




## Exploring the Probability of Drought and selecting the most Appropriate Indicator for Climatic Regions of Iran

Lale Salimi<sup>1</sup> | Jafar Masoompour Samakosh<sup>2</sup>  | Firouz Mojarrad<sup>3</sup> | Abdollah Jalilian<sup>4</sup>

1. Department of Geography, Faculty of Literature and Human Sciences, Razi University, Kermanshah, Iran. [Lale\\_salimi@yahoo.com](mailto:Lale_salimi@yahoo.com)

2. Corresponding Author, Department of Geography, Faculty of Literature and Human Sciences, Razi University, Kermanshah, Iran. [j.masoompour@razi.ac.ir](mailto:j.masoompour@razi.ac.ir)

3. Department of Geography, Faculty of Literature and Human Sciences, Razi University, Kermanshah, Iran. [F\\_mojarrad@yahoo.com](mailto:F_mojarrad@yahoo.com)

4. Department of Statistics, Faculty of Science, Razi University, Kermanshah, Iran. [jalilian@razi.ac.ir](mailto:jalilian@razi.ac.ir)

### Article Information

#### Research Paper

**Vol:** 14  
**No:** 53  
**P:** 18-39  
**Received:** 2023-05-26  
**Revised:** 2023-06-25  
**Accepted:** 2023-06-27  
**Published:** 2023-10-15

#### Keywords:

- Drought
- Artificial Neural Network
- Computational Intelligence Models
- Cloud Theory
- Uncertainty
- Climatic Regions of Iran

#### Cite this Article:

Salimi, L., Masoompour Samakosh, J., Mojarrad, F., Jalilian, A. (2023). Exploring the Probability of Drought and selecting the most Appropriate Indicator for Climatic Regions of Iran. *Journal of Arid Regions Geographic Studies* 14(53): 18-39.  
doi: 10.22034/JARGS.2023.403437.1041

**Publisher:** Hakim Sabzevari University

© The Author(s)



### Abstract

**Aim:** Iran is a vast country with a different climate due to its geographical location and topographical conditions. The current research was carried out to select the most appropriate drought index in Iran's climatic regions and investigate the probability of its occurrence through uncertainty methods.

**Material & Method:** In this research, in the first step, through multi-criteria decision-making methods, the most suitable index for each climate zone is selected based on the percentage of suitability, and finally, based on artificial neural network methods, probability analysis is calculated and the probability of the phenomenon occurring. In this research, after choosing the appropriate index, the statistical data of the country's synoptic station in a statistical period of 28 years (1990-2017) has been used to express the probability of drought, and the Kernel method has been used to converge the data.

**Finding:** The final result of the cloud theory analysis of the studied data shows that in all the stations examined in the target year, i.e., 2017, the country of Iran and all the representative stations have shown climatic conditions close to the normal range. The highest likelihood of occurrence belongs to Tabriz station (96%) and Hamedan station (94%).

**Conclusion:** Based on the results, the selective uncertainty model has a high ability in probability analysis and has predicted the probability of drought with an acceptable percentage of confidence.

**Innovation:** Due to the difference in climatic regions of Iran, the elimination of user intervention, and the use of scientific and mathematical calculations, the error rate in selecting the index is reduced. Then, with the help of uncertainty methods such as cloud theory, the ability to predict the probability of drought in the future increases.

## **Extended Abstract**

### **1. Introduction**

Researchers have used several methods to predict and monitor drought in recent years. Still, so far, only one scientific method based on the copula function has been presented to determine the probability of drought for these predictions. These studies show that some studied areas are more exposed to this phenomenon, and others are less at risk. Also, one of the other results of this method is that probability estimation can be a crucial step in the direction of correct planning by relevant officials and managers. Therefore, the estimation of the probability of drought is diverse based on probabilistic analysis methods. In this way, it is possible to check the correct performance of drought forecasting in the past and ensure the accuracy of forecasting performance for the future. Nowadays, several indices, such as SPI, SPEI, MSDI, PDSI, PNPI, RDI, etc., are used to investigate and monitor drought in different parts of the world and according to the needs of researchers. However, a suitable method for each region should be selected and, according to the type of climate in that region, increases the study's accuracy.

### **2. Materials and Methods**

The study area includes Gorgan, Zahedan, Ahvaz, Isfahan, Tehran (Mehrabad), Tabriz, Kermanshah, Mashhad, Rasht, Hamedan, Shiraz, Meshkinshahr, and Abali stations located in different regions of Iran. In this study, to select the best drought index in Iran, the monthly and annual data of average temperature, pressure, relative humidity, evaporation, precipitation, etc., of the nine mentioned synoptic stations representing the nine climatic regions of Iran have been used. In this research, in the first step, through multi-criteria decision-making methods, the most appropriate index for each climatic region was selected based on the percentage of appropriateness. Finally, based on the methods of artificial neural networks, probability analysis, and the rate of probability, the occurrence of drought phenomena has been determined for each area. After choosing the appropriate index, the statistical data of the country's synoptic station in a 28-year statistical period (1990–2017) has been used to express the probability of drought. According to the rainfall data sequence, two types of normal and deep neural networks were used to investigate the drought phenomenon. In addition, the Kernel method was used to generate data for neural network training to compensate for the lack of data and increase the speed of network convergence. Also, Cloud theory was used to analyze the artificial neural network and calculate the probability of drought occurrence.

### **3. Results and Discussion**

In this study, 15 indicators were selected among the existing drought indicators and calculated among the meteorological drought indicators. It should be noted that the effective parameters in this study were temperature, precipitation, total hours of sunshine, potential evapotranspiration, and relative humidity. The results of the model show that in the climatic region Bsh, Bsk, Csb, Dsa, Dsb, Csa, Cfa, SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI-MSDI-PNPI-ERI indices The most suitable index is the SPEI-RDI index in the BWh climate area, followed by the PDSI and SPI indices. In the BWk climate area, the SPEI-RDI index and the PDSI index with different percentages are suitable.

According to the output graphs for the mentioned stations, the network's performance in Isfahan, Abali, and Mashhad stations is less capable than other stations, respectively, which may be related to the type of data in the mentioned stations. On the other hand, the best performance of the network was in Tehran, Shiraz, Kermanshah, and Tabriz stations at one level, respectively, and at the next level in Hamedan and finally in Gorgan, which shows the high ability of the network in predicting the selected parameter. In connection with Rasht, Ahvaz, and Zahedan stations, it has a relatively high performance and can predict parameter values with suitable capability.

Based on the output graphs and data analysis from the probabilistic analysis of cloud theory, the value of the SPI index for all the selected stations is in the range of -3 to +3, and the data distribution is non-parametric. By choosing one year as the target year (2017), the results indicate that compared to the value of the SPI index based on observational data, the highest probability of drought is related to Tabriz station (96 percent). Then, Hamedan (95 percent), and the lowest is related to Ahvaz with 64 percent. In fact, for all stations, the model and actual data are very close to each other, which indicates the high ability of both networks to determine the uncertainty of the selected stations.

### **4. Conclusions**

The results of Fuzzy logic showed that in the climatic region Bsh (Shiraz and Tehran station), Bsk (Mashhad and Tabriz station), Csb (Meshkinshahr station), Dsa (Nojeh-Hamadan station), Dsb (Abali station), Csa (Kermanshah and Gorgan station), Cfa (Rasht station), SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI-MSDI-

PNPI-ERI index, in the BWh climate zone, SPEI-RDI index And after them, the PDSI and SPI indices, the SPEI-RDI index, and the PDSI index with different proportion percentages are suitable in the BWk climate zone. The selected index for the neural network model in the climatic regions Bsh, Bsk, Csb, Dsa, Dsb, Csa, and Cfa is the SPI index, and in the climatic regions BWh and BWk, it is the SPEI index. The analysis of the neural network model results based on two deep and classical types, and according to the lack of data, indicated better performance of the classical network than the deep one because, in general, deep networks need data to improve performance. Also, the final results of the Cloud theory analysis of the studied data showed that all the stations in the target year, i.e., 2017, Iran, and all the representative stations, showed climatic conditions close to the normal range. Iran's drought severity in the mentioned year was almost within the normal range. The comparison of the obtained results with the actual data also shows the same thing. This issue indicates the very high ability of possible uncertainty analysis in determining the occurrence of the drought phenomenon.

## 5. Funding

The manuscript did not receive a grant from any organization


## 6. Conflict of Interest

- The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.
- The authors declare no conflict of interest.



## بررسی احتمال خشکسالی و انتخاب مناسبترین شاخص در نواحی اقلیمی

### ایران

لاله سلیمی<sup>۱</sup>، جعفر معصوم پور سماکوش<sup>۲</sup> <sup>ib</sup>، فیروز مجرد<sup>۳</sup>، عبدالله جلیلیان<sup>۴</sup>

- ۱- گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه رازی، کرمانشاه، ایران. [Lale\\_salimi@yahoo.com](mailto:Lale_salimi@yahoo.com)
- ۲- نویسنده مسئول، گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه رازی، کرمانشاه، ایران. [j.masoompour@razi.ac.ir](mailto:j.masoompour@razi.ac.ir)
- ۳- گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه رازی، کرمانشاه، ایران. [F\\_mojarrad@yahoo.com](mailto:F_mojarrad@yahoo.com)
- ۴- گروه آمار، دانشکده علوم، دانشگاه رازی، کرمانشاه، ایران. [jalilian@razi.ac.ir](mailto:jalilian@razi.ac.ir)

### چکیده:

**هدف:** ایران کشوری پهناور است که به دلیل موقعیت جغرافیایی و شرایط توپوگرافی، دارای آب و هوایی متفاوت است. پژوهش حاضر با هدف انتخاب مناسبترین شاخص خشکسالی در نواحی اقلیمی ایران و بررسی احتمال وقوع آن از طریق روش‌های عدم قطعیت انجام شده است.

**روش و داده:** لذا در این پژوهش در گام نخست از طریق روش‌های تصمیم‌گیری چندمعیاره، مناسبترین شاخص برای هر ناحیه اقلیمی بر اساس درصد تناسب، انتخاب و در نهایت بر اساس روش‌های شبکه عصبی مصنوعی، آنالیز احتمالی محاسبه و درصد احتمال وقوع پدیده خشکسالی برای هر ناحیه تعیین شده است. پس از انتخاب شاخص مناسب، برای بیان احتمال وقوع خشکسالی از داده‌های آماری ایستگاه‌های سینوپتیک کشور در یک دوره آماری ۲۸ ساله (۲۰۱۷-۱۹۹۰) استفاده شده است. با توجه به توالی داده‌های بارشی، از دو نوع شبکه عصبی معمولی و عمیق برای بررسی پدیده خشکسالی استفاده گردید. ضمناً برای جبران کمبود داده‌ها و افزایش سرعت همگرایی شبکه، از روش کرنل برای تولید داده‌ها در آموزش شبکه عصبی، و برای تحلیل شبکه عصبی مصنوعی و محاسبه احتمال رخداد پدیده خشکسالی، از نظریه تئوری ابری استفاده شده است.

**یافته‌ها:** در حالت کلی نتیجه نهایی آنالیز تئوری ابری از داده‌های مورد مطالعه نشان می‌دهد که در تمامی ایستگاه‌های بررسی شده در سال هدف یعنی سال ۲۰۱۷، کشور ایران و تمامی ایستگاه‌های نماینده، وضعیت اقلیمی نزدیک به محدوده نرمال را نشان داده‌اند و کشور به لحاظ شدت خشکسالی در سال مذکور تقریباً در محدوده نرمال قرار داشته است. بیشترین قطعیت وقوع خشکسالی، به ترتیب به ایستگاه تبریز (۹۶ درصد) و ایستگاه همدان (۹۴ درصد) تعلق دارد. **نتیجه‌گیری:** بر مبنای نتایج، مدل عدم قطعیت انتخابی در آنالیز احتمال از توانایی بالایی برخوردار بوده و با درصد اطمینان قابل قبولی احتمال رخداد خشکسالی را پیش‌بینی کرده است. **نوآوری، کاربرد نتایج:** با توجه به تفاوت مناطق اقلیمی ایران و حذف مداخله کاربر، و با استفاده از محاسبات علمی و ریاضی، ضریب خطا در انتخاب شاخص کاهش می‌یابد. سپس با کمک روش‌های عدم قطعیت مانند تئوری ابری، توانایی پیش‌بینی احتمال وقوع خشکسالی در آینده افزایش می‌یابد.

### اطلاعات مقاله

#### مقاله پژوهشی

شماره:	۱۴
دوره:	۵۳
صفحه:	۱۸-۳۹
تاریخ دریافت:	۱۴۰۲/۰۳/۰۵
تاریخ ویرایش:	۱۴۰۲/۰۴/۰۴
تاریخ پذیرش:	۱۴۰۲/۰۴/۰۶
تاریخ انتشار:	۱۴۰۲/۰۷/۲۳

#### کلیدواژه‌ها:

- خشکسالی
- مدل‌های هوش محاسباتی
- تئوری ابری
- عدم قطعیت
- نواحی اقلیمی ایران

#### نحوه ارجاع به این مقاله:

سلیمی، لاله، معصوم پور سماکوش، جعفر، مجرد، فیروز، جلیلیان، عبدالله. (۱۴۰۲). بررسی احتمال خشکسالی و انتخاب مناسبترین شاخص در نواحی اقلیمی ایران. *مطالعات جغرافیایی مناطق خشک*، ۱۴(۵۳): ۱۸-۳۹.

doi: 10.22034/JARGS.2023.403437.1041

ناشر: دانشگاه حکیم سبزواری



© نویسنده(گان).

## ۱- مقدمه

اقلیم یک منطقه در حالت کلی تعیین کننده شرایط آب و هوایی آن منطقه در یک دوره بلندمدت است که از طریق تعامل پارامترهای متعدد اقلیمی تعیین و مطالعه می‌گردد. یکی از اساسی‌ترین پارامترهایی که اقلیم هر منطقه را مشخص می‌کند بارش است، به نحوی که کمبود آن عمدتاً منجر به خشکسالی می‌شود. خشکسالی علاوه بر بارش، تحت تأثیر پارامترهای دیگر نیز قرار می‌گیرد و تغییر یا کمبود هم‌زمان مجموعه‌ای از پارامترها از جمله بارش در سال‌های اخیر سبب بروز این پدیده در مناطق مختلف دنیا شده است (Hassanzadeh et al., 2012). خشکسالی پدیده‌ای طبیعی است که احتمال وقوع آن در هر ناحیه اقلیمی وجود دارد و در هر منطقه و با توجه به اقلیم و پارامترهای اقلیمی، به‌گونه‌ای متفاوت تعریف شده و جنبه‌های مختلفی دارد (AghaKouchak et al., 2021).

در نگاه کلی، خشکسالی عبارت است از کمبود بارش در دوره‌های بلندمدت، به نحوی که سبب کمبود رطوبت در خاک و همچنین کاهش آب‌های زیرزمینی و سطحی می‌شود و از این رو، روند طبیعی فعالیت‌های انسانی، حیات گیاهی و زندگی جانوری را بر هم می‌زند. از این رو بررسی این رویداد آب و هوایی اهمیت زیادی در برنامه‌ریزی و مدیریت منابع آبی و طبیعی دارد (Dehbozorgi et al., 2015). تا نیمه اول قرن بیستم مطالعات مربوط به پدیده خشکسالی به طور پراکنده در گوشه و کنار جهان انجام شده است؛ اما امروزه با پیشرفت روزافزون علوم کامپیوتری و روش‌های هواشناسی، این مطالعات به شیوه‌های مختلف در سراسر نقاط دنیا در حال انجام است. با توجه به اینکه ایران کشوری پهناور است که به دلیل موقعیت جغرافیایی و توپوگرافی دارای آب و هوایی متفاوت بوده و میانگین بارندگی آن ۲۲۴ تا ۲۷۵ میلی‌متر گزارش شده، و با توجه قرار گرفتن آن در کمربند خشک آب‌وهوایی جهان و کمبود نزولات جوی، بایستی اذعان داشت که بروز بحران‌های آبی و خشکسالی از مشخصه‌های اصلی آب‌وهوای ایران به شمار می‌آید (Younesi et al., 2018). از جمله آثار مخرب این پدیده در کشور، کاهش محصولات کشاورزی، وزن دام، تلفات دام، درآمد حاصل از دامداری، نرخ اشتغال، سرانه تولید، راندمان تولید، کاهش ذخیره‌های آب زیرزمینی و کیفیت منابع آبی و غیره است (Alipour et al., 2013). بدون شک، اولین گام به منظور مقابله با خشکسالی و پیامدهای آن، شناخت و درک دقیق این پدیده و اثرات ناشی از آن در ابعاد مختلف است تا بتوان بر اساس آن، راهبردها و راهکارهای اثربخشی را در این زمینه تدوین کرد و به کار گرفت.

بر همین مبنا و با توجه به اینکه در سال‌های اخیر روش‌های متعددی جهت پیش‌بینی و پایش خشکسالی مورد استفاده پژوهشگران قرار گرفته، اما تاکنون تنها یک روش علمی بر اساس تابع کاپولا برای تعیین احتمال وقوع خشکسالی بر اساس این پیش‌بینی‌ها ارائه گردیده که نتایج آنها نشان می‌دهد که برخی از مناطق مورد مطالعه استعداد بیشتری برای رخداد پدیده و برخی مناطق در خطر کمتری هستند، همچنین از نتایج دیگر این روش این است که تخمین احتمال می‌تواند یک گام بسیار مهم در جهت برنامه‌ریزی صحیح مسئولان و مدیران مربوطه باشد (Reiber et al., 2020)؛ لذا تخمین احتمال وقوع خشکسالی بر اساس روش‌های آنالیز احتمالی متنوع است چرا که از این طریق می‌توان میزان عملکرد صحیح پیش‌بینی خشکسالی را در زمان‌های گذشته بررسی و از صحت عملکرد پیش‌بینی برای آینده اطمینان حاصل کرد.

امروزه شاخص‌های متعددی مانند  $SPI^1$ ،  $SPEI^2$ ،  $MSDI^3$ ،  $PDSI^4$ ،  $PNPI^5$ ،  $RDI^6$  و ... برای بررسی و پایش خشکسالی در نقاط مختلف دنیا و با توجه به نیاز پژوهشگران مورد استفاده قرار می‌گیرد. یکی از مهم‌ترین مسائل در مطالعه خشکسالی، انتخاب شاخص مناسب و حذف سلیقه کاربر در انتخاب آن شاخص است؛ بنابراین با توجه به شرایط آب و هوایی مختلف در کشور ایران و با توجه به اینکه پارامترهای تعیین‌کننده برای انتخاب شاخص مناسب زیاد است و محاسبه ذهنی این پارامترها نیز توسط انسان هم زمان بر بوده و هم میزان دقت مطالعه را کاهش می‌دهد می‌توان روشی را برگزید که در هر منطقه و با توجه به نوع اقلیم آن، شاخص مناسب را انتخاب و دقت مطالعه را افزایش داد.

با توجه به روال رو به رشد استفاده از منابعی که رفتار غیرقطعی دارند، مدل‌سازی عدم قطعیت تأثیرات پررنگ‌تری در پیاده‌سازی رفتار سیستم موردنظر در اختیار قرار خواهد داد؛ بنابراین مطالعه و بهبود روش‌های مدل‌سازی عدم قطعیت شامل حوزه گسترده‌ای از تحقیقات شده که روز به روز اهمیت بیشتری می‌یابد (Hashemipour et al., 2020). امروزه برای پیاده‌سازی روش‌های مدل‌سازی عدم قطعیت از تکنیک‌های خاصی نظیر منطق فازی یا روش قیده‌های احتمالی (Hashemipour & Aghaei, 2017) و ... استفاده می‌شود که با استفاده

<sup>1</sup> Standardized Precipitation Index

<sup>2</sup> Standardised Precipitation-Evapotranspiration Index

<sup>3</sup> Multivariate Standardized Drought Index

<sup>4</sup> Palmer Drought Severity Index

<sup>5</sup> Precipitation Normal's Percent Index

<sup>6</sup> Reconnaissance Drought Index

از آن‌ها رفتار پارامترهای خروجی تخمین زده خواهد شد. استفاده از رویکرد احتمالی ملزوم به بودن اطلاعات کافی برای تعیین نمودن تابع چگالی احتمال (PDF<sup>1</sup>) متغیرهای تصادفی است (Aien et al., 2016).

یکی از روش‌های بسیار مهم جهت مطالعه پدیده خشکسالی استفاده از روش‌های هوش مصنوعی و از جمله شبکه‌های عصبی مصنوعی است. استفاده از این روش‌ها در پیش‌بینی پدیده‌های اقلیمی مانند خشکسالی به دلیل دقت بالا در سال‌های اخیر توسعه یافته است. در طول دهه‌های گذشته، شبکه‌های عصبی توانایی زیادی در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و غیرثابت نشان داده‌اند (Masoompour Samakosh et al., 2022).

یکی از انواع پرکاربرد شبکه عصبی استفاده از شبکه عصبی رادیال بیس است. از این شبکه به عنوان روش محاسباتی برای پیش‌بینی خشکسالی استفاده می‌شود. در مطالعه خشکسالی به کمک همین شبکه از الگوهای پیوند از دور و برخی از عناصر اقلیمی مؤثر به عنوان ورودی شبکه عصبی مصنوعی، و مقادیر شاخص SPI که نمایش کمی خشکسالی است به عنوان خروجی شبکه عصبی مصنوعی استفاده می‌شوند. همچنین، می‌توان از شاخص‌های اقلیمی Nino 1+2, Nino 3, Nino 4 SW monsoon و همچنین عناصر اقلیمی بیشینه و کمینه دما، بیشینه رطوبت نسبی و بارش، موجب بهبود نتایج مدل‌ها استفاده نمود که در این میان الگوهای مورد بررسی بارش، کمینه و بیشینه دما نقش مثبتی در پیش‌بینی خشکسالی ۳ ماهه دارد (Khosravi et al., 2013).

پژوهش‌های دیگری در زمینه پیش‌بینی و بررسی خشکسالی در سال‌های اخیر انجام شده که هرکدام به نحوی سبب تکامل روند مطالعات و بهبود نتایج گردیده‌اند که از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی - موجکی (Dehbozorgi et al., 2015; Malekian et al., 2012; Hassanzadeh et al., 2014) و الگوریتم ژنتیک (Masoompour Samakosh et al., 2022) برای پیش‌بینی خشکسالی استفاده کرده‌اند. تمامی آن‌ها نشان دادند که شبکه عصبی مصنوعی به خوبی قادر به پیش‌بینی روابط غیرخطی بارش و خشکسالی بوده و نتایج حاصل از این پیش‌بینی به طور زیادی منطبق با مقادیر واقعی است. از این رو با استفاده از این روش می‌توان وضعیت خشکسالی را در سال‌های آتی، پیش‌بینی و در مدیریت و بهره‌وری منابع آب و نیز مدیریت خشکسالی و تغییرات اقلیمی بهره جست.

یکی از روش‌هایی که در سال‌های اخیر مورد توجه پژوهشگران قرار گرفته تلفیق شبکه عصبی مصنوعی - موجک و سری‌های زمانی ARIMA<sup>2</sup> برای پیش‌بینی پدیده خشکسالی است که در یکی از مهم‌ترین مطالعات پژوهشگران به این نتیجه رسیدند که تلفیق این دو مدل نتایج بهتری را در پیش‌بینی این پدیده نمایان می‌سازد (Younesi et al., 2018). بعد از ظهور شبکه‌های عصبی در پیش‌بینی پدیده‌های اقلیمی و عملکرد مناسب آن، منطق فازی وارد مطالعات پیش‌بینی پدیده‌ها شد. رستمی و همکاران در مطالعه خشکسالی از طریق سیستم عصبی فازی نشان دادند که دقت روش شبکه‌های عصبی مصنوعی از روش سیستم استنتاج عصبی - فازی تطبیقی بیشتر است. همچنین یافته‌های حاصل از این بررسی نشان می‌دهد که هرچه پراکندگی داده‌های ورودی مدل بیشتر باشد مدل استنتاج عصبی - فازی تطبیقی، توانایی بیشتری در شبیه‌سازی این نوع از داده‌ها دارد (Rostami et al., 2015).

ترابی پوده و همکاران در تخمین خشکسالی لرستان از شبکه‌های هوشمند نظیر شبکه عصبی موجک و مصنوعی استفاده کردند. نتایج آن‌ها نشان داد که هر دو مدل نتایج قابل قبولی را برای تخمین خشکسالی ارائه می‌کنند. از جمله معیارهای تعیین‌کننده در این مطالعه جهت ارزیابی عملکرد مدل‌ها، ضریب همبستگی، ریشه میانگین مربعات خطا و میانگین قدرمطلق خطا بوده است (Torabipodeh et al., 2019). میشرا و دیسای<sup>3</sup>، از مدل‌های تصادفی خطی ARIMA / SARIMA، شبکه عصبی چند مرحله‌ای بازگشتی و شبکه عصبی چند مرحله‌ای مستقیم برای پیش‌بینی خشکسالی استفاده کرد و نشان داد که استفاده از مدل‌های شبکه عصبی بازگشتی، نتایج بهتری را نسبت به مدل‌های سری زمانی ارائه می‌کند (Mishra & Desai, 2006).

از آنجا که روش‌های هوش مصنوعی مانند شبکه عصبی از طریق تولید داده و آموزش، پیش‌بینی و محاسبات را انجام می‌دهد لذا می‌توان از طریق روش‌های عدم قطعیت، احتمال وقوع یک پدیده پیش‌بینی شده از طریق این شبکه‌ها را نیز مطالعه و بررسی کرد (Wu et al., 2019). بای<sup>4</sup> و همکاران به کمک ترکیب الگوریتم ابری و مفاهیم بزرگ‌نمایی و به دنبال آن از طریق تکامل فضایی - زمانی و با توجه به خصوصیات مانند ابر، آنتروپی و هایپر آنتروپی نتایج خود را تحلیل و بررسی نمودند و به این نتیجه رسیدند که بر اساس نتایج عدم قطعیت، میزان خشکسالی مکانی در برخی استان‌های چین بیشتر و در برخی استان‌ها کمتر است (Bai et al., 2020).

<sup>1</sup> Probability density function

<sup>2</sup> Autoregressive integrated moving average

<sup>3</sup> Mishra & Desai

<sup>4</sup> Bai

انصاری و همکاران در پایش خشکسالی ایستگاه سینوپتیک مشهد نشان دادند که استفاده از منطق فازی، توانایی و کارایی بالاتری را در مقایسه با منطق بولی دارد. در این مطالعه دو عملکرد مربوط به SPI (شاخص بارش استاندارد) و SEI (شاخص استاندارد احتمالی تبخیر و تعرق) با هم ترکیب شده و شاخص SPEI ارائه شده است (Ansari et al., 2010).

علاوه بر موارد فوق، از توانمندی‌های منطق فازی در مواجهه با عدم قطعیت‌ها به طور گسترده استفاده شده است. به طور مثال از مدل فازی برای تخمین رواناب در حوضه‌های آبریز مناطق گرمسیری اسپانیا با استفاده از شماره منحنی (Mallapur & Platz, 2019)، و توصیف پارامترهای هواشناسی بر روی آلودگی هوای شهری (Zhang et al., 2020). از تلفیق منطق فازی و شبکه‌های عصبی برای پیش‌بینی یخبندان (Barua et al., 2012)، و بازسازی داده‌های بارندگی مفقود (Aien et al., 2016)، طبقه‌بندی (ریبرو، ۲۰۲۰) و پیش‌بینی خشکسالی‌ها (Ozger et al., 2011; Zhou et al., 2020) استفاده شده است.

با توجه به اینکه در هیچ یک از پژوهش‌های انجام شده انتخاب به موقع و درست شاخص جهت مطالعه موردی بر اساس روابط ریاضیاتی و محاسباتی صورت نگرفته و همین عامل سبب افزایش میزان خطا و کاهش دقت در نتایج مطالعه می‌گردد لذا انتظار می‌رود که در هر پژوهش، زینبندی شاخص‌ها بر اساس شرایط آب و هوایی در هر منطقه تعیین گردد که این کار هم به لحاظ زمانی مقرون به صرفه بوده و هم سبب افزایش میزان دقت نتایج خواهد شد.


با توجه به مفاهیم ذکر شده در ارتباط با این رخداد اقلیمی آمادگی در برابر خشکسالی به پیش‌بینی و پایش صحیح، و در مرحله بعدی بررسی احتمال وقوع آن نیازمند است تا با در دست داشتن برنامه‌های مدون بتوانیم در جهت مدیریت صحیح منابع و کاهش خسارات اقتصادی و طبیعی آن گام برداریم. به عنوان مثال دولت استرالیا بین سال‌های ۱۹۷۰ تا ۱۹۸۴ میلادی حدود ۹۲۵ میلیون دلار را صرف خسارت‌های ناشی از خشکسالی کرد و یا اینکه دولت آفریقای جنوبی برای جبران خسارت‌های ناشی از خشکسالی در سال‌های ۱۹۷۰ تا ۱۹۸۰ حدود ۲/۵ میلیارد دلار صرف نمود (Willhite, 1987).

با توجه به مسائل مذکور در این پژوهش، با توجه به وجود اقلیم‌های متفاوت در نقاط مختلف کشور، ابتدا از طریق مدل منطق فازی از میان شاخص‌های موجود خشکسالی، شاخص مناسب با هر منطقه انتخاب می‌گردد تا با توجه به اقلیم هر منطقه، سلیقه کاربر در انتخاب شاخص حذف شود. به دلیل اینکه این انتخاب بر مبنای محاسبات علمی و ریاضیاتی صورت می‌گیرد میزان خطای مطالعه در این گام کاهش می‌یابد، سپس در گام دوم، از طریق مدل‌های شبکه عصبی پس انتشار و عمیق، به پایش خشکسالی پرداخته و در نهایت به کمک روش‌های عدم قطعیت مانند تئوری ابری، احتمال وقوع پدیده را در آینده بررسی می‌کنیم تا بتوانیم با پایش و بررسی احتمال وقوع خشکسالی، به کاهش خسارت‌های ناشی از آن و برنامه‌ریزی‌های آینده کمک نماییم.

## ۲- مواد و روش

### ۲-۱- منطقه مورد مطالعه

محدوده مورد مطالعه، ایستگاه‌های گرگان، زاهدان، اهواز، اصفهان، تهران (مهرآباد)، تبریز، کرمانشاه، مشهد و رشت، همدان، شیراز، مشکین‌شهر و آملی واقع در اقلیم‌های مختلف ایران است (شکل ۱). در این مطالعه برای انتخاب بهترین شاخص خشکسالی در گستره ایران از داده‌های ماهانه و سالانه دمای متوسط، فشار، رطوبت نسبی، تبخیر، بارش و غیره ۹ ایستگاه سینوپتیک که نماینده ۹ ناحیه اقلیمی ایران (Raziei, 2017) هستند برای یک دوره آماری ۲۸ ساله (۱۹۹۰-۲۰۱۷) استفاده شده است.



شکل ۱. موقعیت ایستگاه‌های منتخب در نواحی اقلیمی ایران

## ۲-۲- روش پژوهش

در این مطالعه، روش‌های محاسبه به دو قسمت مجزا تقسیم می‌شوند. در گام نخست ابتدا از طریق مدل منطق فازی، شاخص مناسب با هر اقلیم از میان شاخص‌های موجود انتخاب می‌گردد و در گام دوم از طریق دو مدل شبکه عصبی عمیق و کلاسیک، پیش‌بینی بارش در ایستگاه‌های نماینده محاسبه می‌شود. نهایتاً از طریق روش عدم قطعیت تئوری ابری، احتمال رخداد پدیده خشکسالی از طریق خروجی بارش در ایستگاه‌های نماینده بررسی و آنالیز می‌شود.

### ❖ منطق فازی

این علم نوعی منطق است که روش‌های متنوع نتیجه‌گیری در مغز بشر را جایگزین الگوهای ساده‌تر ماشینی می‌کند و به عنوان یک متدولوژی کنترل در حوزه هوش مصنوعی، راهی برای پردازش داده‌ها، بر مبنای مجاز کردن عضویت گروهی کوچک، به جای عضویت گروهی دسته‌ای، ارائه می‌دهد. ساده‌ترین تلقی برای تعریف منطق فازی این است که "منطق فازی جواب یک سؤال را به جای تقسیم به دو بخش درست یا نادرست، در اصل به یک محدوده جواب در این بین توسعه داده است (Natke & Tomlinson, 2012).

### ❖ شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی، ایده‌ای برای پردازش اطلاعات است که از سیستم عصبی زیستی الهام گرفته و مانند مغز به پردازش اطلاعات می‌پردازد. البته این ادعا که شبکه‌های عصبی مصنوعی دقت هوش بشری را دارند ادعایی اغراق‌آمیز است (Bishop, 1994).


### ❖ عناصر پردازشی

سیستم عصبی ما از شمار زیادی عناصر پردازشی فوق‌العاده به هم پیوسته تشکیل شده که برای حل یک مسأله با هم هماهنگ عمل می‌کند. به هر یک از عناصر پردازشی، یک نرون<sup>۱</sup> گفته می‌شود (Bishop, 1994).

### ❖ ساختار نرون

هر نرون طبیعی از سه قسمت اصلی و یک قسمت فرعی تشکیل شده است:

- دندریت<sup>۲</sup>: مناطق دریافت سیگنال‌های الکتریکی است.
  - بدنه سلول<sup>۳</sup>: وظیفه تأمین انرژی موردنیاز جهت فعالیت‌های نرون را به عهده دارد.
  - اکسون<sup>۴</sup>: سیگنال‌های الکتروشیمیایی دریافتی از هسته سلول را به نرون‌های دیگر منتقل می‌کند.
  - سیناپس: محل تلاقی یک اکسون از یک سلول به دندریت‌های سلول‌های دیگر را سیناپس می‌گویند. توسط سیناپس‌ها ارتباطات ما بین نرون‌ها برقرار می‌شود. به فضای مابین اکسون و دندریت‌ها فضای سیناپسی گویند.
- در حالت کلی و به طور مختصر این شبکه شبکه‌ای از تعداد دلخواهی سلول یا نرون است که مجموعه ورودی‌ها را به خروجی ربط می‌دهد. شکل ۲ ساختار یک شبکه عصبی الهام گرفته از سیستم عصبی را نشان می‌دهد (Bishop, 1994).



شکل ۲. ساختار شبکه عصبی مصنوعی (Bishop, 1994)

<sup>1</sup> neuron  
<sup>2</sup> dendrite

<sup>3</sup> Some  
<sup>4</sup> axon



- ❖ لایه ورودی: وظیفه دریافت ورودی از فضای بیرون و ارائه آن به شبکه عصبی را عهده‌دار است.
- ❖ لایه مخفی: وظیفه انجام محاسبات سیستم عصبی بر روی ورودی را دارد.
- ❖ لایه خروجی: وظیفه ارائه خروجی سیستم به فضای بیرون را دارد.
- ❖ به گره‌های پردازش شبکه عصبی، نرون و به ارتباطات متصل کننده این نرون‌ها، یال گفته می‌شود. در ادامه به بررسی روش همگرایی داده‌ها و عدم قطعیت پرداخته شده است.

### ❖ روش کرنل

الگوریتم‌های کرنل برای مدل‌سازی روابط غیرخطی بین متغیرهای مستقل و وابسته ایجاد شده‌اند. از این منظر، داده‌های اصلی با استفاده از یک تابع نگاشت<sup>۱</sup> از فضای ورودی به فضای خروجی تبدیل می‌شوند. انتقال داده‌ها از فضای ورودی به فضای ویژگی باید با دقت بالایی انجام شود؛ چراکه مدل خطی به دست آمده باید با یک راه‌حل غیرخطی در فضای داده اصلی مطابقت داشته باشد. برای نگاشت داده‌ها از فضای ورودی توابع کرنل<sup>۲</sup> استفاده می‌شود (Boccard & Rudaz, 2013).

### ❖ روش عدم قطعیت

روش عدم قطعیت تئوری ابری یک رویکرد مدل‌سازی عدم قطعیت مبتنی بر شبیه‌سازی (Kavousi-Fard et al., 2016) - به عنوان مدل آنتروپی - آنتروپی است که دارای توانایی بالایی در مدل کردن اثرات عدم اطمینان در هر مسئله غیرخطی یا خطی است. در مقایسه با روش مونت کارلو، تئوری ابری می‌تواند با در نظر گرفتن سطح اطمینان برای واریانس داده‌های بزرگ، یک قدم اساسی‌تر در مدل‌سازی عدم اطمینان قرار دهد (Kavousi-Fard et al., 2016). این فرایند با اعمال یک تابع توزیع نرمال ثانویه به داده‌ها انجام می‌شود و بنابراین، عدم اطمینان با دقت بسیار بیشتری مدل می‌شود. در این روش که از رایج‌ترین روش‌های عددی در مدل‌سازی عدم قطعیت است یک مسئله به ازای مقادیر مختلف و بر اساس تابع چگالی احتمال با تعداد تکرارهای بالا به اجرا درمی‌آید.

### ❖ انتخاب شاخص مناسب بر اساس تصمیم‌گیری فازی

در این بخش ابتدا بر اساس طبقه‌بندی اقلیمی کوپن کایگر (جدول ۱) در مطالعه رضیئی (Raziei, 2017)، ایستگاه‌های نماینده هر ناحیه اقلیمی انتخاب (جدول ۲)، و سپس با استفاده از منطق فازی، مناسب‌ترین شاخص از میان شاخص‌های خشکسالی (جدول ۳) مورد استفاده برای هر اقلیم معرفی می‌شود.

جدول ۱. ویژگی‌های گروه اقلیمی کوپن - کایگر موجود در ایران (Raziei, 2017)

ردیف	کد یا نام اقلیم کوپن - کایگر	ویژگی‌ها
۱	BWh	بیابان خشک و بسیار گرم
۲	BSh	نیمه‌بیابانی (استپ) خشک و بسیار گرم
۳	Bsk	نیمه‌بیابانی (استپ) خشک و سرد
۴	BWk	بیابان خشک و سرد
۵	Csa	معتدل با تابستان‌های خشک و بسیار گرم
۶	Csb	معتدل با تابستان‌های خشک و گرم
۷	Cfa	معتدل پرباران (بدون فصل خشک) با تابستان‌های گرم
۸	Dsa	اقلیم برفی با تابستان‌های خشک و بسیار گرم
۹	Dsb	اقلیم برفی با تابستان‌های خشک و گرم

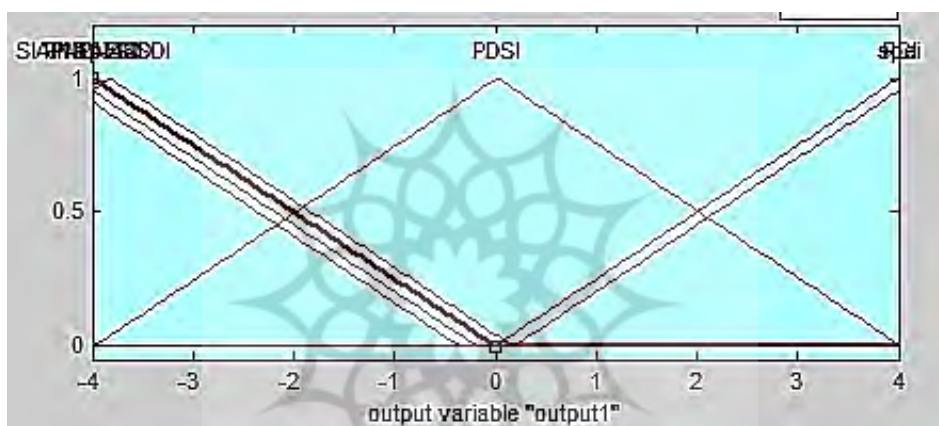
<sup>1</sup> mapping function

<sup>2</sup> kernel function

جدول ۲. اسامی ایستگاه‌های منتخب نواحی اقلیمی در مطالعه حاضر

ایستگاه نماینده	نام اقلیم
اهواز، زاهدان	BWh
شیراز، تهران	BSh
مشهد، تبریز	BSk
اصفهان	BWk
کرمانشاه - گرگان	Csa
مشکین شهر	Csb
رشت	Cfa
همدان - نوژه	Dsa
آبعلی	Dsb

پس از تعریف قوانین در مدل منطق فازی و وارد نمودن روابط ریاضیاتی نتیجه به شرح زیر حاصل شده است:



شکل ۳. خروجی‌های منطق فازی بر اساس شاخص‌های داده شده

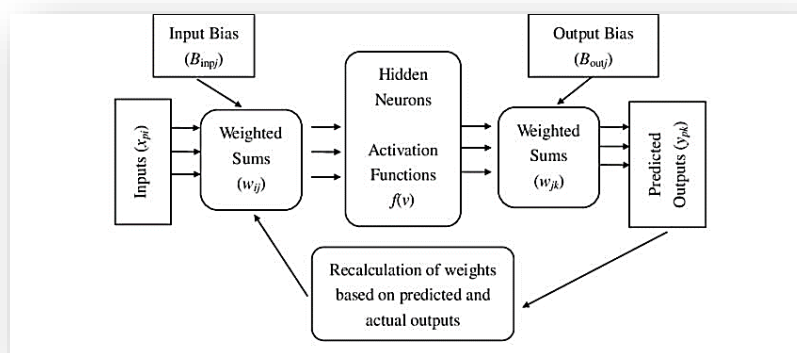
در شکل فوق خروجی‌های برنامه به سه زیر بخش تقسیم و شاخص‌ها در آن قرار داده شده‌اند.

جدول ۳. شاخص‌های خشکسالی مورد استفاده در پژوهش

بر اساس دما و بارش	بر اساس بارش و تبخیر - تعرق	بر اساس بارش
PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI

#### ❖ روش ارائه شده در بلوک شبکه عصبی

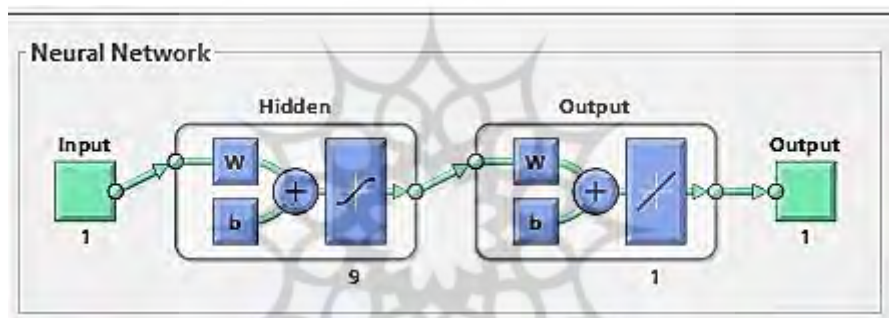
یکی از روش‌های مدل‌سازی رفتار بارش، استفاده از شبکه‌های عصبی است که از مؤلفه‌های هوش مصنوعی محسوب می‌شود. بلوک دیاگرام روش ارائه شده در شکل ۴ قابل مشاهده است.



شکل ۴. بلوک دیاگرام روش ارائه شده

### ❖ طراحی و پیاده‌سازی شبکه عصبی

شبکه عصبی مورد استفاده در این پژوهش، شبکه عصبی پیش‌خور است که از الگوریتم کاهش گرادیان به منظور آموزش آن استفاده شده است. شبکه طراحی شده در شکل ۵ آورده شده است.



شکل ۵. شبکه عصبی طراحی شده

بعد از پیش‌بینی مقادیر ماهانه بارش به کمک شبکه عصبی، با استفاده از رابطه شاخص خشکسالی به محاسبه مقدار این شاخص پرداخته و با استفاده از آنالیز احتمالی، احتمال خشکسالی در هر سال پیش‌بینی خواهد شد.

### ❖ پیاده‌سازی شبکه عصبی عمیق با استفاده از کتابخانه کراس در پایتون

در این بخش علاوه بر شبکه عصبی پس‌انتشار معمولی، یک شبکه عمیق در پایتون طراحی و مورد استفاده قرار گرفته است. این شبکه برای پیش‌بینی مقادیر بارش سال آینده با استفاده از سری‌های زمانی سال‌های گذشته از کتابخانه کراس در پایتون طراحی شده است.

### ۳- یافته‌ها

در این مطالعه که از داده‌های ایستگاهی ۱۳ ایستگاه منتخب در نواحی ۹ گانه اقلیمی ایران طی سال‌های ۱۹۹۰-۲۰۲۰ استفاده شده، از میان شاخص‌های خشکسالی هواشناسی، ۱۵ شاخص انتخاب شد (جدول ۳). در ادامه با استفاده از منطق فازی، مناسب‌ترین شاخص برای هر ناحیه اقلیمی انتخاب و در گام بعدی به کمک دو مدل شبکه عصبی کلاسیک و عمیق، پیش‌بینی خشکسالی انجام شد. در نهایت به کمک تحلیل تئوری ابری، احتمال وقوع خشکسالی در ایستگاه‌های منتخب بررسی شد.

### ۳-۱- تحلیل منطق فازی

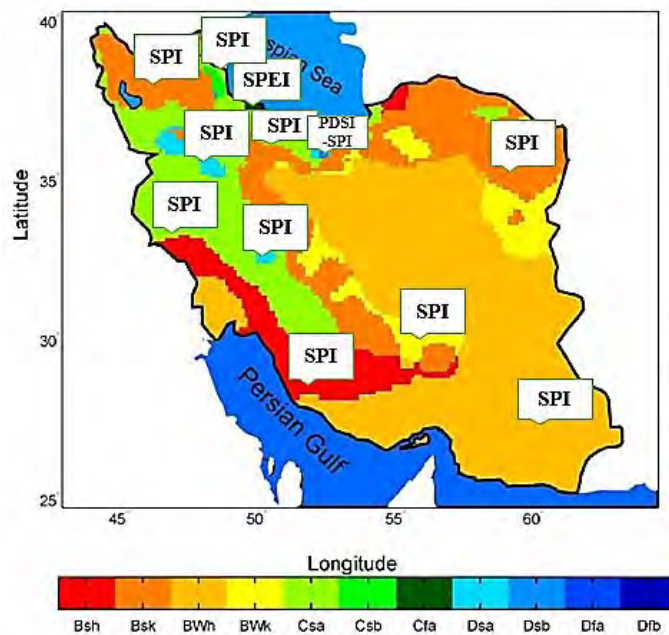
از طریق مدل منطق فازی مناسب‌ترین شاخص در نواحی نه‌گانه اقلیمی ایران به تفکیک درصد تناسب به دست آمد (جدول ۴).

در مرحله اجرای مدل فازی، ۹۳ قانون انتخاب و در مرحله اجرا حداقل ۲ و حداکثر ۴ قانون فعال شده است. لازم به ذکر است که پارامترهای مؤثر در این مطالعه دما، بارش، درجه حرارت، مجموع ساعات آفتابی، تبخیر - تعرق پتانسیل و رطوبت نسبی بوده است. نتایج حاصل از مدل نشان می‌دهد که در ناحیه اقلیمی Bsk, Bsh, Csb, Dsa, Dsb, Csa, Cfa شاخص‌های SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI مناسب‌ترین شاخص، در ناحیه اقلیمی BWh شاخص SPEI-RDI و پس از آنها شاخص‌های PDSI و SPI، در ناحیه اقلیمی Bwk شاخص SPEI-RDI و پس از آنها شاخص PDSI با درصدهای تناسب متفاوت، مناسب هستند (جدول ۴، شکل ۵).

جدول ۴. خروجی‌های شاخص بر اساس درصد در منطق فازی طراحی شده برای ایستگاه‌های منتخب

ردیف	نام ایستگاه	بر اساس دما و بارش	بر اساس بارش و تبخیر - تعرق	بر اساس بارش
۱	زاهدان، اهواز	PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI
		درصد تناسب: ۱۵ درصد	درصد تناسب: ۱۱ درصد	درصد تناسب: ۶۴ درصد
۲	تهران، شیراز	PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI
		درصد تناسب: ۱۹ درصد	درصد تناسب: ۵۹ درصد	درصد تناسب: ۲۲ درصد
۳	تبریز، مشهد	PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI
		درصد تناسب: ۳۲ درصد	درصد تناسب: ۲۱ درصد	درصد تناسب: ۴۷ درصد
۴	اصفهان	PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI
		درصد تناسب: ۲۷ درصد	درصد تناسب: ۱۳ درصد	درصد تناسب: ۶۰ درصد
۵	رشت	PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI
		درصد تناسب: ۲۵ درصد	درصد تناسب: ۴۷ درصد	درصد تناسب: ۲۸ درصد
۶	کرمانشاه	PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI
		درصد تناسب: ۱۸ درصد	درصد تناسب: ۳ درصد	درصد تناسب: ۷۹ درصد
۷	مشکین شهر	PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI
		درصد تناسب: ۳۵ درصد	درصد تناسب: ۱۶ درصد	درصد تناسب: ۴۹ درصد
۸	همدان - نوژه	PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI
		درصد تناسب: ۳۴ درصد	درصد تناسب: ۱۵ درصد	درصد تناسب: ۵۱ درصد
۹	آبعلی	PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI
		درصد تناسب: ۴۱ درصد	درصد تناسب: ۱۹ درصد	درصد تناسب: ۴۰ درصد
۱۰	گرگان	PDSI	SPEI-RDI	SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI
		درصد تناسب: ۲۶ درصد	درصد تناسب: ۲ درصد	درصد تناسب: ۷۱ درصد

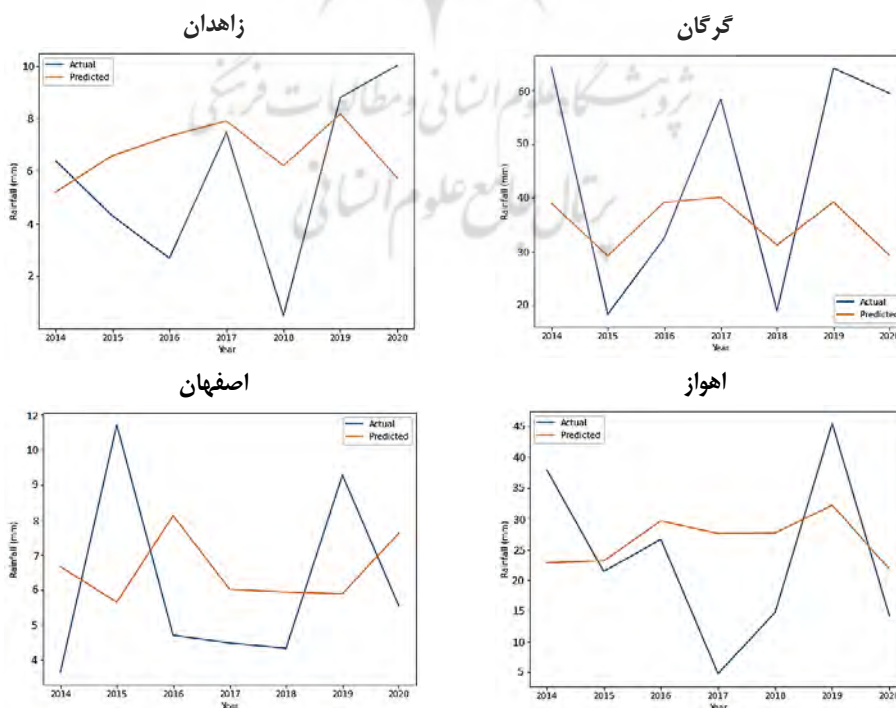
نتایج جداول بالا در شکل ۵ ارائه شده است.

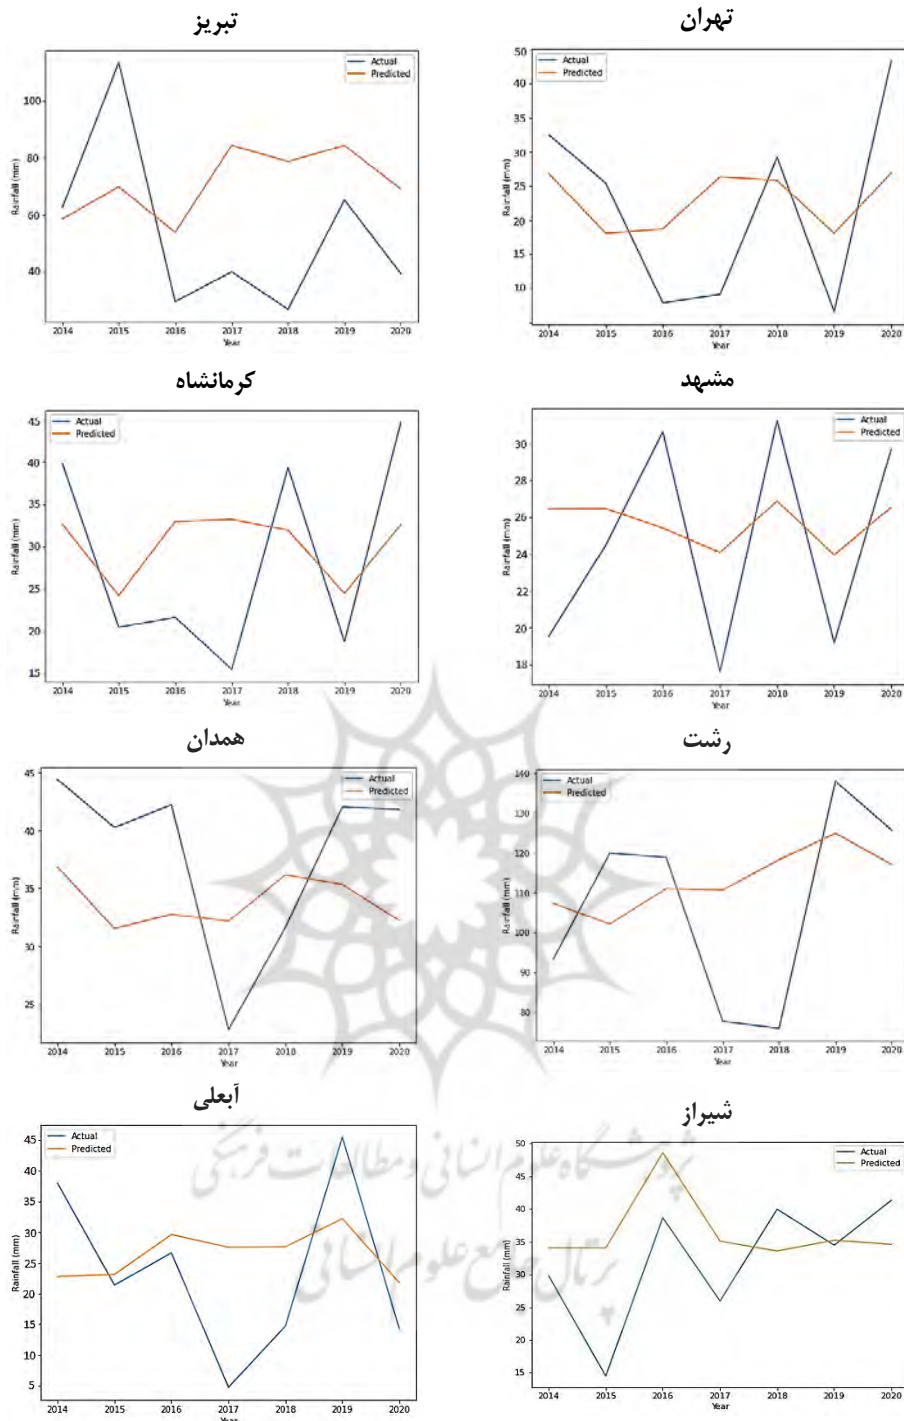


شکل ۵. نمایش مناسب‌ترین شاخص برای هر اقلیم به تفکیک رنگ

### ۳-۲- بررسی روند و ارزیابی مدل شبکه عصبی پس‌خور برای ایستگاه‌های منتخب

نمودارهای پیش‌بینی شبکه عصبی برای بارش، نمودارهایی هستند که تغییرات زمانی مقدار بارش پیش‌بینی شده را نشان می‌دهند. این نمودارها شامل مقادیر واقعی برای بارش واقعی و پیش‌بینی شده برای هر ایستگاه هستند. تحلیل روند این نمودارها ابزاری برای تعیین دقت عملکرد شبکه عصبی در پیش‌بینی بارش است. در ادامه نمودارهای مربوط به ۱۳ ایستگاه به تفکیک ارائه شده است. با مشاهده هر یک از آنها پیداست که روند کلی تغییرات در مقادیر پیش‌بینی شده، مقادیر واقعی را دنبال می‌کند و حتی برای بعضی ایستگاه‌ها این مقادیر بروی یکدیگر قرار گرفته‌اند (شکل ۶) که این مسئله نشان‌دهنده دقت قابل قبول شبکه عصبی است. دلیل مواردی که خطای اندازه‌گیری شده بیشتر بوده دلیل است که داده‌های اندازه‌گیری نشده در پایگاه داده اصلی بیشتر است، بنابراین شبکه دچار کاهش دقت می‌شود.





شکل ۶. روند نموداری ایستگاه‌های مورد مطالعه بر اساس پیش‌بینی شبکه عصبی

## جدول ۵. نتایج پیش‌بینی شبکه عصبی مصنوعی برای بارش ایستگاه‌های منتخب

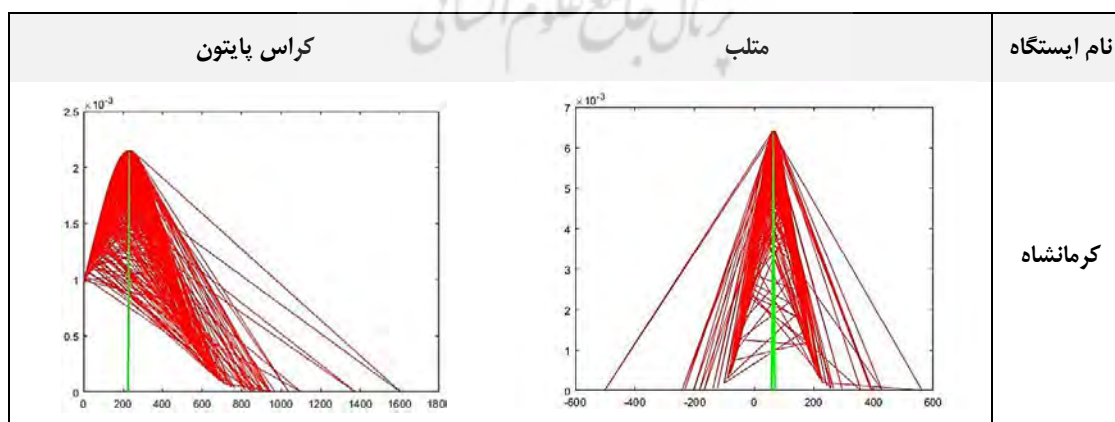
(با توجه به عدم داده‌های موجود جهت صحت‌سنجی، استثنائاً سال ۲۰۲۲ برای پیش‌بینی ایستگاه همدان انتخاب و بررسی شد)

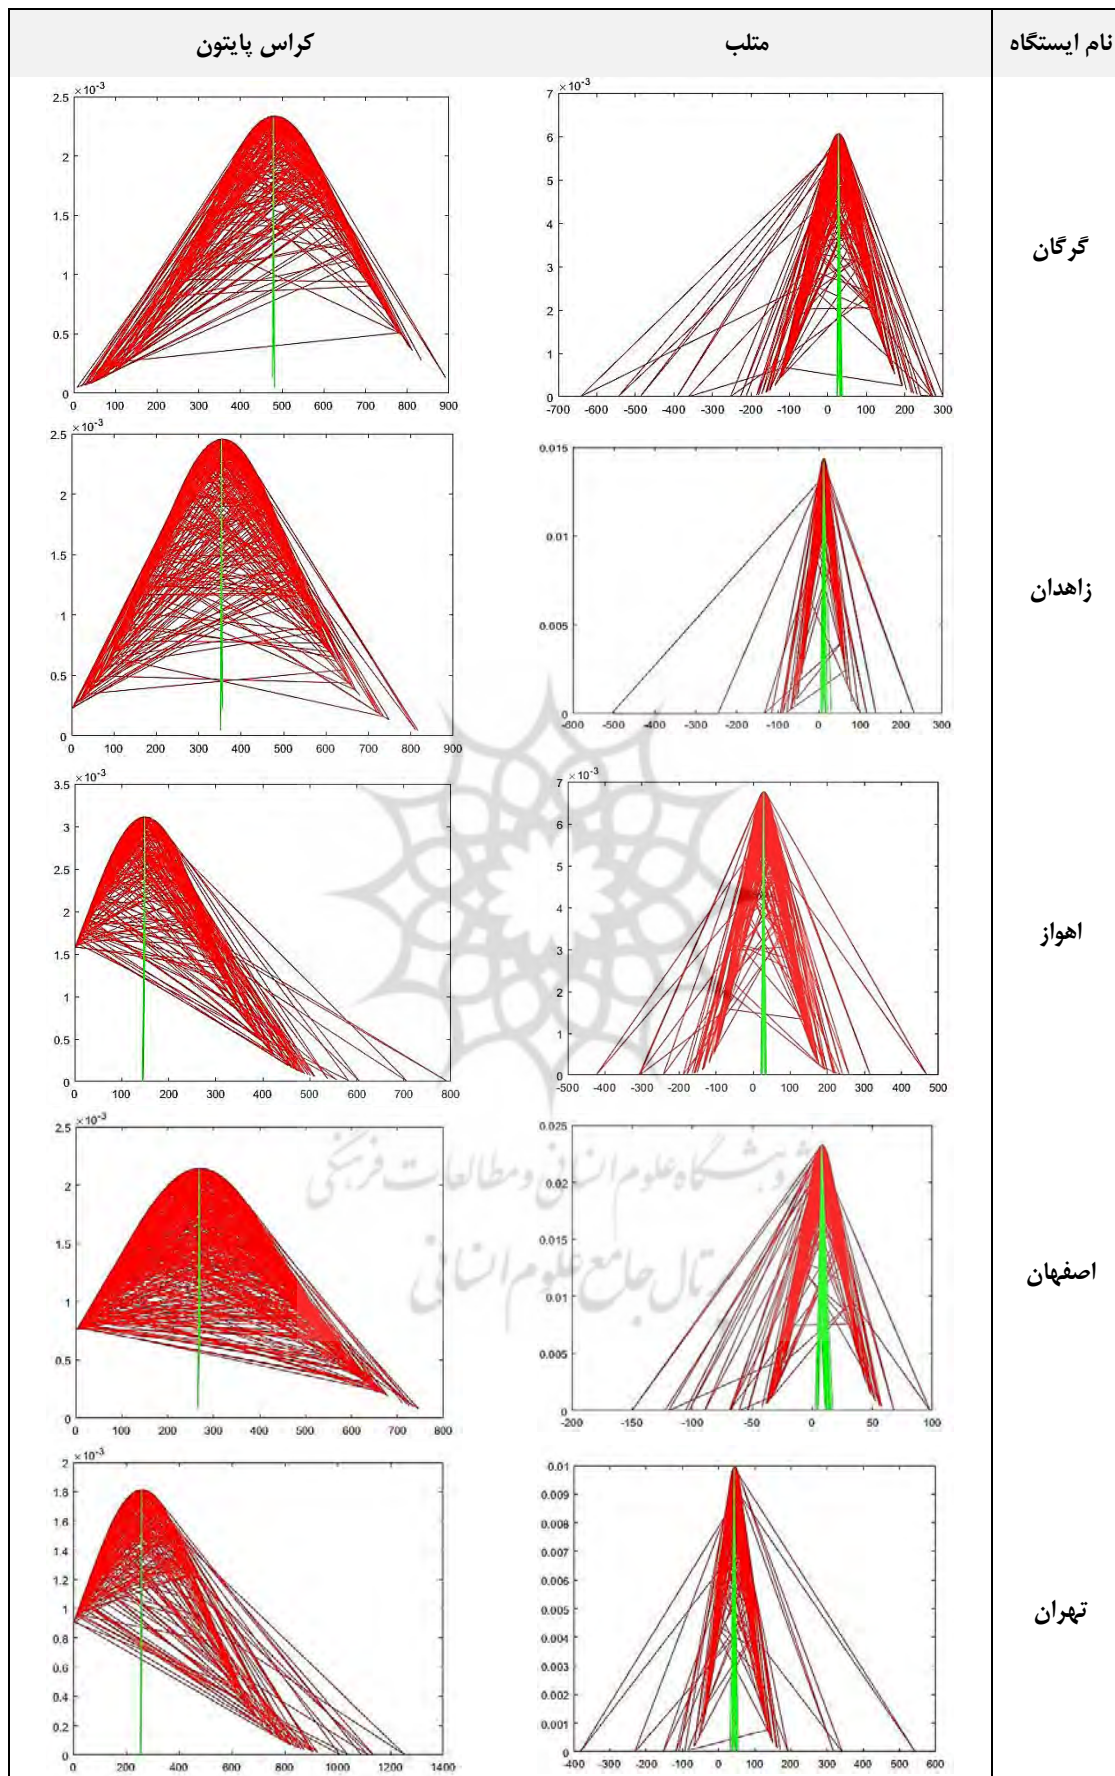
ردیف	نام ایستگاه	RMSE	MAE	مقدار واقعی سال ۲۰۲۱	پیش‌بینی مقدار سال ۲۰۲۱ (میلی‌متر)
۱	گرگان	۰/۵۷	۰/۴۴	۲۲۲/۰۳	۲۱۷/۹۲
۲	زاهدان	۰/۶۹	۰/۴۳	۱۵/۶۱	۱۰/۷۱
۳	اهواز	۰/۶۱	۰/۴۹	۹۹/۴۹	۹۰/۵۰
۴	اصفهان	۰/۸۴	۰/۶۴	۶۳/۶۱	۵۶/۷۴
۵	تهران - مهرآباد	۰/۳۰	۰/۲۴	۱۴۴/۱۹	۱۴۳/۱۲
۶	تبریز	۰/۴۴	۰/۳۶	۲۶۳/۶۲	۲۶۲/۸۴
۷	مشهد	۰/۸۱	۰/۷۲	۷۳/۱۳	۶۹/۴۴
۸	کرمانشاه	۰/۴۴	۰/۵۱	۱۳۰/۱۹	۱۲۹/۳۷
۹	رشت	۰/۶۹	۰/۵۱	۱۱۴۸/۴۵	۱۱۳۶/۹۳
۱۰	همدان - نوژه	۰/۴۹	۰/۳۶	۲۱۱/۷۰	۲۰۸/۶۹
۱۱	شیراز	۰/۳۳	۰/۱۹	۸۳/۸۵	۸۲/۱۴
۱۲	آبعلی	۰/۸۳	۰/۷۸	۳۰/۸	۲۸۵/۵۰

برای تمامی ایستگاه‌ها، عملکرد شبکه به ترتیب در ایستگاه‌های اصفهان، آبعلی و مشهد دارای توانایی کمتری نسبت به سایر ایستگاه‌ها است که این مسئله می‌تواند به نوع داده‌های این ایستگاه‌های ذکر شده ارتباط داشته باشد در مقابل آن بهترین عملکرد شبکه به ترتیب در ایستگاه‌های تهران، شیراز، کرمانشاه و تبریز در یک مرتبه و در مرحله بعدی همدان و در آخر گرگان بوده که نشان‌دهنده توانایی بالای شبکه در پیش‌بینی پارامتر انتخابی است. در ارتباط با ایستگاه‌های رشت، اهواز و زاهدان دارای عملکرد نسبتاً بالایی بوده و قابلیت خوبی قادر به پیش‌بینی مقادیر پارامتر بوده است (شکل ۶ و جدول ۵).

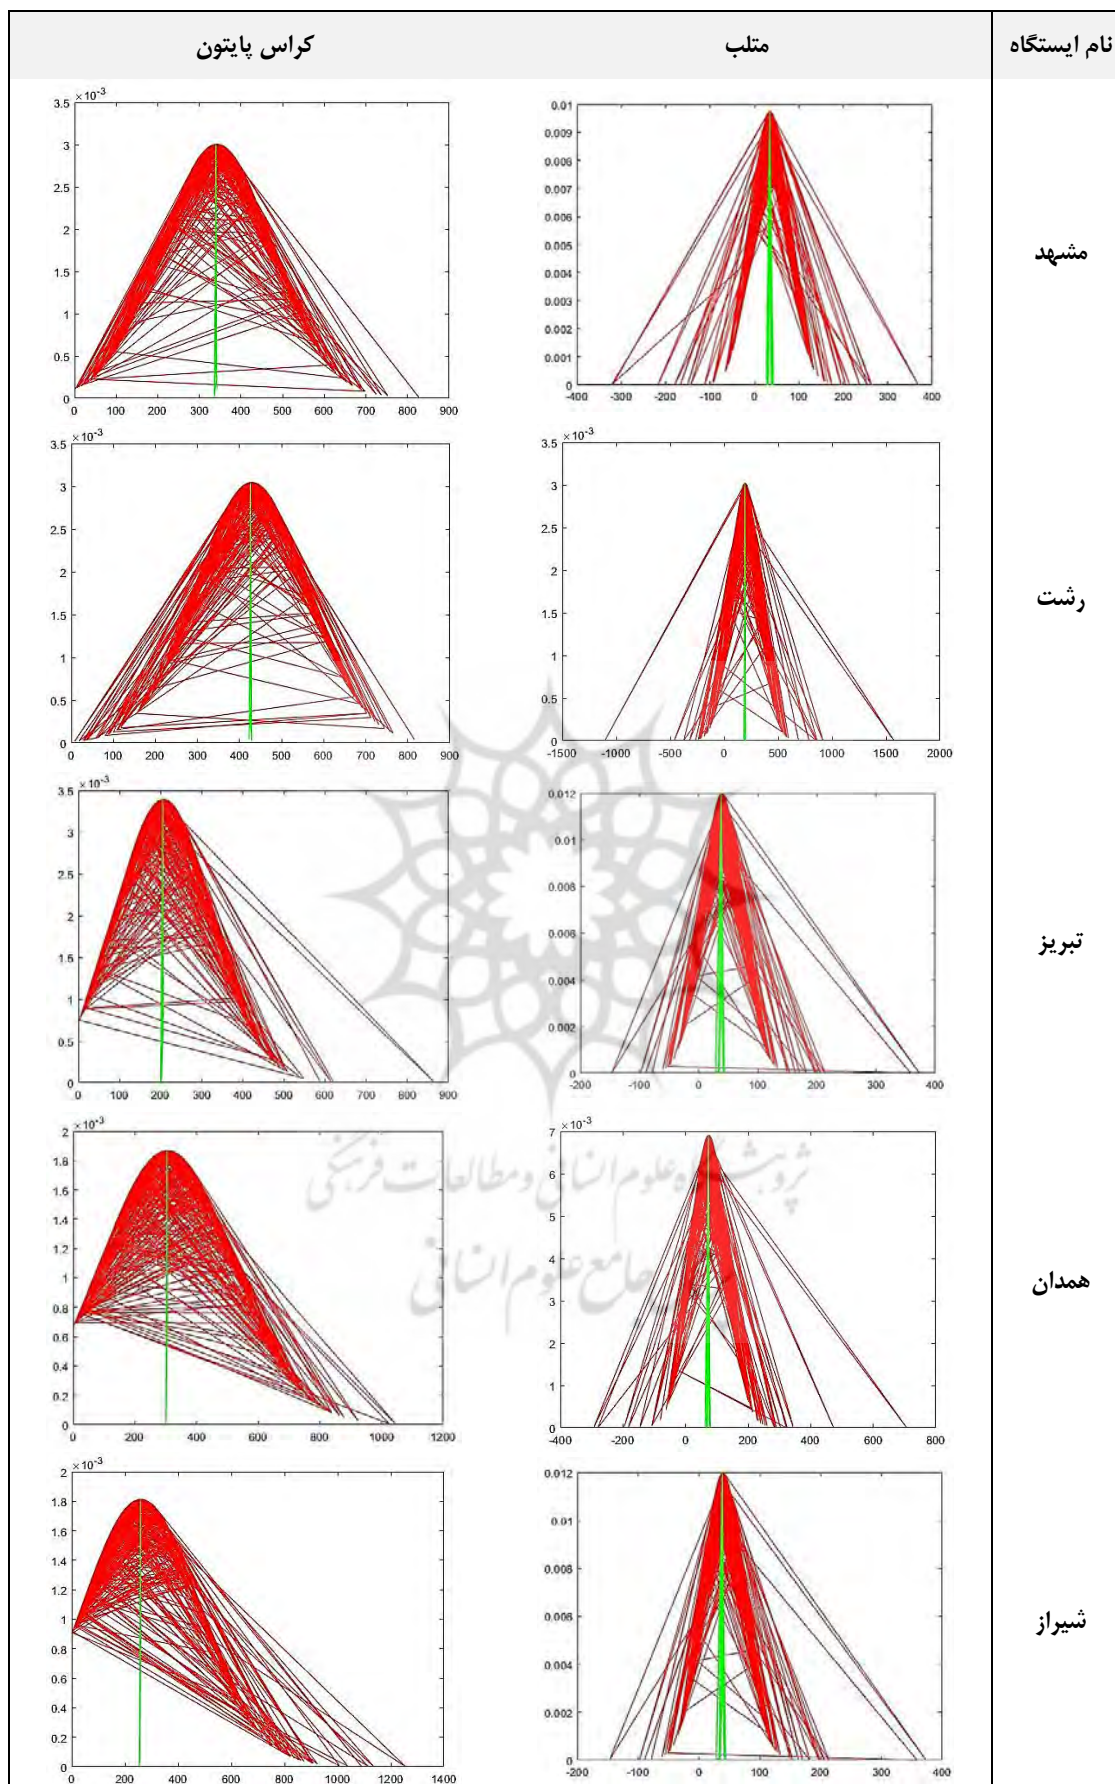
## ۳-۳- تحلیل احتمالی خشکسالی ایستگاه‌های منتخب جهت بررسی عدم قطعیت

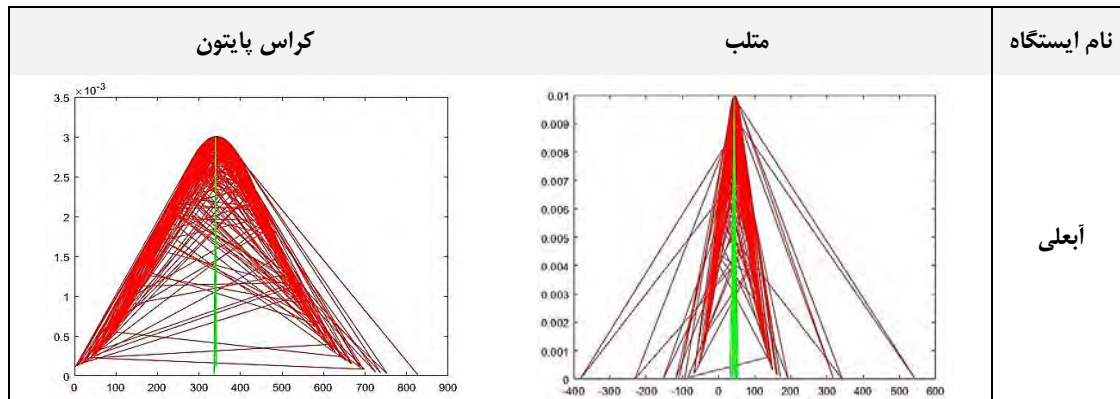
از آنجا که شبکه عصبی نتایج را بر اساس تصحیح و خطای پارامترهای تصادفی ایجاد می‌کند و به دلیل وجود این ماهیت تصادفی، به نظر می‌رسد که استفاده از روش‌های تحلیل عدم قطعیت برای اینکه بتوانیم احتمال رخداد یک پدیده را بررسی کنیم امری ضروری به نظر می‌رسد. در این پژوهش از روش تئوری ابری که ورودی‌های آن، از شبکه عصبی پس‌انتشار در متلب و همچنین شبکه عصبی پس‌خور که با استفاده از کتابخانه کراس در پایتون ۱۰۰۰ بار اجرا شده‌اند استفاده شده است، تا میزان عدم قطعیت مربوط به شاخص‌های متناسب با هر ایستگاه مشخص شود (شکل ۷).











شکل ۷. نمودارهای خروجی متلب و کراس پایتون ایستگاه‌های مورد مطالعه

خروجی نتایج عددی احتمال خشکسالی و عدم قطعیت آن در برنامه‌های متلب و کراس پایتون برای هر ایستگاه بررسی و مشخص شده است (جدول ۶).

بر اساس نمودارهای خروجی و تحلیل داده‌ها بر اساس آنالیز احتمالی تئوری ابری (شکل ۷)، مقدار شاخص SPI برای همه ایستگاه‌های منتخب در محدوده (-۳ تا +۳) قرار دارد که توزیع داده‌ها ناپارامتریک است. با انتخاب یک سال به عنوان سال هدف (سال ۲۰۱۷)، نتایج حاکی از آن است که در مقایسه با مقدار شاخص SPI بر اساس داده‌های مشاهداتی (جدول ۷)، بیشترین احتمال وقوع خشکسالی مربوط به ایستگاه تبریز (۹۶ درصد) و بعد از آن همدان (۹۵ درصد)، و کمترین مربوط به اهواز با ۶۴ درصد است (جدول ۶). در واقع برای تمامی ایستگاه‌ها، داده‌های مدل و واقعی بسیار به هم نزدیک هستند که این موضوع بیانگر توانایی بالای هر دو شبکه در تعیین عدم قطعیت ایستگاه‌های منتخب هستند.

جدول ۶- داده‌های واقعی و پیش‌بینی شبکه عصبی عمیق (Back propagation) و کلاسیک شاخص (Feed forward) SPI برای سال ۲۰۱۷ در ایستگاه‌های منتخب

نام ایستگاه	مقدار SPI مشاهداتی	مقدار SPI مدل	نوع شبکه
کرمانشاه	-۰/۲۶	-۰/۳۹	Back propagation
		-۰/۲۸	Feed forward
گرگان	-۰/۵۱	-۰/۴۴	Back propagation
		-۰/۵۶	Feed forward
زاهدان	-۰/۱۶	-۰/۱۳	Back propagation
		-۰/۱۷	Feed forward
اهواز	-۰/۹۲	-۱/۰۱	Back propagation
		-۰/۵۹	Feed forward
اصفهان	-۰/۶۶	-۰/۶۲	Back propagation
		-۰/۳۹	Feed forward
تهران - مهرآباد	-۰/۴۲	-۰/۳۲	Back propagation
		-۰/۰۴	Feed forward
تبریز	-۰/۰۸	-۰/۰۸	Back propagation
		-۰/۰۲	Feed forward
مشهد	-۰/۰۱	-۰/۰۲	Back propagation
		-۰/۴۸	Feed forward
رشت	-۰/۴۳	-۰/۴۴	Back propagation
		-۰/۰۷	Feed forward
همدان	-۰/۰۷	-۰/۰۹	Back propagation
		-۰/۰۹	Feed forward

نام ایستگاه	مقدار SPI مشاهداتی	مقدار SPI مدل	نوع شبکه
شیراز	+۰/۰۷	+۰/۰۶	Back propagation
		+۰/۰۷	Feed forward
آبلی	+۰/۰۶۸	+۰/۰۷	Back propagation
		+۰/۰۶	Feed forward

در حالت کلی نتیجه نهایی آنالیز تئوری ابری از داده‌های مورد مطالعه نشان می‌دهد که در تمامی ایستگاه‌های بررسی شده در سال هدف یعنی سال ۲۰۱۷، کشور ایران و تمامی ایستگاه‌های نماینده، وضعیت اقلیمی نزدیک به محدوده نرمال را نشان داده‌اند و کشور ایران به لحاظ شدت خشکسالی در سال مذکور تقریباً در محدوده نرمال قرار داشته است که بررسی و مقایسه نتایج به دست آمده با داده‌های واقعی نیز گویای همین مطلب است و این موضوع حکایت از توانایی بسیار بالای آنالیز احتمالی عدم قطعیت در تعیین رخداد پدیده خشکسالی دارد.

#### ۴- بحث و نتیجه‌گیری

هدف پژوهش حاضر، بررسی و انتخاب شاخص مناسب خشکسالی از میان شاخص‌های موجود برای هر ناحیه اقلیمی ایران و نیز بررسی احتمال وقوع خشکسالی در آن نواحی به کمک شاخص انتخاب شده است. تا سلیقه متخصص و کاربر در انتخاب شاخص حذف و با این عمل میزان خطای مطالعه کاهش یافته و بررسی موضوعات اقلیمی و از جمله پایش و بررسی خشکسالی به صورت تخصصی و با دقت بیشتری انجام شود.

با توجه به اینکه تاکنون مطالعه‌ای در ارتباط با بررسی آنالیز احتمالی و عدم قطعیت پدیده خشکسالی به روش تئوری ابری انجام نشده و محققان تنها به مسائلی از قبیل بررسی عدم قطعیت از طریق توزیع گاما (Jamal et al., 2020) و ریزمقیاس‌نمایی پارامترهای اقلیمی (Pourmohammadi & Khalili, 2013) و تحلیل عدم قطعیت مشخصه‌های خشکسالی هیدرولوژیکی با استفاده از ابرمکعب لاتین (Ghasem Nezhad et al., 2019) پرداخته‌اند، لذا انتظار می‌رود که این پژوهش بتواند راهگشای استفاده از تئوری‌های دیگر عدم قطعیت در مطالعه پدیده‌های اقلیمی مانند خشکسالی و... باشد.

نتایج نشان داد که پس از انتخاب شاخص مناسب برای هر منطقه و انتخاب ایستگاه نماینده برای هر اقلیم، مدل شبکه عصبی عمیق در کراس پایتون و شبکه عصبی پس انتشار در متلب عملکرد تقریباً مشابهی داشته‌اند. همچنین مدل عدم قطعیت انتخابی در آنالیز احتمال رخداد پدیده از توانایی بالایی برخوردار بوده و با درصد اطمینان قابل قبولی احتمال رخداد خشکسالی را به درستی پیش‌بینی کرده است، به طوری که بیشترین قطعیت رخداد پدیده مربوط به ایستگاه تبریز با ۹۶ درصد، ایستگاه همدان در رتبه بعدی با ۹۴ درصد و کمترین احتمال رخداد پدیده در ایستگاه اهواز با ۶۴ درصد شاهد بودیم.

نتایج حاصل از منطق فازی نشان داد که در ناحیه اقلیمی Bsh (ایستگاه شیراز و تهران)، Bsk (ایستگاه مشهد و تبریز)، Csb (ایستگاه مشکین‌شهر)، Dsa (ایستگاه نوزه-همدان)، Dsb (ایستگاه آبلی)، Csa (ایستگاه کرمانشاه و گرگان)، Cfa (ایستگاه رشت)، شاخص‌های SPI-ND-IA-ID-PN-DI-ZSI-SIAP-RAI -MSDI-PNPI-ERI در ناحیه اقلیمی BWh شاخص SPEI-RDI و پس از آنها شاخص‌های PDSI و SPI، در ناحیه اقلیمی BWk شاخص SPEI-RDI و پس از آنها شاخص PDSI با درصدهای تناسب متفاوت مناسب هستند.

شاخص‌های انتخابی برای مدل شبکه عصبی در ناحیه اقلیمی Bsk، Bsh، Csb، Dsa، Dsb، Csa، Cfa شاخص SPI در ناحیه اقلیمی BWh و BWk شاخص SPEI انتخاب و تحلیل نتایج مدل شبکه عصبی از دو نوع عمیق و کلاسیک بر اساس آنها و با توجه به کمبود داده حکایت از عملکرد بهتر شبکه کلاسیک نسبت به عمیق داشت، زیرا در حالت کلی شبکه‌های عمیق برای بهبود عملکرد نیاز به داده‌های بسیار زیادی دارند. همچنین نتایج نهایی آنالیز تئوری ابری از داده‌های مورد مطالعه نشان داد که در تمامی ایستگاه‌های مورد مطالعه در سال هدف یعنی سال ۲۰۱۷، کشور ایران و تمامی ایستگاه‌های نماینده وضعیت اقلیمی نزدیک به محدوده نرمال را نشان داده‌اند و کشور ایران به لحاظ شدت خشکسالی در سال مذکور تقریباً در محدوده نرمال قرار داشته است که بررسی و مقایسه نتایج به دست آمده با داده‌های واقعی نیز گویای همین مطلب است. این موضوع حکایت از توانایی بسیار بالای آنالیز احتمالی عدم قطعیت در تعیین رخداد پدیده خشکسالی دارد.

## ۵- سپاس‌گزاری

این مقاله برگرفته از پایان‌نامه مقطع دکتری خانم لاله سلیمی است که با حمایت‌های مادی و معنوی دانشگاه رازی انجام شده است.

## ۶- فهرست منابع

- انصاری، حسین؛ داوری، کامران و ثنایی‌نژاد، سید حسین. (۱۳۸۹)، پایش خشکسالی با استفاده از شاخص بارندگی و تبخیر و تعرق استاندارد شده (SPEI) توسعه یافته براساس منطق فازی، نشریه آب و خاک، ۲۴ (۱)، ۵۲-۳۸.
- پورمحمدی، سمانه. (۱۳۹۲). بررسی عدم قطعیت‌های شاخص خشکسالی در دوره‌های آبی توسط روش‌های ریزمقیاس‌نمایی مدل‌های گردش عمومی جو (مطالعه موردی: ایستگاه نوژه همدان)، پنجمین کنفرانس مدیریت منابع آب.
- ترابی پوده، حسن؛ دهقانی، رضا و رستمی، سعید. (۱۳۹۷). تخمین خشکسالی در استان لرستان با استفاده از شبکه‌های هوشمند، پژوهش‌های اقلیم‌شناسی، ۹ (۳۵)، ۵۲-۴۱.
- جمال، مریم؛ ابراهیمی، حسین و موسوی جهرمی، سیدحیی. (۱۳۹۹). عدم قطعیت در محاسبه شاخص خشکسالی هیدرولوژیکی با کاربرد توزیع گاما (مطالعه موردی: حوضه آبریز دریاچه ارومیه) (یادداشت فنی)، تحقیقات منابع آب ایران، ۱۶ (۴)، ۳۱۲-۳۰۲.
- حسن‌زاده، یوسف؛ عبدی کردانی، امین و فاخری فرد، احمد. (۱۳۹۱). پیش‌بینی خشکسالی با استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی - موجکی. نشریه آب و فاضلاب، ۲۳ (۳)، ۵۹-۴۸.
- خسروی، محمود؛ نصیری، مریم و صفوی، سیدعلی اکبر. (۱۳۹۰). پیش‌بینی خشکسالی شیراز به کمک شبکه عصبی رادیال بیس، پنجمین کنفرانس سراسری آبخیزداری و مدیریت منابع آب و خاک کشور، کرمان.
- ده بزرگی، مه‌رو، ملکیان، آرش و احسانی، امیرهوشنگ. (۱۳۹۴). ارزیابی عملکرد شبکه عصبی مصنوعی در پیش‌بینی خشکسالی هواشناسی در شمال غرب ایران. تحقیقات کاربردی علوم جغرافیایی (علوم جغرافیایی)، ۱۵ (۳۶)، ۱۵۶-۱۳۹.
- رستمی، مهناز؛ پهلوان‌روی، احمد و مقدم‌نیا، علیرضا. (۱۳۹۴). پیش‌بینی خشکسالی با به کارگیری از مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی در حوزه‌مند استان فارس، مخاطرات محیط طبیعی، ۴ (۶)، ۳۲-۲۱.
- رضیعی، طیب. (۱۳۹۶). منطقه‌بندی اقلیمی ایران به روش کوپن - گایگر و بررسی جابه‌جایی مناطق اقلیمی کشور در سده بیستم، فیزیک زمین و فضا، ۴۳ (۲)، ۴۳۹-۴۱۹.
- علی‌پور، حسن؛ چهارسوقی، امین و قریب، حامد. (۱۳۹۲). بررسی اثرات خشکسالی بر وضعیت اقتصادی - اجتماعی کشاورزان، مطالعه موردی: گندم‌کاران شهرستان نهبندان، پژوهش‌های آبخیزداری (پژوهش و سازندگی)، ۲۶ (۲)، ۱۲۵-۱۱۳.
- قاسم‌نژاد، فائزه؛ فاضلی، مهدی؛ بذرافشان، ام‌البنین و پروین‌نیا، محمد. (۱۳۹۸). تحلیل عدم قطعیت مشخصه‌های خشکسالی هیدرولوژیکی با استفاده از ابرمکعب لاتین (مطالعه موردی: حوزه آبخیز سد میناب)، مرتع و آبخیزداری (منابع طبیعی ایران)، ۷۲ (۲)، ۵۴۲-۵۲۷.
- معصوم‌پور سماکوش، جعفر، سهرابی، وحید و میری، مرتضی. (۱۴۰۱). ارزیابی و پیش‌بینی خشکسالی‌های غرب و شمال غرب ایران با استفاده از شبکه هوش عصبی، فصلنامه مطالعات جغرافیایی مناطق کوهستانی، ۲ (۱۰)، ۳۷-۱۹.
- ملکیان، آرش؛ مه‌رو، ده بزرگی؛ احسانی، امیر هوشنگ و کشت‌کار، امیررضا. (۱۳۹۲). کاربرد شبکه عصبی مصنوعی در پیش‌بینی و شبیه‌سازی شاخص اقلیمی خشک‌سالی هواشناسی دهک بارش (مطالعه موردی: استان سیستان و بلوچستان)، نشریه مرتع و آبخیزداری، ۶۷ (۱)، ۱۳۹-۱۲۷.
- یونسی، محبوبه؛ شهرکی، نادیا؛ معروفی، صفر و نوذری، حامد. (۱۳۹۷). پیش‌بینی خشکسالی با استفاده از مدل تلفیقی شبکه عصبی مصنوعی موجک و مدل سری زمانی ARIMA، علوم و مهندسی آبیاری، ۴۱ (۲)، ۱۸۱-۱۶۷.

## References

- AghaKouchak, A., Mirchi, A., Madani, K., Di Baldassarre, G., Nazemi, A., Alborzi, A., ... & Wanders, N. (2021). Anthropogenic drought: definition, challenges, and opportunities. <https://doi.org/10.1029/2019RG000683>

- Aien, M., Hajebrahimi, A., & Fotuhi-Firuzabad, M. (2016). A comprehensive review on uncertainty modeling techniques in power system studies. *Renewable and Sustainable Energy Reviews*, 57, 1077-1089. <https://doi.org/10.1016/j.rser.2015.12.070>
- Alipour, H., CHAHRSOOGHI, A. A., & Gharib, A. (2013). Effects of drought on socio-economic status of farmers: A case study on the Nehbandans wheat farmers. *Watershed managment researchs (Pajouhesh-va-sazandegi)*, 26(2 (99)), 113-125. **[in persian]**.
- Ansari, H., Davari, K., & Sanaeinezhad, S. H. (2010). Drought monitoring with new precipitation and evapotranspiration index based on fuzzy logic. *Journal of water and soil (Agricultural of water and soil)*, 24 (1), 38-52. **[in persian]**.
- Ashraf, S., Nazemi, A., & AghaKouchak, A. (2021). Anthropogenic drought dominates groundwater depletion in Iran. *Scientific reports*, 11(1), 9135. <https://doi.org/10.1038/s41598-021-88522-y>
- Bai, X., Wang, Y., Jin, J., Ning, S., Wang, Y., & Wu, C. (2020). Spatio-temporal evolution analysis of drought based on cloud transformation algorithm over Northern Anhui Province. *Entropy*, 22(1), 106. <https://doi.org/10.3390/e22010106>
- Barua, S., Ng, A. W. M., & Perera, B. J. C. (2012). Artificial neural network-based drought forecasting using a nonlinear aggregated drought index. *Journal of Hydrologic Engineering*, 17(12), 1408-1413. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000574](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000574)
- Bishop, C. M. (1994). Neural networks and their applications. *Review of scientific instruments*, 65(6), 1803-1832. <https://doi.org/10.1063/1.1144830>
- Boccard, J., & Rudaz, S. (2013). Mass spectrometry metabolomic data handling for biomarker discovery. In *Proteomic and metabolomic approaches to biomarker discovery* (pp. 425-445). Academic Press. <https://doi.org/10.1016/B978-0-12-394446-7.00027-3>
- Dehbozorgi, M., Malekian, A., & Ehsani, A. H. (2015). Evaluation the Efficiency of Using Artificial Neural Networks in Predicting Meteorological Droughts in North-West of Iran. *Journal of Applied researches in Geographical Sciences*, 15 (36), 139-156. **[in persian]**.
- Ghasem Nezhad, F., Mehdi, F., Bazrafshan, O., & Parvinnia, M. (2019). Uncertainty Analysis of Hydrological Drought Characteristics Using Latin Hypercube Sampling (Case Study: Minab Dam Watershed). *Journal of Range and Watershed Managment*, 72(2), 527-542. **[in persian]**
- Hashemipour, N., Aghaei, J., Lotfi, M., Niknam, T., Askarpour, M., Shafie khah, M., & Catalão, J. P. (2020). Multi objective optimisation method for coordinating battery storage systems, photovoltaic inverters and tap changers. *IET Renewable Power Generation*, 14(3), 475-483. <https://doi.org/10.1049/iet-rpg.2019.0644>
- Hashemipour, S. N., & Aghaei, J. (2017, December). Chance constrained power-flow for voltage regulation in distribution systems. In *2017 Smart Grid Conference (SGC)* (pp. 1-6). IEEE. <https://doi.org/10.1109/SGC.2017.8308848>
- Hassanzadeh, Y., Abdi Kordani, A., & Fakheri Fard, A. (2012). Drought forecasting using genetic algorithm and conjoined model of neural network-wavelet. *Journal of Water and Wastewater*, 23(3), 48-59. **[in persian]**.
- Jamal, M., Ebrahimi, H., & Mousavi, J. H. (2020). Uncertainty in Calculating Hydrological Drought Index Using Gamma Distribution (Case Study: Urmia Lake Basin). *Iran – water resources research* 16 (4), 302 – 312. **[in persian]**.
- Kavousi-Fard, A., Niknam, T., & Fotuhi-Firuzabad, M. (2015). A novel stochastic framework based on cloud theory and  $\theta$ -modified bat algorithm to solve the distribution feeder reconfiguration. *IEEE Transactions on Smart Grid*, 7(2), 740-750. <https://doi.org/10.1109/TSG.2015.2434844>
- Khosravi, M., Nasiri, M., & Safavi, S. A. (2013). Shiraz drought prediction using radial base neural network, the fifth national conference on watershed management and water and soil resources management, Kerman. **[in persian]**.
- Malekian, A., Dehbozorgi, M., Ehsani, A. H., & Keshtkar, A. R. (2014). Application of Artificial Neural Networks in Simulating and Forecasting of Meteorological Drought Decile Percentage Index (Case study: Sistan & Balouchestan Province). *Journal of Range and Watershed Managment*, 67(1), 127-139. **[in persian]**.
- Mallapur, S., & Platz, R. (2019). Uncertainty quantification in the mathematical modelling of a suspension strut using Bayesian inference. *Mechanical Systems and Signal Processing*, 118, 158-170. <https://doi.org/10.1016/j.ymssp.2018.08.046>
- Mandic, D., & Chambers, J. (2001). *Recurrent neural networks for prediction: learning algorithms, architectures and stability*. Wiley. ISBN: 978-0-471-49517-8

- 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. [in persian].
- Mishra, A. K., & Desai, V. R. (2006). Drought forecasting using feed-forward recursive neural network. *ecological modelling*, 198(1-2), 127-138. <https://doi.org/10.1016/j.ecolmodel.2006.04.017>
- Natke, H. G. (Ed.). (2012). *Safety evaluation based on identification approaches related to time-variant and nonlinear structures*. Springer Science & Business Media., ISBN: 978-3-322-89467-0.
- Ozger, M., Mishra, A. K., & Singh, V. P. (2011). Estimating Palmer Drought Severity Index using a wavelet fuzzy logic model based on meteorological variables. *International journal of climatology*, 31(13), 2021-2032. <https://doi.org/10.1002/joc.2215>
- Pourmohammadi, S., & Khalili, M. (2013). examining the uncertainties of the drought index in future periods by the microscale exponential methods of atmospheric general circulation models (case study: Hamedan Noje station), the 5th Iran Water Resources Management Conference, Tehran. [in persian].
- Raziei, T. (2017). Koppen-Geiger climate classification of Iran and investigation of its changes During 20th Century. 43(9), 419- 439. [in persian].
- Ribeiro, A. F., Russo, A., Gouveia, C. M., & Pires, C. A. (2020). Drought-related hot summers: A joint probability analysis in the Iberian Peninsula. *Weather and Climate Extremes*, 30, 100279. <https://doi.org/10.1016/j.wace.2020.100279>
- Rostami, M., Pahlavanravi, A., & Moghaddamnia, A. (2015). Comparison of artificial neural network models and adaptive neuro-fuzzy inference system in predicting the drought Mond Basin of Fars Province. *Journal of Natural Environmental Hazards*, 4(6), 21-32. [in persian].
- Torabipodeh, H., Deghani, R., & Rostami, S. (2019). Estimation Drought in Lorestan using Intelligent Networks. *Journal of Climate Research*, 1397(35), 41-52. [in persian].
- Willhite, D. A. (1987). *The role of government in planning for drought, toward a reduction of social vulnerability*, Boulder, Co:westview press.
- Wu, C., Zhou, L., Zhang, L., Jin, J., & Zhou, Y. (2019). Precondition cloud algorithm and Copula coupling model-based approach for drought hazard comprehensive assessment. *International Journal of Disaster Risk Reduction*, 38, 101220. <https://doi.org/10.1016/j.ijdr.2019.101220>
- Younesi, M., Shahraki, N., Marofi, S., & Nozari, H. (2018). Drought forecasting using artificial wavelet neural network integrated model (WA-ANN) and time series model (ARIMA). *Irrigation Sciences and Engineering*, 41(2), 167-181. [in persian].
- Zhang, H., Wang, T., Ding, Z., Zhang, X., & Han, L. (2020). Uncertainty analysis of impact factors of eco-environmental vulnerability based on cloud theory. *Ecological Indicators*, 110, 105864. <https://doi.org/10.1016/j.ecolind.2019.105864>.