Archive of SID.ir

Research Paper

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

Omolbani Mohammadrezapour[1*] **Hadi Siasar**[2] **Hosein Sharifan**[1]

[1] Associated Professor of Water Engineering, Department of Water Engineering, Faculty of Soil and Water, Gorgan University of Agricultural Sciences and Natural Recourses. (Corresponding author)

[2]Reserch Institute of Zabol

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 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.

* **Corresponding Author:** Omolbani Mohammadrezapour
Address: Department of Water Engineering, Faculty of Soil and Water, Gorgan University of Agricultural Sciences and Natural Recourses.
Email: Acadenmic Email: Mohammadrezapour@Gau.ac.ir
Tel: Number

Archive of SID.ir

Archive of SID.ir

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.

Archive of SID.ir

Archive of SID.ir

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 evaportation 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

Archive of SID.ir

Archive of SID.ir

نشریه علمی پژوهشی مهندسی آبیاری و آب ایران
سال پانزدهم. شماره پنجاه و نه.بهار۱۴۰۴

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

ام البنی محمدرضاپور[۱*]، هادی سیاسر[۲]، حسین شریفان[۲]

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 مؤثرجهت برنامه‌ریزی دقیق آبیاری می‌باشد. لذا، برآورد دقیق نیاز آبی گیاه، تاثیر شایانی بر کاهش معضل بحران آب، خواهد داشت. علی‌رغم اهمیت تبخیر-تعرق در برنامه-ریزی و مدیریت منابع آبی، وابستگی آن به مولفه‌های اقلیمی از یک‌سو و تاثیرپذیری این مولفه‌ها از یکدیگر از سویی دیگر تخمین تبخیر-تعرق را دشوار ساخته است. در این راستا، ابتدا بر اساس رابطه‌ی فائو پنمن-مانتیث، میزان تبخیر-تعرق پتانسیل ماهانه در ایستگاه های سینوپتیک مورد انتخاب از داده‌های هواشناسی ماهانه محاسبه و به عنوان ورودی مدل های هیبریدی فراکاووشی شامل شبکه عصبی مصنوعی (ANN)، بردار پشتیبان ارتقا یافته (ESVM) و مدل یادگیری ترکیبی متا (Stacking) استفاده می شود. واسنجی داده‌ها به وسیله 70 درصد داده‌ها (برای آموزش) و عملکرد روش‌ها با استفاده از ۳۰ درصد داده‌های باقی‌مانده ارزیابی می گردد. همچنین در این تحقیق برای ارزیابی دقت مدل ها از سه معیار ریشه میانگین مربعات خطا، ضریب همبستگی و میانگین قدر مطلق خطا استفاده شد. از بررسی نتایج همه ایستگاه‌ها مشاهده شد، تمام‌مدل های پیش‌بینی پارامتر تبخیر و تعرق مرجع از کارایی خوبی برخوردار هستند. اما مدل یادگیری ترکیبی متا در همه ایستگاه های مورد مطالعه در بهترین سناریوها از مقادیر کمترین میانگین قدر مطلق خطا (گرگان: ۰/۲۵، گنبد: ۰/۰۸، کردکوی: ۰/۲۵، بندر ترکمن: ۰/۸، علی آباد: ۰/۳۳ و مینودشت: ۰/۹۷) و ضریب تعیین بسیار زیاد (گرگان: ۰/۹۹۶، گنبد: ۰/۹۹، کردکوی: ۰/۹۹، بندر ترکمن: ۰/۹۹۶، علی آباد: ۰/۹۹۱ و مینودشت: ۰/۹۹۲) و کمترین ریشه دوم مربعات خطا (گرگان: ۶/۸۴۹، گنبد: ۹/۹۱۹، کردکوی: ۹/۶۷۱، بندر ترکمن: ۶/۵۶۱، علی آباد: ۹/۱۲۳ و مینودشت: ۸/۷۳) برخوردار می‌باشد. همچنین بعد از مدل یادگیری ترکیبی متا در همه ایستگاه ها مدل شبکه عصبی مصنوعی و سپس مدل بردار پشتیبان ارتقا یافته از دقت بیشتری نسبت به بقیه مدل ها برخوردار می‌باشند.

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

[۱] دانشیار گروه مهندسی آب - دانشگاه علوم کشاورزی و منابع طبیعی گرگان ایمیل:omohammadrezapour@gmail.com (نویسنده مسول)

[۲] استادیار، گروه کشاورزی، دانشگاه پیام نور، زابل، ایران. ایمیل:hadisiasar@yahoo.com

Archive of SID.ir

Archive of SID.ir

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 کشورکه به عنوان مهم ترین 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 تعیین کننده معادلات انرژی در سطح زمین و توازن آب است و در زمینه های مختلف علوم، مانند هیدرولوژی، کشاورزی، مدیریت جنگل و مرتع و مدیریت منابع آب مورد نیاز است(Gao et al, 2008). همچنین آب مهم ترین عامل محدود کننده 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 مدل های ریاضی و کامپیوتری بسیاری به‌منظور شبیه‌سازی مقدار تبخیر و تعرق پتانسیل موردتوجه قرارگرفته است. در این میان مدل های هوش مصنوعی برای مدل‌سازی رفتار پدیده‌های مختلف موردتوجه محققین زیادی قرارگرفته‌اند. 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 مدل های هوش مصنوعی در برآورد تبخیر-تعرق پتانسیل پرداخته‌اند که به برخی از آنها اشاره می شود.

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 تشت 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 تشت برخودار 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- مانتیث تقریب بزند. توانایی عملکرد برنامه-ریزی بیان ژن (GEP) برای مدل سازی 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-مانتیث 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 داده ای 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_o) چهار ایستگاه آب و هوا یی استفاده کردندو روش پنمن مانتیث به عنوان مرجع

Archive of SID.ir

Archive of SID.ir

انتخاب و نتایج برنامه نویسی بیان ژن (GEP) با سیستم تطبیقی عصبی فازی استنتاج (ANFIS)، پریستلی- تیلور 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 (Guven 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 پشتبان تکاملی (ESVM) و شبکه عصبی مصنوعی (ANN) با استفاده از 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 باشند. 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-مانتیث، 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 پارامترتبخیر و تعرق مرجع استان گلستان طی سال‌های ۱۴۰۰-۱۳۷۰ می‌باشد

مواد و روش ها

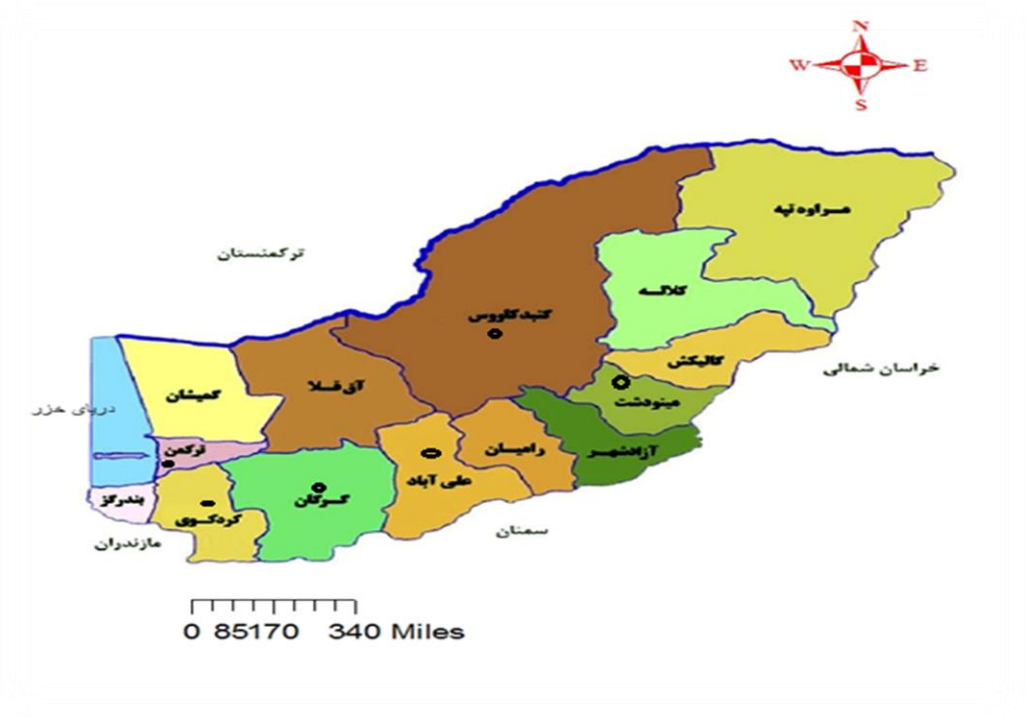
معرفی منطقه مورد مطالعه:

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 و۵۰ دقیقه تا ۵۶ درجه و ۱۸دقیقه 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

Archive of SID.ir

Archive of SID.ir

مناطق مختلف استان متفاوت می‌باشد. در این استان اقلیم نیمه خشک در نوار مرزی و حوضه آبریز اترک تا معتدل و نیمه مرطوب در مناطق جنوبی و غربی متغیر است (مساعدی، ۱۳۸۶).



شکل(۱) منطقه مورد مطالعه (استان گلستان)

جمع آوری داده ها : جمع‌آوری داده‌های هواشناسی روزانه شش ایستگاه سینوپتیک به مدت ۳۱ سال (۱۳۷۰-۱۴۰۰)، شامل دمای هوا، مقدار تابش روزانه خورشیدی، رطوبت نسبی، نقطه شبنم، سرعت باد، تبخیر از سازمان هواشناسی جمع‌آوری شد. در جدول ۱ مشخصات آماری برخی از پارامترهای استفاده شده در مدلسازی نشان داده شده است. (علی آباد، بندر ترکمن، گنبد، گرگان، کردکوی و مینودشت) طی دوره آماری ۳۰ ساله (۱۳۷۰-۱۴۰۰) نشان می‌دهد. در این جدول چهار پارامتر کلیدی شامل تبخیر، ساعات آفتابی، رطوبت نسبی و دمای میانگین مورد بررسی قرار گرفته و برای هر پارامتر، شاخص‌های آماری حداکثر، حداقل، میانگین و ضریب تغییرات محاسبه شده است. بررسی داده‌ها نشان می‌دهد که میزان تبخیر در ایستگاه‌های مورد مطالعه از حداقل ۹/۳ میلی‌متر در ایستگاه‌های علی‌آباد، گنبد و کردکوی تا حداکثر ۳۵۱/۸ میلی‌متر در همین ایستگاه‌ها متغیر است، در حالی که ساعات آفتابی از صفر ساعت در گرگان تا ۳۱۶/۲۰ ساعت در بندر ترکمن ، رطوبت نسبی از ۴۳/۰ درصد در مینودشت تا ۸۵/۳۴ درصد در بندر ترکمن و دمای میانگین از ۴۳ درصد دربندر ترکمن تا ۸۵/۳۴ درصد در بندر ترکمن در نوسان می‌باشد. ضریب تغییرات نشان می‌دهد که در بین پارامترهای مورد بررسی، ساعات آفتابی با ضریب تغییرات ۶۹/۹۲ درصد در مینودشت تا ۸۶/۰۴ درصد در بندر ترکمن بیشترین تغییرپذیری، و رطوبت نسبی با ضریب تغییرات ۵/۲۱ درصد در بندر ترکمن تا ۸/۰۹۱ درصد در علی‌آباد کمترین تغییرپذیری را در طول دوره آماری داشته است. همچنین، میانگین تبخیر در ایستگاه‌های مورد مطالعه از ۱۸۸/۸ میلی‌متر در گرگان تا ۲۰۰/۱ میلی‌متر در گنبد و کردکوی متغیر است. این اطلاعات پایه‌ای مهم برای تحلیل‌های اقلیمی و مطالعات مرتبط با تبخیر و تعرق در منطقه فراهم می‌کند

Archive of SID.ir

Archive of SID.ir

جدول(۱) مشخصات آماری برخی پارامترهای استفاده شده

شهرها	پارامترها	تبخیر(میلیمتر)	ساعات آفتابی(ساعت)	رطوبت نسبی(درصد)	دمای میانگین(درجه سانتیگراد)
	حداکثر(Max)	۳۵۱/۸	۳۱٤	۸۲/٦	۳۲/۹
علی آباد	حداقل(Min)	۹/۳	۷/۸	٤٥/۹	۲/٦٥
	میانگین(Average)	۲۰۰/۰۹	۱۱۳/۷۸	٦٦/۷۸	۱۸/۷٦
	ضریب تغییرات(CV)	٦۷/٦۰٦	۷٥/۷۱۳	۸/۰۹۱	۸/۰۱٥
	حداکثر(Max)	۳٤۰/۱	۳۱٦/۲۰	۸٥/۳٤	۳۰/۰۷
بندر ترکمن	حداقل(Min)	۸٦/٦	۱۰/٥	٦۰/٥۲	۲/۹
	میانگین(Average)	۱۹۸/۲۸	۱۳۰/۰۹	۷۳/۷٦	۱۸/۳۲
	ضریب تغییرات(CV)	٦۱/٤٤	۸٦/۰٤	٥/۲۱	۷/٦
	حداکثر(Max)	۳٥۱/۸	۳۱٤	۸۲/٦	۳۲/۹
گنبد	حداقل(Min)	۹/۳	۷/۸	٤٥/۹	۲/۷
	میانگین(Average)	۲۰۰/۱	۱۱۳/۹	٦٦/۸	۱۸/۸
	ضریب تغییرات(CV)	٦۷/٦۱	۷٥/٦۲	۸/۰۹	۸/۰۲
	حداکثر(Max)	۳٤۷/۸	۲۹۳/۲	۸٥/۱	۳۱/۳
گرگان	حداقل(Min)	٥۷/۷	۰	٥۲	۲/۸
	میانگین(Average)	۱۸۸/۸	۱۱۱/٤	۷۰/۲	۱۸
	ضریب تغییرات(CV)	٥٥/۹	۷۰/۹٦	٦/۲۷	۷/٦۷
	حداکثر(Max)	۳٥۱/۸	۳۱٤	۸۲/٦	۳۲/۹
کردکوی	حداقل(Min)	۹/۳	۷/۸	٤٥/۹	۲/۷
	میانگین(Average)	۲۰۰/۱	۱۱۳/۸	٦٦/۸	۱۸/۸
	ضریب تغییرات(CV)	٦۷/٦۱	۷۲/۷۲	۸/۰۹	۸/۰۲
	حداکثر(Max)	۳۳۹/۹	۲۹۹/٤	۷٥/۸	۳۲/٦
مینودشت	حداقل(Min)	۷۷/۷	۲۸/۷	٤۳	٦/۸
	میانگین(Average)	۱۹۹/٤	۱۲٤/٤	٥۹/٥	۱۹/٥
	ضریب تغییرات(CV)	٦۳/٦۹	٦۹/۹۲	۷/٦۳	۷/٦٥

مدل شبکه های عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی به دلیل توانایی بالای آن‌ها در مدل‌سازی فرآیندهای غیرخطی پیچیده، کاربرد گسترده‌ای در پیش‌بینی تبخیر و تعرق مرجع یافته‌اند. این روش از طریق یادگیری از داده‌های مشاهده‌شده و ایجاد ارتباطات درونی بین نرون‌های مختلف قادر به پیش‌بینی دقیق پارامترهای هیدرولوژیکی است. مطالعات اخیر مانند تحقیق Zhang et al. (۲۰۲۰) نشان می‌دهد که شبکه‌های عصبی مصنوعی دقت بالایی در مدل‌سازی تبخیر و تعرق مرجع دارند و می‌توانند به‌عنوان یک ابزار کارآمد در مناطق خشک و نیمه‌خشک استفاده شوند. همچنین در پژوهشی دیگر، Ramesh et al. (۲۰۲۱) کارایی مدل ANN را در مقایسه با روش‌های سنتی مانند پنمن-مانتیث مورد تأیید قرار داده و نشان داده‌اند که ANN قادر به کاهش خطاهای پیش‌بینی در داده‌های پیچیده اقلیمی است.

مدل ماشین بردار پشتیبان ارتقا یافته:

ماشین بردار پشتیبان (Support Vector Machine یا SVM) یکی از روش‌های پیشرفته یادگیری نظارت‌شده است که در سال‌های اخیر به دلیل عملکرد بهتر

Archive of SID.ir

Archive of SID.ir

نسبت به روش‌های قدیمی‌تری مانند شبکه‌های عصبی پرسپترون چندلایه، مورد توجه قرار گرفته است SVM . برای دسته‌بندی و رگرسیون کاربرد دارد و بر اساس نظریه یادگیری آماری طراحی شده است. این روش به‌طور خاص برای دسته‌بندی داده‌های دودسته‌ای مناسب است و مرزهای تصمیم‌گیری را با استفاده از یک ابرصفحه خطی در فضای ویژگی‌ها تعیین می‌کند. نمونه‌هایی که به این مرز نزدیک‌تر هستند، به‌عنوان بردارهای پشتیبان شناخته می‌شوند و نقشی کلیدی در تعیین معادله مرز تصمیم‌گیری دارند. به همین دلیل، این روش در مسائل پیش‌بینی بسیار مؤثر عمل می‌کند (Zhao et al., 2020) .

الگوریتمهای شبیه‌سازی هوشمند کلاسیک مانند شبکه‌های عصبی مصنوعی، معمولاً قدر مطلق خطا یا مجموع مربعات خطای داده‌های 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 yبه مجموعه‌ای 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.

$$Y= f (x)+nois \quad (۱)$$

بنابراین موضوع اصلی، پیدا کردن فرم تابع f است که بتواند به صورت صحیح، موارد جدیدی را که SVMتاکنون تجربه نکرده است پیشبینی کند این تابع با آموزش مدل SVMبر روی یک مجموعه داده که به‌عنوان مجموعه آموزشی شناخته می‌شود، به دست می‌آید. در فرآیند آموزش، مدل تلاش می‌کند تا تابع خطا را بهینه‌سازی کرده و بهترین رابطه ممکن بین داده‌های ورودی و خروجی را برقرار کند. تابع خطا در مدل SVM به‌گونه‌ای طراحی شده است که خطاهای ساختاری و آموزشی را حداقل کند و دقت پیش‌بینی را افزایش دهد. این فرآیند شامل تنظیم مقادیر پارامترهایی مانند وزن‌ها و بایاس است تا مدل بتواند به شکلی بهینه داده‌های جدید را پیش‌بینی کند:

$$\frac{1}{2}w^T w + C\sum_{i=1}^{N}\varepsilon_i + C\sum_{i=1}^{N}\varepsilon_i \quad (۲)$$

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

$$w^T\emptyset(x_i) + b - y_i \le \varepsilon + \varepsilon_i^* \quad (۳)$$
$$y_i - w^T\emptyset(x_i) - b \le \varepsilon + \varepsilon_i^*$$
$$\varepsilon_i, \varepsilon_i^* \ge 0$$

که در این روابط C ثابت گنجایش، Wبردار ضرایب، w* ترانهاده بردار ضرایب، ξ*i ،ξ 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 میباشد. ماشین‌های 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 روش‌های پیشرفته یادگیری ماشین است که برای بهبود دقت پیش‌بینی‌ها از ترکیب خروجی‌های چندین مدل پایه استفاده می‌کند. این مدل ابتدا پیش‌بینی‌های اولیه مدل های پایه مانند شبکه عصبی و جنگل تصادفی را استخراج و سپس آن‌ها را به مدل متا وارد می‌کند. مدل متا با یادگیری روابط میان خروجی‌های مدل های پایه و داده‌های واقعی، پیش‌بینی نهایی را ارائه می‌دهد. این روش به دلیل انعطاف‌پذیری بالا، کاهش خطاهای پیش‌بینی و قابلیت ترکیب نقاط قوت مدل های مختلف، در مسائل پیچیده‌ای 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 پیش‌بینی‌ها حمایت کرده‌اند(Liu et al., 2021 ؛Wang et al., 2020).

روش تحقیق

پس از اخذ آمار و اطلاعات مربوط به داده‌های 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

Archive of SID.ir

Archive of SID.ir

پیش‌بینی پارامتر تبخیر و تعرق پتانسیل پرداخته شد. جهت انجام کار، از روش‌های هوش مصنوعی شامل مدل شبکه عصبی مصنوعی (ANN) بردار پشتیبان ارتقا یافته (ESVM) مدل یادگیری ترکیبی متا (Staking)، و در هشت سناریو که در جدول (۲) آمده است، جهت پیش‌بینی پارامتر تبخیر و تعرق پتانسیل استان گلستان استفاده شد. داده‌ها به دودسته داده‌های واسنجی (آموزش) و داده‌های آزمون(تست) تقسیم شد. آموزش به‌وسیله ۷۰ درصد داده‌ها انجام شد و از ۳۰ درصد باقی‌مانده که در آموزش نقشی نداشته‌اند به‌عنوان داده‌های آزمون استفاده شد

جدول(۲) ترکیبات مختلف مدل های مورد مطالعه

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

معیارهای ارزیابی

برای ارزیابی و بررسی کارآیی 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.

ضریب تعیین (۴)
$$R^2 = 1 - \left(\frac{\sum_1^n (M_i - E_i)^2}{\sum_1^n (M_i - \bar{E})^2}\right)$$

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

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

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 Ei: مقدار پیش‌بینی‌شده متغیر، Mi : مقدار اندازه‌گیری شده متغیر و N تعداد داده‌ها می‌باشد.

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 مصنوعی (ANN) در شهرهای علی‌آباد، بندر ترکمن، گرگان، کردکوی، مینودشت و گنبد ارائه می‌دهند. این

Archive of SID.ir

Archive of SID.ir

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 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 مدلANN

		Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
گرگان	RMSE	۲۸/۷۵	۲۲/۰۷۲	۲۱/۳۲۷	۲۰/۳۳۶	۱۷/۹۲۶	۱۶/٤٥۱	۱۷/٤۹۹	۱٤/۹٥۷
	MAE	۲۰/۹	۱۰/٤۱	۸/۰٦	٦/۱	۳/۱	۰/٦٥	۸/۲۳	۳/٤۸
	R^2	۰/۹٦	۰/۹٦	۰/۹٦	۰/۹٦	۰/۹۷	۰/۹۷	۰/۹۷	۰/۹۸
گنبد	RMSE	۲۲/٦۹۹	۲۱/٤۹۱	۲٦/۸٤۷	۲۲/٤۰۱	۲۰/۸۱۱	۱۹/۲۰۱	۱۷/٦۱۱	۱۸/۸۰۳
	MAE	٥/۹٥	۱/٦۹	۱٦/۲۱	۷/۷٥	٦/۱٥	۸/۱۹	٤/۱۷	٦/۹
	R^2	۰/۹٥۱	۰/۹٥۲	۰/۹٥۲	۰/۹٥٤	۰/۹٦	۰/۹٦۸	۰/۹٦۹	۰/۹٦۹
کردکوی	RMSE	۲۳/۱۱۳	۲۱/۷٦۷	۲۷/۳۸٦	۲۲/۸۱۷	۲۱/۳٤٤	۱۹/٥۸٥	۱۷/۷۱۳	۱۹/٦۱٦
	MAE	۱/۷۲	۲/۷٤	۱٦/٥۹	۸/۲٥	۷/۰۲	۷/۸٤	۲/۸۸	۷/٤۳
	R^2	۰/۹٥	۰/۹٥	۰/۹٥	۰/۹٥	۰/۹٦	۰/۹۷	۰/۹۷	۰/۹۷
بندر ترکمن	RMSE	۲۸/۳٤۸	۲۰/٥٥۸	۱۹/۸۹۱	٥٥/٥٥۱	۱۸/۲۰۷	۱٦/٥٦۹	۱٥/٥۷۲	۱٥/۰۳۹
	MAE	۱۸/۸۳	۱/۸۷	٤/٦٥	۱٦/۳٦	٤/٦۹	۷/۱۸	٥/۰۲	۱/۲۹
	R^2	۰/۹٥۸	۰/۹٥۹	۰/۹٦	۰/۹٦٤	۰/۹٦۹	۰/۹۷۸	۰/۹۷۹	۰/۹۸
علی آباد	RMSE	۲۲/٦۱۲	۲۱/٤٦٤	۲٦/۷۲۲	۲۲/۳۷٥	۲۰/۷٦۲	۱۸/۷۳۷	۱۸/۸۱٥	۱۸/۹۲۳
	MAE	٥/٤۲	۲/۰٦	۱٦/۰۷	۷/۷٤	٦/۰۳	٥/۲۸	۷/۱٥	۷/۳۱
	R^2	۰/۹٥	۰/۹٥۲	۰/۹٥۲	۰/۹٥٤	۰/۹٥۹	۰/۹٦۸	۰/۹٦۸	۰/۹٦۹
مینودشت	RMSE	۳۰/٦۲٦	۲۹/۸۷۳	۲۸/٤۱٥	۲۸/۰۲	۲۷/٤۹۳	۲٥/٦٤٥	۲٦/٦٦۱	۱۸/۱۲٦
	MAE	۱۰/۸۸	۱۰/٥	٥/۷٤	۰/۰٤	۱/٦٦	۷/٦	۹/۹٥	۳/۳۸
	R^2	۰/۹۰۲	۰/۹۰۷	۰/۹۰۸	۰/۹۰٦	۰/۹۱	۰/۹۲۹	۰/۹۲۷	۰/۹٦۳

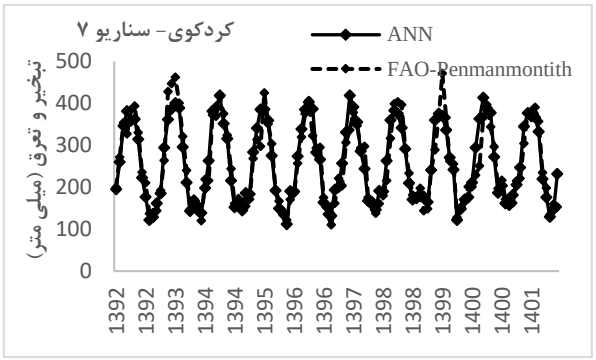
جدول(۴) نتایج پیش‌بینی برای مراحل آزمون با استفاده از مدلANN

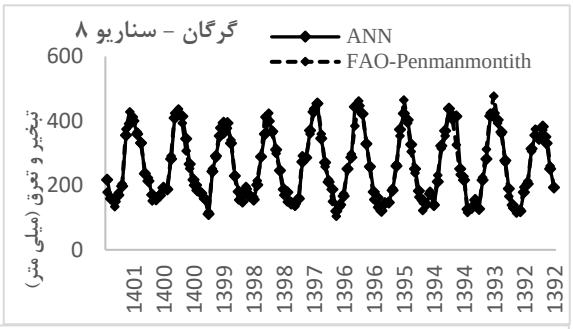
		Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
گرگان	RMSE	۳۰/٦۷۱	۲٦/۰۳۳	۲٥/۹۱۳	۲٤/۱۹۷	۲۲/٤۹۸	۲۰/۰۰٦	۱۸/۷۱۹	۱۸/٥
	MAE	۱۸/٤۷	۱۰/۱٦	۹/۳۹	٤/۷	۳/٤۹	۲/٦۹	۲/۹۲	۲/۰۱
	R^2	۰/۹٥	۰/۹٥	۰/۹٥	۰/۹٥	۰/۹٦	۰/۹٦	۰/۹۷	۰/۹۷
گنبد	RMSE	۳۱/٥۱٦	۲۹/٦۹٤	۳٤/٤۳۸	۳۰/۷۸٦	۲۸/٦٤۸	۲٦/۰۷۲	۲٥/٦۹۹	۲٥/٦۱٤
	MAE	٤/٦۷	۲/۷٤	۱٦/٥	۸/۳٥	۳/۹۹	۷/۰٥	۳/٥٥	۷/۲٤
	R^2	۰/۸۹۷	۰/۹۰٥	۰/۹۰۲	۰/۹۰٥	۰/۹۱۳	۰/۹۳۳	۰/۹۳	۰/۹۳٥
کردکوی	RMSE	۳۲/۹٤٤	۲۹/٦٤۱	۳٤/٦٤۹	۳۰/۸٦٦	۲۸/٦۹٥	۲٦/۱٥۸	۲٥/۱٥۹	۲٦/۱۷۲
	MAE	۲/٦۱	٤/۰۲	۱٦/۹۲	۸/۹	٤/٦۷	٦/۷	۹/۲۹	۷/۹٥
	R^2	۰/۸۸	۰/۹۱	۰/۹	/۰۹	۰/۹۱	۰/۹۳	۰/۹۳	۰/۹۳
بندر ترکمن	RMSE	۱۸/٥۱۷	۲۱/۳۲٥	۲۰/۹۹	۲٤/۸۰۹	۱۷/۹۷۷	۱٦/٤۳٦	۱٤/٤٦۹	۱٤/۳۷۹
	MAE	۱۹/۰۳	۰/۳۳	٤/٦۸	۱۳/۷۷	۳/۸٥	٦/۱	۳/۲۹	۱/۰۹
	R^2	۰/۹٥۳	۰/۹٥۳	۰/۹٦	۰/۹٥٦	۰/۹٦۸	۰/۹٦۷	۰/۹۷۹	۰/۹۷۹
علی آباد	RMSE	۳۱/۳۱۹	۲۹/٤۲۷	۳٤/۱۰۱	۳۰/٥۳٦	۲۸/۳٥۸	۲٦/٥۷۸	۲٥/۷۳۹	۲٥/۷۰٦
	MAE	٤/۱٦	۳/۱۲	۱٦/٤۸	۸/۳٦	۳/۸۹	۱/٤۷	۷/۷۹	۷/٦۹
	R^2	۰/۹	۰/۹۰۷	۰/۹۰۳	۰/۹۰٦	۰/۹۱٤	۰/۹۲۹	۰/۹۳٥	۰/۹۳٥
مینودشت	RMSE	۳۳۱/۳۲۲	۳۰/۰۲۲	۲۸/۹۸	۲۸/۸۷۹	۲۹/۱٤۱	۲۷/۳۸۱	۲۸/۱۰۲	۱۳/۹٦۸
	MAE	۸/۷۷	۹/٦۸	۳/۱٤	۲	۰/۷٥	٦/۲۳	۸/۷۳	۲/٤٥
	R^2	۰/۸۹٦	۰/۹۰٦	۰/۹۰٤	۰/۹۰٤	۰/۹۰۲	۰/۹۸۱	۰/۹۱۸	۰/۹۷۸

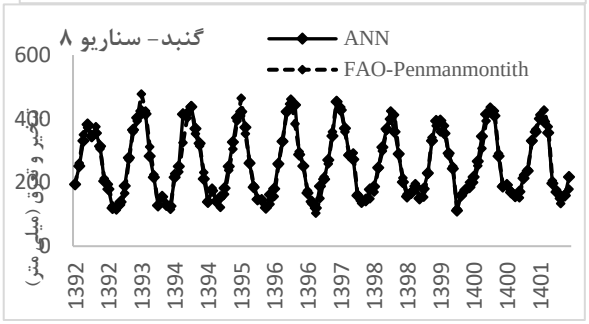
Archive of SID.ir

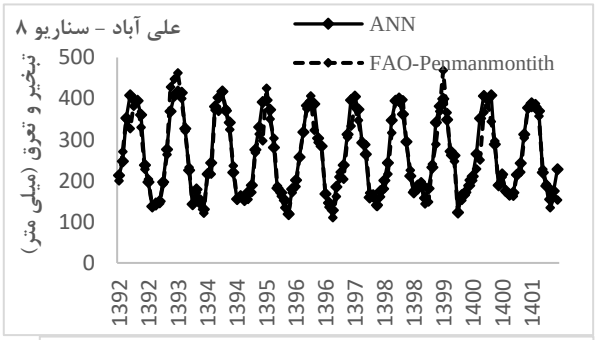
Archive of SID.ir

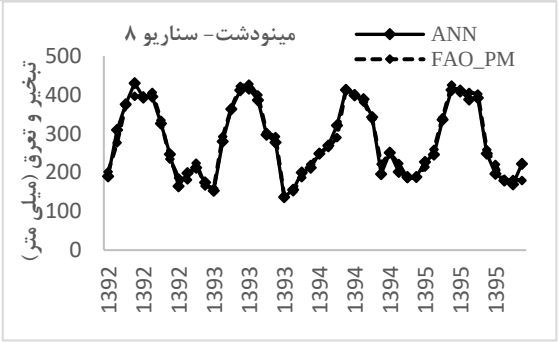
همانطور که از جدول (۳) مشخص است نتایج آزمون مدل شبکه عصبی مصنوعی برای سناریوی ۸ دارای کمترین مقادیر ریشه دوم مربعات خطا ومیانگین قدرمطلق خطا و همجنین بیشترین مقادیر ضریب تعیین در شهرهای گرگان (۱۸/۵، ۲/۰۱، ۰/۹۷)، گنبد (۲۵/۶۱۴، ۷/۲۴، ۰/۹۳۵)، بندر ترکمن(۱۴/۳۷۹، ۱/۰۹، ۰/۹۷۹)، علی آباد(۲۵/۷۰۶، ۷/۶۹، ۰/۹۳۵) و مینودشت (۱۳/۹۶۸، ۲/۴۵، ۰/۹۷۸) می‌باشد. اما در شهر کردکوی مدل ۷ با مقادیر ۲۵/۳۹، ۲/۲۹ و ۰/۹۳ به ترتیب کمترین مقادیر ریشه دوم مربعات خطا ومیانگین قدرمطلق خطا و بالاترین مقادیر 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 بوده‌اند. اما در شهر کردکوی بعد از مدل ۷ مدل ۶ و سپس مدل ۸ دارای بالاترین عملکرد می‌باشند و همجنین در شهر مینودشت بعد از مدل ۸، مدل ۶ و سپس مدل ۷ دارای عملکرد مناسب می‌باشند. در شکل (۲) مقادیر مشاهداتی و مقادیر شبیه سازی شده با استفاده از مدل شبکه عصبی مصنوعی با بهترین ورودی‌های انتخاب شده برای شهرهای مورد مطالعه نشان داده شده است

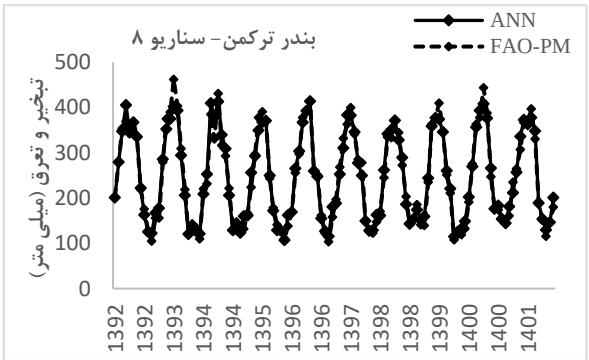












شکل (۲) نمودار مقادیرمشاهداتی و مقادیر شبیه سازی شده تبخیر تعرق مرجع شهرهای مورد مطالعه با استفاده از مدل شبکه عصبی با سناریوهای برتر

Archive of SID.ir

Archive of SID.ir

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

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، مینودشت و گنبد نشان داده شده است

. **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	/۰۶۷۳	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
	R2	۰/۷۹۳	۰/۸۱۶	۰/۷۴۸	۰/۹۸۸	۰/۸۸۹	۰/۷۲۹	۰/۷۴	۰/۸۷۸

Archive of SID.ir

Archive of SID.ir

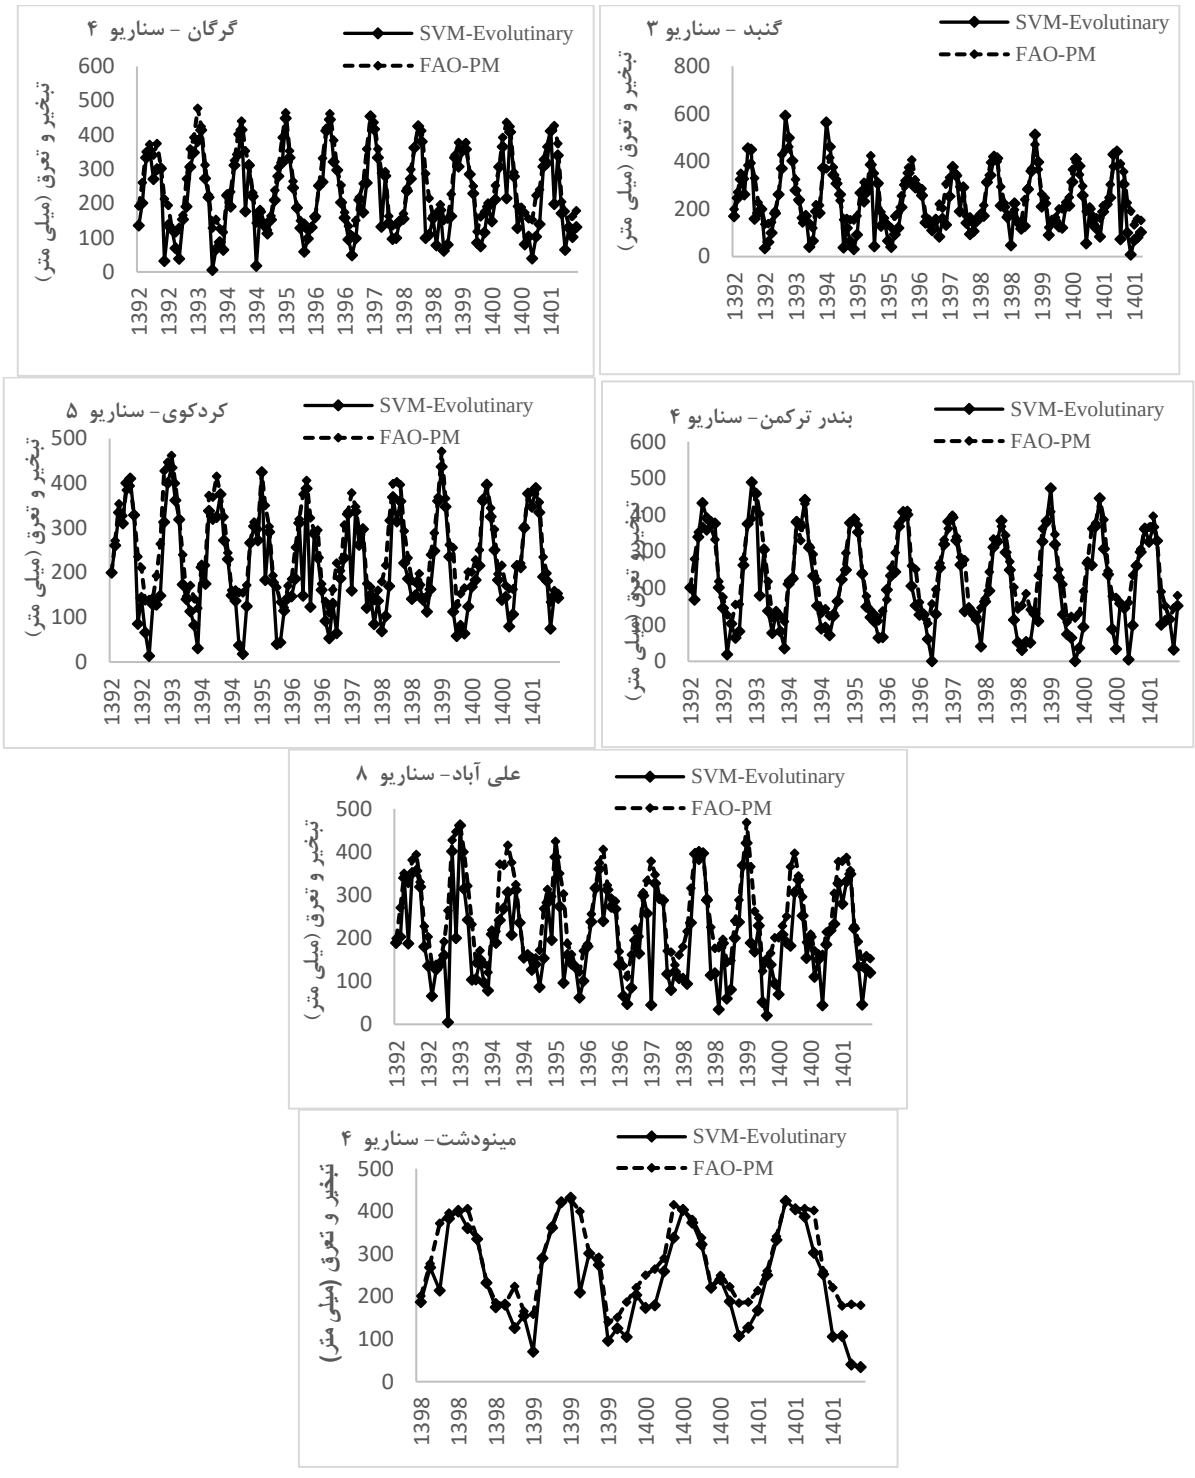
جدول (۶) نتایج پیش‌بینی برای مراحل آموزش و آزمون با استفاده از مدل بردار پشتیبان ارتقا یافته (ESVM)

		Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
گرگان	RMSE	۱۱٤/٤۱۹	۸۸/۹۸۸	٦۷/٦٦۷	٦٥/٤۷۲	۷۸/٦۹۲	۷۳/۲۲	۷۰/٥۸٤	۷۳/۰٥۲
	MAE	٤۹/۰۷	۱/۲٦	۲٦/۲٦	٤٦/۷۷	٥۲/۸	٥۲/٤٦	٤۷/۹۱	٤۹/٥۱
	R^2	۰/۷۹	۰/۷۲٦	۰/۷٦۸	۰/۸۳۷	۰/۷٥	۰/۷۷٦	۰/۸۰۲	۰/۷۸
گنبد	RMSE	۱۰٤/٤٤٥	۷٦/٦۳۷	۳٥/۷۲۹	٦۹/۳٤۳	۸۸/۲٦۲	۷۸/٤۳٥	۷۸/۰٥۷	۹۸/۷۸۹
	MAE	۳۲/٦۳	۲۰/۰۲	۱/٥۱	٤٥/٦۳	٦۲/۱٦	٥۳/۸٦	٥٥/۷۲	٦۸/٦۸
	R^2	۰/٦۹	۰/۷٥۳	۰/۸٦۸	۰/۸۱۲	۰/٦۷۲	۰/۷۰٥	۰/۷۸٤	۰/٥۸۹
کردکوی	RMSE	۹۷/۱۸۹	۷٦/٦۳۷	۷٥/۲۹۹	۷٥/۱۰۹	۷۰/٤٤۱	۷٤/۰۲۲	۷٤/۱۲۰	۹۷/۳۰۹
	MAE	۸/۰۳	۲۰/۰۲	۳۹/۲۳	٥۰/۷۱	٥۱/۱۲	٥۱/۹۷	٥۳/٤٥	٦۷/٤٥
	R^2	۰,٦٥	۰/۷۳٥	۰/۷٥	۰/۷٥٥	۰/۸۰۱	۰/۷۹۱	۰/۷۷۷	۰/٦
بندر ترکمن	RMSE	۹۹/۰٦	۷٤/٦٦	۸۹/۳٤	٦۸/۲۲	۸٤/۳۱	٥٤/۳٦	٥٤/۳٦	۸۱/۳۹
	MAE	۲۳/۳٤	٤۳/۳۱	٥٥/۰٥	٤٥/٦۷	٥۸/۱۳	۳٤/٤٤	۳٤/٤٤	٥٥/۷
	R^2	۰/٦٥	۰/٦۹	۰/٦۷	۰/۸۷	۰/٦۷	۰/۸٤	۰/۸٤	۰/٦۹
علی آباد	RMSE	۱۰۲/۰٥۳	۸۲/۸٥۸	۷۳/۹۲٦	۸٦/۱۱٥	۹۲/۲۹۹	۹۲/۰۲٤	۸۰/۹۰۹	۷٦/۲۱٥
	MAE	۲۹/٤	٥/۱	۳۳/٦۷	٥۹/٤٦	٦۳/۰۱	٦۲/۸۹	٥٤/۰۷	٥۷/٥٦
	R^2	۰/۷۲	۰/۷٤۸	۰/۷۱۹	۰/٦۸۲	۰/٦٦	۰/٦٦۲	۰/٦۸٤	۰/۷۹٦
مینودشت	RMSE	۹۸/۰٤۱	٥۷/۹۳	٦۱/۰۳۹	۱۰/٦۷٤	٥٤/۰٦۷	۷۳/۲۰۳	۷۷/۸۹٤	٥٤/۸٤۲
	MAE	٤۱/٦٦	٤/۳۲	۳۰/۹٤	۰/۸۷	۳۳/۳٦	٤۳/٦٥	٥۷/٤۸	۳۷/۱۲
	R^2	۰/۷۹۳	۰/۸۱٦	۰/۷٤۸	۰/۹۸۸	۰/۸۸۹	۰/۷۲۹	۰/۷٤	۰/۸۷۸

همانطور که از جدول (۶) مشخص است نتایج آزمون مدل بردار پشتیبان ارتقا یافته با ورودی های سناریو ۴ (دمای میانگین، دمای میانگین حداقل، دمای میانگین حداکثر، تبخیر) دارای کمترین مقادیر ریشه دوم مربعات خطا ومیانگین قدرمطلق خطا و همچنین بیشترین مقادیر ضریب تعیین در شهرهای گرگان (۶۵/۴۷۲، ۴۶/۷۷، ۰/۹۳۷)، بندر ترکمن (۶۸/۲۲، ۴۵/۶۷، ۰/۸۷) و مینودشت (۱۰/۶۷۴، ۰/۸۷، ۰/۹۸۸) می‌باشد. اما در شهر گنبد سناریو ۳ با مقادیر ۳۵/۷۲۹، ۱/۵۱ و ۰/۸۶۸ به ترتیب کمترین مقادیر ریشه دوم مربعات خطا ومیانگین قدرمطلق خطا و بالاترین مقادیر ضریب تعیین می باشد. در شهر کردکوی نیز سناریو ۵ با ورودی های (دمای میانگین، دمای میانگین حداقل، دمای میانگین حداکثر، تبخیر، نقطه شبنم) به ترتیب دارای مقادیر بالاترین مقادیر ضریب تعیین، میانگین قدرمطلق خطا و کمترین مقادیر ریشه دوم مربعات خطا می باشد. همچنین بررسی جدول (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 7، 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.

Archive of SID.ir

Archive of SID.ir



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

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

در جداول(۷) و (۸) نتایج معیارهای ارزیابی برای مرحله آزمون ترکیبات مختلف برای پیش‌بینی تبخیر و تعرق مرجع با استفاده از مدل یادگیری ترکیبی متا در شهرهای گرگان، گنبد، کردکوی، بندر ترکمن، علی آباد،

Archive of SID.ir

Archive of SID.ir

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	۷/٦٦٦	۷/٥٦۱	۸/٤۰۱	۷/۳۹۳	٦/۸۰۸	۷/۱٥۹	۷/٦۱٥
	MAE	۰/۲٤	۰/۲۹	۰/۰٥	۰/۰٥	۰/٤٦	۰/٦۲	۰/۲۱	۰/۲۲
	R^2	۰/۹۹۲	۰/۹۹۳	۰/۹۹	۰/۹۹۲	۰/۹۹٤	۰/۹۹٥	۰/۹۹٤	۰/۹۹
گنبد	RMSE	۹/٤٥۱	۷/۹۸۱	۷/۸۱۱	۸/۳٥۹	۸/٤۲۸	٦/٥٥۳	٦/۸۹۹	۹/۰۳۷
	MAE	۰/٥	۰/۰۷	۰/۱۳	۰/۱۳	۰/۲٤	۰/۲۳	۰/٤۷	۰/٤۱
	R^2	۰/۹۹۱	۰/۹۹۳	۰/۹۹٤	۰/۹۹۳	۰/۹۹۳	۰/۹۹٥	۰/۹۹٥	۰/۹۹۲
کردکوی	RMSE	۹/٦٦۷	۸/٤٦٤	۸/۲۹۸	٦/٦٥٥	۸/۰۹۸	٦/۹۹۲	٦/۸۷۳	۹/۱٦۱
	MAE	۰/٥۹	۰/۱٦	۰/۲٤	۰/٦۱	۰/۱٥	۰/۳	۰/۷۱	۰/۳۱
	R^2	۰/۹۹	۰/۹۹۲	۰/۹۹۳	۰/۹۹۲	۰/۹۹۳	۰/۹۹٥	۰/۹۹٥	۰/۹۹
بندر ترکمن	RMSE	۷/۳٥٦	۱۸/۲۲۲	۷/۰۲۳	٦/۲۹	۸/٤۲۸	۷/۰۸۲	۱٤/۲۲۹	۷/٥٦۱
	MAE	۰/۲٥	۱/۲۹	۰/۲۱	۰/۲٤	۰/۲٤	۰/٥٦	۱/٤۹	۱/۰۱
علی آباد	R2	۰/۹۹٥	۰/۹٦۸	۱	۰/۹۹٦	۰/۹۹۳	۰/۹۹٥	۰/۹۸	۰/۹۹
	RMSE	۹/٦۹٤	۸/۲٤	۸/۰۹٤	۸/۲٦٦	۸/۰	۷/۰۲۸	٦/۹۰٦	۸/۹۰۹
	MAE	۰/٤۳	۰/۰٦	۰/۳۷	۰/۰۱	۰/۲۱	۰/۲۹	۰/۰۷	۰/٦۹
	R^2	۰/۹۹	۰/۹۹۳	۰/۹۹۳	۰/۹۹۳	۰/۹۹۳	۰/۹۹٥	۰/۹۹٥	۰/۹۹۲
مینودشت	RMSE	۱۳/۰۳۱	۱۱/۷۲۹	۱۰/٦۲٤	۱۳/٤۰۳	۱۰/۸۰۸	۱۱/٦	۱۱/۷۹٥	۱۰/٤۷۳
	MAE	۱/۰۸	۰/۷۱	۰/۷۸	۰/۷۹	۰/۱	۰/٤۹	۰/۲۲	۱/۰٤
	R^2	۰/۹۸	۰/۹۸٤	۰/۹۸۷	۰/۹۷۹	۰/۹۸٦	۰/۹۸٤	۰/۹۸۳	۰/۹۸۷

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

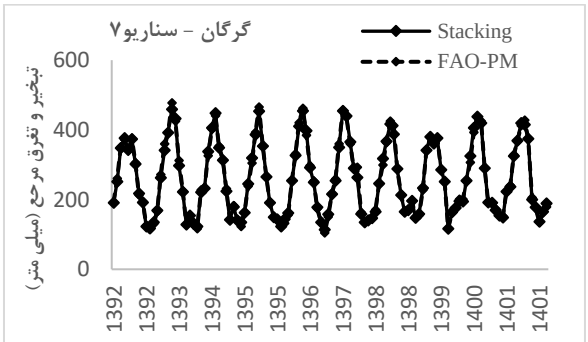
		Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
گرگان	RMSE	۹/٥۰۸	۸/۰٥۸	۸/۰۳٥	۸/٦۹٥	٦/۹۹۲	۷/۰۹٤	٦/۸٤۹	۸/۳۱٥
	MAE	۰/۰۸۸	۰/٥	۰/٦۱	۰/۲۲۳	۰/۳٦	۰/٥۹	۰/۲٥	۰/۷٤
	R^2	۰/۹۹۲	۰/۹۹٤	۰/۹۹	۰/۹۹۳	۰/۸۸٦	۰/۹۹٦	۰/۹۹٦	۰/۹۹
گنبد	RMSE	۱۰/۷۹٥	۹/۳۳۲	۹/۳۷۹	۱۰/۳۲۱	۱۰/۲۰٦	۹/۹۱۹	۱۰/٤۸۲	۱۱/۸۲
	MAE	۰/۱٤	۰/۱٤	۰/۷۲	۰/۱۱	۰/٥٦	۰/۰۸	۰/۰۱	۰/۱۲
	R^2	۰/۹۸۷	۰/۹۹۱	۰/۹۹۱	۰/۹۸۹	۰/۹۸۹	۰/۹۹	۰/۹۸۹	۰/۹۸٥
کردکوی	RMSE	۱۱/۳٤۷	۹/۱۰٤	۹/٦۷۱	۱۱/۲۳٦	۱۰/۲۹۹	۱۰/۳٦۷	۱۰/۳۲۲	۱۱/٥۲۲
	MAE	۰/۳۱	۰/٤٤	۰/۲٥	۰/۱۱	۰/۱	۰/٥	۰	۱/۳٥
	R^2	۰/۹۸٦	۰/۹۹۱	۰/۹۹	۰/۹۸٦	۰/۹۸۹	۰/۹۸۹	۰/۹۸۹	۰/۹۹
بندر ترکمن	RMSE	۹/۰٦۱	۱۹/۷۷۹	٦/٦٥۳	٦/٦۰۷	۱۰/۲۰٦	٦/٥٦۱	۱٥/۰۰۲	۸/۱۲٥
	MAE	۱/۳٦	٤/۷۸	۰/۱٦	۰/۱٦۱	۰/٥٦	۰/۸	۳/۱۸	۰/۰٦
	R^2	۰/۹۹۲	۰/۹٦۲	۰/۹۹	۰/۹۹٥	۰/۹۸۹	۰/۹۹٦	۰/۹۷۸	۰/۹۹۳
علی آباد	RMSE	۱۰/۳۸۲	۹/۱۲۳	۹/٦۸٤٥	۱۰/۱٤	۱۰/٥۱۷	۱۰/۳۸۸	۹/٥٥٥	۱۰/۳۹۳
	MAE	۰/٤۳	۰/۳۳	۰/٥٥	۰/٤۸	۰/٦٦	۰/۲۳	۰/٥۳	۰/٦۹
	R^2	۰/۹۹	۰/۹۹۱	۰/۹۹	۰/۹۸۹	۰/۹۸۸	۰/۹۸۹	۰/۹۹	۰/۹۸۹
مینودشت	RMSE	۱۱/۱۱۳	۹/٤۹۱	۸/۸۳	۹/٤٦۹	۸/۷۳	۹/٥٥۱	۹/٤۹۸	۹/۹۷٦
	MAE	۱/۷۹	۰/۷۳٤	۱/۲۲	۱/۲	۰/۹۷	۰/۷۱	۰/۷۷	۰/۷۷
	R^2	۰/۹٦۸	۰/۹۹	۰/۹۹۱	۰/۹۹	۰/۹۹۲	۰/۹۹	۰/۹۹	۰/۹۸۹

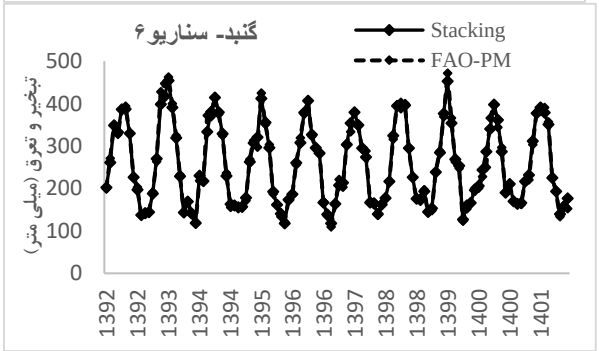
همانطور که از جدول (۸) مشخص است نتایج آزمون مدلیادگیری ترکیب متا با ورودی های سناریو ۶ (دمای میانگین، دمای میانگین حداقل، دمای میانگین حداکثر، تبخیر، نقطه شبنم، میانگین رطوبت نسبی) دارای

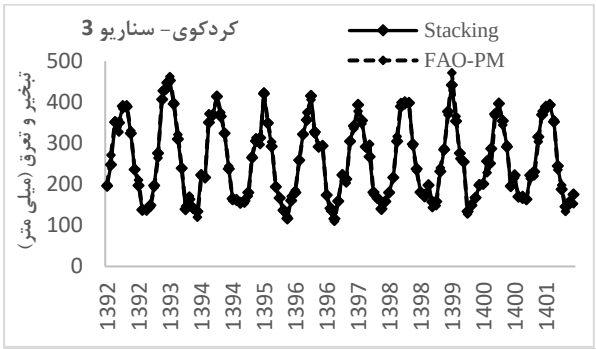
Archive of SID.ir

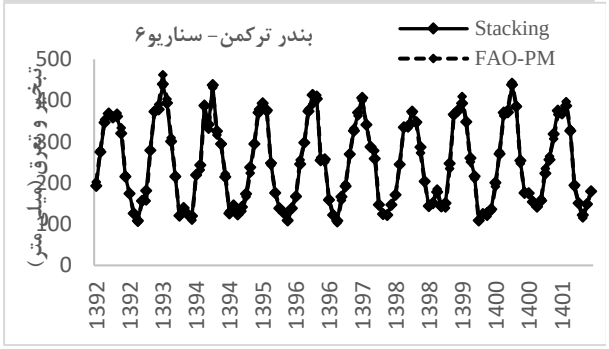
Archive of SID.ir

کمترین مقادیر ریشه دوم مربعات خطا ومیانگین قدرمطلق خطا و همجنین بالاترین مقادیر ضریب تعیین در شهرهای بندر ترکمن (۶/۵۶۱، ۰/۸، ۰/۹۹۶)، گنبد(۹/۹۱۹، ۰/۰۸، ۰/۹۹)، می‌باشد. اما در شهر گرگان سناریو ۷ با مقادیر ۶/۸۴۹، ۰/۲۵ و ۰/۹۹۶ به ترتیب کمترین مقادیر ریشه دوم مربعات خطا ومیانگین قدرمطلق 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، ۹/۱۲۳) دارای حداکثر مقادیر ضریب تعیین، میانگین قدرمطلق 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 (۰/۹۷) و کمترین ریشه دوم مربعات خطا (۸/۷۳) می‌باشد.در شهر کردکوی نیز سناریوی ۳ با داشتن بالاترین ضریب تعیین (۰/۹۹) و کمترین میانگین قدر 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 می‌باشند و همجنین در شهر مینودشت بعد از مدل ۵، مدل ۳و سپس مدل ۴ دارای عملکرد مناسب می‌باشند. 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 ورودی‌های انتخاب شده برای شهرهای مورد مطالعه نشان داده شده است



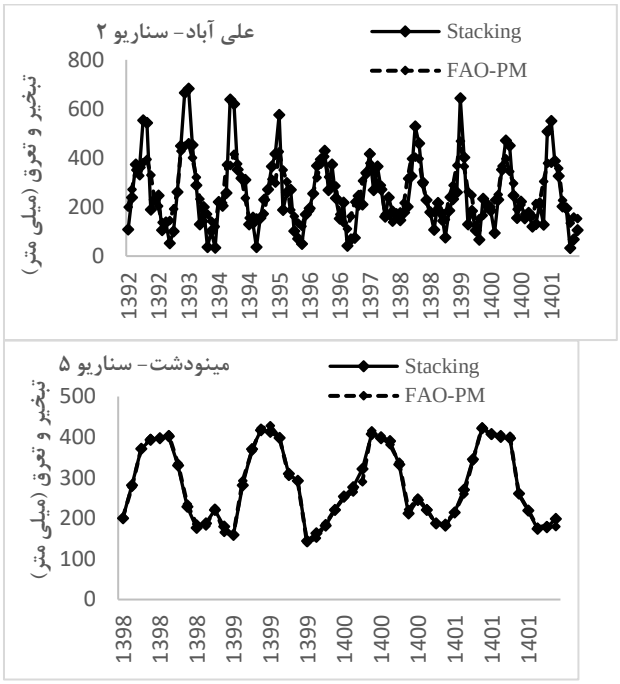






Archive of SID.ir

Archive of SID.ir



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

مقایسه نتایج بهترین ورودی مدل های مورد مطالعه

مدل های ANN-MLP, ESVM, Staking با ورودی‌های مختلف برای پیش‌بینی پارامترتبخیر و تعرق مرجع استان گلستان مورد بررسی قرار گرفت و با توجه به ضرایب آماری مقایسه خروجی مدل با مقادیر مشاهداتی داده‌های آزمون بهترین مدل ها به ترتیب صحت خروجی انتخاب گردید. با توجه به اینکه تمامی این ورودی‌ها قابل‌قبول نیستند، بنابراین با توجه به مقایسه خروجی به دست آمده از مدل ها (با ورودی‌های مختلف) با مقادیر مشاهده شده، تعدادی از این ورودی‌ها به‌عنوان ورودی‌های برتر انتخاب شدند که ضرایب مربوط به داده‌های آزمون این مدل در (جدول ۹) ارائه شده است.

Archive of SID.ir

Archive of SID.ir

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

	TEST	ANN-MLP	RF	ESVM	DL	Staking	GLM
گرگان	RMSE	۱۸/۵	۸/۳۶۶	٦٥/٤٧٢	۱٥/٥۲٦	٦/۸٤۹	۲٤/۰۸٤
	MAE	۲/۰۱	۰/۷۱	٤٦/۷۷	۱/۹۹	۰/۲٥	۰/٤۱
	R^2	۰/۹۷	۰/۹۹٤	۰/۸۳۷	۰/۹۸	۰/۹۹٦	۰/۹٥
گنبد	RMSE	۲٤/٦۱٤	۱۱/٥۳۱	۳٥/۷۲۹	۲٤/۲۱۹	۹/۹۱۹	۳۰/۹٦۹
	MAE	۷/۲٤	۰/۷٦	۱/٥۱	۲/۰۱	۰/۰۸	۱/۲۷
	R^2	۰/۹۳٥	۰/۹۸۷	۰/۸٦۸	۰/۹٤۱	۰/۹۹	۰/۸۹۷
کردکوی	RMSE	۲٥/۱٥۹	۱۱/٥۳۱	۷۰/٤٤۱	۲۳/۲٤۷	۹/٦۷۱	۳۱/۳۱۹
	MAE	۲/۲۹	۰/٥۹	٥۱/۱۲	۰/۲۸	۰/۲٥	۱/۳۲
	R^2	۰/۹۳	۰/۹۸٦	۰/۸۰۱	۰/۹٤	۰/۹۹	۰/۸۹
بندر ترکمن	RMSE	۱٤/۳۷۹	۷/۰٤۱	٦۸/۲۲	۱۳/٦۰۷	٦/٥٦۱	۱۷/۹۲٦
	MAE	۱/۰۹	۱/۲۳	٤٥/٦۷	۱/٥۲	۰/۸	۰/۱٥
	R^2	۰/۹۷۹	۰/۹۹٥	۰/۸۷	۰/۹۸۲	۰/۹۹٦	۰/۹٦۸
علی آباد	RMSE	۲٥/۷۰٦	۱۱/۷۰۳	۷٦/۲۱٥	۲٦/٦٤۲	۹/۱۲۳	۲۲/۸۷۸
	MAE	۷/٦۹	۰/۲۳	٥۷/٥٦	۰/۸۹	۰/۳۳	۱/۲٦
	R^2	۰/۹۳٥	۰/۹۸٦	۰/۷۹٦	۰/۹۲٥	۰/۹۹۱	۰/۹٤۸
مینودشت	RMSE	۱۳/۹٦۸	۱۰/٤۹٤	۱۰/٦۷٤	۲۷/٤۷۲	۸/۷۳	۳۰/۲۷۲
	MAE	۲/٤٥	۰/۰۳	۰/۸۷	۲۲/۷۳	۰/۹۷	۱/۰۹
	R^2	۰/۹۷۸	۰/۹۸۸	۰/۹۸۸	۰/۹۷۳	۰/۹۹۲	۰/۸۹۷

همانطور که از بررسی نتایج در جدول (۹) مشاهده می‌شود در همه شهرها مدل های پیش بینی 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 می-باشد. همینطور از جدول مشاهده می شود که بعد از مدل یادگیری ترکیبی متا در همه شهرها مدل RF و سپس مدل DL از دقت بیشتری نسبت به بقیه مدل ها برخوردار می-باشند. 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 مورداستفاده 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 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 حداقل 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 (Ikram et al., 2022؛ Kushwaha 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(Chen et al., 2020؛ Banerjee et al., 2024) . 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

Archive of SID.ir

Archive of SID.ir

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 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

.

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 شماره۱. 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.(۱۵)۵.

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): ۸۸-۷۲.

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 شهابی، م. ۱۳۸۶. مدیریت ریسک خشکسالی با شناخت میکروکلیماهای 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): ۴۵-۳۳.

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 evaportation 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.

Guven, 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.

Archive of SID.ir

Archive of SID.ir

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. Landeras, 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.

Archive of SID.ir