

Evaluation of the Performance of CANFIS, MLPNN, MLR and M5 Models in the Simulation of Meteorological Drought Index (Case Study: Kermanshah Synoptic Station)

H. Mazandarani Zadeh^{1*} and F. Khodabakhshi²

*1** - Corresponding Author, Associate Professor, Department of Water Engineering and Sciences, Imam Khomeini International University, Qazvin, Iran. (mazandaranzadeh@eng.ikiu.ac.ir)

2 - PhD Student, Department of Water Engineering and Sciences, Imam Khomeini International University, Qazvin, Iran.

ARTICLE INFO

Article history:

Received: 11 November 2022

Revised: 22 June 2022

Accepted: 26 June 2022

Keywords:

drought index, drought prediction, fuzzy-neural model, decision tree.

TO CITE THIS ARTICLE :

Mazandarani zadeh, H., Khodabakhshi, F. (2024). 'Evaluation of the Performance of CANFIS, MLPNN, MLR and M5 Models in the Simulation of Meteorological Drought Index (Case Study: Kermanshah Synoptic Station)', *Irrigation Sciences and Engineering*, 47(1), pp. 83-98. doi: 10.22055/jise.2023.42231.2046.

Introduction

Drought is one of the most destructive phenomena in the world, especially in Iran. The timely prediction of drought and its severity can make it easier to take the necessary measures to combat this phenomenon. Different methods have been proposed to predict droughts; however, what matters is which method can make the predictions more accurate. Many researchers have compared the CANFIS model with other models such as neural networks and linear regression Malik and Kumar (2020b); Malik et al(2020a); Malik et al (2019), but it has not been tested against the M5 tree model. In this study, CANFIS, M5, MLPNN and MLR models have been used to predict drought in Kermanshah synoptic station, to enhance the accuracy of drought prediction by using a variety of modeling methods in addition to the influential variables of the SPI index.

Methodology

This study examined the performance of the CANFIS fuzzy-neural model against other models, such as MLPNN, MLR, and M5 decision tree model, in predicting the SPI drought index in timescales of 12, 9, 6, 3, 1, and 24 months, for 70 months. The SPI index was developed by McKee and his colleagues at Colorado State University in 1993 (McKee et al., 1993). A lack of rainfall can be calculated based on the probability of occurrence over a range of times from one month to 48 months utilizing this index. The optimal input was selected by using autocorrelation and partial autocorrelation analyses. In order to determine the relationship between the PACE charts and significant time delays for each index, MINITAB software was utilized to extract the PACE charts and calculate the significant time delays. In the context of different scenarios, the relationship between these variables is assessed using the CANFIS, MLR, MLPNN, and M5 tree models, ensuring that 70% of the data were used for training, 15% were checked for validation, and 15% were used for testing. CANFIS, MLR, MLPNN, and M5 tree models were evaluated by root mean square error (MSE), root mean square error (RMSE), standard deviation (MAD), coefficient of determination (R²), and visual interpretation using scatter diagrams. In order to implement the CANFIS and MLPNN fuzzy neural models, the NeuroSolution software was used, and in order to

model the M5 and MLR decision tree algorithms, the Weka software prepared by researchers at Wikato University was used.

Results and discussion

Kermanshah station receives an annual rainfall of 429.6 mm. The rainfall at Kermanshah meteorological station has been lower than the average level for three consecutive periods. The first period is from 1951 to 1956, the second period is from 1958 to 1961, and the third period is from 1988 to 2015. The highest amount of decrease in 2021 was recorded at Kermanshah station with about 299 mm compared to the average and the highest amount of increase was recorded in 1969 with about 355 mm compared to the average. The SPI index with a period of 1 month has a lower coefficient of determination in all models than other indices. This can be explained by the relatively poor performance of the models during this period. In general, the SPI index has less fluctuations when its time scale increases; on the other hand, droughts with longer periods may show greater severity. As an example, the value of this index will be greater at the end of a six-month period of low rainfall compared with the same time and on a three-month basis since in the six-month scale, the effect of the entire period of low rainfall is considered, while in the three-month scale, only the effect of the two penultimate months is considered. Based on the scatter diagram, it can be seen that the performance of the models in the time step of one, three and six months was not suitable in the limit values; however, from the time step of nine months onwards, the conditions have improved in all the models and accurately simulate the behavior of the model.

Conclusion

M5 decision trees with coefficients of determination equal to 0.93 and mean square errors equal to 0.248 performed better than other models. Furthermore, the mean square error of the CANFIS, MLR, and MLPNN models was 0.307, 0.399, and 0.312, respectively, indicating that the CANFIS neural-fuzzy network model performed better in predicting the drought index as compared with MLPNN and MLR. Based on statistical calculations and network evaluation indices, it was found that the choice of time step has a significant impact on the results of the modeling process. In all models, the correlation between observed drought and calculated drought was more acceptable when time steps were of 9 months or more. According to the results, the M5 tree model was recognized as the best model among the four investigated models based on all evaluation criteria. Additionally, the M5 tree model demonstrated a relatively high level of predictive capability by providing practical and understandable linear relationships that are easy to interpret. According to CANFIS network, which is based on fuzzy sets, the drought of Kermanshah climatic region was successfully predicted with relatively high reliability.

Acknowledgment

The authors would like to thank the staff of the National Meteorological Organization for their assistance in providing the data for this research.

References

- 1- Malik A, Kumar A, Salih S.Q, Kim S, Kim N.W, Yaseen, Z.M. and Singh, VP., 2020a Drought index prediction using advanced fuzzy logic model: Regional case study over Kumaon in India. *Journal PLoS*, 15(5), pp. 256-271.
- 2- Malik A. and Kumar A., 2020b Meteorological drought prediction using heuristic approaches based on effective drought index: a case study in Uttarakhand. *Arabgeo* 13(2), pp. 27-39.
- 3- Malik A, Kumar A, and Singh R.P., 2019 Application of Heuristic Approaches for Prediction of Hydrological Drought Using Multi-scalar Streamflow Drought Index. *Water Resource Manage* 33(2), pp. 3985–4006.

- 4- McKee T. Doesken J, and Kleist, D., 1993 the relationship of drought frequency and duration to time scales. Proc. of the 8th Conference on Applied Climatology, *American Meteorological Society, Boston*, 12(4), pp.179-184.



© 2024 Shahid Chamran University of Ahvaz, Ahvaz, Iran. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0 license) (<http://creativecommons.org/licenses/by/4.0/>).

ارزیابی عملکرد مدل‌های CANFIS، MLPNN، MLR و M5، در شبیه‌سازی شاخص خشکسالی هواشناسی (مطالعه موردی: ایستگاه سینوپتیک کرمانشاه)

حامد مازندرانی زاده^{۱*} و فریا خدابخشی^۲

^{۱*} -نویسنده مسئول، دانشیار گروه علوم و مهندسی آب، دانشگاه بین‌المللی امام خمینی (ره)، قزوین. mazandaranizadeh@eng.ikiu.ac.ir

^۲ - دانشجوی دکتری گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.

دریافت: ۱۴۰۱/۰۸/۲۰

بازنگری: ۱۴۰۲/۰۴/۰۱

پذیرش: ۱۴۰۲/۰۴/۰۵

چکیده

پیش‌بینی به‌موقع خشکسالی و شدت بروز آن، می‌تواند در اتخاذ تمهیدات لازم برای مقابله با این پدیده اثرگذار باشد. استان کرمانشاه در دهه اخیر به یکی از کانون‌های اصلی بحران خشکسالی در کشور تبدیل شده است. در این پژوهش به مقایسه مدل فازی-عصبی CANFIS با مدل‌های دیگر شامل MLPNN، MLR و مدل درخت تصمیم‌گیری M5 در پیش‌بینی شاخص خشکسالی SPI در مقیاس زمانی ۱، ۳، ۶، ۹، ۱۲ و ۲۴ ماهه، به مدت ۷۰ سال پرداخته شده است. برای انتخاب بهینه ورودی از آنالیز خودهمبستگی و خودهمبستگی جزئی استفاده شد. نتایج بررسی نشان داد که درخت تصمیم‌گیری M5 با ضریب تعیین برابر با ۰/۹۳ و میانگین مربعات خطا برابر با ۰/۲۴۸ نسبت به سایر مدل‌ها عملکرد بهتری داشته است همچنین میانگین مربعات خطا در مدل‌های CANFIS، MLR و MLPNN به ترتیب ۰/۳۰۷، ۰/۳۹۹ و ۰/۳۱۲ مشخص کرد که مدل شبکه عصبی-فازی CANFIS در مقایسه با MLPNN و MLR عملکرد بهتری را در پیش‌بینی شاخص خشکسالی داشته است. بر اساس محاسبات آماری و شاخص‌های ارزیابی شبکه مشخص شد که انتخاب گام زمانی تأثیر زیادی در نتایج مدل‌سازی دارد به طوری که همبستگی با گام‌های زمانی نه ماهه و بیشتر در تمامی مدل‌ها نتایج قابل قبول تری بین خشکسالی مشاهده شده و خشکسالی محاسبه شده ارائه داد. در مجموع نتایج نشان داد در برآورد خشکسالی مدل درختی M5 مدلی کارآمد است که می‌توان برای تسهیل توسعه و پیاده‌سازی استراتژی‌های مدیریتی به منظور جلوگیری از ایجاد خشکسالی مفید است.

کلیدواژه‌ها: مدل فازی-عصبی، پیش‌بینی خشکسالی، شاخص خشکسالی، درخت تصمیم‌گیری.

مقدمه

در دهه اخیر خشکسالی به یکی از ویژگی‌های زبان بار اقلیمی کشور تبدیل شده است. پایش و تحلیل آثار خشکسالی از نیازهای اساسی برنامه‌ریزی‌های مدیریت منابع آب محسوب می‌شود. از این رو توسعه و استفاده از مدلی که در عین سادگی بتواند خشکسالی آینده را به صورت کوتاه‌مدت و یا بلندمدت، پیش‌بینی کند کمک بزرگی به مدیران و برنامه‌ریزان خواهد بود.

به طور کلی اکوسیستم‌های طبیعی، همراه با پیچیدگی، پویایی و عدم قطعیت هستند. منطق فازی ابزاری توانمند در مواجهه با ابهام در پدیده‌ها است. منطق فازی با استفاده از مفاهیم ساده و انعطاف‌پذیر، می‌تواند در مدل‌سازی داده‌های مبهم و پیچیده کارساز واقع شود. منطق فازی در بسیاری از مباحث مرتبط با منابع آب و خاک هنوز به طور جدی مورد استفاده قرار نگرفته است. هرچند که استفاده از سیستم‌های مبتنی بر قوانین فازی به دلیل ذات تکرار شونده خشکسالی و وجود عدم قطعیت در داده‌ها رو به گسترش است. برخی محققین برای پیش‌بینی خشکسالی، دو روش رگرسیون آماری و فازی را مورد مقایسه قرار داده‌اند (Malik et al., 2020). نتایج مقایسه مدل CANFIS با مدل‌های MLR و MLPNN نشان داد که این مدل از توانایی

بیشتری در مقایسه با سایر مدل‌ها برخوردار است (Malik et al., 2020). در تحقیقی دیگر توانایی مدل CANFIS در پیش‌بینی شاخص خشکسالی هیدرولوژیکی SDI مورد بررسی قرار گرفت. نتایج حاکی از برتری این مدل نسبت به مدل رگرسیون آماری است (Malik et al., 2019). استفاده از مدل CANFIS برای مدل‌سازی تبخیر و تعرق مرجع روزانه (ETO) با استفاده از پارامترهای جوی روزانه نشان داد این مدل به طور قابل توجهی بهتر از مدل‌های معمولی بوده و می‌تواند یک جایگزین بهبود یافته برای مدل‌های فعلی باشد (Aytek., 2009). همچنین از روش فازی برای بررسی تغییرات ویژگی‌های خشکسالی همچون درصد فراوانی، دوره‌های خشک و تر و روند تغییرات خشکسالی تحت تأثیر تغییر اقلیم استفاده شده است (Koochi et al., 2022).

با استفاده از مدل CANFIS، سری زمانی و نمایه‌های آماری اقلیمی در پیش‌بینی خشکسالی در ایستگاه سینوپتیک بیرجند نشان داد این شبکه با اعتبار نسبتاً خوب و تعداد ورودی‌های کمتر نسبت به مدل‌های آماری، با موفقیت در پیش‌بینی خشکسالی منطقه اقلیمی بیرجند قابل استفاده است (Rezaei and Memarian., 2016). در کنار CANFIS می‌توان از مدل‌های هوشمند دیگری برای پیش‌بینی خشکسالی

تأثیر شرایط حاکم به مقادیر شاخص خشکسالی می‌باشد. پیش‌بینی خشکسالی با روش‌های مختلفی انجام شده است. مدل CANFIS با مدل‌هایی مثل شبکه عصبی و رگرسیون خطی توسط پژوهشگران مختلف مقایسه شده است. از طرفی، در محدوده مورد مطالعه و بعضاً سایر مناطق، مقایسه‌ای بین CANFIS و M5 انجام نشده است از این رو در این پژوهش نیز سعی بر این است که مقایسه CANFIS با M5 به‌عنوان یک روش متداول، انجام گردید.

روش تحقیق

منطقه مورد مطالعه

استان کرمانشاه در میانه ضلع غربی کشور بین ۳۳ درجه و ۴۱ دقیقه تا ۳۵ درجه و ۱۷ دقیقه عرض شمالی و ۴۵ درجه و ۲۴ دقیقه تا ۴۸ درجه و ۶ دقیقه طول شرقی قرار دارد. این استان از شمال به استان کردستان، از جنوب به استان‌های ایلام و لرستان، از شرق به استان همدان و از غرب به کشور عراق محدود شده است. همچنین ارتفاع متوسط استان از سطح دریای آزاد حدود ۱۲۰۰ متر است (شکل ۱). بر اساس روش دومارتن ۵۳/۶ درصد مساحت استان دارای اقلیم نیمه‌خشک و ۳۹/۹ درصد دارای اقلیم مدیترانه‌ای است. اقلیم نیمه مرطوب حدود ۳/۵ درصد، اقلیم خشک حدود دو درصد و در نهایت کمترین مساحت استان دارای اقلیم مرطوب (یک درصد) است. در این تحقیق از آمار و اطلاعات ایستگاه سینوپتیک شهر کرمانشاه استفاده شده است. این ایستگاه در سال ۱۹۵۰ تأسیس شده و در ارتفاع ۱۵۲۰ متری از سطح دریا و طول جغرافیایی ۴۷/۹ و عرض جغرافیایی ۳۴/۳ واقع شده است (Haghizadeh et al., 2019).

طول دوره آماری مورد استفاده ۱۹۵۱-۲۰۲۱ است. در این ایستگاه، ماه‌هایی وجود دارند که آماربرداری نشده‌اند. برای پر کردن خلأ آماری مزبور از همبستگی درون ایستگاهی و استفاده از نسبت موجود برای پارامترهای گرایش به مرکز نظیر میانه و میانگین استفاده شده است.

استفاده کرد. استفاده از مدل عصبی فازی تطبیقی در پیش‌بینی خشکسالی ایستگاه‌های دریاچه‌ای ارومیه نشان داد مدل سیستم استنتاج عصبی- فازی تطبیقی در تخمین خشکسالی در مقیاس طولانی‌مدت از عملکرد مطلوبی برخوردار است (Asadzadeh et al., 2016). در تحقیق دیگری خشکسالی هواشناسی، هیدرولوژیکی و کشاورزی با استفاده از روش موجک مورد بررسی قرار گرفت. خروجی این تحقیق تعیین موجک مادر بهینه برای پیش‌بینی انواع خشکسالی بر مبنای روش تلفیقی موجک- شبکه‌ی عصبی بود (Mashayekhi and Zakeri Niri., 2020). روش‌ها و مدل‌های مختلفی در قالب داده‌کاوی وجود دارد که به جستجوی رابطه و الگوی پنهان بین داده‌ها می‌پردازند. یکسری از این روش‌ها مانند مدل درختی M5 روابط و معادله‌های ساده و صریحی را بیان و نتایج مطلوبی را ارائه می‌کنند. این روش‌ها در مقابل روش‌هایی مثل شبکه عصبی مصنوعی قرار می‌گیرند که معادله مشخصی را ارائه نمی‌کنند و در اصطلاح به مدل‌های جعبه سیاه شهرت دارند. تاکنون مطالعاتی در زمینه استفاده از مدل درختی M5 به‌منظور برآورد پارامترهای هیدرولوژیکی صورت پذیرفته است. به‌عنوان مثال برآورد پیش‌بینی بارش ماهانه و مقایسه مدل درختی M5 با مدل شبکه عصبی Sattari et al (2014)، برآورد تبخیر تعرق مرجع Moradi و Rahimikhoob (2013)، پیش‌بینی خشکسالی با مدل درختی M5 Sattari et al (2016)، مقایسه مدل‌های برنامه‌ریزی ژنتیکی و مدل درختی M5 در پیش‌بینی خشکسالی Komasi et al (2018)، مقایسه‌ی مدل‌های درختی M5 و الگوریتم نزدیک‌ترین همسایگی K در پیش‌بینی بارش ماهانه (Poursalehi et al., 2020). به‌طور کلی مدل درختی M5 به لحاظ سادگی، قابل فهم بودن و ارائه روابط خطی ساده، توانسته است در سال‌های اخیر مدل قابل‌پذیرشی برای مدل‌سازی در زمینه پیش‌بینی باشد.

به‌طور کلی، یکی از چالش‌های پایش خشکسالی، تعیین شاخصی با قابلیت اطمینان بالا می‌باشد. عملکرد روش‌های مختلف شبیه‌سازی، در سری‌های زمانی شاخص خشکسالی، تحت

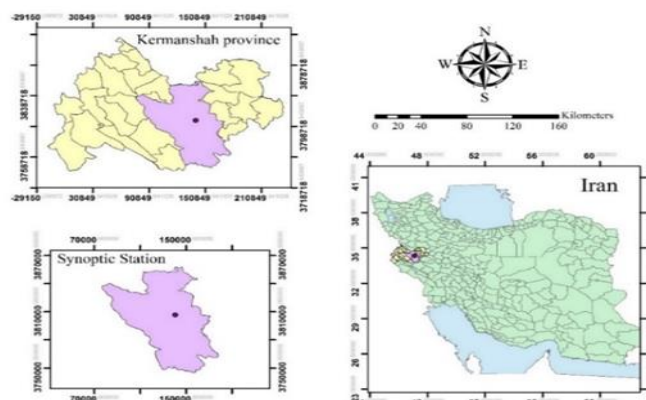


Fig.1- Map of the study area and geographical location of synoptic station.

شکل ۱- نقشه منطقه مورد مطالعه و محل ایستگاه سینوپتیک

جدول ۱- طبقه‌بندی خشکسالی با استفاده از شاخص SPI
Table 1- Classification of drought based on the SPI index

SPI category	SPI
Extremely wet	$SPI \geq +2.00$
Severely wet	$1.50 \leq SPI \leq 1.99$
Moderately wet	$1.00 \leq SPI \leq 1.49$
Mildly wet	$0.50 \leq SPI \leq 0.99$
Normal	$-0.49 \leq SPI \leq 0.49$
Mild drought	$-0.99 \leq SPI \leq 0.00$
Moderate drought	$-1.49 \leq SPI \leq -1.00$
Severe drought	$-1.99 \leq SPI \leq -1.5$
Extreme drought	$SPI \leq -2.00$

یادگیری معمولاً به‌وسیله الگوریتم‌های مختلف از جمله لونیگ-مارکوارت، گرادیان نزولی، گرادیان مزدوج و الگوریتم انتشار برگشتی انجام می‌شود

مدل رگرسیون خطی چندگانه (MLR)

با روش MLR (Multiple Linear Regression) می‌توان هم‌زمان به تحلیل و بررسی چندین متغیر مختلف پرداخت. رگرسیون چندگانه در حقیقت، ارتباط بین یک سری از متغیرهای ورودی را با متغیر خروجی موردنظر بیان می‌کند. در این تحقیق مدل MLR به‌عنوان مدلی دیگر برای ارزیابی توانایی مدل CANFIS برای پیش‌بینی عملکرد SPI انتخاب شد. مدل MLR یک ماژول خطی بین یک متغیر هدف (وابسته) و دو یا چند متغیر مستقل است (Malik et al., 2017; Malik and Kumar., 2015). معادله رگرسیون مدل MLR را می‌توان به‌صورت رابطه (۳) نوشت:

$$SPI = W_0 + W_1SPI_{t-1} + w_2SPI_{t-2} + \dots + w_kSPI_{t-n} \quad (3)$$

که در آن، SPI_{t-1} شاخص خشکسالی با یک تأخیر زمانی، SPI_{t-2} شاخص خشکسالی با دو تأخیر زمانی و ... SPI_{t-n} شاخص خشکسالی با n تأخیر زمانی به‌عنوان پارامترهای ورودی هستند. W_0 نقطه قطع معادله MLR است و W_k وزن‌های معادله MLR است.

مدل درختی M5

مدل درختی M5، نوعی مدل طبقه‌بندی و رگرسیونی است که با یک ساختار درختی وارونه که شامل یک گره ریشه در بالاترین قسمت درخت که به گره‌های دیگر و برگ‌ها منشعب می‌شود و به‌صورت نمایشی در قالب قوانین اگر - آنگاه نشان داده می‌شود. این مدل قادر به استخراج دانش به شکل روابط ریاضی از مجموعه داده‌ها است (Nourani and Molajou., 2017).

در ابتدا مدل درختی با تقسیم کردن فضای مسئله به‌صورت برگشتی یک درخت رگرسیونی می‌سازد. در این الگوریتم برای ایجاد شاخه در یک گره تقسیم از پارامتر انحراف معیار مقادیر

شاخص خشکسالی هواشناسی SPI

شاخص SPI (Standard Precipitation Index) توسط Mckee et al (1993) در دانشگاه ایالتی کلرادو معرفی شد. با استفاده از این شاخص می‌توان کمبود بارش را بر اساس احتمال رخداد برای دوره‌های زمانی مختلف از یک تا ۴۸ ماه برآورد نمود. مقدار SPI به‌عنوان یک متغیر نرمال شده از رابطه (۱) محاسبه می‌شود:

$$SPI = z = \frac{x - \mu}{\sigma} \quad (1)$$

که در آن μ و σ به‌ترتیب تخمین میانگین و انحراف از معیار جامعه می‌باشند. با داشتن مقدار SPI از معادله (۱) می‌توان وضعیت خشکسالی را از جدول (۱) برآورد نمود. مقادیر مثبت SPI معرف بارش بیشتر از میانگین و مقادیر منفی معرف بارش کمتر از میانگین است (McKee et al., 1993).

مدل شبکه عصبی پرسپترون چندلایه (MLPNN)

مدل MLPNN (Multiple-Layer Perceptron) یک مدل شبکه عصبی مصنوعی است که در آن سیستم با استفاده از ترکیب توابع ساده در لایه‌هایی با نورون‌ها (مشابه شبکه سلول مغزی) مدل می‌شود. داده‌های ورودی، وارد لایه ورودی شده و با استفاده از یک تابع مناسب پردازش می‌شوند و نتایج به لایه‌های پنهان و در نهایت به لایه خروجی منتقل می‌شوند. خروجی هر نورون با رابطه (۲) تعریف می‌شود (Talebkeikhah., 2020).

$$Y = f_k \times \left[\sum_{j=1}^{N_j} W_{jk} \times f_i \left(\sum_{i=1}^{N_i} W_{ij} X_i + b_j \right) + b_k \right] \quad (2)$$

در رابطه فوق Y نورون خروجی، f_k تابع انتقال، W_{jk} وزن b_k بایاس N تعداد ورودی ر لایه را نشان می‌دهد. وزن‌ها و بایاس با استفاده از دسته داده‌های یادگیری و کمینه کردن خطای بین خروجی‌های واقعی و محاسبه‌شده قابل تعیین هستند. فرآیند

هر گره در لایه اول رتبه عضویتی است از یک مجموعه فازی (A_1, A_2, B_1, B_2) و تعیین کننده درجه عضویت متغیر ورودی به یکی از مجموعه‌های فازی است. مجموعه‌های فازی به وسیله توابع عضویت تعریف می‌شوند. خروجی‌های این لایه، مقادیر مقدم توابع عضویت، متناسب با ورودی‌های فازی سیستم هستند. لایه دوم دریافت کننده ورودی است به شکل ضرب جفت‌های خروجی از لایه اول است. لایه سوم دارای دو مؤلفه است، مؤلفه بالایی اعمال کننده توابع عضویت بر هریک از ورودی‌ها است درحالی که مؤلفه پایینی بیانی است از شبکه عصبی که برای هر خروجی جمع وزن‌ها را محاسبه می‌کند. در لایه چهارم، گره‌های موجود به صورت تطبیق پذیر درآمده و هر تابع موجود، یک مدل درجه اول با پارامترهای حاصله ارائه می‌دهد و لایه پنجم، لایه خروجی است (Aytek., 2009). نحوه آموزش شبکه عصبی در ساختار CANFIS به صورت یادگیری نظارتی است. از این رو، با آموزش شبکه، توابع ناشناخته ارائه شده توسط داده‌های آموزشی یاد گرفته شده و متناسب با ارزش پارامترهای ورودی، خروجی تعیین می‌شود. در طی فرآیند یادگیری شبکه در ساختار CANFIS، میزان فراگیری توسط شبکه به وسیله توابع هدف به طور مرتب سنجیده می‌شود و در نهایت شبکه‌ای با کمترین میزان خطا مورد پذیرش قرار می‌گیرد (Minasny and Mcbratney., 2002).

معرفی ورودی بهینه و توسعه مدل

انتخاب ورودی بهینه و توسعه مدل متغیرهای ورودی - خروجی مناسب برای مدل سازی فرایندهای غیرخطی هیدرولوژیکی بخش مهم مدل سازی به شمار می‌رود. در این تحقیق از داده‌های بارندگی ماهانه بلندمدت برای محاسبه SPI مقیاس چند زمانه شامل یک، سه، شش، نه، ۱۲ و ۲۴ ماهه، استفاده شد. آنالیز خودهمبستگی ACF (AutoCorrelation Function) و خودهمبستگی جزئی PACF (Partial AutoCorrelation Function) برای انتخاب ورودی‌های بهینه، برای پیش بینی شاخص خشکسالی انجام شد. تابع ACF روشی برای بیان وابستگی زمان در ساختار یک سری زمانی است. رابطه تابع ACF با تأخیر K به صورت رابطه (۷) است.

$$\rho_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)} \times \sqrt{Var(Z_{t+k})}} \quad (7)$$

که در آن مقدار ضریب خودهمبستگی سری زمانی با تأخیر K و Z_t مقادیر متغیرها با داده‌های سری زمانی در مرحله زمانی t است. تابع PACF همبستگی بین Z_t و Z_{t+k} بعد از حذف وابستگی خطی مشترک متغیرهای $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$ به دست می‌آید. منظور از این همبستگی، همبستگی شرطی زیر است که

متغیر هدف به عنوان یک معیار اندازه گیری خطا در آن گره استفاده می‌شود و آزمون برای انجام عملیات تقسیم در گره مذکور انجام شده، سپس صفتی که موجب کاهش بیشتر انحراف معیار گردد به عنوان صفتی که روی آن شاخه زده شده، انتخاب می‌شود. فرمول محاسبه‌ی کاهش انحراف استاندارد SDR (Standard Deviation Ratio) به صورت رابطه (۴) است (Sattari et al., 2013).

$$SDR = Sd(T_i) - \sum_{i=1}^N \frac{|T_i|}{|T|} Sd(T_i) \quad (4)$$

در این روابط، T مجموعه‌ای از نمونه‌ها است که به هر گره وارد می‌شود، T_i نشان دهنده زیر مجموعه‌های از نمونه‌هاست که i امین نتیجه‌ی تست پتانسیلی را دارند، Sd بیانگر انحراف معیار و N تعداد داده‌ها را نشان می‌دهد.

شبکه فازی - عصبی CANFIS

این ساختار حاصل تلفیق شبکه تطبیقی عصبی با قوانین فازی است. CANFIS (CoActive Neuro-Fuzzy Inference System) می‌تواند به عنوان تخمین زننده کلی برای توابع غیرخطی مورد استفاده قرار گیرد (Jang., 1993). در واقع با تسهیم ارزش‌های عضویت فازی، قوانین فازی در این نوع از شبکه‌ها به گونه‌ای ساخته می‌شوند که بتوانند همبستگی بین خروجی‌ها را نیز در شبیه سازی لحاظ کرده و برای تسریع دریافتن جواب صحیح از آن استفاده کنند (Hemachandra and Satyanarayana., 2013). این مدل یک سیستم فازی را در یک ساختار شبکه عصبی اجرا می‌کند و برای فرآیند آموزش، از ترکیبی از روش‌های آموزش پس انتشار خطا و حداقل مربعات خطا استفاده می‌کند. مدل CANFIS یک شبکه چند لایه پیش رونده بوده که از الگوریتم‌های یادگیری شبکه‌های عصبی مصنوعی و استدلال‌های فازی برای پیش بینی متغیر خروجی بر اساس متغیر ورودی استفاده می‌کند (Firat and Gungor, 2007). مدل CANFIS انتخاب شده شامل پنج لایه است (شکل ۲). اختصاص توابع عضویت MF (Membership Functions) در شکل (2a) و ساختار کلی مدل CANFIS را با دو متغیر ورودی (x و y)، یک خروجی (c) در شکل (2b) نشان داده شده است. در روابط (۵) و (۶) مدل مرتبه اول تاکی - سوگو (Takagi Sugeno-Kang) TSK با قوانین اگر - آنگاه برای مدل CANFIS را نشان می‌دهد.

$$\text{Rule 1: IF } x \text{ is } A_1 \text{ any is } B_1 \text{ THEN } c_2 \quad (5)$$

$$= p_1x + q_1y + r_1$$

$$\text{Rule 2: IF } x \text{ is } A_2 \text{ an y is } B_2 \text{ THEN } c_2 \quad (6)$$

$$= p_2x + q_2y + r_2$$

$$MSE = \sum_{i=1}^N \frac{(SPI_{cal,i} - SPI_{per,i})^2}{N} \quad (11)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (SPI_{cal,i} - SPI_{per,i})^2}{\sum_{i=1}^N (\overline{SPI}_{cal} - \overline{SPI}_{per})^2} \quad (12)$$

که در آن‌ها $SPI_{cal,i}$ شاخص خشکسالی محاسبه شده، $SPI_{pr,i}$ شاخص خشکسالی پیش‌بینی شده و N تعداد داده‌ها است. فاکتور RMSE دقت و اعتبار دسته داده‌های آموزش و آزمون را اندازه‌گیری کرده که هرچه قدر به صفر نزدیک‌تر باشد، بیانگر خطای کمتر روش است.

نتایج و بحث

مقدار بارش سالیانه ایستگاه کرمانشاه حدود ۴۲۹/۶ میلی‌متر در سال است، در مجموع سه دوره بارشی کمتر از میانگین در سطح ایستگاه هواشناسی کرمانشاه مشاهده می‌شود شکل (۳). اولین دوره از سال ۱۹۵۱ تا ۱۹۵۶، دومین دوره از ۱۹۵۸ تا ۱۹۶۱ و سومین دوره از ۱۹۸۸ تا ۲۰۱۵؛ که سومین دوره طولانی‌ترین است. بیشترین مقدار کاهشی در سال ۲۰۲۱ در سطح ایستگاه کرمانشاه با حدود ۲۹۹ میلی‌متر نسبت به میانگین و بالاترین مقدار افزایشی نسبت به میانگین در سال ۱۹۶۹ با حدود ۳۵۵ میلی‌متر رخ داده است.

معمولاً در تحلیل سری‌های زمانی، خودهمبستگی جزئی نامیده می‌شود.

$$Corr(Z_t, Z_{t+k}) I(Z_{t+1}, \dots, Z_{t+k-1}) \quad (8)$$

برای تشخیص یک مدل آزمایشی باید حداقل ۵۰ مشاهده از سری موردنظر در اختیار باشد (Khorrim and Boghroniya., 2006).

شاخص‌های ارزیابی عملکرد

عملکرد مدل‌های MLPNN, MLR, CANFIS و مدل درختی M5 توسط ریشه میانگین مربعات خطا (Mean Squared Error) (RMSE)، جذر میانگین مربعات خطا (Root Mean Square Error) (MAD)، انحراف معیار (Mean Square Error Coefficient of Determination) (R^2)، ضریب تعیین (R^2)، ضریب تعیین (determination) و تفسیر بصری با استفاده از نمودار پراکنندگی ارزیابی می‌شوند. این آماره‌ها به ترتیب به صورت روابط (۹) الی (۱۲) ارائه می‌شوند:

$$RMSE = \sqrt{\sum_{i=1}^N \frac{(SPI_{cal,i} - SPI_{per,i})^2}{N}} \quad (9)$$

$$MAD = \frac{\sum_{i=1}^N |SPI_{cal,i} - SPI_{per,i}|}{N} \quad (10)$$

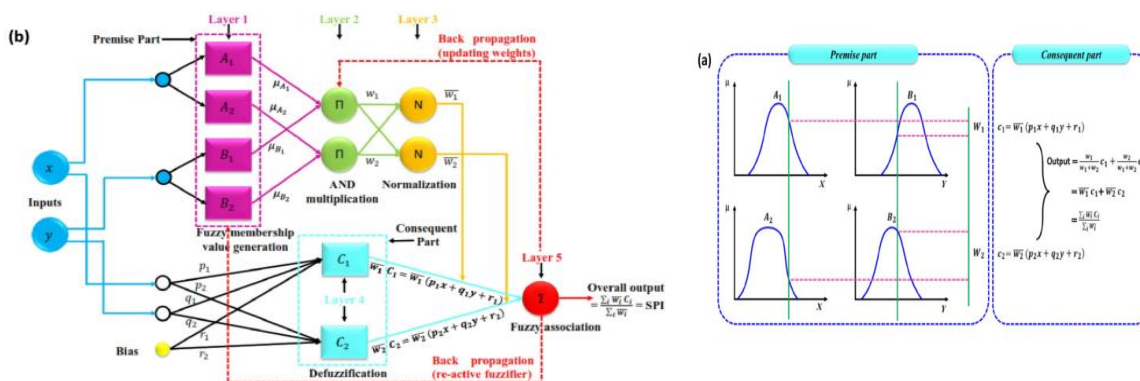


Fig. 2-a) MFs of two input variables in TSK model, and b) architecture of proposed CANFIS model. (Malik et al, 2019)

شکل ۲- a) توابع عضویت دو ورودی در مدل تاکی-سوگنو (b) ساختار کلی مدل CANFIS (Malik et al, 2019).




Fig. 3-Time series of the annual rainfall compared to the average for Kermanshah station
 شکل ۳- سری زمانی بارش سالانه نسبت به میانگین در ایستگاه کرمانشاه




Fig. 4- SPI annual drought indices for Kermanshah Station.
 شکل ۴- نمودار وضعیت شاخص خشکسالی SPI سالانه در ایستگاه کرمانشاه

در این پژوهش شاخص خشکسالی در مقیاس‌های یک، سه، شش، نه، ۱۲ و ۲۴ برآورد شده است. برای انتخاب ورودی‌های بهینه مدل، آنالیز خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) با تأخیر زمانی ۱۲ ماهه با استفاده از نرم‌افزار MINITAB انجام شد که نمودارهای تابع خودهمبستگی جزئی (PACF) در شکل (۵) نشان داده شده است.

بررسی وضعیت خشکسالی و ترسالی در ایستگاه هواشناسی کرمانشاه شکل (۴) نشان‌دهنده آن است که سه دوره خشکسالی ضعیف تا شدید در این ایستگاه رخ داده است که بین سال‌های ۱۹۸۸ تا ۲۰۱۵ شدیدترین خشکسالی‌ها بوده است؛ اما از ۲۰۱۵ تا ۲۰۲۱ نیز خشکسالی متوسط تا شدید به تناوب وجود داشته است. شدیدترین ترسالی در ایستگاه کرمانشاه بین سال‌های ۱۹۶۴ تا ۱۹۷۲ رخ داده است و بعدازاین دوره شرایط بارشی به سمت نرمال یا کاهشی بوده است.

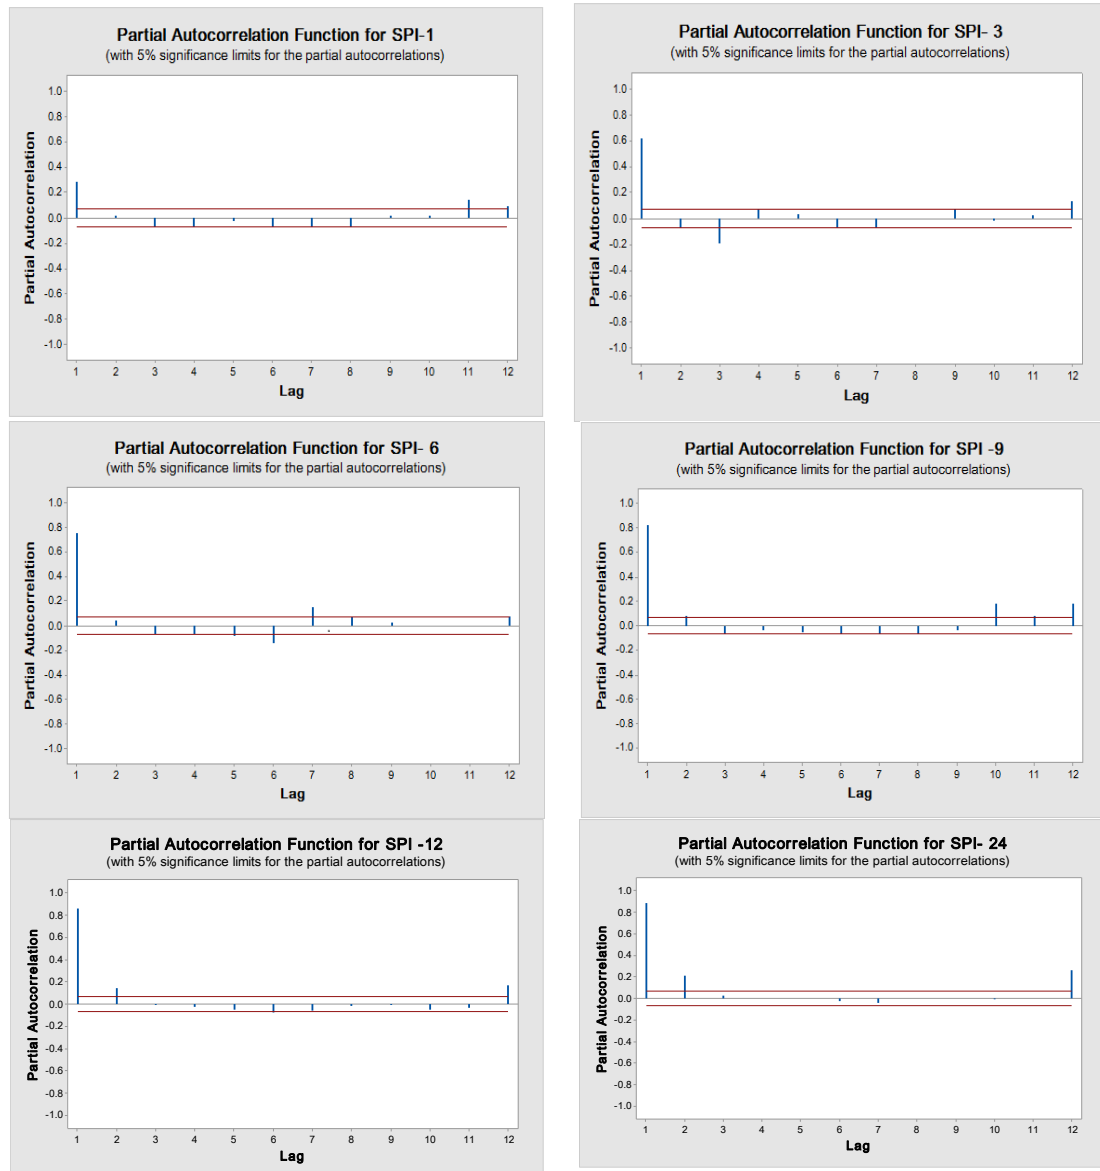


Fig. 5- The statistical calculation of the partial autocorrelation function PACF for SPI-1, SPI-3, SPI-6, SPI-9, SPI-12, and SPI-24.

شکل ۵- نمودار PACF برای شاخص خشکسالی SPI در مقیاس‌های زمانی ۱۲، ۹، ۶، ۳، ۱ و ۲۴ ماهه

مورد استفاده نیز، تابع سیگموئید (لجستیک) و همچنین از تابع گوسی در تخصیص تابع عضویت مدل استفاده شد است. بعد از مدل‌سازی بین مقادیر مشاهداتی و پیش‌بینی شده معیارهای ارزیابی محاسبه شد جدول (۳).

همان‌طور که در جدول (۳) نشان داده شده، در طی آزمون شبکه، میزان MSE و RMSE از ردیف اول تا ششم با افزایش گام زمانی شاخص خشکسالی کاهش می‌یابد به طوری که میزان MSE از ۰/۷۴۳ به ۰/۲۴۲ رسیده است که خود نشان‌دهنده کاهش حدود شش برابری میزان خطا است.

به منظور شبیه‌سازی با مدل شبکه عصبی یک رویکرد یادگیری نظارت‌شده که شامل سه لایه ورودی، پنهان و خروجی است، برای طراحی معماری مدل MLPNN استفاده شد. آموزش

پس از استخراج نمودارهای PACE و محاسبه تأخیرهای زمانی معنادار هر شاخص جدول (۲)، ارتباط این متغیرها با وضعیت خشکسالی سالانه در قالب سناریوهای مختلف به کمک مدل CANFIS، MLPNN، و مدل درختی M5 تحت شرایطی که ۷۰ درصد داده‌ها برای آموزش و ۱۵ درصد برای صحت سنجی و ۱۵ درصد در آزمون به کار گرفته شوند بررسی شدند.

برای اجرای مدل فازی-عصبی CANFIS از نرم‌افزار نروسولوشن (NeuroSolutions) استفاده شده است. دو نوع کلی از توابع عضویت فازی تابع بل و تابع گوسی در نرم‌افزار موجود است. در این مطالعه با توجه آزمون‌وخطاهای انجام‌شده، اندازه گام و نرخ گشتاور به ترتیب برابر با یک و ۰/۷ انتخاب شد. تابع انتقال

شاخص خشکسالی توسط رگرسیون خطی چندگانه نیز تخمین زده شد است جدول (۵). برای انجام این مدل سازی روش های مختلفی وجود دارد که در این تحقیق نرم افزار SPSS به کار گرفته شده است. با توجه به جدول (۵) می توان دریافت که ضریب تعیین از ۰/۳۵ به ۰/۹ رسیده که نشان از بهتر شدن نتایج در گام های زمانی بالاتر است همچنین نسبت به دو روش قبل در SPI24 ماهه ضریب تعیین بهتری دارد اما RMSE و MSE بیشتر شده است که این نشان دهنده این است که نسبت به دو روش قبلی ضعیف تر عمل کرده است.

مدل MLPNN با روش مونتیم و پس از رسیدن به ۱۰۰۰ تکرار با مقدار آستانه ۰/۰۰۱ پایان یافت جدول (۴). در جدول (۴) نتایج مدل سازی و آرایش شبکه عصبی مصنوعی آورده شده است، تعداد نرون ها با توجه آزمون و خطاهای متعدد برای هر گام های زمانی شاخص SPI به دست آمده و از الگوی خاصی پیروی نمی کنند، در بعضی از گام ها با افزایش نرون ها و گاهی نیز با کاهش نرون ها نتایج بهبود پیدا می کند. نتایج شبکه عصبی به مدل CANFIS نزدیک است در این مدل نیز با افزایش گام زمانی توانایی مدل نیز افزایش پیدا کرده است.

جدول ۲- متغیرهای ورودی و خروجی در مدل های پیش بینی خشکسالی
Table 2- Input and output variables in drought prediction models.

Num	Output	Input variables
1	SPI-1	SPI-1(t-1),SPI-1(t-11),SPI-1(t-12)
2	SPI-3	SPI-1(t-1),SPI-1(t-3),SPI-1(t-12)
3	SPI-6	SPI-1(t-1),SPI-1(t-6),SPI-1(t-7)
4	SPI-9	SPI-1(t-1),SPI-1(t-10),SPI-1(t-12)
5	SPI-12	SPI-1(t-1),SPI-1(t-2),SPI-1(t-12)
6	SPI-24	SPI-1(t-1),SPI-1(t-2),SPI-1(t-12)

جدول ۳- نتایج RMSE, MSE, MAD و R² برای گام های زمانی SPI با مدل CANFIS
Table 3- RMSE, MSE, MAD and R² values for multi-scalar SPI by CANFIS model.

Drought index	Model structure	Train				validate				Test			
		MAD	MSE	RMSE	R ²	MAD	MSE	RMSE	R ²	MAD	MSE	RMSE	R ²
SPI1	Gauss-3	0.63	0.74	0.86	0.38	0.65	0.75	0.88	0.37	0.66	0.76	0.89	0.36
SPI3	Gauss-3	0.53	0.55	0.74	0.59	0.57	0.56	0.76	0.58	0.56	0.56	0.76	0.58
SPI6	Gauss-2	0.51	0.47	0.68	0.71	0.56	0.78	0.69	0.71	0.57	0.79	0.69	0.71
SPI9	Gauss-2	0.42	0.36	0.60	0.78	0.43	0.37	0.65	0.77	0.44	0.38	0.66	0.76
SPI12	Gauss-2	0.37	0.28	0.53	0.91	0.38	0.29	0.58	0.90	0.39	0.30	0.58	0.90
SPI24	Gauss-2	0.37	0.24	0.49	0.93	0.39	0.29	0.49	0.92	0.39	0.30	0.50	0.91

جدول ۴- نتایج RMSE, MSE, MAD و R² برای گام های زمانی SPI با مدل MLPNN
Table 4- RMSE, MSE, MAD and R² values for multi-scalar SPI by MLPNN model.

Drought index	method	number of hidden layers	number of neurons	Train				validate				Test			
				MAD	MSE	RMSE	R ²	MAD	MSE	RMSE	R ²	MAD	MSE	RMSE	R ²
SPI1	Momentum	1	10	0.651	0.751	0.866	0.37	0.687	0.768	0.921	0.35	0.689	0.772	0.926	0.35
SPI3	Momentum	1	13	0.552	0.585	0.765	0.57	0.557	0.592	0.812	0.53	0.564	0.594	0.824	0.53
SPI6	Momentum	1	9	0.517	0.479	0.692	0.71	0.524	0.483	0.801	0.70	0.532	0.494	0.811	0.69
SPI9	Momentum	1	7	0.422	0.354	0.595	0.79	0.435	0.369	0.621	0.76	0.446	0.401	0.634	0.75
SPI12	Momentum	1	10	0.387	0.303	0.551	0.86	0.392	0.326	0.603	0.85	0.395	0.338	0.614	0.85
SPI24	Momentum	1	11	0.37	0.274	0.497	0.88	0.389	0.301	0.512	0.87	0.394	0.312	0.521	0.87

جدول ۵- نتایج RMSE, MSE, MAD و R² برای گام‌های زمانی SPI با مدل MLR
Table 5- RMSE, MSE, MAD and R² values for multi-scalar SPI by MLR model.

Drought index	Train				Validate				Test			
	MAD	MSE	RMSE	R ²	MAD	MSE	RMSE	R ²	MAD	MSE	RMSE	R ²
SPI1	0.757	0.85	0.922	0.35	0.823	0.940	1.085	0.34	0.813	0.96	1.019	0.34
SPI3	1.053	1.547	1.244	0.60	1.069	1.632	1.365	0.59	1.126	1.621	1.372	0.58
SPI6	0.782	0.922	0.96	0.77	0.798	1.09	1.08	0.75	0.832	1.110	1.091	0.74
SPI9	0.420	0.322	0.568	0.83	0.436	0.435	0.615	0.81	0.446	0.624	0.621	0.80
SPI12	0.402	0.273	0.522	0.89	0.424	0.289	0.584	0.89	0.436	0.592	0.598	0.88
SPI24	0.480	0.362	0.602	0.92	0.501	0.396	0.614	0.91	0.512	0.399	0.625	0.90

LM num: 1
spi24-t =
0.9906 * i»spi24-t1
- 0.1211 * spi24-t2
+ 0.0994 * spi24-t12
+ 0.0799

LM num: 2
spi24-t =
0.6448 * i»spi24-t1
+ 0.0416 * spi24-t2
+ 0.0563 * spi24-t12
- 0.0535




Fig. 6- Diagram of the M5 model tree with nine linear regression models at the leaves.

شکل ۶- نمودار درخت مدل M5 با ۹ مدل رگرسیون خطی در برگ‌ها

جدول ۶- نتایج RMSE, MSE, MAD و R² برای گام‌های زمانی SPI با مدل درختی M5
Table 6- RMSE, MSE, MAD and R² values for multi-scalar SPI by M5 model tree.

Drought index	Number of rules	Train				Validate				Test			
		MAD	MSE	RMSE	R ²	MAD	MSE	RMSE	R ²	MAD	MSE	RMSE	R ²
SPI1	2	0.664	0.769	0.877	0.44	0.721	0.828	0.926	0.42	0.732	0.831	0.931	0.41
SPI3	2	0.568	0.556	0.746	0.59	0.621	0.563	0.813	0.57	0.635	0.569	0.823	0.56
SPI6	1	0.475	0.409	0.639	0.79	0.524	0.515	0.689	0.77	0.541	0.519	0.673	0.76
SPI9	1	0.406	0.303	0.55	0.87	0.489	0.420	0.639	0.85	0.491	0.426	0.642	0.84
SPI12	1	0.357	0.244	0.494	0.92	0.372	0.315	0.521	0.91	0.381	0.319	0.534	0.91
SPI24	1	0.322	0.181	0.425	0.94	0.390	0.241	0.536	0.93	0.225	0.248	0.539	0.93

$$LM1: SPI24 = 0.9906 \times SPI24_{T1} - 0.1211 \times SPI24_{T2} + 0.0994 \times SPI24_{T12} + 0.0799 \quad (۱۳)$$

که در آن، SPI_{T1} شاخص SPI بیست چهارماهه با یک تأخیر زمانی، SPI_{T2} شاخص SPI بیست و چهارماهه با دو تأخیر زمانی و SPI_{T12} شاخص SPI بیست و چهارماهه با ۱۲ تأخیر زمانی به‌عنوان پارامترهای مستقل همچنین پارامتر SPI_{T24} شاخص SPI بیست و چهارماهه به‌عنوان پارامتر وابسته است. از شکل (۶) می‌توان دریافت که مجموعه داده‌های پژوهش در نه بخش LM1, LM2, ..., LM9 قابل دسته‌بندی هستند که برای هر کدام از این دسته‌ها یک رابطه خطی مجزا پیشنهاد کرده است.

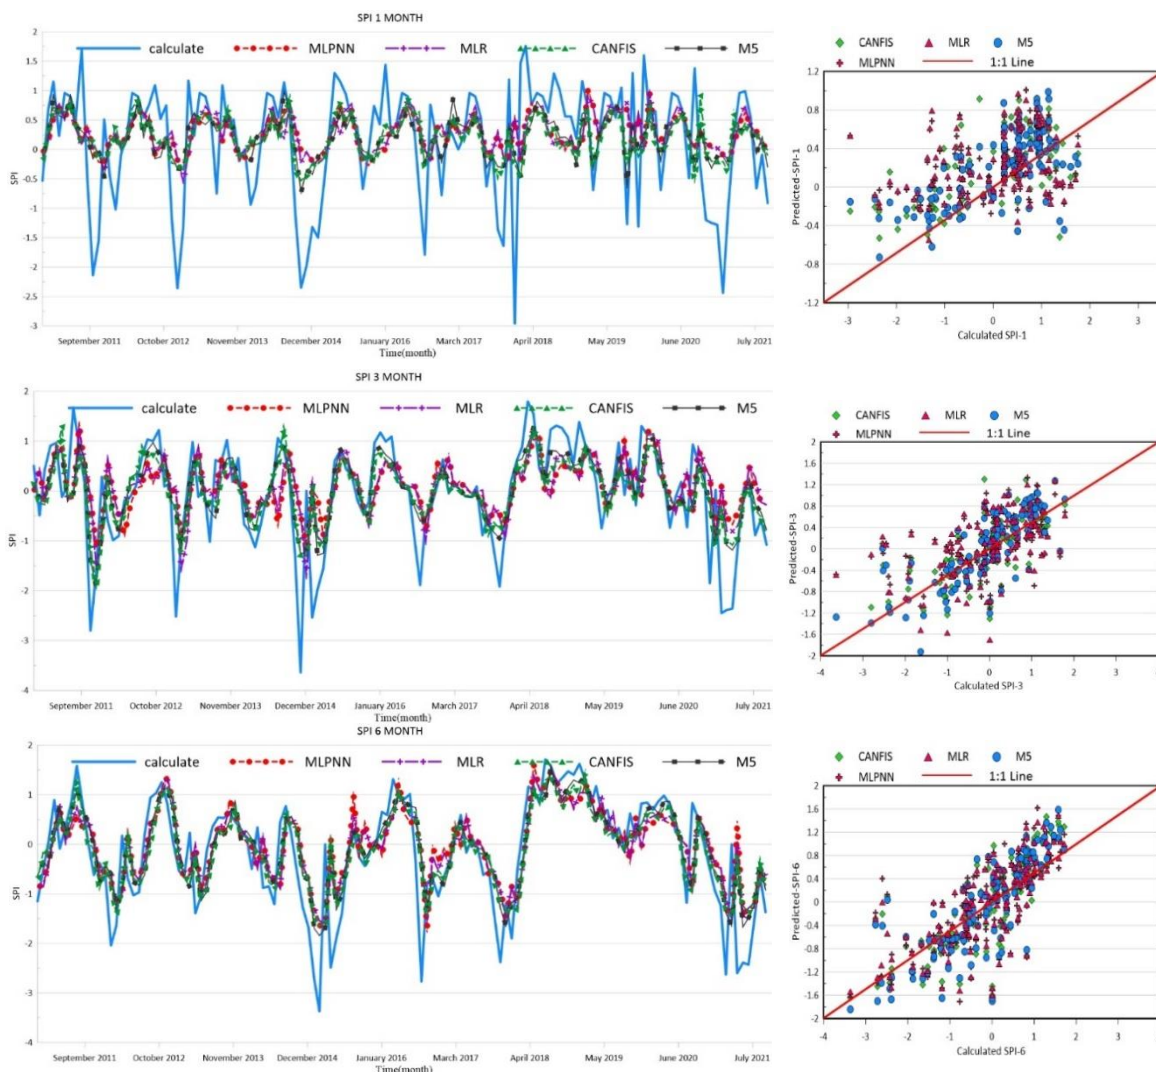
برای مدل‌سازی الگوریتم درخت تصمیم‌گیری M5 از نرم‌افزار وکا (WEKA) که توسط پژوهشگران دانشگاه ویکاتو تهیه شده است استفاده گردیده است. بعد از اجرای الگوریتم، خروجی مدل شامل نمودار درختی است شکل (۶) که در هر برگ این درخت یک رابطه خطی برای شاخص خشکسالی برآورد شده است. همان‌طور که در شکل (۶) نشان داده شده است، در روابط مدل درختی M5، پارامتر LM نشان‌دهنده روابط خطی است، کادر قرمز رنگ در شکل، نشان‌دهنده یک برگ یا گره است. اعداد نشان داده شده در داخل پرانتز به‌عنوان مثال گره اول LM 1 (146/53.68%) / عدد ۱۴۶ تعداد و ۵۳/۶۸ درصد مربوط به تعداد مواردی از مجموعه داده است که در آن رابطه خطی LM1 صدق می‌کند و آن رابطه برای آن تعداد داده از مجموعه داده بکار برده می‌شود.

شش ماهه کمبود بارندگی، مقدار این شاخص در انتهای دوره‌ی کم بارش بیش از مقدار آن در زمان مشابه و در مقیاس سه‌ماهه خواهد بود. چراکه در مقیاس شش‌ماهه اثر تمام دوره‌ی کم بارش لحاظ ولی در مقیاس سه‌ماهه تنها اثر دو ماه ماقبل آخر در نظر گرفته می‌شود.

نمودار پراکندگی یکی از ساده‌ترین روش‌ها برای بررسی همبستگی و ارتباط دو متغیر است. این نمودار، نوع و جهت رابطه را به‌طور بصری ارائه می‌دهد و می‌توان با مشاهده نمودار از نوع رابطه بین دو متغیر و جهت (خطی یا غیرخطی و مثبت یا منفی) و شدت رابطه آگاهی تقریبی یافت. از این نمودار به‌عنوان یکی از معیارهای ارزیابی استفاده شده است. داده‌های مشاهده‌ای و داده‌های پیش‌بینی شده توسط هر مدل برای تمامی گام‌های زمانی در شکل (۷) نشان داده شده است.

همان‌طور که در جدول (۶) نشان داده شده، مدل M5 توانسته است در طی آزمون شبکه، میزان MSE را از ۰/۷۶۹ در SPI یک‌ماهه به ۰/۱۸۱ در SPI بیست‌وچهار ماهه برساند که خود نشان‌دهنده کاهش حدود هشت برابری میزان خطا است؛ و همچنین میزان ضریب تعیین بالاتر و MSE پایین‌تری در تمامی گام‌های زمانی نسبت به سایر مدل‌ها دارد.

با دقت در جدول‌های (۳) الی (۶) مشخص می‌شود که مقدار ضریب تعیین در شاخص SPI با بازه زمانی یک ماهه در تمامی مدل‌ها نسبت به سایر شاخص‌ها پایین‌تر است که علت این امر را می‌توان به آن مرتبط دانست که باعث عملکرد نسبتاً ضعیف‌تر مدل‌ها در این بازه زمانی می‌شود و به‌طور کلی با افزایش مقیاس زمانی در شاخص SPI از نوسانات آن کاسته شده و در مقابل در خشکسالی‌های با دوره‌های طولانی‌تر، شدت خشکسالی ممکن است بیشتر نشان داده شود. به‌عنوان مثال، در یک دوره‌ی



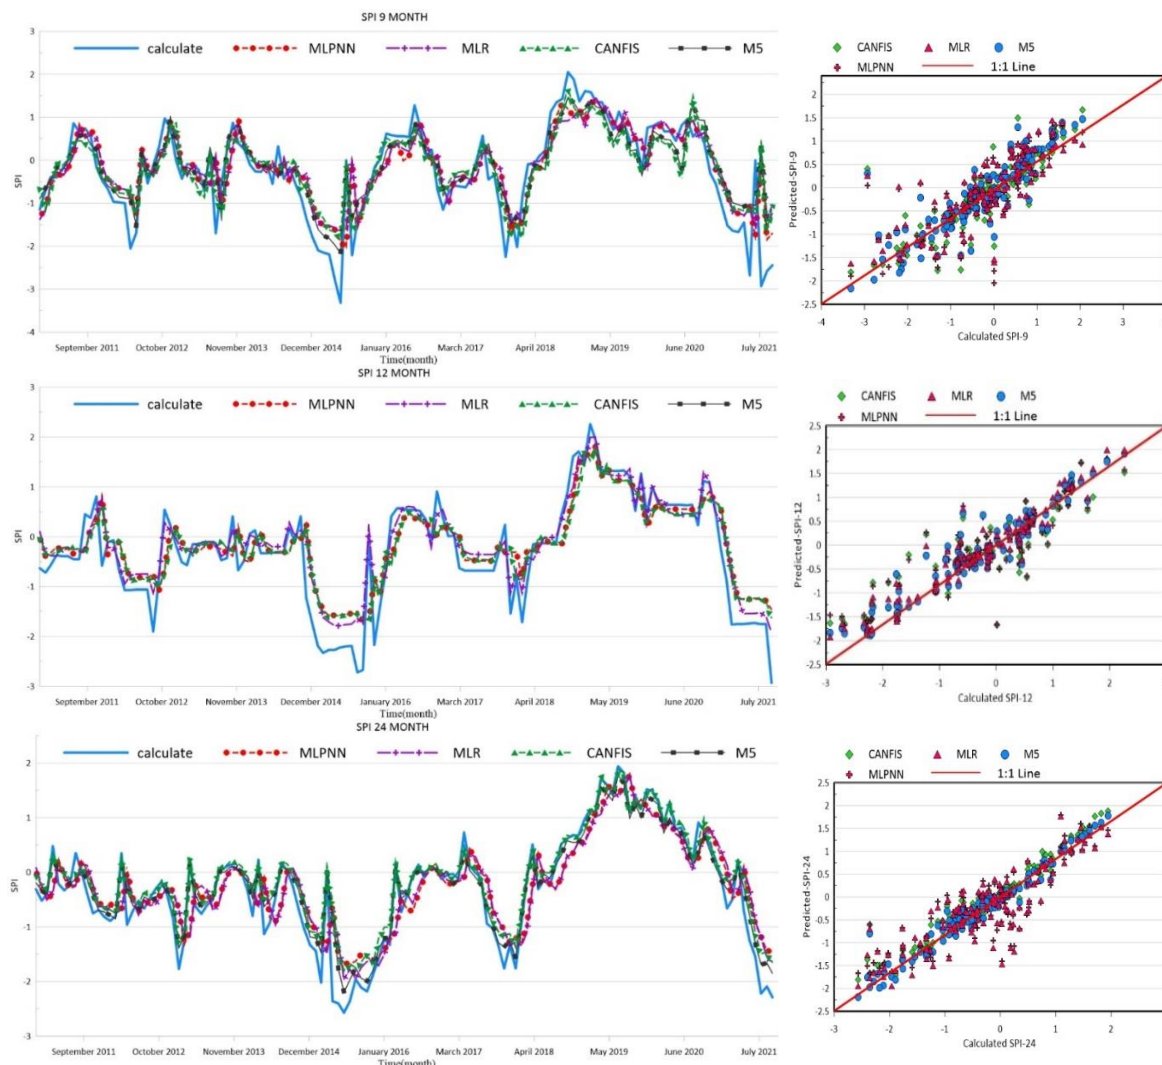


Fig. 7- Scatter plots of predicted and calculated SPI-1, SPI-3, SPI-6, SPI-9, SPI-12, and SPI-24 values by CANFIS, MLPNN, MLR and M5 model tree.

شکل ۷ - پراکندگی نمودارهای پیش‌بینی شده و محاسبه شده SPI در مدل‌های CANFIS, MLPNN, MLR و مدل درختی M5 برای مقیاس‌های زمانی ۱۲، ۹، ۶، ۳، ۱ و ۲۴ ماهه.

استان کرمانشاه مورد ارزیابی قرار گرفت. نتایج نشان داد که با افزایش مقیاس زمانی در شاخص SPI از نوسانات RMSE و MSE کاسته شده و در مقابل در خشکسالی‌های با دوره‌های طولانی‌تر، شدت خشکسالی بیشتر نشان داده شد. در بین چهار مدل مورد بررسی، مدل درختی M5 با تمامی معیارهای ارزیابی بهترین مدل شناخته شد؛ و مشخص گردید که مدل درختی M5 با استفاده از تقسیم‌بندی فضای داده‌ها و ارائه رابطه خطی متمایز برای هر گروه از داده‌ها، از توانایی نسبتاً بالای در پیش‌بینی خشکسالی برخوردار است.

در رتبه بعد شبکه CANFIS که از مجموعه‌های فازی استفاده می‌کند، توانست با اعتبار نسبتاً خوبی با موفقیت در پیش‌بینی خشکسالی منطقه اقلیمی کرمانشاه به کار گرفته شود. با توجه به اینکه مدل‌های هوش مصنوعی بر پایه روش داده‌کاوی استوار است، این مدل‌ها را می‌توان برای هر حوضه دلخواه مورد

بر اساس شکل (۷)، مشاهده می‌شود که عملکرد مدل‌ها در گام‌های زمانی یک، سه و شش ماهه در مقادیر حدی مناسب نبوده است ولی از گام زمانی نه ماهه به بعد در تمامی مدل‌ها شرایط بهتر شده و رفتار مدل را به خوبی شبیه‌سازی نموده است که این نتیجه با نتایج Malik et al (2020) و Kumar (2020) همخوانی دارد. در مجموع، با بررسی معیارهای ارزیابی شبکه و همچنین نمودارهای پراکندگی می‌توان مدل M5 را در تمامی گام‌های زمانی شاخص SPI با ضریب تعیین بالاتر و RMSE پایین‌تر به عنوان مناسب‌ترین مدل برای پیش‌بینی خشکسالی در منطقه کرمانشاه معرفی کرد.

نتیجه‌گیری

در این تحقیق میزان کارایی مدل‌های CANFIS، MLR، MLPNN و مدل درختی M5 در پیش‌بینی خشکسالی‌های

تقدیر و تشکر

بدین وسیله از سازمان هواشناسی کشور به خاطر همکاری لازم در خصوص در اختیار گذاشتن داده‌های این پژوهش نهایت تشکر و قدردانی به عمل می‌آید.

آموزش قرارداد و از این رهگذر یک شبکه آموزش‌دیده برای آن حوضه داشت؛ بنابراین هر شبکه آموزش بافته برای داده‌های همان حوضه قابل اعتبار است و تنها برای همان حوضه می‌تواند به کار گرفته شود. ولی متدلوژی و روش یادشده در پژوهش، قابل‌تعمیم و کاربرد برای تمامی حوضه‌های دیگر است.

References

- 1- Asadzadeh, F. Byzedi, M. and Kaki, M., 2016. Monitoring and prediction of drought in western Urmia lake basin rain gage stations by ANFIS model. *Iranian Journal of Ecohydrology*, 3(2): 205-218. (In Persian) Doi: doi: 10.22059/ije.2016.59661.
- 2- Ayttek, A., 2009. Co-active neurofuzzy inference system for evapotranspiration modeling. *Soft Computer*, 13. pp. 691-700.
- 3- Firat, M. Gungor, M., 2007. River flow estimation using adaptive neuro fuzzy inference system. *Mathematics and Computers in Simulation*, 75. pp. 87-96. Doi: 10.1016/j.matcom.2006.09.003.
- 4- Haghizadeh, A. Bayat, V. and Arshia A., 2019 Estimation of The Evapotranspiration potential of Kermanshah synoptic stations. *Using Genetic Programming*, 19(67) pp.29-42.
- 5- Hemachandra, S. and Satyanarayana, R. 2013. Co-Active Neuro-Fuzzy Inference System for prediction of electric load. *International Journal of Electrical and Electronics Engineering Research*, 3(2), pp. 217-222.
- 6- Jang, J.S., 1993 ANFIS adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*. 23(3), pp. 665-685.
- 7- Khorrim M, and Boghroniya A., 2006 *Analysis of time series with MINITAB AB14 software*, Sokhongostar publications. 151 p (In Persian).
- 8- Komasi, M. Ghobadi Khosro, S. and hashemi, M., 2018. Comparison Genetic Programming model and M5 model tree in Drought Forecasting. *Iranian Water Researches Journal*, 12(2), pp. 81-90 (In Persian).
- 9- Koochi, S., Azizian, A., and Mazandarani Zadeh, H., 2022. The Effects of Climate Change on Drought Conditions Using Fuzzy Logic under SSP3 and SSP5 scenarios. *Iran-Water Resources Research* (In Persian).
- 10- Malik A, Kumar A, and Kisi, O., 2017 Monthly pan-evaporation estimation in Indian central Himalayas using different heuristic approaches and climate based models. *Computers and Electronics in Agriculture*. 143(3), pp. 302-313. Doi: 10.1016/j.compag.2017.11.008.
- 11- Malik A, Kumar A, Salih S.Q, Kim S, Kim N.W. Yaseen, Z.M. and Singh, VP., 2020 Drought index prediction using advanced fuzzy logic model: Regional case study over Kumaon in India. *Journal PLoS*, 15(5), pp. 256-271. Doi: 10.1371/journal.pone.0233280.
- 12- Malik A, and Kumar A., 2015. Pan Evaporation Simulation Based on Daily Meteorological Data Using Soft Computing Techniques and Multiple Linear Regression. *Water Resources Management*, 29(3), pp. 124-139.
- 13- Malik A. Kumar A, and Singh R.P., 2019 Application of Heuristic Approaches for Prediction of Hydrological Drought Using Multi-scalar Streamflow Drought Index. *Water Resource Manage* 33(2), pp. 3985-4006.
- 14- Malik A. and Kumar A., 2020 Meteorological drought prediction using heuristic approaches based on effective drought index: a case study in Uttarakhand. *Arabgeo* 13(2), pp. 27-39.

- 15-Mashayekhi M, and Zakeri Niri M 2020a. Meteorological, Hydrological and Agricultural Droughts Prediction Using Wavelet Method in Tehran. *Iran-Water Resources Research*, 16(3), pp.120-132 (In Persian).
- 16-McKee T. Doesken J, and Kleist, D., 1993 the relationship of drought frequency and duration to time scales. Proc. of the 8th Conference on Applied Climatology, *American Meteorological Society, Boston*, 12(4), pp.179-184.
- 17-Minasny B, and Mcbratney, A.B., 2002. The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Science Society of America Journal*, 66(3), pp. 352-361. Doi: 10.2136/sssaj2002.3520.
- 18-Moradi, M. and Rahimkhoob, A., 2013 Estimation of Reference Evapotranspiration Using NOAA Satellite Images and M5 Model Tree for Irrigation Networks - Case Study: *Gazvin Irrigation Network. JWSS*, 16(62), pp. 123-135 (In Persian).
- 19-Nourani, V. and Molajou A., 2017. Application of a hybrid association rules/decision tree model for drought monitoring. *Global and Planetary Change* 159(5), pp.37-45. Doi: 10.1016/j.gloplacha.2017.10.008.
- 20-Poursalehi, F. Shahidi, A. and Khashei Siuki, A., 2020. Comparison of Decision Tree M5 and K-Nearest Neighborhood Algorithm Models in the Prediction of Monthly Precipitation (Case Study: Birjand Synoptic Station), *Iranian journal of irrigation and drainage*, 13(5), pp. 1283-1293. (In Persian).
- 21-Rezaei M, and Memarian, H., 2016 Application of Rainfall Time Series and Climatic Indices for Drought Prediction using Co-Active Neurofuzzy Inference System (Case Study: Birjand, Southern Khorasan). *Journal of Arid Biome*, 5(2), pp. 51-67(In Persian).
- 22-Sattari, M. Rezazadeh Joudi, A. and Nahrein F., 2014 Monthly Rainfall Prediction using Artificial Neural Networks and M5 Model Tree (Case study: Station of AHAR). *Physical Geography Research Quarterly*, 46(2), pp. 247-260. Doi: 10.22059/jphgr.2014.51428 (In Persian).
- 23-Sattari, M.T. Nahrein, F. and Azimi, V., 2013. M5 model trees and neural networks based prediction of daily ETO (case study: Bonab station). *Iranian Journal of Irrigation and Drainage* 7(1), pp.104-113 (In Persian).
- 24-Sattari, M. Mirabbai Najafabadi, R. and Alimohammadi, M., 2016. Application of M5 Tree Model in Forecasting Drought (Case Study, Maragheh, Iran). *Hydro geomorphology*, 3(8), pp. 73-92. (In Persian).
- 25-Talebkeikhah, F. Rasam, S. Talebkeikhah, M. Torkashvand, M. Salimi, A. Moraveji, M. K., 2020. Investigation of effective processes parameters on lead (II) adsorption from wastewater by biochar in mild air oxidation pyrolysis process. *International Journal of Environmental Analytical Chemistry*, 12(1), pp. 1-21. Doi: 10.1080/03067319.2020.1777291.