

Research Paper

Prediction of reference evaporation and transpiration values of Golestan province with meta combinatorial learning model (Stacking)

Omolbani Mohammadrezapour^{1*}Hadi Siasar²Hosein Sharifan³Ozgur Kisi⁴

¹ Associate Professor, Department of Water Engineering, Faculty of water and soil, Gorgan University of Agricultural science and Natural Resources. (Corresponding author)

² Assistant Professor, Assistant professor, Faculty of Agricultural, PayamNoor University, Tehran, Iran.

³ Associate Professor, Department of Water Engineering, Faculty of water and soil, Gorgan University of Agricultural science and Natural Resources.

⁴ Department of Civil Engineering, Technical University of Lübeck, 23562, Lübeck, Germany.

E-mail: okisi@ibsu.edu.ge



10.22125/iwe.2025.483811.1836

Received:

June 24, 2024

Accepted:

January 27, 2025

Available online:

April 25, 2025

Keywords:

Artificial intelligence models, Golestan province, Reference evapotranspiration.

Abstract

The land of Iran is located on the dry belt of the world, and despite the scarcity of water, it has been constantly exposed to the fluctuations and irregularities of the rainfall regime, and this issue has created many problems and dilemmas for the management of the country's water resources, which are considered important. It has provided the most sources of water supply needed for agriculture, drinking and industry. Therefore, studying and evaluating the quality of these sources is more important than ever. In this regard, based on the FAO Penman-Mantith relationship, the monthly potential evaporation-transpiration rate in the selected synoptic stations was calculated from the monthly meteorological data and as an input to the hybrid meta-exploratory models including the artificial neural network (ANN). enhanced support vector (ESVM), meta combinatorial learning model (Stacking) is used.

1. Introduction

The land of Iran is located on the dry belt of the world, and despite the scarcity of water, it has been constantly exposed to the fluctuations and irregularities of the rainfall regime, and this issue has created many problems and dilemmas for the management of the country's water resources, which are considered important. It has provided the most sources of water supply needed for agriculture, drinking and industry. Therefore, studying and evaluating the quality of these sources is more important than ever. In this regard, based on the FAO Penman-Mantith relationship, the monthly potential evaporation-transpiration rate in the selected synoptic

* **Corresponding Author:** Omolbani Mohammadrezapour

Address: Department of Water Engineering, Faculty of Soil and Water, Gorgan University of Agricultural Sciences and Natural Recourses.

Email: Academic Email:

Mohammadrezapour@Gau.ac.ir

Tel: Number

stations was calculated from the monthly meteorological data and as an input to the hybrid meta-exploratory models including the artificial neural network (ANN). enhanced support vector (ESVM), meta combinatorial learning model (Stacking) is used.

2. Materials and Methods

To carry out this research, according to the statistics and information collected from the Meteorological Organization of Golestan province, the prediction of evaporation and transpiration parameters of this province was done using smart models. After obtaining statistics and information related to meteorological data including: average temperature data, average minimum temperature, average maximum temperature, average relative humidity, average minimum relative humidity, average maximum relative humidity, sunny hours, evaporation, number of sunny hours, the dew point of Golestan Meteorological Organization and the selection of 6 stations and a common period of 30 years (1370-1401), the prediction of potential evaporation and transpiration parameter was discussed. In order to do the work, artificial intelligence methods including Artificial Neural Network (ANN) model, Enhanced Support Vector (ESVM) and Staking, and in the eight scenarios, to advance The parameters of evaporation and transpiration potential of Golestan province were used. First, the input data was divided into two groups. The data was divided into two categories: calibration data (training) and test data (test). Data training will be done using 70% of the data and the remaining 30% that did not play a role in training was used as test data. After examining the data, the data related to the training and testing of the models were selected (randomly and normalized) and used. Data calibration is evaluated using 70% of the data (for training) and the performance of the methods is evaluated using the remaining 30% of the data. Also, in this research, three measures of root mean square error, correlation coefficient and average absolute value of error were used to evaluate the accuracy of the models.

3. Results

In this section staking, ESVM, ANN-MLP models with different inputs were investigated to predict the evaporation and transpiration parameters of Golestan province, and according to the statistical coefficients comparing the output of the model with the observed values of the test data, the best models were selected in order of output accuracy. Considering that all these inputs are not acceptable, therefore, according to the comparison of the output obtained from the models (with different inputs) with the observed values, some of these inputs were selected as the best inputs. From the examination of the results of all stations, it was observed that all reference evaporation and transpiration parameter prediction models have good performance. But the Stacking model in all studied stations in the best scenarios has the lowest average absolute value of error (Gorgan: 0.25, Gonbad: 0.08, Kordkoi: 0.25, Bandar Turkmen: 0.8, Aliabad: 0.33 and Minodasht: 0.97) and the explanation coefficient is very High (Gorgan: 0.996, Gonbad: 0.99, Kordkoi: 0.99, Bandar Turkmen: 0.996, Aliabad: 0.991 and Minodasht: 0.992) and the lowest square root of the error (Gorgan: 6.849, Gonbad: 9.919, Kordkoi: 9.671, Bandar Turkmen: 6.561, Aliabad: 9.123 and Minodasht: 8.73). Also, after the Stacking model, in all stations, the ANN model and then the ESVM model have higher accuracy than the rest of the models.

4. Discussion and Conclusion

The main goal of this research is to investigate the ability of artificial neural network (MLP) model, enhanced support vector model, rain forest model, deep learning model, meta hybrid memory model and generalized linear model to predict reference evaporation and transpiration parameters in Golestan province with the common period of 30 years (1370-1400) has been used. The input parameters of this research included average temperature, average minimum temperature, average maximum temperature, average relative humidity, average minimum relative humidity, average maximum relative humidity, number of sunny hours, dew point and evaporation. In this research, 8 input combinations of meteorological parameters were used. The results obtained from this research showed that input combination 8 and 7 of the rest of the models have a high ability to estimate the reference evaporation and transpiration parameter. According to the results, it

can be seen that in all the studied cities, the Stacking model is more accurate than the other models in predicting the ETo parameter. After that, RF model and then DL model have good efficiency respectively.

5. Six important references

- 1) Aytac, G and T. Seydou. 2012. Regional-Specific Numerical Models of Evapotranspiration Using Gene Expression Programming Interface in Sahel. *Water Resources Management* (2012) 26: 4367-4380.
- 2) Gao Y, Long D, Li Z. Estimation of daily evapotranspiration from remotely sensed data under complex terrain over the upper Chao River basin in north China. *International Journal of Remote Sensing*. 2008; 29(11): 3295-3315.
- 3) Gulay Tezal and Buyukyildiz. 2015. Modeling of daily pan evaporation in subtropical climate ANN, LS-SRV, fuzzy logic, and ANFIS, *Thero Appl Climatol*. 15. 1392.
- 4) Kisi, O. and M. Zounemat-Kermani. 2014. Comparison of Two Different Adaptive Neuro-Fuzzy Inference Systems in Modelling Daily Reference Evapotranspiration. *Water Resources Management*, 28: 2655-2675.
- 5) Mohammadrezapoura, O., Moradi, M., Kisi, O., Sharifazari. S. 2018, Evolutionary support vector machine for evapotranspiration estimation (case study: Haji Abad region, Hormozgan province), *Desalination and Water Treatment*, 111 (2018) 183–191.
- 6) Mohammadrezapour, O., Piri, J., Kisi, o. 2019. Comparison of SVM, ANFIS and GEP in modeling monthly potential evapotranspiration in arid region (Case study: Sistan and baluchestan province – Iran). *Water Supply* (2019) 19 (2): 392–403. <https://doi.org/10.2166/ws.2018.084>.

Conflict of Interest

Authors declared no conflict of interest.

Acknowledgments

پیش‌بینی مقادیر تبخیر و تعرق مرجع استان گلستان با مدل یادگیری ترکیبی متا

ام‌البنی محمد رضا پور^{۱*}، هادی سیاسر^۲، حسین شریفان^۳، اوزگار کیسی^۴

تاریخ ارسال: ۱۴۰۳/۰۴/۰۴

تاریخ پذیرش: ۱۴۰۳/۱۱/۰۸

مقاله پژوهشی

چکیده

تبخیر و تعرق یکی از مولفه‌های اصلی بیلان آب در یک منطقه و از جمله عوامل مؤثر جهت برنامه‌ریزی دقیق آبیاری می‌باشد. لذا، برآورد دقیق نیاز آبی گیاه، تاثیر شایانی بر کاهش معضل بحران آب، خواهد داشت. علی‌رغم اهمیت تبخیر-تعرق در برنامه‌ریزی و مدیریت منابع آبی، وابستگی آن به مولفه‌های اقلیمی از یک‌سو و تاثیرپذیری این مولفه‌ها از یکدیگر از سوی دیگر تخمین تبخیر-تعرق را دشوار ساخته است. در این راستا، ابتدا بر اساس رابطه‌ی فائو پنمن-مانتیت، میزان تبخیر-تعرق پتانسیل ماهانه در ایستگاه‌های سینوپتیک مورد انتخاب از داده‌های هواشناسی ماهانه محاسبه و به عنوان ورودی مدل‌های هیبریدی فراکاوشی شامل شبکه عصبی مصنوعی (ANN)، بردار پشتیبان ارتقا یافته (ESVM) و مدل یادگیری ترکیبی متا (Stacking) استفاده می‌شود. واسنجی داده‌ها به وسیله 70 درصد داده‌ها (برای آموزش) و عملکرد روش‌ها با استفاده از 30 درصد داده‌های باقی‌مانده ارزیابی می‌گردد. همچنین در این تحقیق برای ارزیابی دقت مدل‌ها از سه معیار ریشه میانگین مربعات خطا، ضریب همبستگی و میانگین قدر مطلق خطا استفاده شد. از بررسی نتایج همه ایستگاه‌ها مشاهده شد، تمام مدل‌های پیش‌بینی پارامتر تبخیر و تعرق مرجع از کارایی خوبی برخوردار هستند. اما مدل یادگیری ترکیبی متا در همه ایستگاه‌های مورد مطالعه در بهترین سناریوها از مقادیر کمترین میانگین قدر مطلق خطا (گرگان: 0/25، گنبد: 0/08، کردکوی: 0/25، بندر ترکمن: 0/8، علی‌آباد: 0/33 و مینودشت: 0/97) و ضریب تعیین بسیار زیاد (گرگان: 0/996، گنبد: 0/99، کردکوی: 0/99، بندر ترکمن: 0/996، علی‌آباد: 0/991 و مینودشت: 0/992) و کمترین ریشه دوم مربعات خطا (گرگان: 6/849، گنبد: 9/919، کردکوی: 9/671، بندر ترکمن: 6/561، علی‌آباد: 9/123 و مینودشت: 8/73) برخوردار می‌باشد. همچنین بعد از مدل یادگیری ترکیبی متا در همه ایستگاه‌ها مدل شبکه عصبی مصنوعی و سپس مدل بردار پشتیبان ارتقا یافته از دقت بیشتری نسبت به بقیه مدل‌ها برخوردار می‌باشند.

واژه‌های کلیدی: مدل‌های هوش مصنوعی، بردار پشتیبان ارتقا یافته، دقت مدل

^۱ دانشیار گروه مهندسی آب - دانشکده آب و خاک - دانشگاه علوم کشاورزی و منابع طبیعی گرگان (نویسنده مسول)
nmohammadrezapour@yahoo.com

^۲ استادیار - گروه کشاورزی - دانشگاه پیام نور - تهران - ایران ایمیل: hadisiasar@yahoo.com

^۳ دانشیار گروه مهندسی آب - دانشکده آب و خاک - دانشگاه علوم کشاورزی و منابع طبیعی گرگان

^۴ دانشکده عمران - دانشکاه تکنولوژی لوبک - آلمان

مقدمه

سرزمین ایران بر روی کمربند خشک جهان واقع است و علی‌رغم کم‌آبی، پیوسته در معرض نوسانات و بی‌نظمی‌های رژیم بارش نیز قرار گرفته است، و این موضوع مشکلات و معضلات متعددی را برای مدیریت منابع آبی کشور که به عنوان مهم‌ترین منابع تامین آب مورد نیاز برای بخش کشاورزی، شرب و صنعت می‌باشد، فراهم آورده است. لذا مطالعه و ارزیابی کیفیت این منابع بیش از پیش از اهمیت زیادی برخوردار می‌باشد (Mohammadrezapour et al, 2018).

مطالعات داخلی نیز اهمیت تبخیر و تعرق در چرخه هیدرولوژی را تأیید کرده‌اند. به‌طور مثال، پژوهش‌های اخیر نشان داده‌اند که تبخیر و تعرق به‌عنوان عامل کلیدی در ارزیابی منابع آب کشاورزی نقش بسزایی دارد و مدل‌های هوش مصنوعی برای پیش‌بینی این مقادیر نتایج امیدوارکننده‌ای ارائه کرده‌اند (هاشمی و همکاران، ۱۴۰۰؛ کریمی و همکاران، ۱۳۹۹؛ صالحی و رضوی، ۱۴۰۱). در این مطالعات استفاده از داده‌های هواشناسی نظیر دما، رطوبت نسبی و ساعات آفتابی در کنار مدل‌های پیشرفته‌ای مانند سیستم‌های استنتاج فازی و ماشین بردار پشتیبان مورد تأکید قرار گرفته است.

در بسیاری از مناطق جهان تبخیر و تعرق بعد از بارش، دومین عامل مهم در چرخه هیدرولوژی و از عوامل تعیین‌کننده معادلات انرژی در سطح زمین و توازن آب است و در زمینه‌های مختلف علوم، مانند هیدرولوژی، کشاورزی، مدیریت جنگل و مرتع و مدیریت منابع آب مورد نیاز است (Gao et al, 2008). همچنین آب مهم‌ترین عامل محدودکننده کشاورزی در ایران است. از این رو باید توجه ویژه‌ای به افزایش کارایی مصرف آن در تولید محصولات کشاورزی شود (Hejazizadeh et al., 2017؛ اسدی و کرمی، ۱۴۰۰). در سال‌های اخیر مدل‌های ریاضی و کامپیوتری بسیاری به‌منظور شبیه‌سازی مقدار تبخیر و تعرق پتانسیل موردتوجه قرار گرفته است. در این میان مدل‌های هوش مصنوعی برای مدل‌سازی رفتار پدیده‌های مختلف موردتوجه محققین زیادی قرار گرفته‌اند. شبکه‌های عصبی مصنوعی، مدل جنگل باران، مدل بردار پشتیبان ارتقا یافته، مدل یادگیری عمیق، مدل یادگیری ترکیبی متا

و مدل خطی تعمیم یافته و غیره ابزاری قدرتمند جهت شبیه‌سازی فرآیندهای پیچیده و غیرخطی به شمار می‌روند که ازجمله کارآمدترین ابزارهای پیش‌بینی پارامترها هستند. به همین دلیل، پژوهش‌های متعددی به ارزیابی مدل‌های هوش مصنوعی در برآورد تبخیر-تعرق پتانسیل پرداخته‌اند که به برخی از آنها اشاره می‌شود.

(Kisi and Zounemat-Kermani, 2014) در پژوهشی نشان دادند که روش‌های فراابتکاری مانند شبکه عصبی مصنوعی، الگوریتم ژنتیک، برنامه‌ریزی ژنتیک و سیستم‌های استنتاج فازی قابلیت زیادی در برآورد میزان تبخیر - تعرق دارند. در تحقیقی با استفاده از داده‌های مشاهده شده تحت کلاس A، کاربرد روش‌های شبکه‌های عصبی مصنوعی، سیستم استنتاج فازی-عصبی و هم چنین روش تجربی استیفان-استوارت، جهت برآورد تبخیر روزانه کرمان مورد بررسی قرار گرفت. نتایج تحقیق نشان داد که روش عصبی-فازی نسبت به بقیه روش‌ها، از دقت بیشتری برای برآورد تبخیر از تحت برخوردار است (شادمانی و معروفی، ۱۳۹۰). (Guo (2011) در تحقیقی به برآورد تبخیر و تعرق گیاه مرجع بصورت روزانه با استفاده از ماشین بردار پشتیبان پرداختند که نتایج تحقیق ایشان نشان داد که مدل ماشین بردار پشتیبان می‌تواند داده‌های تبخیر و تعرق گیاه مرجع را تا ۹۰٪ با مقادیر محاسبه شده با روش پنمن-مانتیت تقریب بزند. توانایی عملکرد برنامه-ریزی بیان ژن (GEP) برای مدل‌سازی تبخیر-تعرق پتانسیل با استفاده از داده‌های آب و هوایی ده ساله کشور ساحلی، بورکینا فاسو مورد ارزیابی قرار گرفت. برای این کار تبخیر-تعرق پتانسیل برآورد شده از روش پنمن-مانتیت به عنوان مدل مرجع مورد استفاده قرار گرفت و نتایج نشان داد که روش مدل برنامه‌نویسی بیان ژن توانایی خوبی برای ارائه مدل عددی بر اساس داده‌ای منطقه‌ای داراست (Aytac and seydou, 2012). شیری و همکاران (۲۰۱۲) در تحقیقی در شمال اسپانیا در کشور باسک از مدل برنامه ریزی بیان ژن (GEP) برای برآورد تبخیر و تعرق مرجع روزانه (ET_0) چهار ایستگاه آب و هوا بی استفاده کردند و روش پنمن مانیت به عنوان مرجع انتخاب و نتایج برنامه نویسی بیان ژن (GEP) با سیستم تطبیقی عصبی فازی استنتاج (ANFIS)، پرستلی-تیلور

داده‌های هواشناسی در منطقه حاجی آباد استان هرمزگان پرداختند و سپس نتایج را با داده های لایسیمتر مقایسه کردند. بررسی نتایج تحقیق نشان دادند که مدل ماشین بردار پشتیبان تکاملی با ورودی‌های میانگین دما و رطوبت نسبی بهترین مدل در برآورد تبخیر و تعرق در این تحقیق می باشد. محمد رضا پور و همکاران (2019) به بررسی امکان پیش‌بینی تبخیر و تعرق با استفاده از یک مدل ریاضی پرداختند. در این راستا، ابتدا بر اساس رابطه‌ی فائو پنمن-مانتیت، میزان تبخیر-تعرق پتانسیل ماهانه در چهار ایستگاه سینوپتیک زاهدان، زابل، ایرانشهر و چابهار با استفاده از داده‌های هواشناسی ماهانه محاسبه و به عنوان ورودی مدل های سیستم استنتاج عصبی- فازی، روش برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان استفاده شد. مقایسه بین ۳ مدل در این تحقیق نشان داد که در همه ایستگاه‌ها مدل ماشین بردار پشتیبان در مرتبه اول و سپس مدل برنامه ریزی بیان ژن در آخر مدل نروفازی برای تخمین مقادیر تبخیر-تعرق پتانسیل ماهانه قرار دارند. هدف از این تحقیق بررسی عملکرد مدل های مختلف هوش مصنوعی از قبیل مدل شبکه عصبی مصنوعی (ANN) بردار پشتیبان ارتقا یافته (ESVM) جنگل مدل یادگیری ترکیبی متا (Staking)، جهت پیش‌بینی پارامتر تبخیر و تعرق مرجع استان گلستان طی سال‌های ۱۳۷۰-۱۴۰۰ می‌باشد

مواد و روش ها

معرفی منطقه مورد مطالعه:

استان گلستان (شکل ۱) با مساحتی بالغ بر ۲۰۳۷۸ کیلومترمربع در جنوب شرقی دریای خزر قرار دارد و در حدود ۱/۳ درصد از مساحت کل کشور را شامل می‌شود. این استان بین ۳۶ درجه و ۲۵ دقیقه تا ۳۸ درجه و ۸ دقیقه عرض شمالی و ۵۳ درجه و ۵۰ دقیقه تا ۵۶ درجه و ۱۸ دقیقه طول شرقی واقع شده است. استان گلستان بر اساس موقعیت جغرافیایی و توپوگرافی دارای اقلیم‌های متفاوت بوده (شکل ۱) و تحت تاثیر عوامل مختلف آب و هوایی قرار گرفته است. به همین علت ریزش‌های جوی در مناطق مختلف استان متفاوت می‌باشد. در این استان اقلیم نیمه خشک در نوار مرزی و حوضه آبریز اترک تا معتدل و

و مدل هارگریوز - سامانی مقایسه گردید. نتایج نشان دادند GEP بهتر از مدل سیستم تطبیقی مبتنی بر استنتاج عصبی-فازی، پریستلی- تیلور و هارگریوز- سامانی است و مدل سیستم تطبیقی مبتنی بر استنتاج عصبی-فازی به عنوان دومین مدل انتخاب گردید. در دو قسمت از شمال کالیفرنیا از مدل های رگرسیون ماشین بردار پشتیبان، شبکه‌های عصبی و مدل های تجربی برای برآورد تبخیر و تعرق روزانه گیاه مرجع استفاده گردید (Gou 2011 ; Kisi and Zounemat-Kermani, 2014). نتایج نشان داد که مدل ماشین بردار پشتیبان در هر دو قسمت کالیفرنیا از دقت بالاتری نسبت به بقیه مدل ها برخوردار است. در تحقیق (Terzi (2013)، عملکرد دو مدل برنامه‌نویسی بیان ژن (GEP) و سیستم تطبیقی مبتنی بر استنتاج عصبی-فازی (ANFIS) برای برآورد تبخیر روزانه یک دریاچه در جنوب غربی ترکیه مقایسه شد. این مطالعه با استفاده از ترکیبات مختلف داده‌های ورودی انجام گرفت و نتایج نشان داد که مدل مدل برنامه‌نویسی بیان ژن عملکرد بهتری نسبت به مدل سیستم تطبیقی مبتنی بر استنتاج عصبی-فازی داشته و توانایی بیشتری در پیش‌بینی مقادیر تبخیر روزانه از خود نشان داده است. و مشاهده شد که نتایج مدل مدل برنامه‌نویسی بیان ژن نسبت به مدل سیستم تطبیقی مبتنی بر استنتاج عصبی-فازی بهتر است. در تحقیقی در جنوب شرق ترکیه برای پیش بینی تبخیر ماهانه از شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده شد. نتایج نشان داد که هر دو مدل شبکه‌های عصبی و ماشین بردار پشتیبان از دقت بالا و نزدیک به هم برخوردار هستند (Guvén and kisi, 2011). همچنین در تحقیقی در هند برای برآورد تبخیر از تشتک، از مدل های شبکه‌های عصبی مصنوعی، نروفازی، ماشین بردار پشتیبان، منطق فازی و مدل های تجربی هارگریوز - سامانی و استفان - استوارت استفاده گردید. نتایج تحقیق نشان داد که مدل های ماشین بردار پشتیبان و منطق فازی از دقت مناسبی برای برآورد تبخیر روزانه برخوردار هستند (Gulay and Buyukyildiz, 2015). محمدرضاپور و همکاران (۲۰۱۸) به برآورد مقدار تبخیر و تعرق با استفاده از مدل های ماشین بردار پشتیبان تکاملی (ESVM) و شبکه عصبی مصنوعی (ANN) با استفاده از

شهرها	پارامترها	تبخیر (میلیمتر)	ساعات	رطوبت	دمای میانگین (درجه سانتیگراد)
علی آباد	حداکثر (Max)	۳۵۱/۸	۳۱۴	۸۲/۶	۳۲/۹
	حداقل (Min)	۹/۳	۷/۸	۴۵/۹	۲/۶۵
	میانگین (Average)	۲۰۰/۰۹	۱۱۳/۷۸	۶۶/۷۸	۱۸/۷۶
	ضریب تغییرات (CV)	۶۷/۶۰۶	۷۵/۷۱۳	۸/۰۹۱	۸/۰۱۵
	حداکثر (Max)	۳۴۰/۱	۳۱۶/۲۰	۸۵/۳۴	۳۰/۰۷
بندر ترکمن	حداقل (Min)	۸۶/۶	۱۰/۵	۶۰/۵۲	۲/۹
	میانگین (Average)	۱۹۸/۲۸	۱۳۰/۰۹	۷۳/۷۶	۱۸/۳۲
	ضریب تغییرات (CV)	۶۱/۴۴	۸۶/۰۴	۵/۲۱	۷/۶
	حداکثر (Max)	۳۵۱/۸	۳۱۴	۸۲/۶	۳۲/۹
	حداقل (Min)	۹/۳	۷/۸	۴۵/۹	۲/۷
گنبد	میانگین (Average)	۲۰۰/۱	۱۱۳/۹	۶۶/۸	۱۸/۸
	ضریب تغییرات (CV)	۶۷/۶۱	۷۵/۶۲	۸/۰۹	۸/۰۲
	حداکثر (Max)	۳۴۷/۸	۲۹۳/۲	۸۵/۱	۳۱/۳
	حداقل (Min)	۵۷/۷	۰	۵۲	۲/۸
	میانگین (Average)	۱۸۸/۸	۱۱۱/۴	۷۰/۲	۱۸
گرگان	ضریب تغییرات (CV)	۵۵/۹	۷۰/۹۶	۶/۲۷	۷/۶۷
	حداکثر (Max)	۳۵۱/۸	۳۱۴	۸۲/۶	۳۲/۹
	حداقل (Min)	۹/۳	۷/۸	۴۵/۹	۲/۷
	میانگین (Average)	۲۰۰/۱	۱۱۳/۸	۶۶/۸	۱۸/۸
	ضریب تغییرات (CV)	۶۷/۶۱	۷۲/۷۲	۸/۰۹	۸/۰۲
کردکوی	حداکثر (Max)	۳۳۹/۹	۲۹۹/۴	۷۵/۸	۳۲/۶
	حداقل (Min)	۷۷/۷	۲۸/۷	۴۳	۶/۸
	میانگین (Average)	۱۹۹/۴	۱۲۴/۴	۵۹/۵	۱۹/۵
	ضریب تغییرات (CV)	۶۳/۶۹	۶۹/۹۲	۷/۶۳	۷/۶۵
	میانگین (Average)	۱۹۹/۴	۱۲۴/۴	۵۹/۵	۱۹/۵

مدل شبکه های عصبی مصنوعی (ANN) (مصنوعی عصبی های شبکه های عصبی)

Ramesh et al. (۲۰۲۱) کارایی مدل ANN را در مقایسه با روش های سنتی مانند پنمن-مانتیت مورد تأیید قرار داده و نشان داده اند که ANN قادر به کاهش خطاهای پیش بینی در داده های پیچیده اقلیمی است.

مدل ماشین بردار پشتیبان ارتقا یافته:

ماشین بردار پشتیبان (Support Vector Machine) یا SVM یکی از روش های پیشرفته یادگیری نظارت شده است که در سال های اخیر به دلیل عملکرد بهتر نسبت به روش های قدیمی تری مانند شبکه های عصبی پرسپترون چندلایه، مورد توجه قرار گرفته است. SVM برای دسته بندی و رگرسیون کاربرد دارد و بر اساس نظریه یادگیری آماری طراحی شده است. این روش به طور خاص

شبکه های عصبی مصنوعی به دلیل توانایی بالای آن ها در مدل سازی فرآیندهای غیر خطی پیچیده، کاربرد گسترده ای در پیش بینی تبخیر و تعرق مرجع یافته اند. این روش از طریق یادگیری از داده های مشاهده شده و ایجاد ارتباطات درونی بین نرون های مختلف قادر به پیش بینی دقیق پارامترهای هیدرولوژیکی است. مطالعات اخیر مانند تحقیق Zhang et al. (۲۰۲۰) نشان می دهد که شبکه های عصبی مصنوعی دقت بالایی در مدل سازی تبخیر و تعرق مرجع دارند و می توانند به عنوان یک ابزار کارآمد در مناطق خشک و نیمه خشک استفاده شوند. همچنین در پژوهشی دیگر،

$$y_i - w^T \phi(x_i) - b \leq \varepsilon + \varepsilon_i^*$$

$$\varepsilon_i, \varepsilon_i^* \geq 0$$

که در این روابط C ثابت گنجایش، W بردار ضرایب، w^* ترانهاده بردار ضرایب، i^* ثابت ضریب، b، کمبود ضرایب N الگوهای آموزش مدل و ϕ تابع هسته است. اطلاعات کمی در مورد انتخاب تابع غیرخطی مناسب ϕ در دسترس می باشد. ماشین های بردار پشتیبان برای حل مسائل غیرخطی، ابعاد مساله را از طریق توابع کرنل تغییر می دهند.

مدل یادگیری ترکیبی متا (Stacking)

مدل یادگیری ترکیبی متا (Stacking) یکی از روش های پیشرفته یادگیری ماشین است که برای بهبود دقت پیش بینی ها از ترکیب خروجی های چندین مدل پایه استفاده می کند. این مدل ابتدا پیش بینی های اولیه مدل های پایه مانند شبکه عصبی و جنگل تصادفی را استخراج و سپس آن ها را به مدل متا وارد می کند. مدل متا با یادگیری روابط میان خروجی های مدل های پایه و داده های واقعی، پیش بینی نهایی را ارائه می دهد. این روش به دلیل انعطاف پذیری بالا، کاهش خطاهای پیش بینی و قابلیت ترکیب نقاط قوت مدل های مختلف، در مسائل پیچیده ای نظیر تبخیر و تعرق مرجع عملکرد موفقی دارد. مطالعات متعددی از برتری یادگیری ترکیبی متا در مقایسه با مدل های تکی و افزایش دقت آن در پیش بینی ها حمایت کرده اند (Liu et al., 2021; Wang et al., 2020).

روش تحقیق

پس از اخذ آمار و اطلاعات مربوط به داده های هواشناسی شامل: دمای میانگین، دمای میانگین حداقل ها، دمای میانگین حداکثرها، میانگین رطوبت نسبی، میانگین حداقل رطوبت نسبی، میانگین حداکثر رطوبت نسبی، ساعات آفتابی، تبخیر، تعداد ساعات آفتابی و نقطه شبنم از سازمان هواشناسی استان گلستان و انتخاب ۶ ایستگاه و دوره مشترک ۳۱ ساله (۱۴۰۰-۱۳۷۰)، به پیش بینی پارامتر تبخیر و تعرق پتانسیل پرداخته شد. جهت انجام کار، از روش های هوش مصنوعی شامل مدل شبکه عصبی مصنوعی (ANN) بردار پشتیبان ارتقا یافته (ESVM) مدل یادگیری ترکیبی متا (Stacking)، و در هشت سناریو که در جدول (۲) آمده است، جهت پیش بینی

برای دسته بندی داده های دودسته ای مناسب است و مرزهای تصمیم گیری را با استفاده از یک ابرصفحه خطی در فضای ویژگی ها تعیین می کند. نمونه هایی که به این مرز نزدیک تر هستند، به عنوان بردارهای پشتیبان شناخته می شوند و نقشی کلیدی در تعیین معادله مرز تصمیم گیری دارند. به همین دلیل، این روش در مسائل پیش بینی بسیار مؤثر عمل می کند (Zhao et al., 2020).

الگوریتم های شبیه سازی هوشمند کلاسیک مانند شبکه های عصبی مصنوعی، معمولاً قدر مطلق خطا یا مجموع مربعات خطای داده های آموزشی را حداقل می کنند، ولی مدل های SVM، اصل حداقل سازی خطای ساختاری را به کار می گیرند (هامل، ۲۰۰۹). در یک مدل رگرسیونی SVM لازم است وابستگی تابعی متغیر وابسته y به مجموعه ای از متغیرهای مستقل x تخمین زده شود. فرض براین است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط یک تابع معین f به علاوه یک مقدار اضافی اختلال مشخص می شود.

$$Y = f(x) + \text{nois} \quad (1)$$

بنابراین موضوع اصلی، پیدا کردن فرم تابع f است که بتواند به صورت صحیح، موارد جدیدی را که SVM تاکنون تجربه نکرده است پیش بینی کند این تابع با آموزش مدل SVM بر روی یک مجموعه داده که به عنوان مجموعه آموزشی شناخته می شود، به دست می آید. در فرآیند آموزش، مدل تلاش می کند تا تابع خطا را بهینه سازی کرده و بهترین رابطه ممکن بین داده های ورودی و خروجی را برقرار کند. تابع خطا در مدل SVM به گونه ای طراحی شده است که خطاهای ساختاری و آموزشی را حداقل کند و دقت پیش بینی را افزایش دهد. این فرآیند شامل تنظیم مقادیر پارامترهایی مانند وزن ها و بایاس است تا مدل بتواند به شکلی بهینه داده های جدید را پیش بینی کند:

$$\frac{1}{2} w^T w + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* \quad (2)$$

تابع خطای فوق لازم است که با توجه به محدودیت های زیر کمینه گردد:

$$w^T \phi(x_i) + b - y_i \leq \varepsilon + \varepsilon_i^* \quad (3)$$

پارامتر تبخیر و تعرق پتانسیل استان گلستان استفاده شد. انجام شد و از ۳۰ درصد باقی مانده که در آموزش نقشی داده‌ها به دودسته داده‌های واسنجی (آموزش) و داده‌های آزمون (تست) تقسیم شد. آموزش به وسیله ۷۰ درصد داده‌ها

جدول (۲) ترکیبات مختلف مدل های مورد مطالعه

متغیرهای ورودی	سناریو ها
دمای میانگین	۱
دمای میانگین، دمای میانگین حداقل ها	۲
دمای میانگین، دمای میانگین حداقل ها، دمای میانگین حداکثرها	۳
دمای میانگین، دمای میانگین حداقل ها، دمای میانگین حداکثرها، تبخیر	۴
دمای میانگین، دمای میانگین حداقل ها، دمای میانگین حداکثرها، تبخیر، نقطه شبنم	۵
دمای میانگین، دمای میانگین حداقل ها، دمای میانگین حداکثرها، تبخیر، نقطه شبنم، میانگین رطوبت نسبی	۶
دمای میانگین، دمای میانگین حداقل ها، دمای میانگین حداکثرها، تبخیر، نقطه شبنم، میانگین رطوبت نسبی، میانگین رطوبت نسبی حداقل ها	۷
دمای میانگین، دمای میانگین حداقل ها، دمای میانگین حداکثرها، میانگین رطوبت نسبی، میانگین حداقل رطوبت نسبی، میانگین حداکثر رطوبت نسبی، تعداد ساعات آفتابی، نقطه شبنم، تبخیر	۸

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [z(x_i) - \bar{Z}(x_i)]^2} \quad \text{ریشه دوم میانگین مربع خطا (۵)}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\bar{Z}(x) - Z(x)| \quad \text{میانگین قدر مطلق خطا (۶)}$$

برای ریشه دوم میانگین مربع خطا و میانگین قدر مطلق خطا؛ n تعداد نقاط مشاهده‌ای، مقدار $\bar{Z}(x_i)$ برآوردی برای نقطه i ام و $Z(x_i)$ مقدار مشاهده‌ای برای نقطه i ام است (آزاد پور، ۱۳۹۳). و برای ضریب تعیین E_i : مقدار پیش‌بینی شده متغیر، M_i : مقدار اندازه‌گیری شده متغیر و N تعداد داده‌ها می‌باشد.

مصنوعی (ANN) در شهرهای علی‌آباد، بندر ترکمن، گرگان، کردکوی، مینودشت و گنبد ارئه می‌دهند. این جداول مقادیر شاخص‌های ارزیابی مانند ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، و ضریب تعیین (R^2) را برای مدل های مختلف نشان می‌دهند و عملکرد آن‌ها در هر شهر را مقایسه

معیارهای ارزیابی

برای ارزیابی و بررسی کارایی روش‌های استفاده شده جهت پیش‌بینی پارامترهای کیفی آب‌های زیرزمینی استان گلستان، از معیارهای ارزیابی مختلفی شامل ریشه دوم میانگین مربع خطا، ضریب تعیین و میانگین قدر مطلق خطا استفاده شد.

$$R^2 = 1 - \left(\frac{\sum_{i=1}^n (M_i - E_i)^2}{\sum_{i=1}^n (M_i - \bar{E})^2} \right) \quad \text{ضریب تعیین (۴)}$$

نتایج و بحث

نتایج پیش‌بینی مقادیر تبخیر و تعرق مرجع با استفاده از مدل شبکه عصبی مصنوعی (ANN) جداول (۳) و (۴) نتایج ارزیابی عملکرد مدل های مختلف در مرحله آموزش و آزمون را برای پیش‌بینی تبخیر و تعرق مرجع با استفاده از مدل شبکه عصبی

می‌کنند. برای پیش‌بینی هرکدام از این پارامترها، تعداد ۸ ترکیب ورودی مختلف به مدل ANN وارد شد.




جدول (۳) نتایج پیش‌بینی برای مراحل آموزش با استفاده از مدل ANN

		Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
گرگان	RMSE	۲۸/۷۵	۲۲/۰۷۲	۲۱/۳۲۷	۲۰/۳۳۶	۱۷/۹۲۶	۱۶/۴۵۱	۱۷/۴۹۹	۱۴/۹۵۷
	MAE	۲۰/۹	۱۰/۴۱	۸/۰۶	۶/۱	۳/۱	۰/۶۵	۸/۲۳	۳/۴۸
گنبد	R ²	۰/۹۶	۰/۹۶	۰/۹۶	۰/۹۶	۰/۹۷	۰/۹۷	۰/۹۷	۰/۹۸
	RMSE	۲۲/۶۹۹	۲۱/۴۹۱	۲۶/۸۴۷	۲۲/۴۰۱	۲۰/۸۱۱	۱۹/۲۰۱	۱۷/۶۱۱	۱۸/۸۰۳
	MAE	۵/۹۵	۱/۶۹	۱۶/۲۱	۷/۷۵	۶/۱۵	۸/۱۹	۴/۱۷	۶/۹
	R ²	۰/۹۵۱	۰/۹۵۲	۰/۹۵۲	۰/۹۵۴	۰/۹۶	۰/۹۶۸	۰/۹۶۹	۰/۹۶۹
کردکوی	RMSE	۲۳/۱۱۳	۲۱/۷۶۷	۲۷/۳۸۶	۲۲/۸۱۷	۲۱/۳۴۴	۱۹/۵۸۵	۱۷/۷۱۳	۱۹/۶۱۶
	MAE	۱/۷۲	۲/۷۴	۱۶/۵۹	۸/۲۵	۷/۰۲	۷/۸۴	۲/۸۸	۷/۴۳
بندر ترکمن	R ²	۰/۹۵	۰/۹۵	۰/۹۵	۰/۹۵	۰/۹۶	۰/۹۷	۰/۹۷	۰/۹۷
	RMSE	۲۸/۳۴۸	۲۰/۵۵۸	۱۹/۸۹۱	۵۵/۵۵۱	۱۸/۲۰۷	۱۶/۵۶۹	۱۵/۵۷۲	۱۵/۰۳۹
	MAE	۱۸/۸۳	۱/۸۷	۴/۶۵	۱۶/۳۶	۴/۶۹	۷/۱۸	۵/۰۲	۱/۲۹
	R ²	۰/۹۵۸	۰/۹۵۹	۰/۹۶	۰/۹۶۴	۰/۹۶۹	۰/۹۷۸	۰/۹۷۹	۰/۹۸
علی آباد	RMSE	۲۲/۶۱۲	۲۱/۴۶۴	۲۶/۷۲۲	۲۲/۳۷۵	۲۰/۷۶۲	۱۸/۷۳۷	۱۸/۸۱۵	۱۸/۹۲۳
	MAE	۵/۴۲	۲/۰۶	۱۶/۰۷	۷/۷۴	۶/۰۳	۵/۲۸	۷/۱۵	۷/۳۱
مینودشت	R ²	۰/۹۵	۰/۹۵۲	۰/۹۵۲	۰/۹۵۴	۰/۹۵۹	۰/۹۶۸	۰/۹۶۸	۰/۹۶۹
	RMSE	۳۰/۶۲۶	۲۹/۸۷۳	۲۸/۴۱۵	۲۸/۰۲	۲۷/۴۹۳	۲۵/۶۴۵	۲۶/۶۶۱	۱۸/۱۲۶
	MAE	۱۰/۸۸	۱۰/۵	۵/۷۴	۰/۰۴	۱/۶۶	۷/۶	۹/۹۵	۳/۳۸
	R ²	۰/۹۰۲	۰/۹۰۷	۰/۹۰۸	۰/۹۰۶	۰/۹۱	۰/۹۲۹	۰/۹۲۷	۰/۹۶۳




جدول (۴) نتایج پیش‌بینی برای مراحل آزمون با استفاده از مدل ANN

		Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
گرگان	RMSE	۳۰/۶۷۱	۲۶/۰۳۳	۲۵/۹۱۳	۲۴/۱۹۷	۲۲/۴۹۸	۲۰/۰۰۶	۱۸/۷۱۹	۱۸/۵
	MAE	۱۸/۴۷	۱۰/۱۶	۹/۳۹	۴/۷	۳/۴۹	۲/۶۹	۲/۹۲	۲/۰۱
گنبد	R ²	۰/۹۵	۰/۹۵	۰/۹۵	۰/۹۵	۰/۹۶	۰/۹۶	۰/۹۷	۰/۹۷
	RMSE	۳۱/۵۱۶	۲۹/۶۹۴	۳۴/۴۳۸	۳۰/۷۸۶	۲۸/۶۴۸	۲۶/۰۷۲	۲۵/۶۹۹	۲۵/۶۱۴
	MAE	۴/۶۷	۲/۷۴	۱۶/۵	۸/۳۵	۳/۹۹	۷/۰۵	۳/۵۵	۷/۲۴
	R ²	۰/۸۹۷	۰/۹۰۵	۰/۹۰۲	۰/۹۰۵	۰/۹۱۳	۰/۹۳۳	۰/۹۳	۰/۹۳۵
کردکوی	RMSE	۳۲/۹۴۴	۲۹/۶۴۱	۳۴/۶۴۹	۳۰/۸۶۶	۲۸/۶۹۵	۲۶/۱۵۸	۲۵/۱۵۹	۲۶/۱۷۲
	MAE	۲/۶۱	۴/۰۲	۱۶/۹۲	۸/۹	۴/۶۷	۶/۷	۹/۲۹	۷/۹۵
بندر ترکمن	R ²	۰/۸۸	۰/۹۱	۰/۹	/۰۹	۰/۹۱	۰/۹۳	۰/۹۳	۰/۹۳
	RMSE	۱۸/۵۱۷	۲۱/۳۲۵	۲۰/۹۹	۲۴/۸۰۹	۱۷/۹۷۷	۱۶/۴۳۶	۱۴/۴۶۹	۱۴/۳۷۹
	MAE	۱۹/۰۳	۰/۳۳	۴/۶۸	۱۳/۷۷	۳/۸۵	۶/۱	۳/۲۹	۱/۰۹
	R ²	۰/۹۵۳	۰/۹۵۳	۰/۹۶	۰/۹۵۶	۰/۹۶۸	۰/۹۶۷	۰/۹۷۹	۰/۹۷۹
علی آباد	RMSE	۳۱/۳۱۹	۲۹/۴۲۷	۳۴/۱۰۱	۳۰/۵۳۶	۲۸/۳۵۸	۲۶/۵۷۸	۲۵/۷۳۹	۲۵/۷۰۶
	MAE	۴/۱۶	۳/۱۲	۱۶/۴۸	۸/۳۶	۳/۸۹	۱/۴۷	۷/۷۹	۷/۶۹
مینودشت	R ²	۰/۹	۰/۹۰۷	۰/۹۰۳	۰/۹۰۶	۰/۹۱۴	۰/۹۲۹	۰/۹۳۵	۰/۹۳۵
	RMSE	۳۳۱/۳۲۲	۳۰/۰۲۲	۲۸/۹۸	۲۸/۸۷۹	۲۹/۱۴۱	۲۷/۳۸۱	۲۸/۱۰۲	۱۳/۹۶۸
	MAE	۸/۷۷	۹/۶۸	۳/۱۴	۲	۰/۷۵	۶/۲۳	۸/۷۳	۲/۴۵
	R ²	۰/۸۹۶	۰/۹۰۶	۰/۹۰۴	۰/۹۰۴	۰/۹۰۲	۰/۹۸۱	۰/۹۱۸	۰/۹۷۸

ضریب تعیین می باشد. همچنین بررسی نتایج نشان دادند که در شهرهای گرگان، گنبد، بندر ترکمن و علی آباد بعد از مدل ۸ به ترتیب مدل ۷ و سپس مدل ۶ دارای بهترین عملکرد بوده اند. اما در شهر کردکوی بعد از مدل ۷ مدل ۶ و سپس مدل ۸ دارای بالاترین عملکرد می باشند و همچنین در شهر مینودشت بعد از مدل ۸، مدل ۶ و سپس مدل ۷ دارای عملکرد مناسب می باشند. در شکل (۲) مقادیر مشاهداتی و مقادیر شبیه سازی شده با استفاده از مدل شبکه عصبی مصنوعی با بهترین ورودی های انتخاب شده برای شهرهای مورد مطالعه نشان داده شده است



همانطور که از جدول (۳) مشخص است نتایج آزمون مدل شبکه عصبی مصنوعی برای سناریوی ۸ دارای کمترین مقادیر ریشه دوم مربعات خطا و میانگین قدرمطلق خطا و همچنین بیشترین مقادیر ضریب تعیین در شهرهای گرگان (۰/۹۷، ۲/۰۱، ۱۸/۵)، گنبد (۰/۹۷، ۲۵/۶۱۴، ۷/۲۴)، بندر ترکمن (۰/۹۳۵، ۱/۰۹، ۱۴/۳۷۹)، علی آباد (۰/۹۳۵، ۷/۶۹، ۲۵/۷۰۶) و مینودشت (۰/۹۳۵، ۱۳/۹۶۸، ۲/۴۵، ۲۵/۳۹، ۲/۲۹ و ۰/۹۳ به ترتیب کمترین مقادیر ریشه دوم مربعات خطا و میانگین قدرمطلق خطا و بالاترین مقادیر



شکل (۲) نمودار مقادیر مشاهداتی و مقادیر شبیه سازی شده تبخیر و تعرق طرح شهرهای مورد مطالعه با استفاده از مدل شبکه عصبی با سناریوهای برتر

نتایج پیش‌بینی مقادیر تبخیر و تعرق مرجع با استفاده از مدل بردار پشتیبان ارتقا یافته (SVM- (Evolutionary

مینودشت و گنبد نشان داده شده است

در جداول (۵) و (۶)، نتایج معیارهای ارزیابی برای
مرحله آزمون ترکیبات مختلف برای پیش‌بینی تبخیر و
تعرق مرجع با استفاده از مدل بردار پشتیبان ارتقا یافته در
شهرهای علی آباد، بندر ترکمن، گرگان، کردکوی،

. جدول (۵) نتایج پیش‌بینی برای مراحل آموزش و آزمون با استفاده از مدل بردار پشتیبان ارتقا یافته (ESVM)


		Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
گرگان	RMSE	۱۱۰/۷۹۷	۸۲/۵۲	۷۵/۱۰۶	۶۶/۹۲۷	۷۸/۶۷	۸۷/۲۳۶	۶۶/۳۵۶	۷۰/۴۱۲
	MAE	۳۹/۵	۱۱/۰۹	۳۳/۶۶	۴۶/۶۶	۵۶/۳۸	۶۳/۷۳	۴۵/۵۶	۵۱/۰۱
	R ²	۰/۷۸۱	۰/۷۰۵	۰/۷۳۶	۰/۷۸۸	۰/۷۴۸	۰/۶۷۸	۰/۸۰۳	۰/۷۹
گنبد	RMSE	۱۰۵/۷۲	۷۹/۹۹۴	۶۹/۰۴	۷۰/۵۶۸	۸۵/۶۸۱	۷۴/۷۸۹	۷۵/۲۹۹	۸۱/۷۲۳
	MAE	۳۲/۲	۱۸/۹۷	۳۲/۲۲	۴۸/۸	۶۱/۵۵	۵۲/۳۸	۵۲/۹۷	۵۶/۷۷
	R ²	۰/۷۹۶	۰/۷۱	۰/۸	۰/۷۸۴	0.700	۰/۷۵۹	۰/۷۷۹	۰/۷۲۳
کردکوی	RMSE	۹۷/۹۰۹	۷۹/۹۹۴	۶۹/۵۱۳	۷۳/۸۴۷	۶۹/۹۰۱	۷۱/۴۳۳	۸۷/۴۰۳	۸۱/۷۰۷
	MAE	۲۰/۶۷	۱۸/۹۷	۳۳/۱۸	۵۲/۸۸	۴۷/۸۳	۵۰/۹۵	۶۱/۴۶	۵۶/۱۲
	R ²	۰/۸۰۴	۰/۷۱	۰/۸۰۱	۰/۷۷۲	۰/۷۸۹	۰/۷۸۳	۰/۶۷۳	۰/۷۲
بندر ترکمن	RMSE	۱۰۸/۲۷	۶۲/۹۲	۶۷/۲۲	۵۴/۰۹	۶۸/۶۸	۵۷/۸۸	۸۸/۵۷	۸۵/۴۷
	MAE	۳۳/۵۷	۳۴/۶۲	۳۶/۷۵	۲۷	۴۴/۹۶	۳۸/۶۲	۳۸/۶۲	۵۹/۹۳
	R ²	۰/۷۵	۰/۸۲	۰/۸	۰/۸۵	۰/۷۸	۰/۸۳	۰/۸۳	۰/۷۵
علی آباد	RMSE	۱۰۲/۰۵۳	۸۲/۸۸۵	۷۳/۹۲۶	۸۶/۱۱۵	۹۲/۲۹۹	۹۲/۰۲۴	۸۰/۹۰۹	۷۶/۲۱۵
	MAE	۲۹/۴	۵/۱	۳۳/۶۷	۵۹/۴۶	۶۳/۰۱	۶۲/۸۹	۵۴/۰۷	۵۷/۵۶
	R ²	۰/۷۲	۰/۷۴۸	۰/۷۱۹	۰/۶۸۲	۰/۶۶	۰/۶۶۲	۰/۶۸۴	۰/۷۹۶
مینودشت	RMSE	۹۸/۰۴۱	۵۷/۹۳	۶۱/۰۳۹	۱۰/۶۷۴	۵۴/۰۶۷	۷۳/۲۰۳	۷۷/۸۹۴	۵۴/۸۴۲
	MAE	۴۱/۶۶	۴/۳۲	۳۰/۹۴	۰/۸۷	۳۳/۳۶	۴۳/۶۵	۵۷/۴۸	۳۷/۱۲
	R ²	۰/۷۹۳	۰/۸۱۶	۰/۷۴۸	۰/۹۸۸	۰/۸۸۹	۰/۷۲۹	۰/۷۴	۰/۸۷۸

جدول (۶) نتایج پیش‌بینی برای مراحل آموزش و آزمون با استفاده از مدل بردار پشتیبان ارتقا یافته (ESVM)

		Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
گرگان	RMSE	۱۱۴/۴۱۹	۸۸/۹۸۸	۶۷/۶۶۷	۶۵/۴۷۲	۷۸/۶۹۲	۷۳/۲۲	۷۰/۵۸۴	۷۳/۰۵۲
	MAE	۴۹/۰۷	۱/۲۶	۲۶/۲۶	۴۶/۷۷	۵۲/۸	۵۲/۴۶	۴۷/۹۱	۴۹/۵۱
	R ²	۰/۷۹	۰/۷۲۶	۰/۷۶۸	۰/۸۳۷	۰/۷۵	۰/۷۷۶	۰/۸۰۲	۰/۷۸
گنبد	RMSE	۱۰۴/۴۴۵	۷۶/۶۳۷	۳۵/۷۲۹	۶۹/۳۴۳	۸۸/۲۶۲	۷۸/۴۳۵	۷۸/۰۵۷	۹۸/۷۸۹
	MAE	۳۲/۶۳	۲۰/۰۲	۱/۵۱	۴۵/۶۳	۶۲/۱۶	۵۳/۸۶	۵۵/۷۲	۶۸/۶۸
	R ²	۰/۶۹	۰/۷۵۳	۰/۸۶۸	۰/۸۱۲	۰/۶۷۲	۰/۷۰۵	۰/۷۸۴	۰/۵۸۹
کردکوی	RMSE	۹۷/۱۸۹	۷۶/۶۳۷	۷۵/۲۹۹	۷۵/۱۰۹	۷۰/۴۴۱	۷۴/۰۲۲	۷۴/۱۲۰	۹۷/۳۰۹
	MAE	۸/۰۳	۲۰/۰۲	۳۹/۲۳	۵۰/۷۱	۵۱/۱۲	۵۱/۹۷	۵۳/۴۵	۶۷/۴۵
	R ²	۰/۶۵	۰/۷۳۵	۰/۷۵	۰/۷۵۵	۰/۸۰۱	۰/۷۹۱	۰/۷۷۷	۰/۶
بندر ترکمن	RMSE	۹۹/۰۶	۷۴/۶۶	۸۹/۳۴	۶۸/۲۲	۸۴/۳۱	۵۴/۳۶	۵۴/۳۶	۸۱/۳۹
	MAE	۲۳/۳۴	۴۳/۳۱	۵۵/۰۵	۴۵/۶۷	۵۸/۱۳	۳۴/۴۴	۳۴/۴۴	۵۵/۷
	R ²	۰/۶۵	۰/۶۹	۰/۶۷	۰/۸۷	۰/۶۷	۰/۸۴	۰/۸۴	۰/۶۹
علی آباد	RMSE	۱۰۲/۰۵۳	۸۲/۸۵۸	۷۳/۹۲۶	۸۶/۱۱۵	۹۲/۲۹۹	۹۲/۰۲۴	۸۰/۹۰۹	۷۶/۲۱۵
	MAE	۲۹/۴	۵/۱	۳۳/۶۷	۵۹/۴۶	۶۳/۰۱	۶۲/۸۹	۵۴/۰۷	۵۷/۵۶
	R ²	۰/۷۲	۰/۷۴۸	۰/۷۱۹	۰/۶۸۲	۰/۶۶	۰/۶۶۲	۰/۶۸۴	۰/۷۹۶
مینودشت	RMSE	۹۸/۰۴۱	۵۷/۹۳	۶۱/۰۳۹	۱۰/۶۷۴	۵۴/۰۶۷	۷۳/۲۰۳	۷۷/۸۹۴	۵۴/۸۴۲
	MAE	۴۱/۶۶	۴/۳۲	۳۰/۹۴	۰/۸۷	۳۳/۳۶	۴۳/۶۵	۵۷/۴۸	۳۷/۱۲
	R ²	۰/۷۹۳	۰/۸۱۶	۰/۷۴۸	۰/۹۸۸	۰/۸۸۹	۰/۷۲۹	۰/۷۴	۰/۸۷۸

(۶) نشان داد که در شهر علی آباد سناریو ۸ دارای بیشترین ضریب تعیین (۰/۷۹) و کمترین میانگین قدر مطلق خطا (۵۷/۵۶) و کمترین ریشه دوم مربعات خطا (۷۶/۲۱۵) می باشد. بررسی نتایج نشان دادند که در شهر گرگان بعد از مدل ۴ مدل ۳ و سپس مدل ۷ از کارایی بالایی برخوردار بودند. در شهر گنبد بعد از مدل ۳، مدل ۴ و سپس مدل ۲، در شهر کردکوی بعد از مدل ۵ مدل ۶ و سپس مدل ۷، در بندر ترکمن بعد از مدل ۴ مدل ۶ و سپس مدل ۷، در شهر علی آباد بعد از مدل ۸ مدل ۷ و سپس مدل ۳ و در شهر مینودشت نیز بعد از مدل ۴، مدل ۵ و سپس مدل ۸ از بالاترین کارایی برخوردار بودند. در شکل (۳) مقادیر مشاهده شده و مقادیر شبیه سازی شده با استفاده از مدل بردار پشتیبان ارتقا یافته با بهترین ورودی‌های انتخاب شده برای شهرهای مورد مطالعه نشان داده شده است.

همانطور که از جدول (۶) مشخص است نتایج آزمون مدل بردار پشتیبان ارتقا یافته با ورودی‌های سناریو ۴ (دمای میانگین، دمای میانگین حداقل، دمای میانگین حداکثر، تبخیر) دارای کمترین مقادیر ریشه دوم مربعات خطا و میانگین قدر مطلق خطا و همچنین بیشترین مقادیر ضریب تعیین در شهرهای گرگان (۴۶/۷۷، ۶۵/۴۷۲)، بندر ترکمن (۰/۹۳۷، ۴۵/۶۷، ۶۸/۲۲) و مینودشت (۰/۹۸۸، ۰/۸۷، ۱۰/۶۷۴) می باشد. اما در شهر گنبد سناریو ۳ با مقادیر ۳۵/۷۲۹، ۱/۵۱ و ۰/۸۶۸ به ترتیب کمترین مقادیر ریشه دوم مربعات خطا و میانگین قدر مطلق خطا و بالاترین مقادیر ضریب تعیین می باشد. در شهر کردکوی نیز سناریو ۵ با ورودی‌های (دمای میانگین، دمای میانگین حداقل، دمای میانگین حداکثر، تبخیر، نقطه شبنم) به ترتیب دارای مقادیر بالاترین مقادیر ضریب تعیین، میانگین قدر مطلق خطا و کمترین مقادیر ریشه دوم مربعات خطا می باشد. همچنین بررسی جدول



شکل (۳) نمودار مقادیر مشاهداتی و مقادیر شبیه سازی شده تبخیر و تعرق مرجع شهرهای مورد مطالعه با استفاده از مدل بردار پشتیبان ارتقا یافته با سناریوهای برتر

نتایج پیش بینی مقادیر تبخیر و تعرق مرجع با استفاده از مدل یادگیری ترکیبی متا (Stacking)

تخرق مرجع با استفاده از مدل یادگیری ترکیبی متا در شهرهای گرگان، گنبد، کردکوی، بندر ترکمن، علی آباد،

در جداول (۷) و (۸) نتایج معیارهای ارزیابی برای مرحله آزمون ترکیبات مختلف برای پیش بینی تبخیر و

مینودشت نشان داده شده است.

جدول (۷) نتایج پیش‌بینی برای مراحل آموزش با استفاده از مدل یادگیری ترکیبی متا (Stacking)

		Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
گرگان	RMSE	۸/۵۱۸	۷/۶۶۶	۷/۵۶۱	۸/۴۰۱	۷/۳۹۳	۶/۸۰۸	۷/۱۵۹	۷/۶۱۵
	MAE	۰/۲۴	۰/۲۹	۰/۰۵	۰/۰۵	۰/۴۶	۰/۶۲	۰/۲۱	۰/۲۲
گنبد	R ²	۰/۹۹۲	۰/۹۹۳	۰/۹۹	۰/۹۹۲	۰/۹۹۴	۰/۹۹۵	۰/۹۹۴	۰/۹۹
	RMSE	۹/۴۵۱	۷/۹۸۱	۷/۸۱۱	۸/۳۵۹	۸/۴۲۸	۶/۵۵۳	۶/۸۹۹	۹/۰۳۷
کردکوی	MAE	۰/۵	۰/۰۷	۰/۱۳	۰/۱۳	۰/۲۴	۰/۲۳	۰/۴۷	۰/۴۱
	R ²	۰/۹۹۱	۰/۹۹۳	۰/۹۹۴	۰/۹۹۳	۰/۹۹۳	۰/۹۹۵	۰/۹۹۵	۰/۹۹۲
بندر ترکمن	RMSE	۹/۶۶۷	۸/۴۶۴	۸/۲۹۸	۶/۶۵۵	۸/۰۹۸	۶/۹۹۲	۶/۸۷۳	۹/۱۶۱
	MAE	۰/۵۹	۰/۱۶	۰/۲۴	۰/۶۱	۰/۱۵	۰/۳	۰/۷۱	۰/۳۱
علی آباد	R ²	۰/۹۹	۰/۹۹۲	۰/۹۹۳	۰/۹۹۲	۰/۹۹۳	۰/۹۹۵	۰/۹۹۵	۰/۹۹
	RMSE	۷/۳۵۶	۱۸/۲۲۲	۷/۰۲۳	۶/۲۹	۸/۴۲۸	۷/۰۸۲	۱۴/۲۲۹	۷/۵۶۱
مینودشت	MAE	۰/۲۵	۱/۲۹	۰/۲۱	۰/۲۴	۰/۲۴	۰/۵۶	۱/۴۹	۱/۰۱
	R ²	۰/۹۹۵	۰/۹۶۸	۱	۰/۹۹۶	۰/۹۹۳	۰/۹۹۵	۰/۹۸	۰/۹۹
مینودشت	RMSE	۹/۶۹۴	۸/۲۴	۸/۰۹۴	۸/۲۶۶	۸/۰	۷/۰۲۸	۶/۹۰۶	۸/۹۰۹
	MAE	۰/۴۳	۰/۰۶	۰/۳۷	۰/۰۱	۰/۲۱	۰/۷۹	۰/۰۷	۰/۶۹
مینودشت	R ²	۰/۹۹	۰/۹۹۳	۰/۹۹۳	۰/۹۹۳	۰/۹۹۳	۰/۹۹۵	۰/۹۹۵	۰/۹۹۲
	RMSE	۱۳/۰۳۱	۱۱/۷۲۹	۱۰/۶۲۴	۱۳/۴۰۳	۱۰/۸۰۸	۱۱/۶	۱۱/۷۹۵	۱۰/۴۷۳
مینودشت	MAE	۱/۰۸	۰/۷۱	۰/۷۸	۰/۷۹	۰/۱	۰/۴۹	۰/۲۲	۱/۰۴
	R ²	۰/۹۸	۰/۹۸۴	۰/۹۸۷	۰/۹۷۹	۰/۹۸۶	۰/۹۸۴	۰/۹۸۳	۰/۹۸۷

جدول (۸) نتایج پیش‌بینی برای مراحل آزمون با استفاده از مدل یادگیری ترکیبی متا (Stacking)



		Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
گرگان	RMSE	۹/۵۰۸	۸/۰۵۸	۸/۰۳۵	۸/۶۹۵	۶/۹۹۲	۷/۰۹۴	۶/۸۴۹	۸/۳۱۵
	MAE	۰/۰۸۸	۰/۵	۰/۶۱	۰/۲۲۳	۰/۳۶	۰/۵۹	۰/۲۵	۰/۷۴
گنبد	R ²	۰/۹۹۲	۰/۹۹۴	۰/۹۹	۰/۹۹۳	۰/۸۸۶	۰/۹۹۶	۰/۹۹۶	۰/۹۹
	RMSE	۱۰/۷۹۵	۹/۳۳۲	۹/۳۷۹	۱۰/۳۲۱	۱۰/۲۰۶	۹/۹۱۹	۱۰/۴۸۲	۱۱/۸۲
کردکوی	MAE	۰/۱۴	۰/۱۴	۰/۷۲	۰/۱۱	۰/۵۶	۰/۰۸	۰/۰۱	۰/۱۲
	R ²	۰/۹۸۷	۰/۹۹۱	۰/۹۹۱	۰/۹۸۹	۰/۹۸۹	۰/۹۹	۰/۹۸۹	۰/۹۸۵
بندر ترکمن	RMSE	۱۱/۳۴۷	۹/۱۵۴	۹/۶۷۱	۱۱/۲۳۶	۱۰/۲۹۹	۱۰/۳۶۷	۱۰/۳۲۲	۱۱/۵۲۲
	MAE	۰/۳۱	۰/۴۴	۰/۲۵	۰/۱۱	۰/۱	۰/۵	۰	۱/۳۵
علی آباد	R ²	۰/۹۸۶	۰/۹۹۱	۰/۹۹	۰/۹۸۶	۰/۹۸۹	۰/۹۸۹	۰/۹۸۹	۰/۹۹
	RMSE	۹/۰۶۱	۱۹/۷۷۹	۶/۶۵۳	۶/۶۰۷	۱۰/۲۰۶	۶/۵۶۱	۱۵/۰۰۲	۸/۱۲۵
مینودشت	MAE	۱/۳۶	۴/۷۸	۰/۱۶	۰/۱۶۱	۰/۵۶	۰/۸	۳/۱۸	۰/۰۶
	R ²	۰/۹۹۲	۰/۹۶۲	۰/۹۹	۰/۹۹۵	۰/۹۸۹	۰/۹۹۶	۰/۹۷۸	۰/۹۹۳
مینودشت	RMSE	۱۰/۳۸۲	۹/۱۲۳	۹/۶۸۴۵	۱۰/۱۴	۱۰/۵۱۷	۱۰/۳۸۸	۹/۵۵۵	۱۰/۳۹۳
	MAE	۰/۴۳	۰/۳۳	۰/۵۵	۰/۴۸	۰/۶۶	۰/۲۳	۰/۵۳	۰/۶۹
مینودشت	R ²	۰/۹۹	۰/۹۹۱	۰/۹۹	۰/۹۸۹	۰/۹۸۸	۰/۹۸۹	۰/۹۹	۰/۹۸۹
	RMSE	۱۱/۱۱۳	۹/۴۹۱	۸/۸۳	۹/۴۶۹	۸/۷۳	۹/۵۵۱	۹/۴۹۸	۹/۹۷۶
مینودشت	MAE	۱/۷۹	۰/۷۳۴	۱/۲۲	۱/۲	۰/۹۷	۰/۷۱	۰/۷۷	۰/۷۷
	R ²	۰/۹۶۸	۰/۹۹	۰/۹۹۱	۰/۹۹	۰/۹۹۲	۰/۹۹	۰/۹۹	۰/۹۸۹


میانگین، دمای میانگین حداقل، دمای میانگین حداکثر،
تبخیر، نقطه شبنم، میانگین رطوبت نسبی) دارای

همانطور که از جدول (۸) مشخص است نتایج آزمون
مدلیادگیری ترکیب متا با ورودی های سناریو ۶ (دمای

مطلق خطا (۰/۲۵) و کمترین ریشه دوم مربعات خطا (۹/۶۷۱) از عملکرد بالاتری نسبت به بقیه مدل ها برخوردار است. بررسی نتایج نشان دادند که در شهرهای گنبد بعد از سناریوی ۶، سناریوی ۲ و سپس سناریوی ۳ دارای کمترین میانگین قدر مطلق خطا و کمترین ریشه دوم مربعات خطا و بالاترین ضریب تعیین هستند. در شهر گرگان مدل ۷ و سپس مدل ۵ و مدل ۶ به ترتیب دارای بالاترین کارایی می باشند. اما در شهر علی آباد بعد از مدل ۲ مدل ۷ و سپس مدل ۳ دارای حداکثر عملکرد می باشند و همچنین در شهر مینودشت بعد از مدل ۵، مدل ۳ و سپس مدل ۴ دارای عملکرد مناسب می باشند. در شهر بندر ترکمن نیز بعد از مدل ۶ مدل ۴ و مدل ۳ از کارایی بالایی برخوردارند. در شهر کردکوی نیز بعد از مدل ۳، مدل ۲ و سپس مدل ۵ از کارایی زیادی برخوردارند. در شکل (۴) مقادیر مشاهداتی و مقادیر شبیه سازی شده با استفاده از مدل یادگیری ترکیبی متا با بهترین ورودی های انتخاب شده برای شهرهای مورد مطالعه نشان داده شده است

کمترین مقادیر ریشه دوم مربعات خطا و میانگین قدر مطلق خطا و همچنین بالاترین مقادیر ضریب تعیین در شهرهای بندر ترکمن (۰/۸۶، ۰/۸، ۰/۹۹۶)، گنبد (۰/۹۱۹، ۰/۰۸، ۰/۹۹، ۰/۹۹، ۰/۲۵ و ۰/۹۹۶) به ترتیب کمترین مقادیر ریشه دوم مربعات خطا و میانگین قدر مطلق خطا و بالاترین مقادیر ضریب تعیین می باشد. در شهر علی آباد نیز سناریو ۲ با ورودی های (دمای میانگین، دمای میانگین حداقل) به ترتیب (۰/۹۹۱، ۰/۳۳، ۰/۱۲۳) دارای حداکثر مقادیر ضریب تعیین، میانگین قدر مطلق خطا و کمترین مقادیر ریشه دوم مربعات خطا می باشد. همچنین بررسی جدول (۸) نشان داد که در شهر مینودشت سناریو ۵ با ورودی (دمای میانگین، دمای میانگین حداقل، دمای میانگین حداکثر، تبخیر، نقطه شبنم) دارای بالاترین ضریب تعیین (۰/۹۹۲) و کمترین میانگین قدر مطلق خطا (۰/۷۳) و کمترین ریشه دوم مربعات خطا (۸/۷۳) می باشد. در شهر کردکوی نیز سناریوی ۳ با داشتن بالاترین ضریب تعیین (۰/۹۹) و کمترین میانگین قدر





شکل (۴) نمودار مقادیر مشاهده شده و مقادیر شبیه سازی شده تبخیر و تفرق مرجع شهرهای مورد مطالعه با استفاده از مدل یادگیری ترکیبی متا با سناریوهای برتر

مقایسه نتایج بهترین ورودی مدل های مورد مطالعه

برتر انتخاب شدند که ضرایب مربوط به داده های آزمون این مدل در (جدول ۹) ارائه شده است.

مدل های ANN-MLP, ESVM, Staking با ورودی های مختلف برای پیش بینی پارامتر تبخیر و تفرق مرجع استان گلستان مورد بررسی قرار گرفت و با توجه به ضرایب آماری مقایسه خروجی مدل با مقادیر مشاهداتی داده های آزمون بهترین مدل ها به ترتیب صحت خروجی انتخاب گردید. با توجه به اینکه تمامی این ورودی ها قابل قبول نیستند، بنابراین با توجه به مقایسه خروجی به دست آمده از مدل ها (با ورودی های مختلف) با مقادیر مشاهده شده، تعدادی از این ورودی ها به عنوان ورودی های

جدول (۹) نتایج آماری ورودی‌های برتر مدل‌های استفاده‌شده در دوره آزمون

	TEST	ANN-MLP	RF	ESVM	DL	Stacking	GLM
گرگان	RMSE	۱۸/۵	۸/۳۶۶	۶۵/۴۷۲	۱۵/۵۲۶	۶/۸۴۹	۲۴/۰۸۴
	MAE	۲/۰۱	۰/۷۱	۴۶/۷۷	۱/۹۹	۰/۲۵	۰/۴۱
	R ²	۰/۹۷	۰/۹۹۴	۰/۸۳۷	۰/۹۸	۰/۹۹۶	۰/۹۵
گنبد	RMSE	۲۴/۶۱۴	۱۱/۵۳۱	۳۵/۷۲۹	۲۴/۲۱۹	۹/۹۱۹	۳۰/۹۶۹
	MAE	۷/۲۴	۰/۷۶	۱/۵۱	۲/۰۱	۰/۰۸	۱/۲۷
	R ²	۰/۹۳۵	۰/۹۸۷	۰/۸۶۸	۰/۹۴۱	۰/۹۹	۰/۸۹۷
کردکوی	RMSE	۲۵/۱۵۹	۱۱/۵۳۱	۷۰/۴۴۱	۲۳/۲۴۷	۹/۶۷۱	۳۱/۳۱۹
	MAE	۲/۲۹	۰/۵۹	۵۱/۱۲	۰/۲۸	۰/۲۵	۱/۳۲
	R ²	۰/۹۳	۰/۹۸۶	۰/۸۰۱	۰/۹۴	۰/۹۹	۰/۸۹
بندر ترکمن	RMSE	۱۴/۳۷۹	۷/۰۴۱	۶۸/۲۲	۱۳/۶۰۷	۶/۵۶۱	۱۷/۹۲۶
	MAE	۱/۰۹	۱/۲۳	۴۵/۶۷	۱/۵۲	۰/۸	۰/۱۵
	R ²	۰/۹۷۹	۰/۹۹۵	۰/۸۷	۰/۹۸۲	۰/۹۹۶	۰/۹۶۸
علی آباد	RMSE	۲۵/۷۰۶	۱۱/۷۰۳	۷۶/۲۱۵	۲۶/۶۴۲	۹/۱۲۳	۲۲/۸۷۸
	MAE	۷/۶۹	۰/۲۳	۵۷/۵۶	۰/۸۹	۰/۳۳	۱/۲۶
	R ²	۰/۹۳۵	۰/۹۸۶	۰/۷۹۶	۰/۹۲۵	۰/۹۹۱	۰/۹۴۸
مینودشت	RMSE	۱۳/۹۶۸	۱۰/۴۹۴	۱۰/۶۷۴	۲۷/۴۷۲	۸/۷۳	۳۰/۲۷۲
	MAE	۲/۴۵	۰/۰۳	۰/۸۷	۲۲/۷۳	۰/۹۷	۱/۰۹
	R ²	۰/۹۷۸	۰/۹۸۸	۰/۹۸۸	۰/۹۷۳	۰/۹۹۲	۰/۸۹۷

یافته (GLM) برای پیش‌بینی تبخیر و تعرق مرجع در استان گلستان با استفاده از داده‌های هواشناسی طی دوره ۳۱ ساله (۱۳۷۰-۱۴۰۰) بود. متغیرهای ورودی شامل دمای میانگین، میانگین حداقل دما، میانگین حداکثر دما، میانگین رطوبت نسبی، میانگین حداکثر رطوبت نسبی، تعداد ساعات آفتابی، نقطه شبنم و تبخیر بود که در قالب هشت ترکیب ورودی مختلف برای مدل‌سازی استفاده شدند. نتایج این مطالعه نشان داد که مدل یادگیری ترکیبی متا در تمامی ایستگاه‌های مورد بررسی، نسبت به سایر مدل‌ها از دقت بالاتری در پیش‌بینی مقادیر تبخیر و تعرق مرجع برخوردار است. این یافته‌ها با نتایج تحقیقات اخیر که کارایی بالای مدل‌های ترکیبی را در پیش‌بینی پدیده‌های پیچیده آب و هوایی نشان داده‌اند، هم‌خوانی دارد (Kushwaha, Ikram et al., 2022). مدل‌های جنگل تصادفی (RF) و یادگیری عمیق (DL) به ترتیب در رتبه‌های دوم و سوم قرار گرفتند و توانایی خود را در شرایط مختلف آب و هوایی اثبات کردند (Banerjee et al., Chen et al., 2020). همچنین، ترکیب‌های ورودی ۷ و ۸، که شامل بیشترین تعداد متغیرها بودند، عملکرد بهتری نسبت به ترکیب‌های ساده‌تر نشان دادند. با توجه به نتایج این

همانطور که از بررسی نتایج در جدول (۹) مشاهده می‌شود در همه شهرها مدل‌های پیش‌بینی پارامتر تبخیر و تعرق مرجع (GLM, Stacking, DL, ESRV, RF, ANN-MLP) از کارایی بالایی برخوردار هستند. اما مدل یادگیری ترکیبی متا در همه شهرها از مقادیر ضریب تعیین بسیار بالا (بالای ۰.۹۹) و کمترین میانگین قدر مطلق خطا و کمترین ریشه دوم مربعات خطا برخوردار می‌باشد. همین‌طور از جدول مشاهده می‌شود که بعد از مدل یادگیری ترکیبی متا در همه شهرها مدل RF و سپس مدل DL از دقت بیشتری نسبت به بقیه مدل‌ها برخوردار می‌باشند. همچنین بعد از مدل DL مدل ANN و سپس مدل GLM و در نهایت مدل ESVM از کارایی مناسبی برخوردار می‌باشند همچنین می‌توان اظهار داشت که با رعایت یک سری ملاحظات می‌توان هر ۶ مدل را برای پیش‌بینی تبخیر و تعرق مرجع مورد استفاده قرارداد.

نتیجه‌گیری

هدف اصلی این پژوهش، بررسی و ارزیابی دقت مدل‌های مختلف یادگیری ماشین شامل شبکه عصبی مصنوعی (MLP)، مدل بردار پشتیبان ارتقا یافته (ESVM)، مدل جنگل تصادفی (RF)، مدل یادگیری عمیق (DL)، مدل یادگیری ترکیبی متا (Stacking) و مدل خطی تعمیم

منابع آب، به‌ویژه در مناطق خشک و نیمه‌خشک مانند استان گلستان دارد، جایی که محدودیت منابع آب و نوسانات اقلیمی، نیازمند برنامه‌ریزی دقیق و مبتنی بر داده‌های قابل اطمینان است

پژوهش، می‌توان نتیجه گرفت که استفاده از مدل‌های ترکیبی و یادگیری پیشرفته، همراه با انتخاب دقیق پارامترهای ورودی، می‌تواند دقت پیش‌بینی تبخیر و تعرق مرجع را بهبود بخشد. این امر اهمیت ویژه‌ای برای مدیریت

منابع

- اسدی، م.، کرمی، م.، ۱۴۰۰. ارزیابی تبخیر و تعرق با استفاده از تصاویر ماهواره‌ای و الگوریتم سبال (مطالعه موردی: شرق استان آذربایجان شرقی). مجله اکوهیدرولوژی، دوره ۸ شماره ۱، ۱۷-۲۷.
- شادمانی، م. و ص. معروفی. ۱۳۹۰. مقایسه چند روش برآورد تبخیر روزانه از تشت- مطالعه موردی منطقه کرمان. مجله علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک، ۵(۱۵).
- صالحی، ج.، و رضوی، ن. ۱۴۰۱. تحلیل تبخیر و تعرق با مدل‌های ترکیبی یادگیری ماشین: مطالعه موردی استان گلستان. نشریه علوم محیطی و کشاورزی، ۲۸(۱): ۷۲-۸۸.
- کریمی، ر.، نظری، س.، و احمدی، ف. ۱۳۹۹. ارزیابی مدل‌های هوش مصنوعی در پیش‌بینی تبخیر-تعرق با استفاده از داده‌های هواشناسی. مجله تحقیقات آب ایران، ۱۵(۲): ۶۷-۵۵.
- مساعدی، ا.، شریفان، ح. و شهایی، م. ۱۳۸۶. مدیریت ریسک خشکسالی با شناخت میکروکلیمای استان گلستان.
- هاشمی، م.، حسینی، ح.، و صادقی، م. ۱۴۰۰. بررسی تأثیر تغییرات اقلیمی بر تبخیر و تعرق پتانسیل در مناطق خشک ایران. فصلنامه پژوهش‌های آب و خاک، ۳۲(۳): ۳۳-۴۵.
- ytac, G., and T. Seydou. 2012. Regional-Specific Numerical Models of Evapotranspiration Using Gene Expression Programming Interface in Sahel. *Water Resources Management*, 26(12): 4367-4380.
- Banerjee, G., Sarkar, U., Sarkar, S., et al. (2024). EvatCrop: a novel hybrid quasi-fuzzy artificial neural network (ANN) model for estimation of reference evapotranspiration. *PeerJ*, 12, Article e17437.
- Chen, Z., Zhu, Z., Jiang, H., & Sun, S. (2020). Estimating daily reference evapotranspiration based on limited meteorological data using deep learning and classical machine learning methods. *Journal of Hydrology*, 591, 125286.
- Gulay Tezal and Buyukyildiz. 2015. Modeling of daily pan evaporation in subtropical climate ANN, LS-SRV, fuzzy logic, and ANFIS, *Thero Appl Climatol*. 15. 1392.
- Guo, x., X. Sun and X. Ma. 2011. Prediction of daily crop reference evapotranspiration value through a least- square support vector machine model. *Hydrology Reserch*. 42(4). 268- 274.
- Guen, A. And O. Kişi. 2011. Daily pan evaporation modeling using linear genetic programming technique, 29 (2):135-145.
- Hejazizadeh Z, bazmi N, Rahimi A, Toulabi Nejad M, Bosak A. 2017. Modeling of spatio-temporal of albedo over Iran. *Researches in Geographical Sciences*, 17 (47): 1-17.
- Ikram, R. M., Mostafa, R. R., Chen, Z., et al. (2022). Advanced hybrid metaheuristic machine learning models application for reference crop evapotranspiration prediction. *Agronomy*, 13(1), 98.
- Kisi, O. 2007. Adaptive neurofuzzy computing technique for Evapotranspiration Estimation. *Journal of Irrigation and Drainage Engineering*. No. 133(4). pp. 368-379.
- Kisi, O. 2007. Adaptive neurofuzzy computing technique for Evapotranspiration Estimation. *Journal of Irrigation and Drainage Engineering*. No. 133(4). pp. 368-379.
- Kisi, O. and M. Zounemat-Kermani. 2014. Comparison of Two Different Adaptive Neuro-Fuzzy Inference Systems in Modelling Daily Reference Evapotranspiration. *Water Resources Management*, 28: 2655-2675.
- Kushwaha, N. L., Rajput, J., Sena, D. R., et al. (2022). Evaluation of data-driven hybrid machine learning algorithms for modelling daily reference evapotranspiration. *Atmosphere-Ocean*, 60, 519-540.
- Liu, X., Wu, H., & Zhou, J. (2021). Application of stacking ensemble methods for climate-related evapotranspiration modeling. *Computers and Electronics in Agriculture*, 181, 105-115.



Mohammadrezapour, O., Piri, J., Kisi, o. 2019. Comparison of SVM, ANFIS and GEP in modeling monthly potential evapotranspiration in arid region (Case study: Sistan and baluchestan province –Iran). *Water Supply* (2019) 19 (2): 392–403. <https://doi.org/10.2166/ws.2018.084>.

Mohammadrezapoura, O., Moradi, M., Kisi, O., Sharifazari. S. 2018, Evolutionary support vector machine for evapotranspiration estimation (case study: Haji Abad region, Hormozgan province), *Desalination and Water Treatment*, 111 (2018) 183–191.

Ramesh, S., Krishnan, K., & Gupta, N. (2021). Comparative study of ANN and Penman-Monteith for evapotranspiration prediction. *Environmental Modelling & Software*, 139, 104958.

Shiri, j., O. Kişi, G. Landaras, J. López and A.H. Nazemi.2012 .Daily reference evapotranspiration modeling by using genetic programming approach in the Basque Country (Northern Spain).*Journal of Hydrology*, 414:316-302.

Shirsath P.B. and A.K. Singh. 2010. A comparative study of daily pan evaporation estimation using ANN, regression and climate based models. *Water Resource Management*, 24:1571-1581.

Terzi, O. 2013. Daily pan evaporation estimation using gene expression programming and adaptive neural-based fuzzy inference system. *Journal Computing & Applications*, Sep 2013, Vol. 23 Issue 3/4, p1035.

Vafakhah, M., 2012. Application of artificial neural networks and adaptive neuro-fuzzy inference system models to short-term streamflow forecasting. *Canadian Journal of Civil Engineering* 39(4), 402-414

Wang, L., Zhang, J., & Liu, H. (2020). Improving evapotranspiration predictions using Stacking ensemble learning. *Water Resources Management*, 34(7), 2285-2302.

Wang, W.C. and W.L. Men. 2008. Online prediction model based on support vector machine. *Neurocomputing*, 71, 550-558.

Yu P.S, Chen S.T., Chang I.F. 2006. Support vector regression for real-time flood stage forecasting. *Hydrology*, 328: 704-716.

Zhang, Y., Li, P., & Wei, Q. (2020). Artificial neural networks for reference evapotranspiration prediction in arid and semi-arid regions. *Journal of Hydrology*, 590, 125-135.

Zhao, F., Sun, Q., & Wang, J. (2020). Enhanced support vector machines for predicting evapotranspiration using multivariate data. *Agricultural Water Management*, 239, 106272.