

Research Paper

Evaluation and prediction of droughts in the west and northwest of Iran using artificial neural network

Jafar Masoompour Samakoosh^{a,*}, Vahid Sohrabi^b and Morteza Miri^c

^a Associate Professor, Department of Geography, Faculty of Literature and Humanities, Razi University, Kermanshah, Iran

^b M. Sc. in Climatology, Department of Geography, Faculty of Literature and Humanities, Razi University, Kermanshah, Iran

^c Assistant Professor, Soil Conservation and Watershed Management Research Institute (SCWMRI), Agricultural Research Education And Extension Organization (AREEO), Tehran, Iran.

ARTICLE INFO

Article history:

Received: 23 February 2022;

Accepted: 23 April 2022

Available online 30 April 2022

Keywords:

Precipitation, Soil Moisture, Multivariate drought Index, Drought Severity, Genetic Algorithm

ABSTRACT

Drought, as a climate threat, has a significant impact on the environment and, consequently, on humans and other living organisms. Therefore, monitoring and predicting this phenomenon is necessary. This study, to examine and evaluate the drought forecast in the west and north-west of Iran, including Hamedan, Kermanshah, Kurdistan, West Azerbaijan, East Azerbaijan, Ardabil, Zanzan, Qazvin, Ilam, Markazi, Gilan, and Lorestan, have been used multivariate standardized drought index (MSDI) and methods based on artificial intelligence. To predict the values of this index in the study area, monthly rainfall, and soil moisture, as the input, and the calculated amount of MSDI, as output, was applied. The grid data on precipitation and soil moisture for a period of 36 years (1980-2016) were obtained from the MERRA database. The results of monthly drought analysis based on these data showed that the most severe drought in the study area occurred from March to October and the main focus of this phenomenon are Lorestan provinces, especially Ilam and Kermanshah. The findings were following seasonal and annual maps. According to the MSDI index classification, no severe drought was observed in the study area and the droughts were in the middle class. The results of artificial neural network modeling also showed that the use of artificial neural networks, in general, has an appropriate ability to simulate properly. Among the algorithms used to optimize the artificial neural network, the genetic algorithm has the best performance compared to other methods in predicting drought.

1. Introduction

Drought is one of the climate hazards that always affects human activities and the natural environment and can cause a lot of damage to the economy, agriculture, environment, etc (Kogan, 1997; Loukastal, 2007). Therefore, its recognition, monitoring and prediction is very necessary in order to optimally manage water consumption in different sectors. Since it is almost impossible to prevent this phenomenon in any region and

situation, it is possible to predict the return period of drought in different regions by relying on statistics, and using this knowledge, the problems caused by them can be minimized. It is possible to reduce (Wilhite, 1995). Drought indicators, as one of the most important parts of the drought monitoring system, are the determining factor in monitoring the drought situation (Qabaisouq et al., 2015). Since the use of one-dimensional indicators cannot show all aspects of meteorological, agricultural, and hydrological

*Corresponding Author.

Email Addresses: s.mohammadimehr@modares.ac.ir (J. Masoompour SamaKoosh), vahid.sohrabi1008@gmail.com (V. Sohrabi), mmiri@ut.ac.ir (H. Miri)

To cite this article:

Masoompour Samakoosh, J; Sohrabi, V; Miri, M (2022), Evaluation and prediction of droughts in the west and northwest of Iran using artificial neural network. Journal of Geographical Studies of Mountainous Areas, 3(10), 19-37



Doi:10.52547/gasma.3.2.19

droughts, a multivariate approach should be used to achieve these goals. In fact, the lack of a system or model for integrating information related to drought includes; Different climatic variables, drought indicators and their interrelationships prevent the reliable and timely diagnosis of drought and its sustainability (Hao and Agha Kochuk, 2015). Hence, the importance and necessity of carrying out the present research based on examining and recognizing drought using multivariate indicators and also predicting drought using non-linear methods based on artificial neural network and optimizing its structure using algorithms Various things become important.

2. Methodology

With the aim of evaluating the droughts of the western and northwestern provinces of Iran, the monthly rainfall and soil moisture data for the provinces of Hamedan, Kermanshah, Kurdistan, West Azerbaijan, East Azerbaijan, Ardabil, Zanjan, Qazvin, Ilam, Markazi, Gilan and Lorestan for a 36-year period (1980-2016) with a suitable spatial resolution was obtained from the MERRA database as a grid of 0.66 at 0.5 degrees. To investigate and evaluate the drought, the multivariate standardized drought index (MSDI) was used, and it was calculated in the R software environment. Finally, drawing maps for drought analysis and interpretation was done with ArcGIS software. In order to predict drought in the studied area, artificial neural network was used, and also to optimize artificial neural network in drought prediction, genetic algorithm and particle swarm algorithm were used in Matlab software environment. Finally, BIAS MAE, RMSE statistics have been used to check the network data performance.

3. Results

The value of MSDI drought index was calculated in terms of monthly, seasonal and annual time periods for the study area and it was found that severe droughts occurred in the southern parts of the study area i.e., Ilam and Kermanshah provinces. Monthly surveys show that from

March to October, the western provinces (Kermanshah, Lorestan and especially Ilam) experience the maximum amount of drought, as well as the most severe drought, between the months of April and July. and the lowest occurred in January and next in November and December. Seasonal analysis shows that the most severe drought is in spring, and summer is the next in the region, which includes the southern half of the study area (Kermanshah, Lorestan and Ilam). The annual overview of drought based on the MSDI index shows that, except for Ilam province, which is in the middle category, other studied regions are in the category of weak and very weak drought. The minimum intensity of drought in the region is also observed in the northern regions of West Azarbaijan and Ardabil provinces, the center of East Azarbaijan, which corresponds to seasonal distributions.

The error rate of the artificial neural network has a relatively large distance from the optimal limit, so the optimizer functions were used to increase the efficiency of the network. Therefore, two algorithms of particle swarm and genetics were used. The results of the particle swarm algorithm provided better answers than the artificial neural network, which is due to the use of the structure of the particle swarm algorithm in network training. The evaluation of the modeling error using the genetic algorithm showed that this algorithm provides many times better results than the previous two modeling. The reason for this is certainly the appropriate matching of the data structure with the genetic algorithm theory, as well as their optimal training due to the optimized structure used.

4. Discussion

An interesting point that is evident in the monthly, seasonal and annual maps is that according to the classification of the MSDI index, severe drought was not observed in the study area and the most severe droughts are in the middle class.

The results of using artificial neural network showed that the performance of optimized neural network using genetic algorithm is better than other models. The results show the superiority of the genetic algorithm over ANN and PSO in predicting climate parameters, It is consistent with

the research of Moeini et al. (2017) in predicting base flow, Abdullah et al. (2014) in predicting evaporation, and Arshad et al (2013) in predicting the impact of drought on agriculture.

5. Conclusion

Monthly surveys showed that the most severe drought in the study area occurs between the months of April and October, and the main focus of this phenomenon is the provinces of Lorestan, especially Kermanshah and Ilam. The greatest extent of drought is related to the months of April and May. The seasonal and annual spatial pattern

is also similar to the monthly one, so that, except for the spring season, when drought surrounds more than 70% of the region, the southern regions of the study area, namely Kermanshah, Lorestan and Ilam provinces, have the highest amount of drought.

The results of the modeling of artificial neural networks also showed that the use of artificial neural networks generally has a good simulation ability. Among the algorithms used to optimize the artificial neural network, the genetic algorithm has the best performance compared to other methods in predicting droughts.



دانشگاه لرستان

شاپای الکترونیکی: ۲۳۲۵-۲۷۱۷

فصلنامه مطالعات جغرافیایی مناطق کوهستانی

<http://www.gsma.lu.ac.ir>



مقاله پژوهشی

ارزیابی و پیش‌بینی خشکسالی‌های غرب و شمال غرب ایران با استفاده از شبکه عصبی مصنوعی

جعفر معصوم‌پور سماکوش^{۱*}، وحید سهرابی^۲، مرتضی میری^۳

^۱ دانشیار گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه رازی، کرمانشاه، ایران.

^۲ کارشناس ارشد گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه رازی، کرمانشاه، ایران.

^۳ استادیار گروه خشکسالی و تغییر اقلیم، پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

اطلاعات مقاله

دریافت مقاله:

۱۴۰۰/۱۲/۴

پذیرش نهایی:

۱۴۰۱/۲/۳

تاریخ انتشار:

۱۴۰۱/۲/۱۰

چکیده

خشکسالی به‌عنوان مخاطره‌ای اقلیمی، تأثیر بسزایی بر محیط‌زیست و به تبع آن انسان و سایر موجودات زنده دارد. از این رو پایش و پیش‌بینی این پدیده امری لازم و ضروری می‌باشد. در این پژوهش با هدف بررسی و ارزیابی پیش‌بینی خشکسالی در نیمه غربی کشور از شاخص خشکسالی استاندارد شده چند متغیره (MSDI) و روش‌های مبتنی بر هوش مصنوعی استفاده شده است. جهت پیش‌بینی مقادیر این شاخص در محدوده مطالعاتی، از داده‌های ماهانه بارش و رطوبت خاک پایگاه داده MERRA طی دوره ۳۶ ساله (۱۹۸۰-۲۰۱۶) به‌عنوان ورودی و مقادیر محاسبه شده MSDI بعنوان خروجی بهره برده شد. نتایج تحلیل خشکسالی ماهانه براساس این داده‌ها نشان داد که شدیدترین خشکسالی در منطقه مورد مطالعه حد فاصل ماه‌های مارس تا اکتبر به وقوع پیوسته و کانون اصلی وقوع این پدیده، استان‌های لرستان و خصوصاً ایلام و کرمانشاه می‌باشند. این نتایج با بررسی نقشه‌های فصلی و سالانه نیز مطابقت دارد. طبق طبقه‌بندی شاخص MSDI، خشکسالی شدید در منطقه مورد مطالعه ثبت نشده است و خشکسالی‌ها در طبقه متوسط قرار داشتند. نتایج حاصل از مدل‌سازی شبکه‌های عصبی مصنوعی نیز نشان داد که استفاده از شبکه‌های عصبی مصنوعی به‌طور کلی از توانایی شبیه‌سازی مناسبی برخوردار می‌باشند. از بین الگوریتم‌های استفاده‌شده جهت بهینه‌سازی شبکه عصبی مصنوعی، الگوریتم ژنتیک، بهترین عملکرد را نسبت به سایر روش‌ها در پیش‌بینی خشکسالی‌ها دارا می‌باشد.

واژگان کلیدی:

بارش، رطوبت خاک،

شاخص خشکسالی چند

متغیره، شدت خشکسالی،

الگوریتم ژنتیک.

۱. مقدمه

غیره وارد سازد (Kogan, 1997; Loukastal, 2007)،

بنابراین شناخت، پایش و پیش‌بینی آن به‌منظور مدیریت بهینه مصرف آب در بخش‌های مختلف بسیار ضروری است. از مهم‌ترین راهکارها برای مقابله با این پدیده، پیش‌بینی

خشکسالی یکی از مخاطرات اقلیمی است که همواره بر فعالیت‌های انسانی و محیط طبیعی تأثیر می‌گذارد و می‌تواند خسارت‌های فراوانی بر اقتصاد، کشاورزی، محیط‌زیست و

* نویسنده مسئول

ایمیل نویسندگان: s.mohammadimehr@modares.ac.ir (ج، معصوم‌پور سماکوش)، vahid.sohrabi1008@gmail.com (و، سهرابی)، mmiri@ut.ac.ir (م، میری).

نحوه استنادی به مقاله:

معصوم‌پور سماکوش، جعفر؛ سهرابی، وحید؛ میری، مرتضی (۱۴۰۱). ارزیابی و پیش‌بینی خشکسالی‌های غرب و شمال‌غرب ایران با استفاده از شبکه هوش عصبی. فصلنامه مطالعات جغرافیایی مناطق کوهستانی. سال سوم، شماره ۲ (۱۰)، صص ۳۷-۱۹.



Doi:10.52547/gsma.3.2.19

خشکسالی است که بتوان اثرات مخرب ناشی از آن را به حداقل رساند (Hassanzadeh et al., 2012). از آنجا که جلوگیری از این پدیده در هیچ منطقه و شرایطی، تقریباً امکان‌پذیر نیست، می‌توان با تکیه بر آمار، دوره بازگشت خشکسالی را در مناطق مختلف پیش‌بینی کرد و با استفاده از این دانش، مشکلات ناشی از آن‌ها را تا حد امکان کاهش داد (Wilhite, 1995). هرچند به دلیل پیچیدگی علت وقوع و تأثیر این پدیده، تشخیص و بررسی آن بر اساس یک متغیر ممکن است کافی و قابل‌اتکا نباشد (Hao and Aghakouckak, 2014: 89)، با وجود این می‌توان با ایجاد و توسعه یک سیستم بررسی خشکسالی جامع، شروع، شدت، تداوم و گستره خشکسالی را هشدار داد (Mishra and Singh, 2010).

در دهه‌های گذشته معمولاً تحلیل خشکسالی به صورت توصیفی انجام می‌گرفت و کمتر به تحلیل کمی پرداخته می‌شد. اصولاً برای تحلیل کمی خشکسالی، وجود یک شاخص مشخص جهت تعیین دقیق دوره‌های مرطوب و خشک بسیار ضروری است. بر این اساس محققان زیادی سعی در حل این مشکل نموده‌اند.

در دهه‌های گذشته معمولاً تحلیل خشکسالی به صورت توصیفی انجام می‌گرفت و کمتر به تحلیل کمی پرداخته می‌شد. اصولاً برای تحلیل کمی خشکسالی، وجود یک شاخص مشخص جهت تعیین دقیق دوره‌های مرطوب و خشک بسیار ضروری است. بر این اساس محققان زیادی سعی در حل این مشکل نموده‌اند.

در مروری بر مفاهیم خشکسالی، تلاش کردند تا مروری بر مفاهیم بنیادی خشکسالی، طبقه‌بندی انواع خشکسالی‌ها، شاخص‌های خشکسالی، خشکسالی‌های گذشته و ارتباط بین آن‌ها و شاخص‌های مقیاس بزرگ خشکسالی داشته باشند. آن‌ها همچنین در سال ۲۰۱۱، روش‌های مختلف مورد استفاده برای مدل‌سازی خشکسالی را مرور کردند. نتایج آن‌ها نشان داد که مدل‌های هیبریدی، برای پیش‌بینی درازمدت خشکسالی در مقیاس‌های بزرگ مناسب به نظر می‌رسد و به علاوه اینکه مدل‌های کاپولا محور، برای توصیف خشکسالی مناسب تر می‌باشند.

Govindaraju and Kao (2010)، در مطالعه‌ای شاخص کمبود مشترک خشکسالی بر مبنای کوپلا را بررسی کردند. آن‌ها با استفاده از الگوریتم شاخص استاندارد نشده^۱ (SI)، یک شاخص اصلاح شده را که از محاسبات فصلی به دست آمده، برای بارش و رواناب ارائه دادند. همچنین با استفاده از داده‌های طولانی مدت ایستگاه‌های ایندیانا، ساختارهای وابستگی بارش و رواناب را با بازه زمانی مختلف از کوپلاهای تجربی به دست آورده و شاخص کمبود مشترک^۲ (JDI) را ارائه دادند که این شاخص توصیفی بر پایه احتمال، حالات خشکسالی را ارائه می‌دهد. JDI ارائه شده نه تنها شروع و مدت خشکسالی را در یک بازه زمانی منعکس می‌کند، همچنین می‌تواند یک شاخص چند متغیره را تشکیل دهد.

Aghakouchak and Ho (2013)، شاخص خشکسالی استاندارد شده^۳ (MSDI) را برای بررسی خشکسالی‌های کالیفرنیا و کارولینای شمالی مورد استفاده قرار دادند و نتایج حاصل از این شاخص ترکیبی را با شاخص‌های خشکسالی حساسیت به تنش^۴ (SSI) و بارش استاندارد شده^۵ (SPI) مقایسه کردند. نتایج نشان داد که MSDI نشان‌دهنده شروع و پایان خشکسالی بر اساس SPI و SSI است، بدین ترتیب که شروع خشکسالی با SPI و دوام و پایداری آن با رفتار SSI هماهنگی دارد. Singh and JangaReddy (2013)، به مدل‌سازی چند متغیره‌ی خشکسالی با استفاده از تابع کوپلا و روش‌های فرا ابتکاری (متاهوریستیک) پرداختند، و برای تخمین دقیق پارامترهای مدل کوپلا، روش‌های فرا ابتکاری به نام الگوریتم ژنتیکی و بهینه‌سازی ذرات استفاده کردند. Aghakouchak and Farahmand (2014)، چارچوب کلی

¹ Standard Index

² Joint Deficit Index

³ Multivariate Standardized Drought Index

⁴ Stress Susceptibility Index

⁵ Standard Precipitation Index

ویرجینیا مطالعه کردند. در این تحقیق، برای محاسبه خشکسالی از شاخص استاندارد شده رطوبت خاک (SSI) و شاخص استاندارد شده چند متغیره (MSDI) و شاخص شدت خشکسالی اصلاح شده پالم^۴ و از مدل اقلیمی^۵ و مدل CMIP5، برای هر دو دوره گذشته و آینده استفاده شد. نتایج نشان دادند که استفاده از مدل سازی هیبریدی و شاخص های خشکسالی که هر دو تغییرات بارش و دما را لحاظ می کنند از دقت بالاتری برخوردار هستند.

Abbassian and Abrishamchi (2013)، به مقایسه تحلیل چند متغیره با تک متغیره برای وقایع خشکسالی، با استفاده از توابع مفصل پرداختند. نتایج به دست آمده نشان داد که فقط با انجام تحلیل های چند متغیره امکان در نظر گرفتن همبستگی بین متغیرها وجود دارد، و همچنین نتایج تحلیل های تک متغیره ممکن است به طور قابل توجهی بیش برآوردی یا کم برآوردی داشته باشد. Bazrafshan and et al (2015)، کارایی مدل ARIMA، شبکه عصبی و مدل هیبرید آریما-شبکه عصبی مصنوعی را در پیش بینی خشکسالی هیدرولوژی در دو مقیاس زمانی ماهانه و فصلی در دو ایستگاه هیدرومتری واقع در بخش میانی و خروجی در حوزه آبخیز گاماسیاب (دوره آماری ۱۳۵۳-۱۳۸۷) بررسی کردند. نتایج نشان داد که در میان سه مدل مورد استفاده جهت پیش بینی، ترکیب مدل های شبکه عصبی-استوکاستیک نتیجه مناسبی نسبت به مدل های مجزای آنها در مقیاس ماهانه و فصلی دارد. Sadeghian and et al (2018) سعی کردند که با استفاده از روش های پیش بینی سری زمانی، سیستم های استتاجی-فازی تطبیقی و شبکه های عصبی مصنوعی، مدل های مناسبی را جهت پیش بینی خشکسالی شهرستان سمنان ارائه دهند. نتایج نشان داد که مدل ANFIS با ورودی های میانگین بارش، میانگین

برای به دست آوردن شاخص های خشکسالی استاندارد شده غیر پارامتری را بررسی کردند. آنها بیان کردند که SDAT^۱ بر پایه ی چارچوبی غیر پارامتری است که می تواند برای متغیرهای اقلیمی مختلف، مانند بارش و رطوبت خاک و رطوبت نسبی، بدون در نظر گرفتن توزیع های پارامتریک، به کار رود. Golin, et al (2014)، با هدف تحلیل روند خشکسالی های هواشناسی و کشاورزی در ایران با استفاده از شاخص MSDI و آزمون من-کندال نشان دادند که با اطمینان ۹۵٪ در حالی که در شرق ایران آمار قابل توجهی از خشکسالی مشاهده نشد، بخش های شمال، شمال غرب و مرکزی ایران خشکی قابل توجهی را تجربه کرده اند. Aghakouchak (2015)، در پیش بینی خشکسالی، بر مبنای تداوم به کار برده شده برای خشکسالی ۲۰۱۰ و ۲۰۱۱ شرق آفریقا با استفاده از شاخص (MSDI) نشان داد که پیش بینی ها و مشاهدات برهم منطبق هستند. به علاوه نتایج به دست آمده بر توانایی کاربردی این مدل برای هشدار احتمال خشکسالی در شرق آفریقا تأکید می کند.

Farahmand, et al (2015)، به تشخیص شروع خشکسالی با روشی با استفاده از رطوبت نسبی پرداختند. آنها شاخص استاندارد شده رطوبت نسبی^۲ را بر اساس مشاهدات^۳ ناسا معرفی کردند. نتایج نشان داد که SRHI عموماً شروع خشکسالی را زودتر از شاخص SPI تشخیص می دهد، با اینکه AIRS لزوماً برای بررسی خشکسالی محاسبه نشده بود، اما نشان می دهد که داده های رطوبت نسبی آن، رویکردی نو و منحصر به فردی برای بررسی خشکسالی و هشدار پیش از موعد ارائه می دهد. and Kang (2017) Sridhar، مدل هیدرولوژیکی آماری-فضایی ترکیبی را برای ارزیابی شاخص های خشکسالی آینده در

^۴ Modified Palmer Drought Severity Index (MPDSI)

^۵ Soil and Water Assessment Tool (SWAT)

^۱ Standardized Drought Analysis Toolbox

^۲ Standardized Relative Humidity Index (SRHI)

^۳ Atmospheric Infrared Sounder (AIRS)

۲. روش تحقیق

جهت بررسی و ارزیابی خشکسالی از شاخص خشکسالی استاندارد شده چند متغیره (MSDI) استفاده شده است. بدین منظور در ابتدا داده‌های شبکه‌ای ماهانه بارش و رطوبت خاک از سایت MERRA دریافت و در محیط نرم‌افزار R تبدیل به مقادیر عددی شد. پس از آماده سازی داده‌ها، با استفاده از روابط ارائه شده از سوی [Hao and AghaKouchak \(2014\)](#) شاخص خشکسالی استاندارد شده چند متغیره (MSDI) در محیط نرم‌افزار R محاسبه گردید. در نهایت، رسم نقشه‌ها برای تحلیل و تفسیر خشکسالی، با نرم‌افزار ARCGIS انجام گرفت. به منظور پیش بینی خشکسالی در سطح منطقه مورد مطالعه از شبکه عصبی مصنوعی و همچنین جهت بهینه‌سازی شبکه عصبی مصنوعی در پیش بینی خشکسالی از شاخص‌های الگوریتم ژنتیک و الگوریتم ازدحام ذرات در محیط نرم‌افزار Matlab استفاده شد. در نهایت جهت بررسی عملکرد داده‌های شبکه‌ای از آماره‌های RMSE MAE, BIAS استفاده شده است. جهت ارزیابی عملکردی مدل، بررسی داده‌های مورد استفاده ضرورت دارد. جهت بالا بردن دقت شبکه، هریک از نقاط شبکه به صورت جداگانه اجرا شد. داده‌های شبکه‌ای بارش و رطوبت خاک اخذ شده از MERRA بعنوان ورودی، و مقدار عددی محاسبه شده MSDI متناظر با آن‌ها، بعنوان خروجی شبکه بکار گرفته شد. مجموع تعداد داده‌های مورد استفاده ۹۹۳۸۶ عدد می‌باشد.

در مرحله‌ی پیش پردازش داده‌ها که به منظور عملکرد بهتر شبکه صورت می‌پذیرد، جهت جلوگیری از خطاهای ورودی به شبکه (NaN شدن خروجی‌ها)، مقادیر فاقد مقدار MSDI و صفر از روند مدل‌سازی حذف شدند.

شاخص خشکسالی استاندارد شده چند متغیره (MSDI)

حداکثر دما، SPI، به‌عنوان مدل برگزیده انتخاب گردید. در [Hassanvand and et al \(2018\)](#)، کارایی شبکه عصبی را در پیش‌بینی خشکسالی ایستگاه کرمانشاه بر اساس شاخص SPI بررسی کردند. نتایج نشان داد که مدل (ANN-ICA) با توجه به آزمون‌های آماری نتیجه بهتری در پیش‌بینی ۳ ماهه خشکسالی و مدل (ANN-BBO) دقت بالاتری در پیش‌بینی خشکسالی ۶ ماهه و سالانه دارد.

بررسی‌های انجام شده نشان می‌دهد که با توجه به خصوصیات پیچیده این پدیده اقلیمی، فهم و توسعه ابزارهایی به‌منظور پایش و پیش‌بینی کمی و کیفی خشکسالی، به مدیریت این پدیده جهت کاهش اثرات و شدت خسارات آن در سطوح مختلف جوامع درگیر با خشکسالی همانند مناطق مختلف کشور ایران کمک فراوانی خواهد نمود. شاخص‌های خشکسالی به‌عنوان یکی از مهم‌ترین بخش‌های سیستم پایش خشکسالی، عامل تعیین‌کننده در پایش وضعیت خشکسالی است ([Ghobaei, 2016](#)). از آنجا که استفاده از شاخص‌های تک‌بعدی نمی‌تواند تمام جنبه‌های خشکسالی هواشناسی، کشاورزی، هیدرولوژی را نشان دهد، برای رسیدن به این اهداف باید از یک رویکرد چندمتغیره استفاده کرد. در واقع نبود یک سیستم یا مدل تلفیق اطلاعات مرتبط با خشکسالی شامل؛ متغیرهای مختلف اقلیمی، شاخص‌های خشکسالی و روابط متقابل آن‌ها، مانع از تشخیص قابل‌اعتماد و به‌موقع خشکسالی و پایداری آن می‌شود ([Hao and AghaKouchak, 2015](#)). از این رو اهمیت و ضرورت انجام تحقیق حاضر مبتنی بر بررسی و شناخت خشکسالی با استفاده از شاخص‌های چند متغیره و همچنین پیش‌بینی خشکسالی با استفاده از روش‌های غیرخطی مبتنی بر شبکه عصبی مصنوعی و بهینه‌سازی ساختار آن با استفاده از الگوریتم‌های متنوع اهمیت پیدا می‌کند.

بین گره‌ها، روش تعیین وزن‌های ارتباطی و تابع فعالیت معرفی می‌شود. ساختار عادی یک شبکه عصبی مصنوعی معمولاً از لایه‌های ورودی، میانی و خروجی تشکیل شده است (شکل ۲). لایه‌ی ورودی یک لایه‌ی انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. آخرین لایه یا لایه‌ی خروجی، شامل مقادیر پیش‌بینی شده به وسیله شبکه می‌باشد. لایه‌های میانی، یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها می‌باشند. شمار لایه‌های مخفی و شمار گره‌ها در هر لایه مخفی به‌طور معمول به وسیله روش آزمون و خطا مشخص می‌شود. برای استفاده شبکه عصبی مصنوعی، انجام مراحل انتخاب و پیش‌پردازش داده‌ها، معماری شبکه، آموزش و در نهایت آزمون مدل ضروری است.

چهارچوب کار این شاخص، نسخه بسط داده شده‌ی SPI تک متغیره، روی توزیع مشترک بارش و رطوبت خاک می‌باشد که قادر به توصیف شرایط خشکسالی‌های هواشناسی - کشاورزی (جدول ۱) در مقیاس‌های زمانی مختلف می‌باشد (Hao and AghaKouchak, 2013).


جدول ۱. طبقه‌بندی مقادیر MSDI

خشکسالی خیلی ضعیف	-۰/۴۹ تا -۰/۱
خشکسالی ضعیف	-۰/۷ تا -۰/۵
خشکسالی متوسط	-۱/۲ تا -۰/۸
خشکسالی شدید	-۱/۵ تا -۱/۳
خشکسالی بسیار شدید	-۱/۹ تا -۱/۶
خشکسالی فرین	۲- و کمتر

منبع: Hao and AghaKouchak, 2013

شبکه عصبی مصنوعی (ANNs)

ساختار شبکه‌های عصبی مصنوعی به وسیله الگوی ارتباط



شکل ۲. ساختار شبکه عصبی مصنوعی

طرح اولیه و به بیان دیگر یک کروموزوم می‌باشند. با توجه به این موضوع، الگوریتم ژنتیک ابتدا تعدادی از این کروموزوم‌ها را ایجاد می‌نماید که به آن جمعیت اولیه گفته می‌شود. پس از ایجاد جمعیت اولیه، الگوریتم ژنتیک به بررسی این کروموزوم‌ها (که در حقیقت طرح‌های اولیه می‌باشند) پرداخته و متناسب با برازندگی آن‌ها مقادیری را به هر یک نسبت می‌دهند، به طوری که هر چه طرح با شرایط مورد نیاز ما سازگارتر باشد، برازنده‌تر بوده و بنابراین مقدار عددی بیشتری را به خود اختصاص خواهد

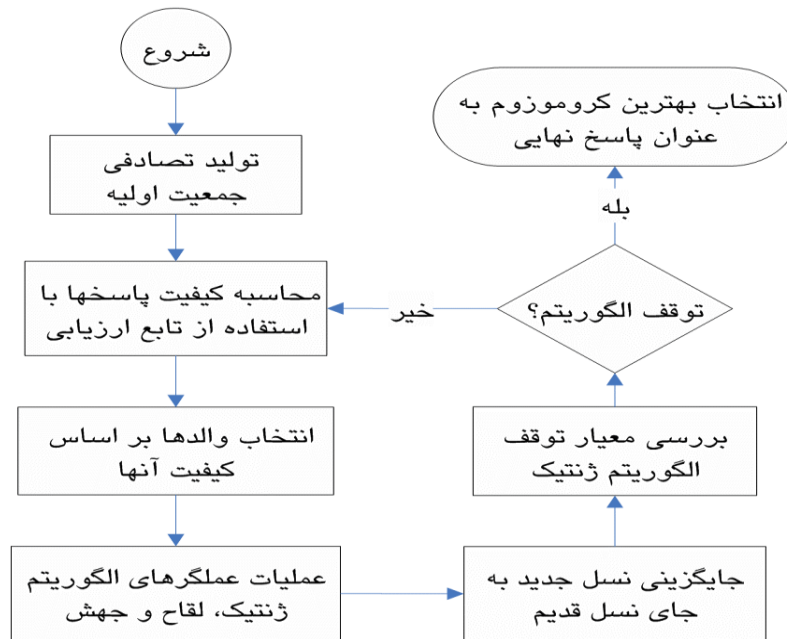
الگوریتم ژنتیک

الگوریتم ژنتیک یک روش بهینه‌سازی عددی است که بر پایه اصول داروین بوده و در آن از وراثتی طبیعی الهام گرفته شده است و در حال حاضر قادر به حل طیف وسیعی از مسائل، از قبیل طراحی بهینه قاب‌ها و طراحی بهینه سازه‌های هیدرولیکی می‌باشد (Hassanzadeh et al., 2012).

الگوریتم‌های ژنتیک، عملیات جستجو را از چندین نقطه در فضای پاسخ آغاز می‌کنند، هرکدام از این نقاط یک

معمولاً برازندگی بیشتری نسبت به نسل قبلی خود دارد (شکل ۳). نسل جدید جانشین نسل پیشین شده و این چرخه تا برآورده شدن معیارهای توقف الگوریتم ادامه خواهد یافت و در نتیجه برازنده ترین فرد نسل همگرا شده، جواب مسئله خواهد بود (Sette and Boullart, 2001).

داد. پس از اتمام بررسی برازندگی تمام افراد جامعه، الگوریتم ژنتیک، افراد بهتر را برای ایجاد نسل آینده انتخاب کرده و افراد ضعیف را حذف می کند. سپس افراد انتخاب شده جهت ایجاد نسل بعدی تحت عمل عملگرهای تصادفی مانند انتخاب، پیوند و جهش قرار می گیرند. پس از اعمال این عملگرها، نسل جدیدی ایجاد می شود که



شکل ۳. چهارچوب مفهومی الگوریتم ژنتیک، منبع: نگارندگان، ۱۴۰۱

همان ذره می باشد، در الگوریتم معادل یک پرنده بوده و خود الگوریتم در واقع حرکت جمعی پرندگان می باشد. هر ذره یک مقدار شایستگی دارد که توسط یک تابع شایستگی محاسبه می شود. هر قدر ذره در فضای پاسخ به هدف (غذا در مدل حرکت پرندگان) نزدیک تر باشد، دارای شایستگی بالاتری می باشد.

ساختار الگوریتم بدین صورت است که ابتدا گروهی از ذرات به صورت تصادفی ایجاد شده و با پیشروی نسل ها، سعی در یافتن راه حل بهینه ایجاد می شود. برای هر ذره و در هر گام، دو بهترین، دو مقدار نوسالزی، و هوش جمعی منجر به به روزرسانی می شود. اولین مورد، بهترین موقعیتی است که تاکنون ذره به آن رسیده که در این حالت موقعیت مذکور شناخته و حفظ می شود (شکل ۴).

الگوریتم ازدحام ذرات

این الگوریتم الهام گرفته از حرکت دسته جمعی پرندگانی که به دنبال غذا می باشند، بود. روش بهینه سازی ازدحام ذرات (PSO)^۱، روشی کمینه سازی بوده که با آن می توان به جواب مسائلی که شامل یک نقطه یا سطح در فضای n بعدی می باشد، دست یافت. گروهی از پرندگان در فضایی به صورت تصادفی دنبال غذا می گردند. تنها یک تکه غذا در فضای مورد جستجو وجود دارد. برای رسیدن جواب در چنین فضایی، بعد از طرح فرضیات، یک سرعت ابتدایی به آنها اختصاص یافته و کانال های ارتباطی بین ذرات منظور می شود. پس از حرکت ذرات مذکور در فضای پاسخ، نتایج به دست می آید. هر راه حل که در واقع

^۱ Particle swarm optimization

دهند. پس از یافتن بهترین مقادیر، سرعت و مکان هر ذره با استفاده از رابطه (۴) و (۵) به روز می شود.

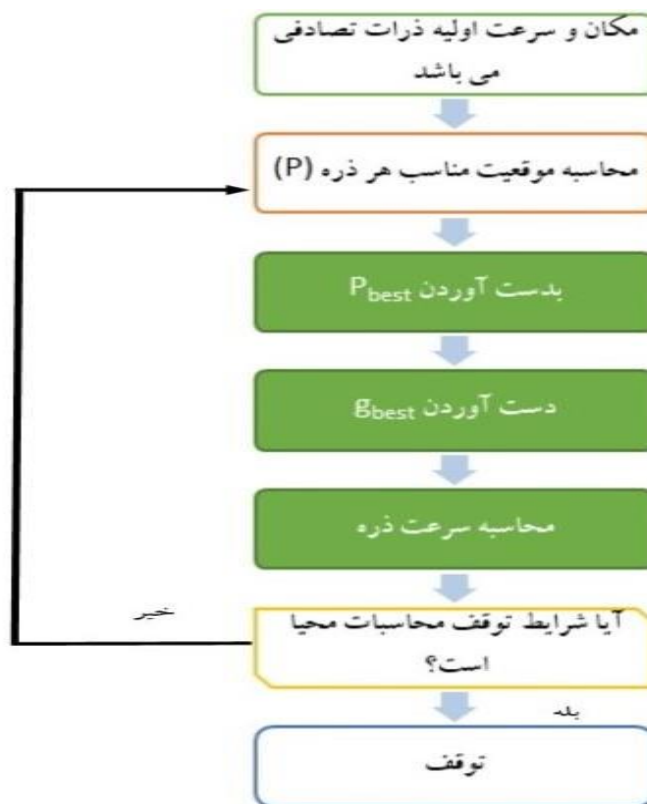
$$V_i(t+1) = W V_i(t) + C_1 r_{1,i}(t)(p_i(t) - X_i(t)) + C_2 r_{2,i}(t)(p_g(t) - X_i(t)) \quad \text{رابطه (۴)}$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad \text{رابطه (۵)}$$

حرکت می کنند. در واقع فرآیند حرکت دسته جمعی ذرات منجر خواهد شد که فضای جستجو به تدریج کوچک شده و جستجویی محلی حول بهترین ذره شکل گیرد (Kennedy and Eberhart, 1995).

مقدار نوسالزی را با pbest نمایش می دهیم. هوش جمعی، بهترین موقعیتی می باشد که به وسیله ی جمعیت ذرات تاکنون به دست آمده است که آن را gbest نمایش می -

سرعت ذرات با توجه به موقعیت فعلی و بهترین تجربه ذره و بهترین تجربه جمع تعیین شده و عملاً تأثیر سرعت کنونی و لختی حذف می شود؛ بنابراین بهترین ذره گروه در جای خود ثابت مانده و سایر ذرات به سمت آن



شکل ۴. چهارچوب مفهومی الگوریتم ازدحام ذرات، منبع: نگارندگان، ۱۴۰۱

دقت بالای داده مدل و خطای کمتر، و مقدار صفر نشان دهنده عدم وجود خطا در برآورد داده است (Price, et al, 2000; Moriasi, et al, 2007).

حال آنکه میانگین خطای مطلق (رابطه ۲) بیانگر تفاوت دو مقدار پیوسته می باشد. در فضای دکارتی، این شاخص بیانگر فاصله عمودی و افقی هر نقطه تا خط مشخصه می باشد. هر قدر این مقدار کمتر باشد بیانگر دقت

روش های ارزیابی

در این پژوهش جهت بررسی عملکرد داده های شبکه ای از آماره های MAE, BIAS, RMSE استفاده شده است. این نمایه ها در روابط (۱) تا (۳) نمایش داده شده اند. نمایه میانگین مربعات خطا بیان کننده تفاوت بین مقادیر برآورد شده (X_i) با مقادیر مشاهده شده (Y_i) است (رابطه ۱). هر چه این مقادیر به صفر نزدیک تر باشند نشان دهنده

۲. ۱. محدوده مورد مطالعه

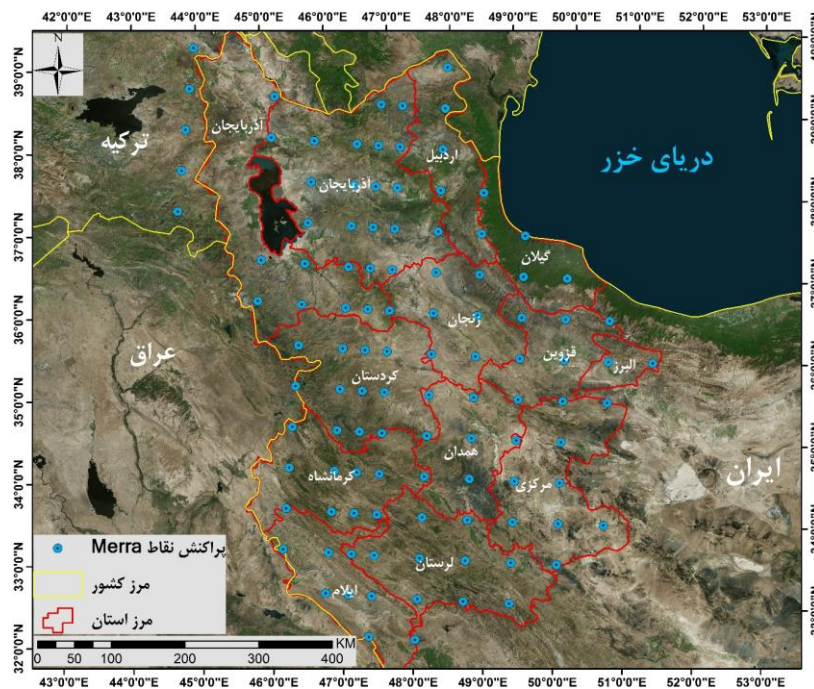
با هدف ارزیابی خشکسالی‌های استان‌های غرب و شمال‌غرب ایران، داده‌های ماهانه بارش و رطوبت خاک برای استان‌های همدان، کرمانشاه، کردستان، آذربایجان غربی، آذربایجان شرقی، اردبیل، زنجان، قزوین، ایلام، مرکزی، گیلان و لرستان برای یک دوره ۳۶ ساله (۱۹۸۰-۲۰۱۶) با قدرت تفکیک مکانی مناسب به صورت شبکه‌ای ۰/۶۶ در ۰/۵ درجه از پایگاه داده MERRA دریافت شد (شکل ۵).

بالتر مدل می‌باشد. BIAS بیانگر مجموع تفاضل بین مقادیر مشاهده‌ای با محاسباتی بر تعداد داده‌ها (n) می‌باشد. نزدیک به صفر بودن پارامتر bias نیز نشان‌دهنده دقت بیشتر مدل در شبیه‌سازی است (Cohen, 2012). (رابطه ۳).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad \text{رابطه (۱)}$$

$$MAE = \left(\frac{\sum_{i=1}^n |X_i - Y_i|}{n} \right) \quad \text{رابطه (۲)}$$

$$Bias = \frac{\sum_{i=1}^n (X_i - Y_i)}{n} \quad \text{رابطه (۳)}$$



شکل ۵. محدوده مورد مطالعه و پراکنش جغرافیایی نقاط Merra (Resource: <https://disc.sci.gsfc.nasa.gov/daac-bin/FTPSubset.pl>), منبع:

نگارنگان، ۱۴۰۱.


است (شکل‌های ۵، ۶ و ۷). شاید بتوان نقش عرض جغرافیایی و پرفشار جنب حاره را در این مورد دارای اهمیت دانست که با حرکت به سمت عرض‌های بالاتر و افزایش عرض جغرافیایی از شدت خشکسالی کاسته می‌شود. نقشه‌های ماهانه نشان دهنده این است که از ماه‌های مارس تا اکتبر (شکل ۵، پ تا د)، استان‌های غربی (کرمانشاه، لرستان و خصوصاً ایلام) بیشینه میزان خشکسالی خود را تجربه می‌کنند، همچنین شدیدترین خشکسالی حداقل

۳. یافته‌های تحقیق

مشخصه‌های مکانی خشکسالی منطقه مورد مطالعه با شاخص MSDI


مقدار شاخص خشکسالی MSDI برحسب دوره‌های زمانی ماهانه (شکل ۵)، فصلی (۶) و سالانه (۷) برای منطقه مورد مطالعه ارائه شده است. مطابق نقشه‌های ماهانه، فصلی و سالانه در دوره مورد مطالعه و همچنین براساس طبقه بندی شاخص MSDI خشکسالی‌های شدید در بخش‌های جنوبی منطقه مورد مطالعه یعنی استان‌های ایلام و کرمانشاه رخ داده

ماه‌های آوریل تا جولای (شکل ۵، ت تا چ) و کمترین در دسامبر (شکل ۶) و در رتبه بعد در نوامبر (شکل ۵ ذ)



شکل ۶. توزیع ماهانه خشکسالی بر اساس شاخص MSDI (دوره زمانی ۲۰۱۶-۱۹۸۰)


بررسی نقشه‌های فصلی نشان دهنده این است که شدیدترین رتبه بعدی در قرار دارد (شکل ۷)، که نیمه جنوبی منطقه خشکسالی در فصل بهار و تابستان (شکل ۵، الف و ب) در مورد مطالعه (کرمانشاه، لرستان و ایلام) را در بر گرفته است.



شکل ۷. توزیع فصلی خشکسالی بر اساس شاخص MSDI (دوره زمانی ۲۰۱۶-۱۹۸۰)

نمای کلی سالانه خشکسالی بر اساس شاخص MSDI نشان دهنده این است که به غیر از استان ایلام که در طبقه متوسط قرار گرفته، سایر مناطق مورد مطالعه در طبقه خشکسالی ضعیف و خیلی ضعیف قرار دارند (شکل ۶). حداقل شدت خشکسالی در منطقه نیز در نواحی شمالی استان‌های آذربایجان غربی و اردبیل، مرکز آذربایجان شرقی مشاهده می‌شود که منطبق بر توزیع فصلی است (شکل ۷). بطور کلی می‌توان نتیجه گرفت که شدت خشکسالی از

جنوب منطقه مورد مطالعه به سمت عرض‌های بالاتر کاسته می‌شود. نکته جالب توجهی که در نقشه‌های ماهانه، فصلی و سالانه بارز می‌باشد، طبق طبقه‌بندی شاخص MSDI، خشکسالی شدید در منطقه مورد مطالعه دیده نشد و شدیدترین خشکسالی‌ها در طبقه متوسط قرار دارند (شکل - های ۶، ۷ و ۸).



شکل ۸. توزیع سالانه خشکسالی بر اساس شاخص MSDI (دوره زمانی ۲۰۱۶-۱۹۸۰)

مقادیر حداقل، حداکثر، میانگین و انحراف از معیار داده‌های هریک از نقاط متناظر محاسبه و در جدول (۲) ارائه شده

بررسی آماری داده‌ها

حداقل خطا بین داده‌های مشاهداتی و محاسباتی، بایستی بخش‌های مختلف اعم از ساختار لایه‌ها، تعداد نرون‌ها، توابع انتقال و یا توابع آموزش را تغییر داد. ازین رو، تغییرات در تعداد نرون‌ها و همچنین توابع آموزش نیز صورت گرفت. نتایج نشان داد که بهترین عملکرد مربوط به ساختار موجود در جدول (۳) می‌باشد که به‌عنوان ساختار بهینه در ادامه مدل‌سازی از آن استفاده شد. برای شبکه بهینه‌شده با استفاده از الگوریتم ذرات (PSO)، نرخ ازدحام ذرات (SwarmSize) و دوره‌های آموزش (MaxIteration) ۵۰ و ۲۵۰ قرار داده شد. در شبکه بهینه‌شده با استفاده از الگوریتم ژنتیک (GA)، با تغییر در ساختار تابع آموزشی شامل PopSize و MaxGenerations تابع بهینه مشخص شد، به گونه‌ای که نرخ جمعیت در این حالت ۴۵ و تعداد نسل‌ها ۱۸۰ به دست آمد. شکل ۸ نمودارهای خروجی نرم‌افزار matlab می‌باشد که از مدل‌سازی داده‌ها با استفاده از ساختار بهینه به دست آمده است.

است. داده‌های این جدول، در راستای تحلیل عملکرد خروجی‌های شبکه و محاسبه شاخص‌های ارزیابی خطا کاربرد خواهد داشت. همان‌گونه که مشخص است، تغییرات مشاهده شده به دلیل ماهیت تفاوت در ماهیت اقلیمی مناطق انتخاب‌شده (استان‌های همدان، کرمانشاه، کردستان، آذربایجان غربی، آذربایجان شرقی، اردبیل، زنجان، قزوین، ایلام، مرکزی، گیلان و لرستان) منطقی است.

جدول ۲. بررسی آماری میانگین داده‌های پژوهش

پارامتر	حداکثر مقدار	حداقل مقدار	میانگین	انحراف از معیار
MSDI حاصل از داده‌های MERRA	0.83	-0.56	1.92	-1.92

منبع: نگارندگان، ۱۴۰۱

نتایج خروجی شبکه عصبی مصنوعی

یکی از گام‌های مهم در مدل‌سازی با کمک شبکه‌های عصبی مصنوعی، یافتن ساختار بهینه شبکه می‌باشد (سلیمی و همکاران، ۲۰۱۸). جهت دست یافتن به ساختار بهینه با

جدول ۳. ساختار بهینه شبکه عصبی مصنوعی مورد استفاده


نوع شبکه	تعداد لایه‌ها	توابع	ساختار نرون‌ها
ANN	4	Tansig tansig purelin purelin	25 20 20 1
ANN-PSO	3	Tansig tansig purelin	20 20 1
ANN-GA	3	Tansig tansig purelin	25 20 1

منبع: نگارندگان، ۱۴۰۱

جدول ۴. نتایج ارزیابی عملکرد مدل‌سازی با استفاده از شبکه عصبی مصنوعی

شبکه	پارامتر	مقدار میانگین در نقاط گره‌ها
ANN	RMSE	0.016
	BIAS	0.00043
	MAE	0.00067
ANN-PSO	RMSE	0.0134
	MAE	0.00144
	BIAS	-0.00138
ANN-GA	RMSE	0.012
	MAE	0.00053
	BIAS	-0.00048

منبع: نگارندگان، ۱۴۰۱



شکل ۸. نتایج تحلیل ساختار بهینه مربوط به شبکه عصبی مصنوعی (الف)، شبکه بهینه شده با PSO (ب) و

مربوط به GA (ج)، منبع: نگارندگان، ۱۴۰۱

نقاط گره‌های شبکه با اعمال دو پارامتر بارش و رطوبت خاک به عنوان ورودی و مقدار MSDI به عنوان خروجی شبیه‌سازی شد.

این تصاویر شامل نقاط (۴۴،۴۰) بعنوان نمونه می‌باشد. نتایج ارزیابی خطای مدل‌سازی مطابق شبکه عصبی مصنوعی، الگوریتم ژنتیک و ازدحام ذرات در جدول (۴) قابل مشاهده است. قابل ذکر است که ۲۲۸ مدل بر اساس

مناسب ساختار داده‌ها با تئوری الگوریتم ژنتیک و همچنین آموزش بهینه آن‌ها به‌واسطه ساختار بهینه‌شده مورد استفاده می‌باشد.

مقایسه نتایج حاصل از شبکه عصبی مصنوعی و بهینه‌شده با داده‌ها

تجمیع جداول ارزیابی خطای مدل‌سازی و انطباق مقادیر میانگین حداقل، حداکثر، میانگین و انحراف از معیار شبکه-های عصبی مصنوعی و جدول بررسی آماری داده‌ها (جدول ۲) در جدول (۵) ارائه شده است. دلیل استفاده از مقدار میانگین، حجم بالای داده‌ها می‌باشد.

جدول ۵. ارزیابی آماری میانگین مقادیر مدل‌سازی و داده‌های MERRA

پارامتر	حداکثر مقدار	حداقل مقدار	میانگین	انحراف از معیار
MSDI حاصل از داده‌های MERRA	0.83	-0.56	1.93	-1.93
MSDI حاصل از ANN	0.90	-0.55	1.87	-1.16
MSDI حاصل از ANN-PSO	0.80	-0.56	1.88	-1.23
MSDI حاصل از ANN-GA	0.82	-0.56	1.90	-1.84

منبع: نگارندگان، ۱۴۰۱

جدول (۶) میانگین شاخص‌های خطا برای تمامی نقاط مدل‌سازی می‌باشد. جهت خلاصه شدن نتایج از میانگین استفاده شده است. بر این اساس، و بر مبنای شاخص‌های ارزیابی، مدل‌سازی با استفاده از الگوریتم ژنتیک دقت مناسب‌تری نسبت به سایر روش‌ها دارد.

جدول ۶. ارزیابی میانگین شاخص‌های خطای روش‌های مدل‌سازی با داده‌های MERRA

ANN-GA	ANN-PSO	ANN	
0.012	0.0134	0.016	RMSE
0.00053	0.00144	0.00067	MAE
-0.00048	-0.00138	0.00043	BIAS

منبع: نگارندگان، ۱۴۰۱

شبکه‌ها و تأثیرپذیری از نرون‌های اطراف خود در پیش‌بینی مقدار نرون هدف است. با استفاده از بهینه‌ساز، ضمن یکدست‌تر شدن نقشه، هدف دیگر شبکه یعنی کاهش میزان خطای هدف نیز صورت می‌گیرد. همان‌طور که در شکل (۹) نیز مشخص است شبکه عصبی مصنوعی در فصل‌های


همان‌گونه که از نتایج مشخص است، میزان خطای شبکه عصبی مصنوعی فاصله نسبتاً زیادی با حد مطلوب دارد. از این‌رو از توابع بهینه‌ساز جهت بالا بردن کارایی شبکه بهره گرفته شد. برای این منظور از دو الگوریتم ازدحام ذرات و ژنتیک استفاده شد. نتایج الگوریتم ازدحام ذرات نسبت به شبکه عصبی مصنوعی جواب‌های بهتری را ارائه نمود که دلیل بهبود عملکرد شبکه، استفاده از ساختار الگوریتم ازدحام ذرات در آموزش شبکه می‌باشد. ارزیابی خطای مدل‌سازی با استفاده از الگوریتم ژنتیک، نشان داد که این الگوریتم نسبت به دو مدل‌سازی قبلی به مراتب نتایج بهتری را عرضه می‌نماید. دلیل این موضوع مسلماً همخوانی

نتایج نشان داد که داده‌های حاصل از مدل‌سازی با شبکه عصبی مصنوعی بهینه‌شده با استفاده از الگوریتم ژنتیک، مشابهت بهتری نسبت به سایر روش‌ها نسبت به داده‌ها دارد (جدول ۵). همان‌طور که از نتایج مشخص است شبکه عصبی مصنوعی ضعیف‌ترین عملکرد را نسبت به سایر روش‌ها داراست که به دلیل روش آموزش آن می‌باشد.

نقشه‌های مربوط به هر الگوریتم نیز جهت بررسی کیفیت مدل‌سازی صورت گرفته در شکل (۹) ارائه شده است. همان‌گونه که در تصاویر نیز مشخص است، شبکه‌های عصبی سعی در ارائه تصاویر نسبتاً یکدست‌تری نسبت به داده‌های ماهواره‌ای دارند که این به دلیل ماهیت عملکردی

باشد (شکل ۹ ک)، اما در جمع بندی کلی بر اساس شاخص های خطای موجود، عملکرد بهینه ساز الگوریتم ژنتیک بهتر از سایر مدل ها می باشد.

بهار و تابستان (شکل ۹ ز و ض) عملکرد موفق تری را از نظر شباهت نقشه تولیدی نسبت به سایر روش ها دارد، حال آنکه در پاییز (شکل ۹ غ) عملکرد الگوریتم ژنتیک بهتر بوده و مدل سازی صورت گرفته است. نتایج شبیه سازی در زمستان مبین آن است که عملکرد الگوریتم ازدحام ذرات بهتر می -



شکل ۹. کیفیت مدل سازی صورت گرفته، (الف، ر، ص و ف) مربوط به MERRA، (ب، ز، ض و ق) مربوط به ANN، (ج، س، ع و ک) مربوط به PSO و (د، ش، غ و گ) مربوط به GA. منبع: نگارندگان، ۱۴۰۱

۴. بحث و نتیجه گیری

خشکسالی به عنوان یکی از پدیده‌های حادی آب و هوایی بر منابع آب تأثیرگذار می‌باشد. هدف اصلی این پژوهش بررسی و ارزیابی خشکسالی و کارآیی روش‌های شبکه عصبی مصنوعی در ارزیابی پیش‌بینی آن برای غرب ایران بود. بر اساس نتایج حاصل از شاخص‌های ارزیابی، مشخص شد که داده‌های مذکور با روش محاسباتی دارای همبستگی مناسبی قرار دارند.

بررسی‌های ماهانه نشان داد شدیدترین خشکسالی در منطقه مورد مطالعه، حداث ماه‌های آوریل تا اکتبر به وقوع می‌پیوندد و کانون اصلی وقوع این پدیده، استان‌های لرستان و خصوصاً کرمانشاه و ایلام می‌باشند. بیشترین گستردگی خشکسالی مربوط به ماه‌های آوریل و می می‌باشد و همچنین در بین سایر ماه‌ها، ماه ژانویه، کمترین میزان خشکسالی را به خود اختصاص داده است. اما آنچه که مشهود است شدت خشکسالی در غرب ایران بیشتر از شمالغرب می‌باشد. الگوی مکانی فصلی و سالانه نیز مشابه ماهانه می‌باشد، بطوریکه، به غیر از فصل بهار که تقریباً خشکسالی بیش از ۷۰ درصد منطقه را احاطه کرده است، نواحی جنوبی منطقه مورد مطالعه یعنی استانهای کرمانشاه، لرستان و ایلام بیشترین مقدار خشکسالی را به خود اختصاص داده‌اند. الگوی سالانه نیز همانند فصلی است و هرچه به سمت عرض‌های بالاتر و شمالغرب ایران می‌رویم از شدت خشکسالی کاسته می‌شود. نکته جالب توجهی که در نقشه‌های ماهانه، فصلی و سالانه بارز می‌باشد، طبق طبقه‌بندی شاخص MSDI، خشکسالی شدید در منطقه مورد مطالعه دیده نشد و شدیدترین خشکسالی‌های در طبقه متوسط قرار دارند.

پس از بررسی خشکسالی در منطقه، با استفاده از شبکه عصبی مصنوعی و الگوریتم‌های بهینه‌ساز ازدحام ذرات و الگوریتم ژنتیک، داده‌ها شبیه‌سازی شدند. نتایج نشان داد که عملکرد

شبکه عصبی بهینه‌شده با استفاده از الگوریتم ژنتیک نسبت به سایر مدل‌ها بهتر می‌باشد. نتایج حاصل مبنی بر برتری عملکرد الگوریتم ژنتیک نسبت به ANN و PSO در پیش‌بینی پارامترهای اقلیمی، با پژوهش Moeeni and et al (2017) در پیش‌بینی جریان پایه، Abdollah and et al (2014) در پیش‌بینی تبخیر و Arshad and et al (2013) در پیش‌بینی تأثیر خشکسالی بر کشاورزی، مطابقت دارد. همچنین از مقایسه نقشه‌ها با مقادیر محاسبه شده در مرحله قبل این‌طور برداشت شد که شبکه عصبی مصنوعی دقت نسبتاً قابل قبولی را در مدل‌سازی دارد و با حذف فرمول از محاسبات و ایجاد امکان ورود پارامترهای مؤثر در محاسبات، می‌تواند مؤثر باشد هرچند نقشه‌های حاصل از آن نسبتاً یکدست‌تر می‌باشد.

۵. فهرست منابع

- Abbasian, M.S., Abrishamchi, A., (2013). Comparison of multivariate analysis with univariate analysis for drought events. 8th National Congress of Civil Engineering, Faculty of Civil Engineering. Babol. (in Persian)
- Abdullah, S. S., Malek, M. A., Mustapha, A., & Aryanfar, A., (2014). Hybrid of Artificial Neural Network-Genetic Algorithm for Prediction of Reference Evapotranspiration (ET^0) in Arid and Semiarid Regions. Journal of Agricultural Science, 6(3), 191.
- Aghakouchak, A., (2015). A multivariate approach for persistence-based drought prediction: Application to the 2010-2-11 East Africa drought, Journal of Hydrology, 526, 127-135.
- Arshad, S., Morid, S., Mobasheri, M. R., Alikhani, M. A., & Arshad, S., (2013). Monitoring and forecasting drought impact on dryland farming areas. International Journal of Climatology, 33(8), 2068-2081.
- Bazrafshan, O., Salajegheh, A., Mahdavi, M., Bazrafshan, J., (2015). A Study of Efficiency of the Hybrid model Artificial Neural Network Models - Stochastic in Hydrological Drought

- Hao, Z., Aghakouchak, A., Nakhjiri, N., Farahmand, A., (2015). Global integrated drought monitoring and prediction system, *Journal of Scientific Data*, doi:10.1038/sdata.2014.1.
- Hao, Z., Singh, V.P., (2015). Drought characterization from a multivariate perspective: A review, *Journals of Hydrology*. Vol 527, 668-678
- Hassanvand, M. R., Karami, H., & Mousavi, S. F., (2018). Investigation of neural network and fuzzy inference neural network and their optimization using meta-algorithms in river flood routing. *Natural Hazards*, 94(3), 1057-1080.
- Hassanvand, M., Salimi, A., MasoompourSamakoosh, J., (2018). Drought prediction using neural network and meta-algorithms (Case study: Kermanshah Station). Conference: The First National Conference on The Role of Civil ENG. in Hazard Mitigation At: Kermanshah, I.R. Iran. (In Persian)
- Hassanzadeh, Y., Abdi Kordani, A., Fakhri Fard, A., (2012). Drought Forecasting Using Genetic Algorithm and Conjoined Model of Neural Network-Wavelet. *Journal of Water and Wastewater*, 83(3); 48-59. (in Persian)
- Holland, J. H (1992), *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. MIT press.
- Janga Reddy, M., Singh, V, P., (2013). Multivariate modeling of drought using copulas and meta-heuristic methods, *Stochastic Environmental Research and Risk Assessment*. Vol 28, 475–489, doi:10.1007/s00477-013-0766-2.
- Kang, H., Sridhar, V., (2017). Combined statistical and spatially distributed hydrological model for evaluating future drought indices in Virginia, *Journal of Hydrology: Regional Studies*, 12, 253-227.
- Kao, SH., Govindaraju, S., (2010). A copula-based deficit index for droughts, *Journal of Hydrology*, 380, 121-134.
- Kennedy, J.; Eberhart, R., (1995), Particle swarm optimization. In *Proceedings of ICNN'95 - International Conference on Neural Networks*. ICNN'95 - International Conference on Neural
- Forecasting Using kappa Statistics (Case Study: Gamasiab Watershed Basin). *Iranian Journal of Watershed Management Science&Engineering*, 8 (27):35-48. (in Persian)
- Cohen Liechti, T., Matos, J.P., Boillat J.L., & Schleiss, A.J., (2012), "Comparison and evaluation of satellite derived precipitation products for hydrological modeling of the Zambezi River Basin". *Hydrol. Earth Syst. Sci.* No. 16: 489–500.
- Farahmand, A., Aghakouchak, A., (2014). A Generalized Framework for Deriving Nonparametric Standardized Drought Indicators, *Advances in Water Resources*, doi: 10.1016/j.advwatres.
- Farahmand, A., Aghakouchak, A., Teixeira, J., (2015). Advantage from space can detect earlier drought onset: An approach using relative humidity, *Journal of Scientific Reports*, 5, doi:10.1038/srep08553.
- Ghamghami, M., Bazrafshan, J., (2012). Prediction of meteorological drought conditions in Iran using the Markov chain model. *Journal of Water and Soil Resources Conservation*, 3(3); 1-12. (in Persian)
- Ghobaei Souq, M., Mosaedi, A., Zare Abianeh, H., (2016). The necessity of drought monitoring based on multivariable indicators. 6th Iranian National Water Resources Management Conference, The University of Kordestan. (in Persian)
- Golin, S., Mazdiyasn, O., Aghakouchak, A., (2014). Trends in meteorological and agricultural drought in Iran. *Theor App Climatol*. DOI:10.1007/s00704-014-1139-6.
- Hao, Z., Aghakouchak, A., (2013), Multivariate Standardized Drought Index: A Parametric Multi-Index Model, *Advances in Water Resources*, 57, 12-18, doi: 10.1016/j.advwatres.2013.03.009.
- Hao, Z., Aghakouchak, A., (2014). A Nonparametric Multivariate Multi-Index Drought Monitoring Framework, *Journal of Hydrometeorology*, 15, 89-101, doi:10.1175/JHM-D-12-0160.1.

Nebraska, Final report submitted to the Natural Resources Commission, Lincoln.Nebraska. p578.

Networks, Perth, WA, Australia, 27 Nov.-1 Dec. 1995; IEEE, 1995; pp 1942-1948, ISBN 0-7803-2768-3.

Kogan, F.N., (1997). Global Drought Watch from Space. Bulletin of the American Meteorological Society. Vol 78 NO 4: 621-636.

Loukas, A., Vasiliades, L., and Tzabiras, J (2007). "Evaluation of climate change on drought impulses in Thessaly, Greece." European Water, 17/18, No. 17-28.

Mishra, A.K., Singh, V.P., (2010). A review of drought concepts, Journal of Hydrology, 391,202-216.

Mishra, A.K., Singh, V.P., (2011). Drought modeling-A review, Journal of Hydrology, 403,157-175.

Moeeni, H., Bonakdari, H., Fatemi, S. E., & Zaji, A. H (2017). Assessment of stochastic models and a hybrid artificial neural network-genetic algorithm method in forecasting monthly reservoir inflow. INAE Letters, 2(1), 13-23.

Moriasi, DN., Arnold JG., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L., (2007), Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. Transactions of the ASABE. 50(3), 885-900.

Price, D., McKenney, D. W., Nalder, I. A., Hutchinson, M. F., Kesteven, J. L., (2000), A comparison of two statistical methods for spatial interpolation of Canadian monthly mean climate data, Agricultural and Forest Meteorology 101: 81-94.

Sadeghian, M., Karami, H., Mousavi, S.F., (2018). Selection of a Proper Model to Predict Monthly Drought in Semnan Using Weather Data and Linear and Nonlinear Models. Journal of Water and Soil science; 21(4): 57-70. (in Persian)

Sette, S.; Boullart, L., (2001) Genetic programming: principles and applications. Engineering Applications of Artificial Intelligence, 14, 727-736, doi:10.1016/S0952-1976(02)00013-1.

Wilhite, D.A., (1995). Developing a precipitation-based index to assess climatic condition across

