE و RMSE و بیشترین مقادیر مربوط به شاخص‌های R² و ET_{0(DDR)MAX} در هر دو گام آموزش و آزمون متعلق به مدل GEP است. در شکل بیان درختی از خروجی مدل GEP ارائه شده است.

جدول ۶- مقادیر پارامترهای تنظیمی مدل GEP

مقدار	پارامتر	ردیف
۸	اندازه رأس	۱
۳۰	تعداد کروموزوم	۲
۳	تعداد ژن در هر کروموزوم	۳
ضرب (x)	تابع پیوند	۴
۰/۰۴۴	نرخ جهش	۵
۰/۱	نرخ وارون‌سازی	۶
۰/۱	نرخ ترانهش درج متوالی	۷
۰/۱	نرخ ترانهش ریشه درج متولی	۸
۰/۳	نرخ ترکیب تک نقطه‌ای	۹



شکل ۵- بیان درختی خروجی مدل GEP

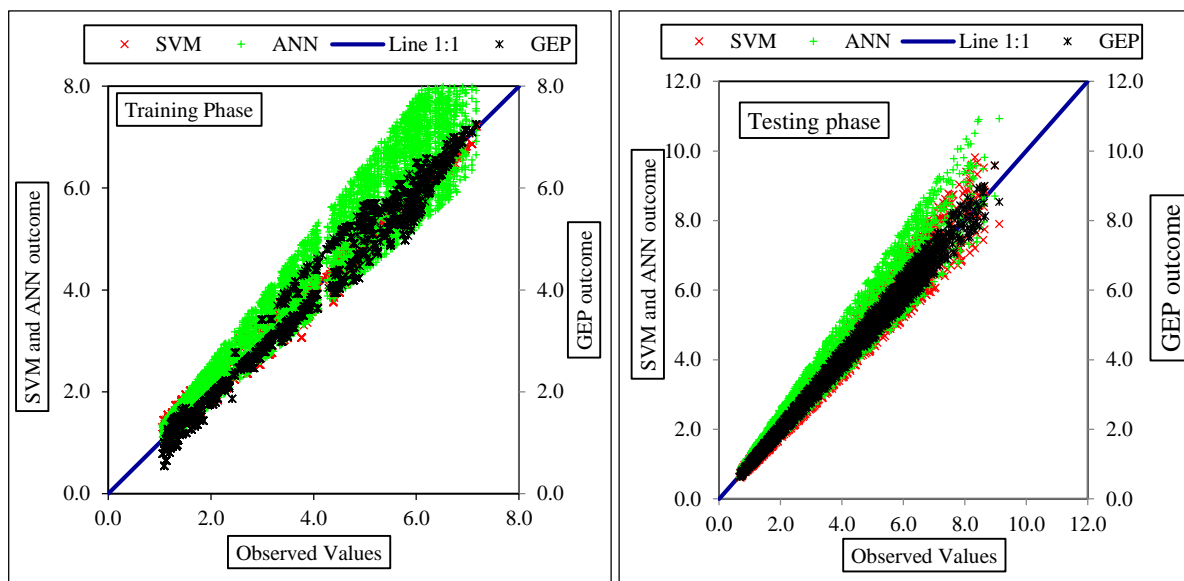
مدل SVM رتبه دوم عملکرد را به خود اختصاص داده است به طوری که مقدار سنج‌های ارزیابی ($RMSE$, MAE , R^2) $ET_{0(DDR)MAX}$ طبق جدول ۵ در گام آموزش برابر با (۴/۱۴)، (۰/۹۸۸۷۶)، (۰/۱۷۸۱۷)، (۰/۲۱۶۷۵) و در گام آزمون برابر با (۴/۲۷)، (۰/۹۶۵۰)، (۰/۳۱۱۵)، (۰/۴۱۰۰) هستند. مقدار پارامترهای تنظیمی مدل SVM به قرار $C=13$ ، $\epsilon=0/10$ ، $\gamma=0/20$ بردار پشتیبان به تعداد ۲۰۰ و تابع کرنل RBF هستند. رتبه سوم شبیه‌سازی مقدار ET_0 به مدل ANN تعلق دارد. جدول ۷ مقدار پارامترهای تنظیمی به کاررفته در اجرای مدل ANN در محیط نرم‌افزاری MATLAB را نشان می‌دهد. طبق جدول ۵، مقدار سنج‌های ارزیابی عملکرد ($RMSE$, MAE , R^2 , $ET_{0(DDR)MAX}$) در گام‌های آموزش و آزمون به ترتیب (۳/۲۱)، (۰/۹۳۶۵۶)، (۰/۴۹۴۰۱) و (۰/۶۵۹۹۸)، (۰/۴۴۳۲)، (۰/۴۶۸۹)، (۰/۹۴۵۶)، (۳/۱۹) هستند.

جدول ۷- پارامترهای تنظیمی مورد استفاده در مدل ANN

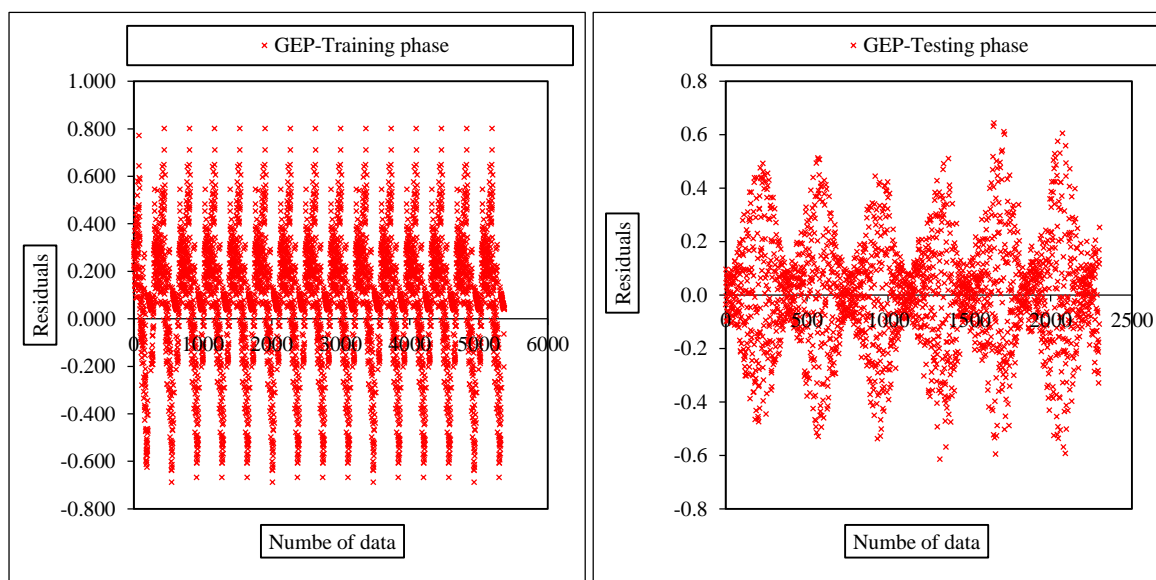
مقدار	پارامتر	ردیف
Feed-forward back propagation	نوع شبکه عصبی	۱
۱	تعداد لایه پنهان	۲
Levenberg-Marquardt	الگوریتم آموزش	۳
۱-۱۰	تعداد نورون	۴
TANSIG	تابع انتقالی برای لایه اول	۵
RURLEIN	تابع انتقالی برای لایه دوم	۶
۲۶۰۰	تعداد تکرار	۷

برای مقایسه گرافیکی خروجی مدل‌ها، شکل ارائه شده است. در این شکل، پراکندگی داده‌های محاسباتی و مشاهداتی در برابر یکدیگر طی دو گام آموزش و آزمون ارائه شده است. علاوه بر این، نیمساز صفحه با نماد خط ۱:۱ نیز ترسیم شده است که فاصله کمتر از این خط حاکی از برتری خروجی مدل مربوطه دارد. به عبارتی دیگر، هر چه توزیع داده‌ها حول خط ۱:۱ بیشتر و

نزدیک‌تر به آن باشد، خروجی مدل از دقت بیشتری برخوردار است. نماد کمی این توصیف، مقدار ضریب تبیین (R^2) است. همان‌طور که در این شکل‌ها نیز مشخص است در هر مرحله آموزش و آزمون، مدل GEP خروجی با خطای کمتری نسبت به دو مدل SVM و ANN داشته است. می‌توان مشاهده نمود خروجی مدل ANN در اغلب موارد بیشتر از مقدار مشاهداتی است. در شکل توزیع خطای باقیمانده خروجی مدل GEP در مراحل آموزش و آزمون ارائه شده است. بیشترین، کمترین و میانگین مقدار خطا در گام آزمون به ترتیب برابر با ۰/۷۷۳، ۰/۳۳۴- و ۰/۱۸۲ و مقدار متناظر آنها در مرحله آزمون به ترتیب ۰/۳۱۱، ۰/۳۰۲- و ۰/۰۰۴ هستند. همان‌طور که مشاهده می‌شود، مقدار خطا در مرحله آزمون به طور قابل توجهی کاهش یافته است که حاکی از صحت انتخاب پارامترهای تنظیمی مدل در گام آموزش است.



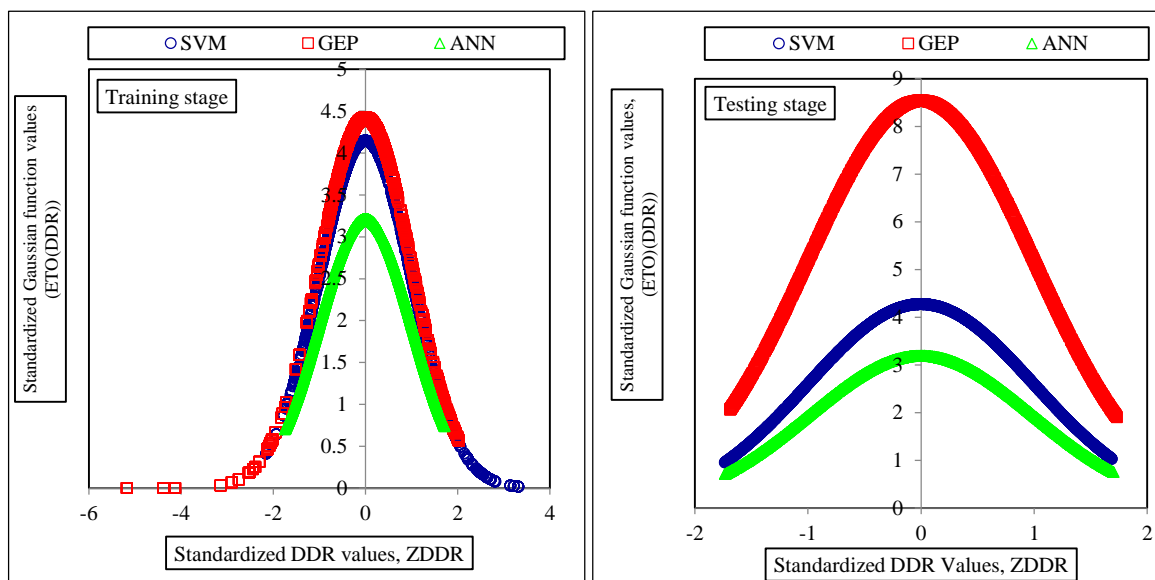
شکل ۶- توزیع داده‌های مشاهداتی و محاسباتی حول خط ۱:۱



شکل ۷- توزیع خطای باقیمانده برای خروجی مدل GEP

یکی دیگر از نمودارهایی که قابلیت بیان گرافیکی مقایسه‌ای عملکرد مدل‌ها را دارد، منحنی توزیع شاخص DDR است. این منحنی برای گام‌های آموزش و آزمون در شکل ۸ ارائه شده است. همان‌طور که قبلاً نیز اشاره شده است، باریک‌بودن منحنی توزیع همراه با دارا بودن بیشترین مقدار روی محور عمودی دلالت بر عملکرد برتر مدل خواهد داشت. برطبق این شکل، اگرچه

کارکرد مدل‌های GEP و SVM در مرحله آموزش تقریباً با یکدیگر مشابه است، مقدار $ET_{0(DDR)MAX}$ برای آنها به ترتیب ۴/۱۴ و ۴/۴۲ هستند، اما در گام آزمون اختلاف فاحشی بین کارکرد GEP با دو مدل دیگر وجود دارد؛ به طوری که مقدار $ET_{0(DDR)MAX}$ برای مدل GEP برابر با ۸/۵۴ و برای مدل‌های SVM و ANN به ترتیب ۴/۲۷ و ۳/۱۹ هستند.



شکل ۸- منحنی توزیع شاخص DDR برای مدل‌های GEP، SVM و ANN

نتیجه‌گیری

ساختار اصلی این پژوهش، بررسی توانایی سه مدل یادگیری ماشین شامل SVM، GEP و ANN برای پیش‌بینی مقدار تبخیر و تعرق پتانسیل در ایستگاه باجگاه در استان فارس است. برای انجام پژوهش از آمار ثبت‌شده روزانه از تاریخ ۱۳۸۷/۰۱/۰۱ تا ۱۳۹۸/۱۲/۲۹ شامل ۷۶۷۰ داده استفاده شد. عناصر اقلیمی روزانه مورد استفاده شامل T ، H ، WS ، SH و P برای پیش‌بینی مقدار ET_0 بودند. سهم فرایندهای آموزش و آزمون برای هر یک از مدل‌های یادگیری ماشین به ترتیب ۷۰ و ۳۰ درصد انتخاب شدند. ارزیابی عملکرد هر یک از مدل‌ها با چهار شاخص $RMSE$ ، MAE ، R^2 و DDR_{MAX} (همراه با توزیع شاخص DDR) انجام شدند. برای انتخاب بهترین ترکیب ورودی برای مدل‌های یادگیری ماشین، از گاما-تست استفاده شد. در مجموع ۲۸ ترکیب برای تحلیل حساسیت ارزیابی شدند و در نهایت مشخص شد هر پنج متغیر مستقل باید به عنوان ورودی در نظر گرفته شوند. نتایج پژوهش نشان داد که رتبه اول دقت شبیه‌سازی به مدل GEP اختصاص دارد. این مدل با ساختار سه ژن توانست با مقادیر $RMSE=0/۲۷۵۲$ ، $MAE=0/۲۲۱۹$ ، $R^2=0/۹۸۱۷$ و $ET_{0(DDR)MAX}=4/۴۲$ در فرایند آموزش و مقادیر $RMSE=0/۱۹۸۵$ ، $MAE=0/۱۵۱۵$ ، $R^2=0/۹۹۰۷$ و $ET_{0(DDR)MAX}=8/۵۴$ در فرایند آزمون بهترین شبیه‌سازی را انجام دهد. رتبه دوم شبیه‌سازی مربوط به مدل SVM بود. با انتخاب تابع کرنل RBF این مدل توانست نتایج بهتری نسبت به مدل ANN بازتولید کند. مقدار ضرایب عملکرد ($RMSE$ ، MAE ، R^2 ، $ET_{0(DDR)MAX}$) برای مدل SVM در گام‌های آموزش و آزمون به ترتیب (۴/۱۴، ۰/۹۸۸۸، ۰/۱۷۸۲، ۰/۲۱۶۷) و (۰/۹۶۵، ۰/۳۱۱۵، ۰/۴۱، ۰/۳/۲۱) به دست آمدند. مقدار این ضرایب در مدل ANN گام آزمون (۰/۹۳۶۶، ۰/۴۹۴، ۰/۶۶) و (۰/۹۴۵۶، ۰/۴۶۸۹، ۰/۶۴۳۲) هستند. همانطور که مشاهده می‌شود تفاوت نسبتاً محسوسی بین عملکرد این دو مدل قابل مشاهده است. در مجموع می‌توان گفت هر سه مدل دارای پتانسیل برای پیش‌بینی و بازتولید مقدار تبخیر و تعرق پتانسیل هستند، اما در این میان استفاده از مدل GEP منجر به نتایج بهتری خواهد شد. نتایج این پژوهش در خصوص قابلیت پیش‌بینی و شبیه‌سازی ET_0 با دقت مناسب با نتایج به دست آمده توسط محمد رضا پور (۱۳۹۵)، عیسی‌زاده،

شیرزاد و رضایی بنفشه (۱۳۹۶)، ملک احمدی (۱۴۰۱) همخوانی دارد؛ به طوری که نتایج پژوهش‌ها ضمن تایید پارامترهای دخیل در شبیه‌سازی تبخیر و تعرق پتانسیل، قابلیت مدل‌های یادگیری ماشین در شبیه‌سازی را تایید می‌کنند.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

نویسندگان اصول اخلاقی را در انجام و انتشار این پژوهش علمی رعایت نموده‌اند و این موضوع مورد تأیید همه آنها است.

مشارکت نویسندگان

جمع‌آوری داده‌ها: جاسم باوی؛ تهیه گزارش پژوهش: اصلان اگدرنژاد، آرش تافته؛ تحلیل داده‌ها: اصلان اگدرنژاد، آرش تافته
مشارکت نویسندگان در مقاله مستخرج از پایان‌نامه تقریباً به شکل زیر بوده است:
جاسم باوی: تهیه و آماده‌سازی نمونه‌ها، انجام آزمایش و گردآوری داده‌ها، انجام محاسبات، تجزیه و تحلیل آماری داده‌ها، تحلیل و تفسیر اطلاعات و نتایج، تهیه پیشنویس مقاله
اصلان اگدرنژاد: استاد راهنمای پایان‌نامه، طراحی پژوهش، نظارت بر مراحل انجام پژوهش، بررسی و کنترل نتایج، اصلاح، بازبینی و نهایی‌سازی مقاله
آرش تافته: استاد مشاور پایان‌نامه، مشارکت در طراحی پژوهش، نظارت بر پژوهش، مطالعه و بازبینی مقاله

تعارض منافع

بنا بر اظهار نویسندگان این مقاله تعارض منافع ندارد.

سپاسگزاری

نگارندگان بر خود فرض می‌دانند از داوران محترم نشریه به خاطر مطالعه متن مقاله حاضر و ارائه نظرهای ارزشمند سپاسگزاری نمایند.

منابع

- احمدزاده کلپیر، ف.، شاه‌محمدی کللق، ش.، فردمرادی‌نیا، س. ۱۴۰۳. شبیه‌سازی تغییرات ضریب یکنواختی توزیع آب در سامانه‌های آبیاری بارانی کلاسیک ثابت با استفاده از مدل‌های داده‌کاوی. *رویکردهای نوین در مهندسی آب و محیط‌زیست*، ۱۱۸-۱۳۵: (۲)۳.
- باقری، ن.، قاسمی، ا.ر. ۱۴۰۲. مدل‌سازی تبخیر روزانه از تشت با استفاده از برنامه نویسی بیان‌ژن و سری‌های زمانی در استان خوزستان. *پژوهش آب/ایران*، ۱۷(۲): ۱-۱۱.
- برزگار، ع.، شهابی، س.، نیازمردی، س.، مددی، م.ر. ۱۴۰۰. ارزیابی قابلیت برنامه‌ریزی بیان‌ژن در تخمین تبخیر تعرق پتانسیل در مقایسه با رابطه هارگریوز-سامانی. *مهندسی آبیاری و آب/ایران*، ۱۱(۴): ۳۱۶-۳۳۰.
- حقی‌زاده، ع.، بیات، و.، ارشیا، آ. ۱۳۹۸. برآورد تبخیر و تعرق پتانسیل ایستگاه‌های سینوپتیک کرمانشاه با استفاده از مدل برنامه‌نویس ژنتیکی. *فضای جغرافیایی*، ۱۹(۶۷): ۲۹-۴۲.
- زارع ابیانه، ح.، بیات ورکشی، م.، معروفی، ص. ۱۳۹۰. محاسبه تبخیر و تعرق واقعی گیاه سیر به روش مدل‌سازی چندگانه تحت شرایط کاشت لایسپمتر. *پژوهش‌های حفاظت آب و خاک*، ۱۸(۲): ۱۴۱-۱۵۹.
- شادمانی، م.، معروفی، ص. ۱۳۹۰. مقایسه چند روش برآورد تبخیر روزانه از تشت-مطالعه موردی منطقه کرمان. *علوم آب و خاک*، ۱۵(۵۵): ۶۹-۸۴.

طباطبائی، س.م.، ناظری تهرودی، م.، دستورانی، م. ۱۳۹۷. مقایسه عملکرد مدل‌های GP، ANN، BCSD و SVM در شبیه‌سازی دما. *هوشناسی و علوم جو*. ۱(۱): ۵۳-۶۴.

عیسی‌زاده، م.، شیرزاد، م.، رضایی بنفشه، م. ۱۳۹۶. ارزیابی عملکرد شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) در تخمین مقادیر روزانه تبخیر (مطالعه موردی: ایستگاه‌های هواشناسی تبریز و مراغه). *پژوهش‌های جغرافیای طبیعی*، ۴۹(۱): ۱۵۱-۱۶۸.

فولادی‌پناه، م.، ماجدی‌اصل، م. ۱۴۰۱. کاربرد محاسبات نرم در افزایش دقت پیش‌بینی ضریب دبی جریان سرریزهای جانبی مستطیلی. *مهندسی آبیاری و آب ایران*، ۱۲(۴): ۲۱۳-۲۳۳.

ماجدی‌اصل، م.، فولادی‌پناه، م.، ذیفر، ر.، قسمی، ز. ۱۴۰۰. استخراج منحنی دبی-اشل در سرریز کلید پیانویی مستغرق استاندارد و اصلاح شده با استفاده از الگوریتم‌های هوشمند. *هیدرولیک*، ۱۶(۲): ۵۹-۷۲.

محبوبی، ع.، عبدال‌آبادی، ح.، محجوبی، ج.، غفوری، ا. ۱۴۰۲. بررسی عملکرد مدل‌های داده‌کاوی در پیش‌بینی بارش و تحلیل وضعیت خشک‌سالی ایستگاه سینوپتیک بندرعباس. *مدیریت آب و آبیاری*، ۱۳(۲): ۴۲۹-۴۹۹.

محمدرضاپور، ا. ۱۳۹۶. پیش‌بینی تبخیر-تعرق پتانسیل ماهانه با استفاده از مدل‌های ماشین بردار پشتیبان، برنامه‌ریزی ژنتیک و سیستم استنتاج عصبی-فازی. *مهندسی آبیاری و آب ایران*، ۷(۳): ۱۳۵-۱۵۰.

ملک‌احمدی، ح.، میرزانی، ا.، خسروی، س.، ابراهیم‌زاده، ع. ۱۴۰۱. مدل‌سازی فرایند تبخیر-تعرق روزانه با استفاده از مدل‌های رگرسیونی و هوشمند. *پژوهش‌های آب ایران*، ۱۶(۱): ۴۹-۶۲.

ناظری تهرودی، م.، امیرآبادی زاده، م.، زینلی، م.ج. ۱۳۹۷. بررسی روش‌های هوش مصنوعی و رگرسیونی در شبیه‌سازی مقادیر دمای روزانه. *هوشناسی و علوم جو*، ۱(۱): ۶۵-۷۶.

Achite, M., Jehanzaib, M., Sattari, M.T., Toubal, A.K., Elshaboury, N., Wałęga, A., Krakauer, N., Yoo, J.Y., Kim, T.W. 2022. Modern techniques to modeling reference evapotranspiration in a semiarid area based on ANN and GEP models. *Water*, 14(8): 1210. <https://doi.org/10.3390/w14081210>

Ahmadzadeh-Kaleybar, F., Shahmohammadi Kalalagh, S., Fard Moradinia, S. 2024. Simulating of Changes in Water Distribution Uniformity Coefficient in Classic Stationary Sprinkler Irrigation Using Data-Mining Models. *Journal of New Approaches in Water Engineering and Environment*, 3(2): 118-135. (In Persian) doi: 10.22034/nawee.2024.471274.1100

Bagheri, N., Ghasemi, A., Nasr-Esfahani, M.A. 2023. Modeling of pan evaporation using Gene Expression Programming and time series in Khuzestan. *Iranian Water Research Journal*, 17(49): 1-11. (In Persian) <https://doi.org/10.22034/iwrj.2023.14189.2480>

Barzkar, A., Shahabi, S., Niazmradi, S., Madadi, M.R. 2021. Gene Expression Programming Capability Assessment in Estimating the Potential Evapotranspiration Compared to Hargreaves-Samani Equation. *Irrigation and Water Engineering*, 11(44): 316-330. (In Persian) <https://doi.org/10.22125/iwe.2021.133766>

Chow, V.T., Maidment, D.R., Mays, L.W. 1988. Applied hydrology. New York, NY: McGraw-Hill.

Deo, R.C., Kisi, O., Singh, V.P. 2017. Drought forecasting in eastern Australia using multivariate adaptive regression spline, least square support vector machine and M5Tree model. *Atmospheric Research*, 184: 149-175. <https://doi.org/10.1016/j.atmosres.2016.10.004>

Ferreira, C. 2006. Gene expression programming: mathematical modeling by an artificial intelligence (Vol. 21). Springer.

Fuladipannah, M., Majedi-Asl, M. 2022. Soft Computing Application to Amplify Discharge Coefficient Prediction in Side Rectangular Weirs. *Irrigation & Water Engineering*, 12(48): 213-233. (In Persian) <https://doi.org/10.22125/iwe.2022.150692>

- Ghorbani, M.A., Kazempour, R., Chau, K.W., Shamsheirband, S., Taherei Ghazvinei, P. 2018. Forecasting pan evaporation with an integrated artificial neural network quantumbehaved particle swarm optimization model: a case study in Talesh. Northern Iran. *Engineering Applications of Computational Fluid Mechanics*, 12(1): 724-737. <https://doi.org/10.1080/19942060.2018.1517052>
- Haghizadeh, A., Bayat, V., Arshia, A. 2019. Estimation of The Evapotranspiration potential of Kermanshah synoptic stations Using Genetic Programming. *Geographic Space*, 19(67): 29-42. (In Persian) <http://geographical-space.iau-ahar.ac.ir/article-1-2967-en.html>
- Isazadeh, M., Shirzad, M., Rezaei Banafsheh, M. 2017. Evaluation of the Performance of Artificial Neural Network and Support Vector Machine Models in Estimation of Daily Evaporation amounts (Case study: Tabriz and Maragheh Synoptic Stations). *Physical Geography Research*, 49(1): 151-168. (In Persian) <https://doi.org/10.22059/jphgr.2017.61585>
- Jain S.K., Das A., Srivastava, D.k. 1999. Application of ANN for reservoir inflow prediction and operation. *Journal of Water Resources Planning and Management*, 125(5): 263-271. [https://doi.org/10.1061/\(ASCE\)0733-9496\(1999\)125:5\(263\)](https://doi.org/10.1061/(ASCE)0733-9496(1999)125:5(263))
- Kim, S., Kim, H.S. 2008. Neural networks and genetic algorithm approach for nonlinear evaporation and evapotranspiration modeling. *Journal of Hydrology*, 351: 299-317. <https://doi.org/10.1016/j.jhydrol.2007.12.014>
- Kisi, O. 2015. Pan evaporation modeling using least square support vector machine .multivariate adaptive regression splines and M5 model tree. *Journal of Hydrology*. 528: 312-320. <https://doi.org/10.1016/j.jhydrol.2015.06.052>
- Kisi, O. 2016. Pan evaporation modeling using least square support vector machine, multivariate adaptive regression splines and M5 model tree. *Journal of Hydrology*, 528: 312-320. <https://doi.org/10.1016/j.jhydrol.2015.06.052>
- Kisi, O., Azamathulla, H. M., Cevat, F., Kullu, C., Kuhdaragh, M., Fuladipanah, M. 2024. Enhancing river flow predictions: Comparative analysis of machine learning approaches in modeling stage-discharge relationship. *Results in Engineering*, 22: 102017. <https://doi.org/10.1016/j.rineng.2024.102017>
- Koncar, N. 1997. Optimisation methodologies for direct inverse neurocentral (Doctoral dissertation, University of London).
- Liu, S., Bai, J., Jia, Z., Jia, L., Zhou, H., Lu, L. 2010. Estimation of evapotranspiration in the Mu Us Sandland of China. *Hydrology and Earth System sciences*, 14: 573-584. <https://doi.org/10.5194/hess-14-573-2010>, 2010
- Mahjoobi, E., Abdolabadi, H., Mahjoobi, J., Ghafoori, E. 2023. Investigating the Performance of Data Mining Models in Rainfall Forecasting and Drought Analysis of Bandar Abbas Synoptic Station. *Water and Irrigation Management*, 13(2): 429-499. (In Persian) <https://doi.org/10.1001.1.22516298.1402.13.2.9.3>
- Majedi-Asl, M., Fuladipanah, M., Zifar, R., Gasami, Z. 2021. Extraction of head-discharge relationship for submerged standard and modified piano key weirs using intelligent algorithms. *Journal of Hydraulics*, 16(2): 59-72. (In Persian) [10.30482/jhyd.2021.265840.1500](https://doi.org/10.30482/jhyd.2021.265840.1500)
- Majhi, B., Naidu D. 2021. Pan evaporation modeling in different agroclimatic zones using functional link artificial neural network. *Information Processing in Agriculture*, 8(1): 134-147. <https://doi.org/10.1016/j.inpa.2020.02.007>
- Malekhamadi, H., Mirzania, E., Khosravi, S., Ebrahim Zadeh, A. 2022. Daily evapotranspiration modeling using regression and intelligent models (Case Study). *Iranian Water Researches Journal*, 16(1), 49-62. (In Persian) <https://doi.org/10.22034/iwrj.2022.10026.2338>
- Mohamadrezapour, O. 2017. Monthly Forecast of Potential Evapotranspiration Models Using Support Vector Machine (SVM), Genetic programming and Neural - Fuzzy Inference System. *Journal of Irrigation and Water Engineering*, 7(21): 135-150. (In Persian)
- Moradinejad, A., Parsaie, A., Hosseini, S.A., Tabatabaei, M. 2025. Assessing Soft Computing Techniques for River Suspended Sediment Estimation. *Journal of New Approaches in Water Engineering and Environment*, 4(2): 188-212. doi: 10.22034/nawee.2025.514714.1147.
- Nazeri Tahroudi, M., Amirabadyzadeh, M., Zeynali, M. 2018. Evaluation of the Accuracy of Artificial Intelligence and Regression Models in Simulation the Daily Temperature. *Journal of Meteorology and Atmospheric Science*, 1(1), 65-76. (In Persian)

- Noori R., Khakpour, A., Omidvar, B., Farokhnia, A. 2010. Comparison of ANN and principal component analysis-multivariate linear regression models for predicting the river flow based on developed discrepancy ratio statistics. *Expert Systems with Applications* 37: 5856-5862. <https://doi.org/10.1016/j.eswa.2010.02.020>
- Nourani, V., Elkiran, G., Abdullahi, J. 2019. Multi-station artificial intelligence-based ensemble modeling of reference evapotranspiration using pan evaporation measurements. *Journal of Hydrology*. 577, 13958. <https://doi.org/10.1016/j.jhydrol.2019.123958>
- Patle, G.T., Chettri, M., Jhajharia, D. 2020. Monthly pan evaporation modelling using multiple linear regression and artificial neural network techniques. *Water Supply*. 20(3): 800-808. <https://doi.org/10.2166/ws.2019.189>
- Qasem, S.N., Samadianfard, S., Kheshtgar, S., Jarhan, S., Kisi, O., Shamshirband, SH., Chau, K.W. 2019. Modeling monthly pan evaporation using wavelet support vector regression and wavelet artificial neural networks in arid and humid climates. *Engineering Applications of Computational Fluid Mechanics*. 13(1): 177-187. <https://doi.org/10.1080/19942060.2018.1564702>
- Shadmani, M., Marofi, S. 2011. Comparison of Some Methods for Estimation of Daily Pan Evaporation: Case Study in Kerman Region. *Journal of Water and Soil Science*, 15(55): 69-84. (In Persian) <http://dorl.net/dor/20.1001.1.24763594.1390.15.55.6.4>
- Shakeri yousefi, Sh., Najarchi, M., Fuladipanah, M., Rabani Bidgoli, M. 2025. Machine Learning models for High-Accuracy Prediction of Energy Dissipation Through Gabion Sills Downstream of Spillways. *Journal of New Approaches in Water Engineering and Environment*, 4(2): 91-106. doi: 10.22034/nawee.2025.507107.1140
- Stefánsson, A., Koncar, N., Jones, A.J. 1997. A note on the gamma test. *Neural Computing & Applications*. 5(3): 131-133.
- Taabtabaei, S., Nazeri Tahroudi, M., Dastourani, M. 2018. Performance comparison of GP, ANN, BCSD and SVM models for temperature simulation Comparison performance of GP, ANN, BCSD and SVM models in temperature simulation. *Journal of Meteorology and Atmospheric Science*, 1(1): 53-64. (In Persian)
- Tabari, H., Marofi, S., Sabziparvar, A.A. 2010. Estimation of daily pan evaporation using artificial neural network and multivariate non-linear regression. *Irrigation Sciences*, 28: 399-406. <https://doi.org/10.1007/s00271-009-0201-0>
- Vapnic V.N. 1988. *Statistical Learning Theory*. Wiley, NEW YORK, USA.
- Wang L., Niu Z., Kisi O., Li C., Yu, D. 2017. Pan evaporation modeling using four different heuristic approaches. *Computers and Electronics in Agriculture*. 140: 203- 213. <https://doi.org/10.1016/j.compag.2017.05.036>
- Zare Abyaneh, H., Bayat Varkeshi, M., Marofi, S. 2011. Forecasting of garlic (*Allium sativum* L.) evapotranspiration by using multiple modeling. *Journal of Water and Soil Conservation*, 18(2): 141-158. (In Persian)