



Environment and Water Engineering

Homepage: [www.jewe.ir](http://www.jewe.ir)



ISSN: 2476-3683

Case study

## Evaluating the Utility of Bivariate Copula-Statistical Models for Forecasting Autumn Precipitation (Case study: Northwest of Iran)

Mohammad Amini<sup>1</sup>, Mansoureh Kouhi<sup>2\*</sup> and Morteza Mohammadi<sup>3</sup>

<sup>1</sup>Professor, Department of Statistic, Faculty of Mathematical Sciences, Ferdowsi University of Mashhad, Mashhad, Iran

<sup>2</sup>Assist. Professor, Department of Applied Climatology, Faculty of Climate Research Institute, Research Institute of Meteorology and Atmospheric Sciences (RIMAS), Mashhad, Iran

<sup>3</sup>Assist. Professor, Department of Statistics, Faculty of Basic Sciences, University of Zabol, Zabol, Iran

### Article information

**Received:** January 28, 2024

**Revised:** April 18, 2024

**Accepted:** April 20, 2024

### Keywords:

Anomaly

Bivariate Models

Copula

Predictor

\*Corresponding author:

[ma.kouhi@alumini.um.ac.ir](mailto:ma.kouhi@alumini.um.ac.ir)



### Abstract

Teleconnection patterns are one of the causes of precipitation fluctuations in various regions of the world, including Iran. This study aims to develop bivariate models for forecasting autumn precipitation in the north-western region of Iran based on teleconnection indices. Copula functions were selected for this assignment due to the nonlinear relationship between precipitation and the teleconnection indices, as well as the fact that the assumption of normal distribution for precipitation data is not met, rendering Pearson correlation inappropriate. The dependence of Pacific and Atlantic Ocean teleconnection indices with precipitation for the period 1991-2020 was calculated using Kendall's and Pearson's rank correlation coefficients for moving average of one to six months. Appropriate copulas and marginal distributions were then used to model precipitation, and the performance of the developed models was evaluated. The results showed that the strongest correlations were obtained between the precipitation and the NINO3.4, SOI, and MEI indices. Consequently, the bivariate models using these indices demonstrated higher efficiency in simulating precipitation anomalies. Among these models, the one with the NINO3.4 predictor provided the best estimate of precipitation anomaly for 2021 and 2022, with values of -4.2 mm and -5.8 mm, respectively.

**How to cite this paper:** Amini, M., Kouhi, M., & Mohammadi, M. (2024). Evaluating the utility of bivariate copula-statistical models for forecasting autumn precipitation (Case study: Northwest of Iran). *Environ. Water Eng.*, 10(4), 572-589. <https://doi.org/10.22034/ewe.2024.437628.1910> (In Persian)



© Authors, Published by **Environment and Water Engineering** Journal. This is an open-access article distributed under the CC BY (license <http://creativecommons.org/licenses/by/4.0/>).



## EXTENDED ABSTRACT

### Introduction

Since the northwestern regions of Iran are important agricultural areas, especially for rainfed agriculture, developing a model for forecasting autumn precipitation can be very useful. This would allow for better resource utilization and more accurate planning in the water and agricultural sectors of this region. Teleconnection patterns are one of the reasons behind precipitation fluctuations in various regions around the world, including Iran. These patterns can be used as predictors in precipitation forecasting models. The aim of this study is to develop bivariate models for forecasting autumn precipitation anomalies in the northwestern region of Iran based on teleconnection indices. Copula functions were chosen for this task because precipitation data is unlikely to be normally distributed (making Pearson correlation unsuitable) and because of the nonlinear relationship between precipitation and the teleconnection indices.

### Material and Methods

The study area encompasses the three provinces of Ardabil, East Azerbaijan, and West Azerbaijan, covering an approximate area of 101,398 km<sup>2</sup> in northwestern Iran. The monthly and seasonal total precipitation data used in this study were obtained from the daily data covering the period from January 1, 1991, to December 31, 2020. These data sets are available from IRIMO ([https://www.irimo.ir/eng/wd/720-Products-](https://www.irimo.ir/eng/wd/720-Products-Services.html)

[Services.html](https://www.irimo.ir/eng/wd/720-Products-Services.html)). These time series are acquired from 16 meteorological stations that are spread over the northwest of Iran. In terms of the homogeneity of the data, the RHtestsV4 software package was used to detect and adjust for multiple change points (shifts) that could exist in the monthly precipitation time series of 16 stations. Seven different climate indices, i.e., Nino 3.4 SST, Southern Oscillation Index (SOI), Multivariate ENSO Index (MEI), North Atlantic Oscillation (NAO), Arctic Oscillation (AO), East Atlantic/West Russia (EA-WR), and Atlantic Multidecadal Oscillation (AMO), were obtained from various sources, such as the National Climate Prediction Center. The inverse form of the conditional distribution functions was used to construct the forecasting model. In the first step, the correlation between the predictor variables and the autumn (OND) precipitation anomaly was assessed using the Kendall and Pearson rank correlation coefficients within a moving average of 1 to 6 months. In the subsequent step, the climate indices and precipitation were fitted to their probability distribution functions based on a statistical goodness-of-fit (GOF) test and graphical analysis. Such GOF tests are also used to select the best-fitting copula function. In the final step, a selected copula function was used to generate the forecasted precipitation anomalies given each climate index. The bivariate models were designated by the letter "M" followed by the number assigned to each teleconnection index. The abbreviated names were used in subsequent analyses.

Table 1 Rank-based correlation coefficients and p-value of Kendall's tau and Spearman's rho between climate indices and the average OND precipitation anomaly for the period 1991–2020

Model Name	Teleconnection Index	Kendall's tau	P-value	Spearman's rho	P-value
M1	MEI (SO)	0.49	0.0001	0.64	0.0001
M2	MEI (JA)	0.48	0.0002	0.61	0.0002
M3	NAO (AM)	0.35	0.006	0.51	0.003
M4	AO (FMAMJJ)	0.35	0.006	0.47	0.007
M5	NINO (JAS)	0.45	0.0004	0.62	0.0002
M6	AO (AMJ)	0.38	0.002	0.51	0.003
M7	NAO (MAMJ)	0.32	0.01	0.47	0.008
M8	NAO (JFMAM)	0.43	0.0007	0.60	0.0004
M9	SOI (JAS)	-0.47	0.0002	-0.61	0.0003
M10	AMO (MJJ)	-0.25	0.04	-0.33	0.06

## Results

The results showed the highest Kendall's Tau and Spearman's rho were obtained between the precipitation and the NINO3.4, SOI, and MEI indices (Table 1). Fig. 1 presents a box plot comparing the simulated values (30 data points) with the observed autumn precipitation anomaly values. In this figure, the dashed line represents the median of the observed data, which is plotted

for ease of comparison. Based on the comparison of the observed mean precipitation anomaly and the simulated mean precipitation anomaly by the nine models, poor performance is observed in models M3, M7, and M8 (predictor NAO). The best models were M2, M4, and M9 based on the matching of the central index and distribution of the data.

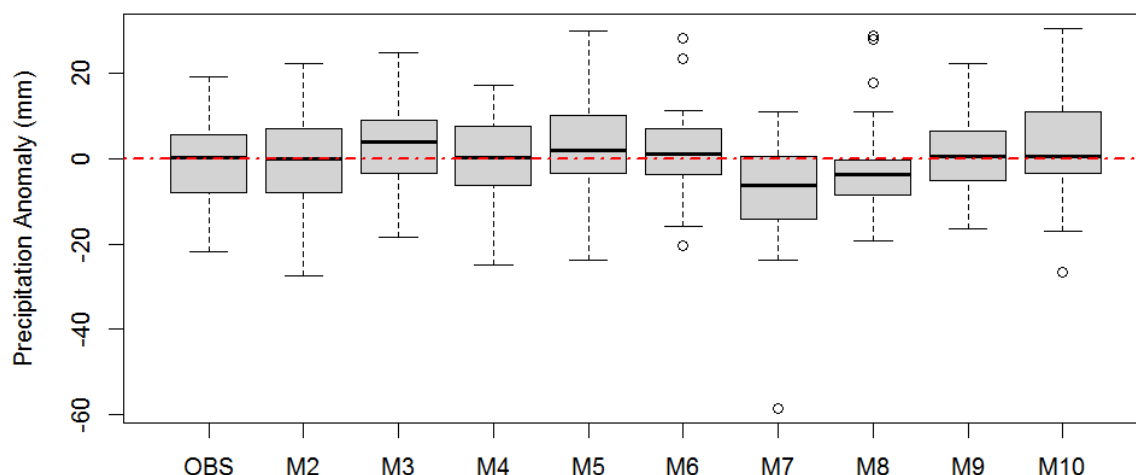


Fig. 1 boxplot of observed and simulated OND precipitation anomalies using nine bivariate models based on copula

## Conclusions

Seasonal precipitation forecasting is one of the most effective tools for adopting adaptation approaches, mitigating the adverse impacts of extreme climate events such as droughts, and supporting the development of risk management strategies. The results indicated:

1. Based on the various central and dispersion statistical indices, the best models were M2, M4, and M9 for autumn precipitation forecasting in this region.
2. The Pacific Ocean indices have higher correlation coefficient values compared to the Atlantic Ocean teleconnection indices.
3. In the validation stage of the developed models with the precipitation anomaly values of 2021 and 2022, the bivariate models using NINO3.4, SOI, and MEI indices showed higher efficiency in simulating precipitation anomalies. All three models forecasted a positive precipitation anomaly for the region in 2023.

4. The NINO3.4 model, which provided the best estimate of precipitation anomalies for 2021 and 2022 with values of -4.2 mm and -5.8 mm, respectively, forecasted a precipitation anomaly of +4.6 mm for 2023.

## Acknowledgment

This paper is extracted from a research project entitled "Evaluating the Utility of Copula-Statistical Models for Predicting Precipitation (Case Study: Northwest of Iran)" which was financially supported by the Iran National Science Foundation. We would like to express our gratitude to the Iran National Science Foundation for their support.

## Data Availability

The data generated in this research is presented in the text of the article.

## Conflicts of interest

The authors of this paper declared no conflict of interest regarding the authorship or publication of this article.



ISSN: 2476-3683

محیط زیست و مهندسی آب

Homepage: [www.jewe.ir](http://www.jewe.ir)

مطالعه موردی

## ارزیابی کارایی مدل های آماری مفصل - مبنا دو متغیره در پیش بینی بارش پاییزه (مطالعه موردی: شمال غرب ایران)

محمد امینی<sup>۱</sup>، منصوره کوهی<sup>۲\*</sup> و مرتضی محمدی<sup>۳</sup><sup>۱</sup>استاد، گروه آمار، دانشکده ریاضی، دانشگاه فردوسی مشهد، مشهد، ایران<sup>۲</sup>استادیار، پژوهشگاه هواشناسی و علوم جو، پژوهشکده اقلیم شناسی و تغییر اقلیم، مشهد، ایران<sup>۳</sup>استادیار، گروه آمار، دانشکده علوم پایه، دانشگاه زابل، زابل، ایران

### چکیده

### اطلاعات مقاله

تاریخ دریافت: [۱۴۰۲/۱۱/۰۸]

تاریخ بازنگری: [۱۴۰۳/۰۱/۳۰]

تاریخ پذیرش: [۱۴۰۳/۰۲/۰۱]

واژه های کلیدی:

پیشگو

مدل دومتغیره

مفصل

ناهنجاری

نویسنده مسئول:

[ma.kouhi@alumini.um.ac.ir](mailto:ma.kouhi@alumini.um.ac.ir)

الگوهای پیوند از دور، از علل نوسان های بارش مناطق مختلف دنیا از جمله ایران به شمار می روند. از این متغیرها می توان به عنوان تخمین گر در مدل های پیش بینی بارش استفاده کرد. هدف این پژوهش، ارائه مدل دو متغیره پیش بینی بارش پاییزه بر مبنای این الگوها برای منطقه شمال غرب کشور می باشد. به دلیل عدم تحقق فرض نرمال بودن بارش و در نتیجه عدم امکان استفاده از ضریب همبستگی پیرسون و همچنین وجود رابطه غیرخطی بین این نمایی ها و بارش، در این پژوهش، از توابع مفصل استفاده شد. وابستگی دورپیوندهای اقیانوس آرام و اقیانوس اطلس با بارش برای دوره ۱۹۹۱-۲۰۲۰ با استفاده از ضریب وابستگی رتبه ای کندال و ضریب وابستگی رتبه ای پیرسون برای میانگین متحرک ۱ تا ۶ ماهه محاسبه شد. مفصل ها و توزیع های کناری مناسب برای مدلسازی ناهنجاری بارش بکار رفت و کارایی مدل های تدوین شده بررسی شد. نتایج نشان داد بالاترین ضریب وابستگی رتبه ای کندال، بین ناهنجاری بارش و دورپیوندهای SOI، NINO3.4 و MEI بدست آمد. در نتیجه، مدل های تدوین شده با این نمایی ها، دارای کارایی بالاتری در شبیه سازی بارش بودند. در این بین، مدل دارای پیشگوی NINO3.4، بهترین برآورد ناهنجاری بارش را برای سال ۲۰۲۱ و ۲۰۲۲ به ترتیب به میزان ۲/۴ mm و ۸/۵- ارائه داد.

### نحوه استناد به این مقاله:

امینی، محمد، کوهی، منصوره & محمدی، مرتضی. (۱۴۰۳). ارزیابی کارایی مدل های آماری مفصل - مبنا دو متغیره در پیش بینی بارش پاییزه (مطالعه موردی: شمال غرب ایران) محیط زیست و مهندسی آب. 10(4) 572-589

<https://doi.org/10.22034/ewe.2024.437628.1910>

## ۱- مقدمه

پیش‌بینی بارش پاییزه را ارائه نمودند. نتایج نشان داد بارش پاییزه بیشتر تحت تأثیر SOI فصل قبل قرار دارد. Modaresi et al. (2015) نیز اقدام به ارائه مدلی برای پیش‌بینی بارش پاییزه در زیرحوضه سیمره در غرب کشور نمودند. در این پژوهش با کاربست منفرد و ترکیب پنج روش بر اساس میانگین تابستانه دو نمایه اقلیمی SOI و NINO 3.4، نشان داده شد که نمایه NINO3.4، مناسب‌ترین متغیر پیشگو برای بارش این فصل می‌باشد. (Ghavidel Rahimi et al. (2014، رابطه بین بارش‌های پاییزی ایستگاه‌های منطقه غرب و شمال غرب کشور را با الگوی پیوند از دور دریای شمال-خزر ( $^{12}$ NCP) بررسی کردند. (Nourani et al. (2016 حداکثر بارش دو ایستگاه تبریز و کرمانشاه را با استفاده از داده‌های دمای سطح دریای سرخ، مدیترانه و سیاه با فازهای تأخیری متفاوت پیش‌بینی نمودند. (Bateni et al. (2018 با استفاده از دمای سطح دریای مدیترانه مدلی را به منظور پیش‌بینی خشکسالی برای حوضه دریاچه ارومیه پیشنهاد دادند. وابستگی نمایه‌ی NAO با بارش پاییزه در منطقه شمال غرب کشور نیز در پژوهش‌هایی مانند (Dostan (2018 و Mirzayi Hasanlo et al. (2020 معنادار به دست آمد.

در اکثر پژوهش‌های انجام شده به منظور بررسی اثرات نمایه‌های اقلیمی، از مدل‌های وایزشی استفاده شده که ساختار وابستگی بین یک نمایه و بارش را با استفاده از ضریب همبستگی خطی پیرسون<sup>۱۳</sup> با در نظر گرفتن توزیع نرمال اندازه‌گیری می‌کند. با این وجود، باید توجه داشت که داده‌های بارش دارای توزیع چوله هستند و رابطه بین نمایه‌های اقلیمی غیرخطی است (Brechmann and Schepsmeier 2013). بنابراین استفاده از ضریب همبستگی پیرسون و فرض نرمال بودن درست نیست. در این راستا، می‌توان از توابع مفصل استفاده کرد. توابع مفصل<sup>۱۴</sup> (Sklar 1959) ابزاری مناسب برای ساخت توزیع توام برای متغیرهای وابسته هستند. با این

ایران به دلیل موقعیت جغرافیایی، تحت نفوذ پرفشار جنب حاره، فرونشینی هوا، گرمایش بی‌دررو و کاهش رطوبت قرار دارد (Saligheh 2017). این امر منجر به کمبود و نوسان ریزش‌های جوی سالانه، افزایش دما، افزایش تبخیر-تعرق، واداشت تابشی و ساعات آفتابی شده، اقلیمی خشک و نیمه خشک را بر غالب مناطق این کشور حاکم کرده است (Ghaemi et al. 2012). الگوهای پیوند از دور از مهم‌ترین علل نوسان‌های بارش بوده و در سال‌های اخیر تحقیقات زیادی در زمینه اثرات این الگوها بر بارش انجام شده است. Xie et al. (2022) برای حوضه رودخانه Huaihe چین، ارتباط نوسان‌های زمانی و مکانی نمایه غلظت بارش فصلی و سالانه را با النینو-نوسان جنوبی ( $^{1}$ ENSO) و نوسان دهه‌ای اقیانوس آرام ( $^{2}$ PDO) بررسی کردند. نتایج نشان داد این نمایه با دو دور پیوند (به‌ویژه ENSO) رابطه منفی دارد. Jung and Kim (2022) در پژوهش خود اقدام به تحلیل ویژگی‌های دما و بارش فصل تابستان در زمان رخداد لنینا - ال‌نینو در حوضه رودخانه Geum کره جنوبی و توسعه مدلی برای پیش‌بینی این دو متغیر برای این فصل سیل‌خیز کردند. بررسی کارایی مدل نشان داد پیش‌بینی دما و بارش با لحاظ این دو پدیده بهبود یافته است. (Mirhashemi and Hasanvand (2023 در پژوهش خود نشان دادند تغییر فاز نمایه‌های دور پیوند اقیانوس آرام ( $^{3}$ SOI,  $^{4}$ Best,  $^{5}$ EP/NP,  $^{6}$ Nino 1+2,  $^{7}$ Nino3.4)، عامل اصلی تغییر معنادار در بارش دو ماه اکتبر و نوامبر ایستگاه خرم آباد و ماه اکتبر ایستگاه کرمانشاه هستند. الگوهای دور پیوند اقیانوس اطلس مانند  $^{6}$ AO,  $^{7}$ NAO,  $^{8}$ SCA,  $^{9}$ EA/WR و  $^{10}$ AMM به‌طور عمده در فصل زمستان منجر به تغییر معناداری در بارش این دو ایستگاه می‌شوند.

برای منطقه شمال غرب ایران، (Fatehi Marj et al. (2006 تأثیر ۶ نمایه NAO, PDO,  $^{11}$ PNA, NINO3.4, SOI و PDO را بر بارش حوضه دریاچه ارومیه مورد بررسی و مدل

<sup>8</sup>Scandinavia Pattern<sup>9</sup>East Atlantic-West Russian<sup>10</sup>Atlantic Meridional Mod(wind)<sup>11</sup>Pacific North American Pattern<sup>12</sup>North Caspian Sea Pattern<sup>13</sup>Pearson<sup>14</sup>Copula Functions<sup>1</sup>El Niño-Southern Oscillation<sup>2</sup>The Pacific Decadal Oscillation<sup>3</sup>The Southern Oscillation Index<sup>4</sup>Bivariate ENSO Timeseries index<sup>5</sup>East Pacific – North Pacific<sup>6</sup>Arctic Oscillation<sup>7</sup>North Atlantic Oscillation

قطبی اقیانوس هند<sup>7</sup> (IOD) منجر به تقویت این نوع فرین‌ها در مناطق حاره‌ای می‌شوند.

با توجه به نیاز بخش‌های مختلف کشاورزی، آب و انرژی به پیش‌بینی بارش و با توجه به تأثیر این نمایه‌ها بر این متغیر، تلاش جهت ارائه مدلی برای پیش‌بینی بارش بر مبنای این نمایه‌ها، بسیار ارزشمند خواهد بود. با توجه به اینکه مناطق شمال غرب و غرب کشور از مناطق عمده کشاورزی (بوژه دیم) کشور (Abbasi et al., 2019) محسوب می‌شوند، افزون بر این امر، جمعیت قابل توجهی نیز در این نواحی اسکان دارند، ارائه مدلی به‌منظور پیش‌بینی بارش فصلی می‌تواند در بهره‌برداری از امکانات و برنامه‌ریزی دقیق‌تر در بخش‌های مختلف آب و کشاورزی مورد استفاده قرار گیرد. لذا هدف این پژوهش، تحلیل اثرات مشترک دور پیوندهای منتخب بر بارش پاییزه در منطقه شمال غرب و توسعه مدل‌های دو متغیره مفصل-مبنا به‌منظور پیش‌بینی بارش فصلی با استفاده از این دور پیوندها می‌باشد.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد بررسی

محدوده مورد مطالعه شامل سه استان اردبیل و آذربایجان شرقی و آذربایجان غربی به وسعت تقریبی  $101398 \text{ km}^2$  در شمال غرب ایران و بین  $39^\circ 0'$  عرض شمالی واقع شده است که در شکل (۱) نشان داده شده است. آذربایجان شرقی در شمال غربی فلات ایران با وسعت  $43660 \text{ km}^2$  در شمال غربی ایران واقع شده است. میانگین بارش متوسط سالانه آن در سطح استان  $375 \text{ mm}$  می‌باشد. ارتفاع استان از  $160 \text{ m}$  تا  $4811 \text{ m}$  متغیر است. اقلیم این استان، سرد و نیمه خشک بوده و میانگین بارش آن  $250\text{--}300 \text{ mm}$  است (Farajnia and Moravej 2020). استان آذربایجان غربی نیز منطقه‌ای کوهستانی محسوب می‌شود که توپوگرافی متنوع و گسترده‌ای دارد. منطقه‌ای سردسیر و کوهستانی و از لحاظ تقسیم‌بندی‌های اقلیمی جزو مناطق نیمه‌خشک به حساب می‌آید که میانگین بارش سالیانه آن  $375 \text{ mm}$  می‌باشد. استان

توابع، ضمن تحلیل توام دو یا چند متغیره، می‌توان ساختار و میزان وابستگی بین آن‌ها را نیز در تحلیل‌ها در نظر گرفت.

در این راستا، (Khedun et al. 2014) از مفصل در مدل‌سازی اثرات ENSO و PDO بر ناهنجاری‌های بارش در تک‌زاس استفاده کردند. نتایج نشان داد گنجاندن PDO در مدل منجر به بهبود عملکرد مدل می‌شود. (Madadgar et al. 2016) چارچوبی را برای مدل‌سازی آماری-دینامیکی پیش‌بینی بارش فصلی بر مبنای آنسامبل چند مدلی آمریکای شمالی (NMME<sup>1</sup>) و یک مدل بیزی بر مبنای مفصل با استفاده از متغیرهای پیشگوی PDO، MEI<sup>2</sup> و AMO<sup>3</sup> توسعه دادند که دقت پیش‌بینی بارش فصلی با برد زمانی ۳-۵ ماه، حدود ۵ تا ۶۰٪ بهبود بخشید. در پژوهشی دیگر، از مفصل‌های واین برای بررسی اثرات واداشتهای اقلیمی دورپیوند بر بارش بهاره در ناحیه کشاورزی-اکولوژیکی (AEZs<sup>4</sup>) کمربند گندم استرالیا استفاده شد (Nguyen-Huy et al. 2017). نتایج نشان داد مدل‌های مفصل مبنا رفتار توام نمایه‌های دور پیوند با بارش را به خوبی تبیین کرده‌اند. (Nguyen-Huy et al. 2018) نشان دادند مدل‌های مفصل-مبنا نسبت به مدل رگرسیون چندکی خطی، از مهارت بالاتری در پیش‌بینی عملکرد محصول گندم در ۵ ایالت استرالیا برخوردار هستند. (Abdourahamane et al. 2019) در پژوهش خود اقدام به ترکیب مفصل فرانک و تبدیل موجک به‌منظور ارائه مدل‌های غیرخطی پیش‌بینی بارش نمودند. روش پیشنهادی با ۲۴ نمایه اقلیمی (متغیرهای پیشگو) برای ۴ ایستگاه در ساحل نیجریه بکار رفت. در پژوهشی دیگر، نشان داده شد که به‌منظور پیش‌بینی بارش، روش GM-Copula از کارایی بالاتری در نمایش پیچیدگی‌ها، نسبت به روش یادگیری ماشین دارد (Maity et al., 2020). (Espinosa et al. 2021) یک رهیافت مفصل مبنا با هدف ارزیابی دوره‌های بازگشت مقادیر روزانه نمایه NAOI جفت شده با بارش‌های حدی روزانه برای جزیره مادیرا<sup>۵</sup> ارائه دادند. (Yanto et al. 2023) نیز از توابع مفصل به‌منظور شناخت واداشتهای اقلیمی فرین‌های هیدروکلیمایی در حوضه رودخانه سرایو<sup>۶</sup> در کشور اندونزی استفاده کردند. نتایج به‌دست آمده نشان داد ال نینو-نوسان جنوبی و نوسان دو

<sup>5</sup>Madeira

<sup>6</sup>Serayu

<sup>7</sup>Indian Oscillation Dipole

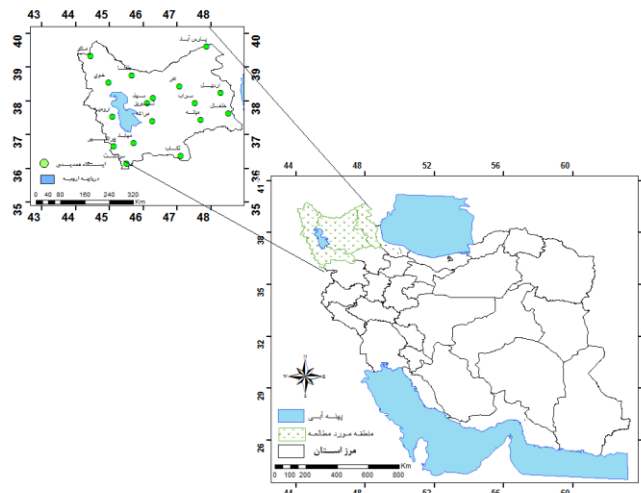
<sup>1</sup>the North American Multi-Model Ensemble

<sup>2</sup>Multi ENSO Index

<sup>3</sup>Atlantic Multidecadal Oscillation

<sup>4</sup>Australia agro-ecological Zones

اردبیل با مساحت  $17880/918 \text{ km}^2$  نیز از اقلیم متنوعی برخوردار است. در کل اقلیم، این استان نیمه خشک محسوب می‌شود (Frotan and Salahi 2023).



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه  
Fig. 1 Geographical location of study area

این روش، در بسته نرم افزاری RHtest (Wang, 2008) گنجانده شده است و در محیط R اجرا می‌شود. در این پژوهش، از نسخه ۴ RHtest به منظور کنترل کیفی و همگن سازی داده‌های ماهانه ایستگاه‌های منطقه استفاده شد.

#### ۲-۴- توابع مفصل

توابع مفصل (Sklar 1959) ابزاری مناسب برای ساخت توزیع توام برای متغیرهای وابسته هستند، زیرا ضمن تحلیل توام دو یا چند متغیره می‌توان ساختار و میزان وابستگی بین آن‌ها را نیز در تحلیل‌ها در نظر گرفت و بر مشکلات مربوط به وابستگی همزمان بین حوادث نادر (بارش‌های فرین) با لحاظ وابستگی‌های دمی (یعنی ساختار وابستگی نامتقارن) فائق آمد (Nelsen 2006).

#### ۲-۴-۱- قضیه اسکالر

(Sklar 1959) ثابت کرد اگر  $X_1, X_2, \dots, X_n$  متغیرهای تصادفی پیوسته با توابع توزیع کناری به ترتیب  $F_1, F_2, \dots, F_n$  باشند، آنگاه تابع مفصل  $C(u_1, \dots, u_n)$  وجود دارد (رابطه ۱) به طوری که

$$F(x_1, \dots, x_n) = C(F_1(x_1), \dots, F_n(x_n))$$

یک توزیع توام با توابع توزیع کناری  $F_1$  تا  $F_n$  باشد.

#### ۲-۲- داده‌ها

داده‌های بارش روزانه (mm) از ۵۰ ایستگاه هواشناسی همدید در سه استان مورد بررسی از سازمان هواشناسی کشور اخذ شد. استان‌های آذربایجان غربی و شرقی دارای ۱۹ ایستگاه و استان اردبیل نیز دارای ۱۲ ایستگاه همدید تکمیلی و فرودگاهی می‌باشند. دوره آماری این ایستگاه‌ها متفاوت بوده، سه ایستگاه ارومیه، خوی و تبریز که ایستگاه‌های همدید فرودگاهی محسوب می‌شوند دارای طولانی‌ترین دوره آماری ثبت داده‌های هواشناسی می‌باشند.

#### ۲-۳- همگنی و کنترل کیفی داده‌های بارش

در زمان استفاده از داده‌های هواشناسی باید از صحت و همگن بودن آنها اطمینان حاصل کرد. در بیشتر موارد فراداده<sup>۱</sup> یا شناسه ایستگاه قابل استناد و در برخی موارد، ایستگاه مرجع در دسترس نیست. اما در این صورت نیز می‌توان با روش‌هایی که تغییر روند معنی‌دار در سری زمانی را شناسایی و تصحیح می‌کنند اقدام به کنترل کیفی و همگن سازی داده‌ها کرد (Wang, 2008; Akhlāghi Yengejeh et al., 2021). آزمون بیشینه F تاوانیده ( $PMF^2$ ) جزء روش‌های کلاسیک کنترل کیفی آماری (در مقابل روش‌های بیزی مانند رگرسیون) محسوب می‌شود که می‌توان از آن استفاده کرد.

<sup>2</sup> Penalized Maximal F test

<sup>1</sup> Meta data

$$C(u_1, \dots, u_n) = F(F_1^{-1}(u_1), \dots, F_n^{-1}(u_n)) \quad 0 \leq u_i \leq 1 \quad i = 1, \dots, n \quad (1)$$

یک روش تولید مفصل بر اساس قضیه اسکالر، روش معکوس است (رابطه ۲). در حالت دو متغیره، فرض کنید  $X$  و  $Y$  دو متغیر تصادفی (در این پژوهش ناهنجاری بارش و نمایه‌ی دور

$$C(u, v) = F(F_1^{-1}(u), F_2^{-1}(v)), \quad u = F_1(x), \quad v = F_2(y) \quad (2)$$

مفصل به روش‌های دیگر همچون روش‌های هندسی و جبری نیز ساخته می‌شود که برای مطالعه این روش‌ها به Nelsen (2006) می‌توان مراجعه کرد. این توابع، در چندین خانواده طبقه‌بندی می‌شوند. مفصل‌های ارشمیدسی و بیضوی پرکاربردترین مفصل‌ها در زمینه‌های مختلف مهندسی و علوم هستند.

### ۲-۴-۲- انتخاب مفصل

با وجود چندین مفصل، لازم است مفصلی که بهترین برازش را بر داده‌های مشاهداتی داشته و به بهترین نحو ساختار وابستگی را نشان دهد، شناسایی شود. انتخاب مفصل، شامل مراحل ارزیابی ساختار وابستگی و شدت وابستگی، ارزیابی وابستگی‌های دمی، برازش توزیع‌های حاشیه‌ای، برآورد پارامتر وابستگی و آزمون‌های نیکویی برازش است. برای ارزیابی ساختار وابستگی، در مدل‌سازی آماری بر مبنای مفصل، از ضرایب رتبه‌ای  $\rho$  اسپیرمن و  $\tau$  کندال<sup>۱</sup> استفاده می‌شود. این ضریب‌ها، جایگزین‌های مناسبی برای مدل‌سازی وابستگی غیر خطی به شمار می‌روند. این دو ضریب، وابستگی کلی بین دو متغیر را اندازه می‌گیرند. ارزیابی ترسیمی با نمودارهای پراکنش<sup>۲</sup>، کای<sup>۳</sup> و کندال انجام می‌شود. به‌طور کلی، برآورد پارامترهای مفصل به دو روش پارامتری شامل روش برآوردگر بیشینه درست‌نمایی<sup>۴</sup> (MLE) و توابع استنباط کناری و نیمه‌پارامتری مانند روش برآوردگر کمینه فاصله<sup>۵</sup> (MD) و برآوردگر درست‌نمایی بیشینه تاوانیده<sup>۶</sup> (PML) انجام می‌شود (Nelsen, 2006). در این پژوهش، از روش PML استفاده شد.

### ۲-۴-۳- مدل پیش‌بینی شرطی مفصل مبنای

برای ساخت مدل‌های پیش‌بینی از وارون تابع توزیع به دست آمده بر مبنای مفصل شرطی استفاده شد. این مدل‌ها نسبت

به سایر روش‌های موجود از دقت بیشتری برخوردار هستند. اگر  $X_1$  و  $X_2$  دو متغیر تصادفی با تابع توزیع توام  $F(x_1, x_2)$  و مفصل متناظر  $C(u_1, u_2)$ ، احتمالات معین  $p \in (0, 1)$  از رابطه (۳) به‌دست می‌آید (Mai & Scherer, 2017).

$$C_v(u) \equiv C_u(v) = P[V \leq v | U = u] = \frac{\partial C(u, v)}{\partial u} \quad (3)$$

$$\text{که،} \quad v = h^{-1}(p) = C_u^{-1}(p), \quad 0 < p < 1$$

$$x_1 = F_1^{-1}(u), \quad x_2 = F_1^{-1}(v) = F_2^{-1}(h^{-1}(p))$$

### ۳- یافته‌ها و بحث

#### ۳-۱- کیفیت داده‌ها

از بین ۵۰ ایستگاه همدید و اقلیم‌شناسی موجود در منطقه، ۱۶ ایستگاه به نحوی انتخاب شدند که هم دارای داده بارش برای دوره ۱۹۹۱-۲۰۲۰ باشند و هم مقادیر مفقود در ایستگاه‌های مذکور، کمتر از ۱۰٪ کل داده‌ها باشد. (Szentimrey et al. 2017). اسامی ایستگاه‌ها در جدول (۱) آورده شده است. بررسی همگنی با استفاده از آزمون PMF انجام شد. بر اساس این آزمون، در سطح اطمینان ۹۵٪، نقطه تغییر در روند سری ماهانه بارش این ایستگاه‌ها مشاهده نشد. بنابراین نتایج نشان داد داده‌های بارش در این ایستگاه‌ها، در سطح اطمینان ۹۵٪ همگن هستند. به‌عنوان نمونه در شکل (۱) سری زمانی داده‌های ماهانه بارش ایستگاه سردشت (پربارش‌ترین ایستگاه)، به همراه خط رگرسیون برازش داده شده بر سری بارش نشان داده شده است. همانگونه که مشاهده می‌شود هیچ نقطه تغییری در این سری زمانی بدست نیامد. در ادامه میانگین منطقه‌ای با استفاده از داده‌های ماهانه ایستگاه‌های جدول (۱) محاسبه و ناهنجاری بارش پاییزه برای سه ماهه اکتبر-نوامبر - دسامبر (OND) برای دوره ۱۹۹۱-۲۰۲۰ محاسبه شد.

<sup>4</sup>Maximum Likelihood Estimation

<sup>5</sup>Minimum Distance

<sup>6</sup>Pseudo-maximum likelihood

<sup>1</sup>Kendall

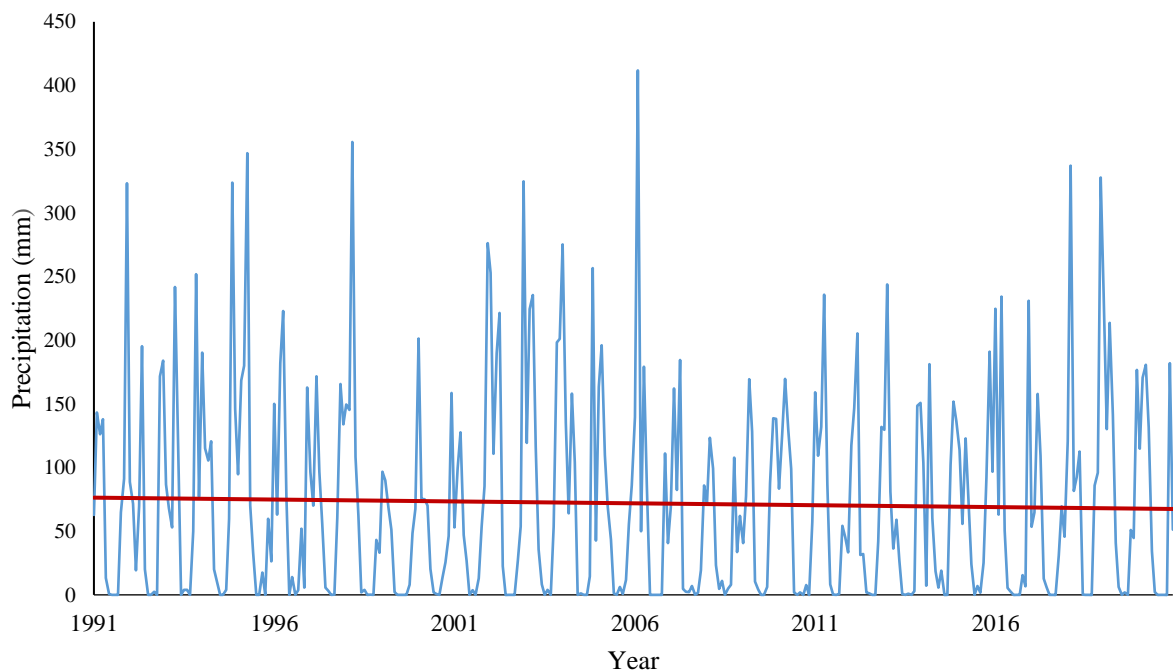
<sup>2</sup>Scatter plot

<sup>3</sup>Chi plot

جدول ۱- مختصات جغرافیایی ایستگاه‌های مورد بررسی

Table 1 Geographical coordinates of the stations under study

Row	Station Name	Longitude (degree/decimal degree)	Latitude (degree/decimal degree)	Elevation (m)
1	Ardebil	48.2	38.1	1335
2	Orumiyeh	45.1	37.5	1328
3	Ahar	47.1	38.4	1391
4	Pars Abad	47.8	39.6	78
5	Piranshahr	45.1	36.6	1443.5
6	Tabriz	46.2	38.1	1361
7	Takab	47.1	36.3	1817.2
8	Jolfa	45.6	38.7	736.2
9	Khalkhal	48.5	37.6	1797.4
10	Khoy	44.9	38.5	1104.4
11	Sarab	47.5	37.9	1682
12	Sardasht	45.5	36.1	1556.8
13	Makou	44.4	39.3	1411.2
14	Maraghe	46.2	37.4	1344
15	Mahabad	45.7	36.7	1351.8
16	Miyaneh	47.7	37.4	1110



شکل ۱- سری پایه و خط رگرسیون برازش داده شده برای بارش ماهانه ایستگاه سردشت  
Fig. 1 Base series and regression fit of monthly precipitation Sardasht station

### ۳-۲- انتخاب متغیرهای پیشگو

انتخاب شدند. به منظور بررسی وابستگی نمایه‌های دور پیوند، میانگین متحرک یک تا شش ماهه نمایه‌ها محاسبه و میزان وابستگی آنها با میانگین ناهنجاری بارش فصلی با استفاده از ضریب رتبه‌ای کندال و اسپیرمن بررسی شد.

از بین نمایه‌های دور پیوند موجود، با توجه به پیشینه پژوهش، الگوهای دور پیوند جدول (۲) که جزو نمایه‌های دور پیوند اقیانوس آرام (NINO3.4, MEI, SOI) و اقیانوس اطلس (NAO, AO, EA-WR, AMO) محسوب می‌شوند، به عنوان متغیرهای پیشگو

جدول ۲- فهرست پیشگوهای اقلیمی مورد بررسی و منبع داده مورد استفاده

Table 2 List of climate predictors and data sources used

Name	Explanation	Period	Data source
SOI	Southern Oscillation Index	1951-now	<a href="https://www.cpc.ncep.noaa.gov/data/indices/soi">https://www.cpc.ncep.noaa.gov/data/indices/soi</a>
NAO	North Atlantic Oscillation	1950-now	<a href="https://www.ncei.noaa.gov/access/monitoring/nao/">https://www.ncei.noaa.gov/access/monitoring/nao/</a>
AO	Arctic Oscillation	1950-now	<a href="https://www.ncei.noaa.gov/access/monitoring/ao/">https://www.ncei.noaa.gov/access/monitoring/ao/</a>
MEI	Multi ENSO Index	1979-now	<a href="https://psl.noaa.gov/enso/mei/data/meiv2.data">https://psl.noaa.gov/enso/mei/data/meiv2.data</a>
NINO3.4	East Central Tropical Pacific Sea Surface Temperature (5N-5S)(170-120W)	1880-now	<a href="http://climexp.knmi.nl/selectindex.cgi?id=so-meone@somewhere">http://climexp.knmi.nl/selectindex.cgi?id=so-meone@somewhere</a>
EA-WR	The East Atlantic /West Russia	1950-now	<a href="https://www.cpc.ncep.noaa.gov/data/teledoc/eawruss.shtml">https://www.cpc.ncep.noaa.gov/data/teledoc/eawruss.shtml</a>
AMO	Atlantic Multidecadal Oscillation	1880-now	<a href="http://climexp.knmi.nl/getindices.cgi?WMO=NCDCData/amo_ersst&amp;STATION=AMO_ersst">http://climexp.knmi.nl/getindices.cgi?WMO=NCDCData/amo_ersst&amp;STATION=AMO_ersst</a>

## ۳-۳- توسعه مدل پیش‌بینی

می‌شود NAO دو ماهه ND (نوامبر-دسامبر)، دارای بیشترین مقدار وابستگی با میانگین ناهنجاری بارش OND است. اما قابل پیش‌بینی به‌موقع نیست و نمی‌توان از آن به‌عنوان یک متغیر پیشگو استفاده کرد. لازم به ذکر است که یکی از معیارهای در نظر گرفته شده به‌منظور انتخاب نمایه دور پیوند پیشگو، زمان در دسترس قرار گرفتن نمایه است. با توجه به این موضوع، نمایه‌هایی که دارای بالاترین مقدار ضریب وابستگی تا قبل از ماه سپتامبر بود در نظر گرفته شد.

در اولین گام، مقادیر  $\tau$  کنдал و  $\rho$  اسپیرمن بین میانگین ناهنجاری‌های بارش پاییزه و نمایه‌های دور پیوند منتخب در پنجره‌های زمانی ۱ تا ۶ ماه محاسبه شد. در جدول (۳) به‌عنوان نمونه، مقدار این ضرایب به همراه نتیجه آزمون معنی‌داری آن‌ها در سطح اطمینان ۹۵٪ (اعداد ستاره‌دار) برای پنجره زمانی ۲ ماهه آورده شده است. همانطور که مشاهده

جدول ۳- ضریب وابستگی رتبه‌ای  $\tau$  کنдал بارش پاییزه با میانگین متحرک دو ماهه نمایه‌های دور پیوند اقلیمیTable 3 Rank-based correlation coefficient of Kendall's tau ( $\tau$ ) between two-month moving average of climate indices and average OND precipitation anomaly

DJ	ND	ON	SO	AS	JA	JJ	MJ	AM	MA	FM	JF	Index
0.10	*-0.32	*-0.37	*-0.47	*-0.45	*-0.46	*-0.40	*-0.25	-0.08	-0.12	0.01	0.14	SOI
0.23	*0.41	0.19	-0.05	0.03	-	0.06	0.23	*0.36	0.21	0.12	*0.29	NAO
					0.009							
-0.20	*0.33	0.24	0.10	0.08	0.07	0.06	-	-0.07	0.11	0.03	-0.12	EA-WR
							0.002					
0.17	0.27	0.09	-0.07	0.21	-0.03	0.02	*0.30	*0.30	0.20	0.05	0.08	AO
0.03	*-0.26	-0.22	-0.18	-0.15	-0.19	*-0.26	-0.22	-0.10	-	0.05		AMO
									0.002			
-0.15	*0.49	*0.48	*0.44	*0.47	*0.42	*0.37	*0.27	0.11	0.07	-0.12	-0.16	NIN
												O3.4
-0.07	*0.47	*0.45	*0.49	*0.46	*0.47	*0.44	0.20	0.05	0.07	-0.07	-0.1	MEI

\*: significant at 0.05 level

اعداد ستاره‌دار: معنی‌دار در سطح ۰/۰۵

داد با بزرگ‌تر شدن پنجره زمانی نمایه‌ها، فراوانی ماه‌هایی با ضریب وابستگی معنی‌دار در نمایه NAO افزایش یافته است.

بررسی معنی‌داری ضریب وابستگی بارش پاییزه و میانگین متحرک نمایه‌های دور پیوند در پنجره‌های زمانی متفاوت نشان

MEI در پنجره زمانی سپتامبر-اکتبر و جولای-اگوست (میانگین دو ماهه MEI) و کمترین مقدار  $\tau$  کندال و  $\rho$  اسپیرمن بین ناهنجاری بارش با نمایه‌های دورپیوند اقیانوس اطلس یعنی AO، NAO و AMO بدست آمد. در کل نمایه‌های اقیانوس آرام، دارای مقادیر ضرایب وابستگی بالاتری نسبت به نمایه‌های دور پیوند اقیانوس اطلس هستند. در این رابطه، بیشتر محققان نیز، عامل مؤثر بر بارش ایران را الگوی جوی-اقیانوسی انسو می‌دانند (Ahmadi, 2014). همچنین این نتیجه با نتایج پژوهش Modaresi et al. (2015) و Fatehi Marj et al. (2006) همسو می‌باشد. مدل‌های دو متغیره با حروف M و با اعداد اختصاص یافته به هر نمایه دورپیوند مشخص شدند که در تحلیل‌های انجام شده از نام مخفف استفاده شد.

بیش‌ترین فراوانی در مقادیر با ضریب وابستگی بالا در نمایه AO نیز در پنجره زمانی ۶ ماهه به دست آمده است (نتایج آورده نشده است). با بررسی انجام شده، نمایه MEI به‌عنوان معتبرترین نمایه انسو و نمایه‌های AO، NAO و AMO (مربوط به فشار جوی بین ناحیه قطبی و عرض‌های میانی)، SOI و NINO3.4 در پنجره‌های زمانی مؤثر و دارای وابستگی معنی‌دار، به‌عنوان متغیرهای پیشگو مدل پیش‌بینی بارش فصل پاییز انتخاب شدند.

در جدول (۴)، بیش‌ترین مقدار ضریب وابستگی کندال و اسپیرمن برای متغیرهای پیشگو منتخب به‌منظور مقایسه و تعیین مؤثرترین نمایه (بالاترین مقدار ضریب وابستگی) آورده شده است. همانطور که مشاهده می‌شود بیش‌ترین مقدار هر دو ضریب وابستگی، بین ناهنجاری بارش با نمایه دور پیوند

جدول ۴- مقدار ضرایب وابستگی رتبه‌ای کندال و اسپیرمن و مقدار P بین میانگین ناهنجاری بارش OND با نمایه‌های اقلیمی  
Table 4 Rank-based correlation coefficients and p-value of Kendall's tau and Spearman's rho between climate indices and average OND precipitation anomaly

P-value	Spearman's rho	P-value	Kendall's tau	Teleconnection Index	Model Name
0.0001	0.64	0.0001	0.49	MEI (SO)	M1
0.0002	0.61	0.0002	0.48	MEI (JA)	M2
0.003	0.51	0.006	0.35	NAO (AM)	M3
0.007	0.47	0.006	0.35	AO (FMAMJJ)	M4
0.0002	0.62	0.0004	0.45	NINO (JAS)	M5
0.003	0.51	0.002	0.38	AO (AMJ)	M6
0.008	0.47	0.01	0.32	NAO (MAMJ)	M7
0.0004	0.60	0.0007	0.43	NAO (JFMAM)	M8
0.0003	-0.61	0.0002	-0.47	SOI (JAS)	M9
0.06	-0.33	0.04	-0.25	AMO (MJJ)	M10

توزیع کناری برای ناهنجاری بارش انتخاب شد (جدول ۵). برای متغیرهای پیشگوی منتخب، از بین توزیع‌های مختلف، توزیع مقادیر فرین تعمیم یافته ( $GEV^1$ ) برای AO، تابع توزیع لوگ نرمال برای NINO3.4 و برای سایر متغیرهای پیشگو (MEI، NAO، AO، SOI و AMO)، تابع لجستیک تعمیم یافته بهترین نتایج را نشان دادند. در مطالعات مشابه مانند Khedun et al., (2014)، از توزیع GEV و ویبول به ترتیب برای دو نمایه دورپیوند PDO و NSOI استفاده شد. Nguyen-Huy et al. (2017)، به‌منظور تدوین مدل پیش‌بینی بارش از توزیع‌های لجستیک و نرمال برای دو متغیر SOI و NTPI و از GEV، گاما و ویبول برای متغیر بارش

چندین توزیع احتمال بر مقادیر ناهنجاری بارش و نمایه‌های دورپیوند برازش داده شد و توزیع‌های مناسب با استفاده از ارزیابی گرافیکی شامل بررسی نمودارهای چگالی، CDF، Q-Q و احتمال - احتمال (P-P) بررسی و بهترین توزیع کناری بر مبنای آزمون کلموگوروف-اسمیرنوف (K-S) (Kolmogorov, 2013)، آزمون آندرسون-دارلینگ (Scholz & Stephens, 1987) و معیار اطلاعاتی آکائیک (AIC) (Akaike, 1974) انتخاب شد. در بررسی انجام شده برای متغیر بارش، توزیع‌های نرمال و لجستیک دارای مقدار p بیش از سطح معنی‌داری ( $\alpha=0.05$ ) بودند. با استفاده از آزمون‌های نیکویی برازش، در نهایت توزیع لجستیک به‌عنوان

نواحی مختلف منطقه مورد بررسی، استفاده کردند. Dayal et al. (2020) در پژوهش خود برای NINO4 و SOI به ترتیب توزیع ویبول و لجستیک را انتخاب کردند.

جدول ۵- نتایج برازش توزیع‌های کناری (متغیرهای پیشگو و مقادیر ناهنجاری بارش) به همراه پارامترها

Table 5 Selected marginal distributions with parameters

Distribution parameters	Marginal distribution	Teleconnection Indices
loc=0.08, Scale=5.9	logistic	Precipitation anomaly OND
Scale=6.1, Loc=-0.82	logistic	MEI (OS)
loc=-0.02, scale=0.52, shape=0.95	generalized logistic	MEI (JA)
loc=-1.4, scale=0.65, shape=5.9	generalized logistic	NAO (AM)
loc=0.16, scale=0.11, shape=0.50	generalized logistic	AO (FMAMJJ)
shape = 0.18, scale = 1.36, thres = -3.98	log normal	NINO3.4(JAS)
loc=-0.04, scale=0.45, shape=1.11	generalized logistic	SOI(JAS)
Loc=-0.04, scale=0.50, shape=-0.55	GEV	AO(AMJ)
loc=0.07, scale=0.11, shape=0.68	generalized logistic	AMO(MJJ)
loc=-0.05, scale=0.33, shape=1.12	generalized logistic	NAO (MAMJ)
loc=0.46, scale=0.22, shape=0.66	generalized logistic	NAO (JFMAM)

### ۳-۳- انتخاب مفصل

دمی، در گام آخر مفصل مناسب تعیین شد. همانطور که ذکر شد از نمودارهای ترسیمی کای و کندال به منظور ارزیابی وابستگی دو متغیر تصادفی استفاده می‌شود. بررسی نشان داد همه نمودارها (به جز SOI و AMO) وابستگی مثبت متغیرهای پیشگو را با ناهنجاری بارش را نشان می‌دهند.

به منظور تولید تابع دو متغیره بر اساس قضیه اسکالر، شناسایی مفصلی که بهترین برازش را بر داده‌ها داشته باشد ضروری است. پس از بررسی و انتخاب توزیع‌های کناری و بررسی ساختار وابستگی داده‌ها و برآورد مقدار ضریب وابستگی

جدول ۶- پارامترهای مفصل،  $\tau$  کندال، بیشینه لگاریتم درست‌نمایی برای هر مفصل بین نمایه منتخب اقلیمی و میانگین ناهنجاری بارش

#### OND

Table 6 Copula parameters, Kendall's tau ( $\tau$ ), maximum log-likelihood for each copula between selected teleconnection indices and average OND precipitation anomaly

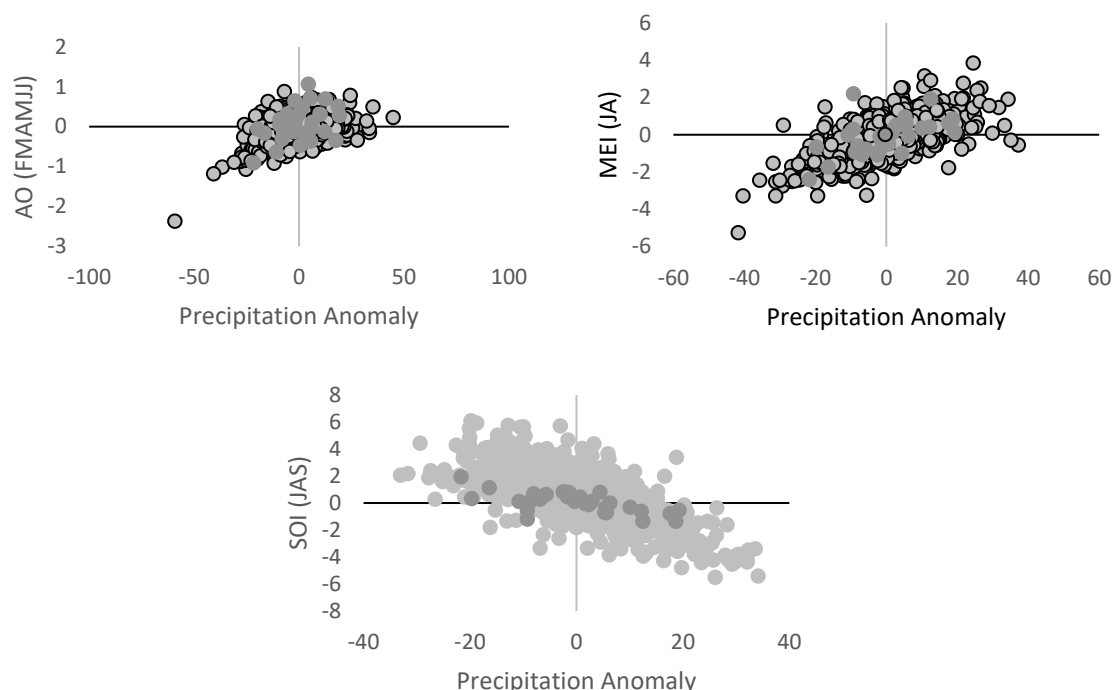
loglike	$\tau$	Parameter(s)	Selected Copula	Teleconnection Indices	Model name
8.6	0.45	Par=1.8	Gumbel(rotation=180)	MEI (JA)	M2
7.5	0.41	Par=2.2	Joe (rotation=180)	NAO (AM)	M3
3.1	0.24	Par=1.57	Joe (rotation=180)	AO (FMAMJJ)	M4
8	0.44	Par=1.58	Clayton	NINO (JAS)	M5
4.8	0.36	Par=3.7	Frank	AO (AMJ)	M6
5.3	0.36	Par=2.01	Joe (rotation=180)	NAO (MAMJ)	M7
6.7	0.42	Par=1.45	Clayton	NAO (JFMAM)	M8
8.5	-0.49	Par=-1.98	Gumbel(rotation=270)	SOI (JAS)	M9
3.4	-0.20	Par1=-3.75, par2=0.22	Tawn (rotation=90)	AMO (MJJ)	M10

صرف نظر شد (Nelsen 2006). بر اساس برخی ویژگی‌های مفصل‌ها نیز می‌توان اقدام به حذف موارد نامناسب کرد. اهمیت در نظر گرفتن وابستگی دمی بالا در انتخاب مفصل مهم است زیرا وابستگی دمی بالا به درجه وابستگی بین مقادیر فرین متغیرهای مورد بررسی بستگی دارد. در جدول ۶، مفصل‌های منتخب آورده شده است با استفاده از توزیع‌های کناری

در جدول (۶) مقادیر  $\tau$  کندال بین مقادیر بارش و نمایه‌های دور پیوند آورده شده است. با توجه به مقدار ضریب وابستگی محاسبه شده، چون ضریب وابستگی مفصل‌هایی چون علی-میخائیل-هاگ در بازه  $[-0.1817, 0.33]$  و  $\tau \in [-0.1817, 0.33]$  در بازه  $[0, 0.4184]$  قرار دارند، به جز برای نمایه‌های AMO، NAO و AO، برای سایر نمایه‌ها، از این مفصل‌ها

(وابستگی ضعیف) و M9 (وابستگی منفی قوی) ترسیم شد که قرار گرفتن داده‌های مشاهداتی در ابر داده‌های شبیه‌سازی شده (۱۰۰۰ نمونه) نشان دهنده انتخاب مفصل مناسب برای این نمایه‌ها بود.

منتخب و مفصل مناسب، شبیه‌سازی داده‌های ناهنجاری بارش انجام شد. در شکل (۳)، برای نمونه، پراکنش داده‌های مشاهداتی (نقاط تیره) در مقابل داده‌های شبیه‌سازی شده (نقاط خاکستری) سه مدل M2 (وابستگی مثبت قوی)، M4

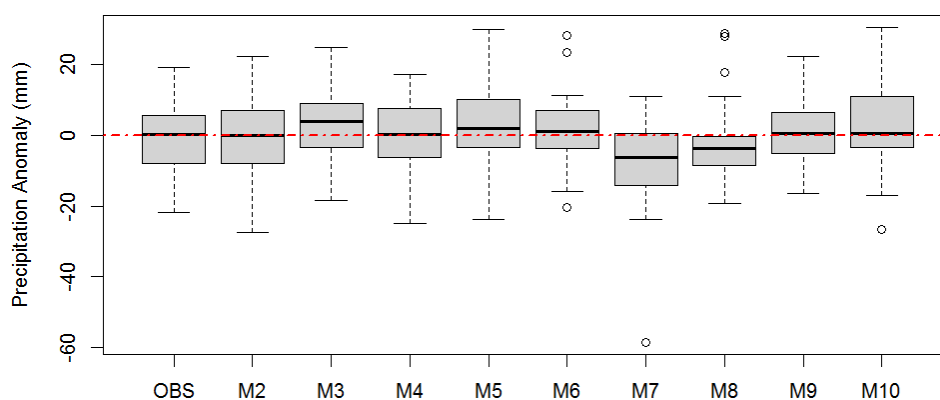


شکل ۳- مقایسه مقادیر ناهنجاری بارش پاییزه مشاهداتی در مقابل نمونه‌های ۱۰۰۰ تایی مقادیر ناهنجاری بارش پاییزه شبیه‌سازی توسط سه مدل M4، M2 تا M9

Fig. 3 Comparison of observed autumn precipitation anomalies with 1000 random samples of generated autumn precipitation anomalies using M5, M4 and M9 Models

در آن استفاده شده است. در این نمودار از جعبه، برای نمایش فاصله بین چارک اول و سوم استفاده می‌شود و خط داخل جعبه، میانه (چارک دوم) را مشخص می‌کند.

نمودار جعبه‌ای مقادیر شبیه‌سازی شده (۳۰ داده) در مقابل مقادیر مشاهداتی میانگین ناهنجاری بارش پاییز در شکل (۴) نشان داده شده است. این نمودار به منظور توصیف پراکندگی داده به کار می‌رود و از چند شاخص مرکزی و پراکندگی آماری



شکل ۴- نمودار جعبه‌ای ناهنجاری بارش شبیه‌سازی شده با استفاده از ۹ مدل دو متغیره بر مبنای مقادیر مشاهداتی

Fig. 4 Boxplot of observed and simulated OND precipitation anomaly using 9 bivariate models based on copula

مدل‌ها M2، M4 و M9 بر اساس تطابق شاخص مرکزی و توزیع داده‌ها مشخص شد. به‌منظور بررسی کارایی و اعتبارسنجی مدل‌های تبیین شده با استفاده از وارون تابع توزیع شرطی دو متغیره (رابطه ۳)، مقادیر میانگین ناهنجاری بارش برای سه سال ۲۰۲۱، ۲۰۲۲ و ۲۰۲۳ به ازای مقدار ۹ نمایه پیشگو منتخب به دست آمد که نتایج در جدول (۷) آورده شده است. با توجه به کامل نبودن سری داده‌های ماهانه بارش ایستگاه‌های همدید منطقه در زمان اجرای طرح (مهرماه ۱۴۰۲)، امکان محاسبه میانگین منطقه‌ای بارش برای پاییز ۲۰۲۳ وجود نداشت. بنابراین مقادیر موجود نشان دهنده‌ی پیش‌بینی ناهنجاری بارش پاییزه برای این سال می‌باشد.

در شکل (۴) خط خط‌چین، میانه داده‌های مشاهداتی است که به‌منظور تسهیل در مقایسه میانه‌ها ترسیم شد. با توجه به فاصله میانگین ناهنجاری بارش مشاهداتی در مقابل فاصله میانگین ناهنجاری بارش شبیه‌سازی شده توسط ۹ مدل، نتایج ضعیف در مدل‌های M3، M7 و M8 (متغیر پیشگو NAO) مشاهده شد که تفاوت بیشتری در خط میانه و فاصله اطمینان میانگین شبیه‌سازی شده توسط این سه مدل با مقادیر مشاهداتی به دست آمد. در مدل M3 (M7)، داده‌های شبیه‌سازی شده دارای میانه و دامنه تغییرات بزرگ‌تری (کم-تری) نسبت به داده‌های مشاهداتی بودند یعنی جعبه بالاتر (پایین‌تر) از جعبه داده‌های مشاهداتی قرار داشت. بهترین

جدول ۷- مقدار ناهنجاری بارش پیش‌بینی شده فصل پاییز با استفاده از مدل‌های دو متغیره مفصل

Table 7 Predicted autumn precipitation anomaly using bivariate copula models

year	Model name	Index	Value of index	Precipitation Anomaly	Mean
2021	M1	MEI-SO	-1.5	-3.4	-11.3
	M2	MEI-JA	-1.35		-10.2
	M3	NAO-AM	-1.34		-15.9
	M4	AO (FMAMJJ)	0.11		1.7
	M5	NINO3.4 (JAS)	-0.44		-2.8
	M6	AO (AMJ)	0.16		0.58
	M7	NAO (MAMJ)	-0.29		-1.6
	M8	NAO (JFMAM)	-0.58		-13.8
	M9	SOI (JAS)	0.9		-7.3
	M10	AMO (MJJ)	0.15		-13.8
2022	M1	MEI-SO	-1.71	-10.4	-14
	M2	MEI-JA	-1.79		-14.4
	M3	NAO-AM	0.18		2.9
	M4	AO (FMAMJJ)	-0.04		0.37
	M5	NINO3.4 (JAS)	-0.87		-9.3
	M6	AO (AMJ)	0.18		0.87
	M7	NAO (MAMJ)	0.25		3.3
	M8	NAO (JFMAM)	0.78		5.2
	M9	SOI (JAS)	1.1		-8.5
	M10	AMO (MJJ)	-0.03		5.2
2023	M1	MEI-SO	1.1	-	4.2
	M2	MEI-JA	-0.03		1.1
	M3	NAO-AM	0.43		-0.19
	M4	AO (FMAMJJ)	-0.12		6.4
	M5	NINO3.4 (JAS)	-0.09		-2
	M6	AO (AMJ)	1.36		-4.2
	M7	NAO (MAMJ)	-0.04		-0.7
	M8	NAO (JFMAM)	-0.48		7.6
	M9	SOI (JAS)	0.16		-0.7
	M10	AMO (MJJ)	-0.8		4.2

سال ۲۰۲۱، ۲۰۲۲ و ۲۰۲۳ برای میانگین ناهنجاری بارش پاییزه به دست آمد. نزدیکترین مقادیر پیش‌بینی شده به

بر اساس مدل پیش‌بینی بر مبنای وارون تابع توزیع شرطی، مقدار ناهنجاری بارش برای مقادیر نمایه‌های پیشگو در سه

#### ۴- نتیجه‌گیری

پیش‌بینی فصلی بارش، یکی از مؤثرترین ابزارها به‌منظور اتخاذ رهیافت‌های سازگاری و کاهش اثرات مخرب ناشی از رویدادهای حدی اقلیمی مانند خشکسالی و حمایت از توسعه استراتژی‌هایی در زمینه مدیریت خطر است. هدف از انجام پژوهش حاضر، تدوین مدلی برای پیش‌بینی بارش با استفاده از نمایه‌های دورپیوندی بر مبنای مدل‌های آماری مفصل مبنا بود که تاکنون در پژوهش‌های پیش‌بینی بارش در منطقه مورد نظر انجام نشده است. نتایج نشان داد:

۱- مقایسه ضریب وابستگی بین نمایه‌های منتخب و بارش نشان داد در کل نمایه‌های اقیانوس آرام، دارای مقادیر ضرایب وابستگی بالاتری نسبت به نمایه‌های دور پیوند اقیانوس اطلس هستند.

۲- بر اساس تطابق شاخص مرکزی و توزیع داده‌ها، بهترین مدل‌ها به منظور پیش‌بینی فصل پاییز برای این منطقه، M2، M4 و M9 بدست آمد.

۳- در مرحله اعتبارسنجی مدل‌های تدوین شده با مقدار ناهنجاری بارش سال‌های ۲۰۲۱ و ۲۰۲۲، مدل‌های دو متغیره که در آن از نمایه‌های SOI، NINO3.4 و MEI استفاده شده دارای کارایی بالاتری در شبیه‌سازی ناهنجاری بارش بودند. هر سه مدل برای سال ۲۰۲۳، ناهنجاری مثبت در بارش این منطقه را پیش‌بینی کرده‌اند.

۴- مدل NINO3.4 که بهترین برآورد ناهنجاری بارش را برای سال ۲۰۲۱ و ۲۰۲۲ به میزان  $-2/4$  mm و  $-8/5$  mm داشته است. برای بارش سال ۲۰۲۳ ناهنجاری بارش را  $6/4$  mm + برآورد کرده است.

با توجه به پیچیدگی ارتباط نمایه‌های اقلیمی با بارش و وجود وابستگی بین سایر نمایه‌های دور پیوند یا یک نمایه در پنجره‌های زمانی متفاوت با آن، می‌توان به تبیین مدل‌های آماری مفصل مبنا با ابعاد بالاتر (۳ و ۴ متغیره) پرداخت و امکان بهبود عملکرد این مدل‌ها را در پیش‌بینی بارش با افزایش تعداد متغیرهای کمکی بررسی نمود. لازم است بررسی‌هایی مشابه در مقیاس‌های زمانی ماهانه به‌منظور امکان‌سنجی کاربرد چنین مدل‌هایی در پیش‌بینی بارش در این مقیاس زمانی و همچنین پژوهش‌هایی با هدف پیش‌بینی

میانگین ناهنجاری بارش ثبت شده در منطقه شمال غرب کشور طی سال‌های ۲۰۲۱ با مدل‌های M5، M7 و M9 و برای سال ۲۰۲۲ به ترتیب توسط مدل‌های M5، M9، M1 و M2 به دست آمد. بیشترین اختلاف در برآورد میانگین ناهنجاری بارش پاییزه با مقادیر شبیه‌سازی شده برای سال‌های ۲۰۲۱ و ۲۰۲۲، در مدل‌های تدوین شده با نمایه‌های دورپیوند اقیانوس اطلس مشاهده شد. بر اساس مقادیر نمایه‌های دور پیوند که از سایت مربوطه برای سال ۲۰۲۳ به دست آمد، محاسبات انجام شد. نتایج نشان داد مدل M2 و M5 برای بارش منطقه شمال غرب کشور ناهنجاری مثبت بارش پیش‌بینی کرده‌اند این درحالی است که مدل M7 برای این منطقه مقادیر بارش کمتر از میانگین پیش‌بینی کرده است.

مطالعات مختلفی در زمینه پیش‌بینی فصلی بارش در کشور انجام شده است که بیشتر بر مبنای توسعه روش‌های آماری یا داده‌محور و یا با استفاده از برون‌داد مدل‌های دینامیکی پیش‌بینی‌های فصلی انجام شده است. در زمینه میزان دقت پیش‌بینی‌های فصلی بر اساس مدل‌های دینامیکی، Najafi et al. (2017) در ارزیابی برون‌داد مدل‌های همادی آمریکای شمالی طی یک دوره ۳۸ ساله در حوزه‌های آبخیز درجه ۶ کشور نشان دادند که مدل‌های آمریکای شمالی به خصوص در زمان انتظار صفر (ماه) مهارت قابل قبولی در پیش‌بینی بارش دارند. همبستگی ناهنجاری محاسبه شده برای این مدل‌ها در حوزه‌های آبخیز غرب کشور در فصول پربارش، بالا ارزیابی شد. به‌عنوان مثال مهارت مدل پیش‌بینی فصلی NASA (با در نظر گرفتن معیار همبستگی ناهنجاری) برای بارش فصل OND در برای حوضه شمال غرب در زمان انتظار صفر تا ۲ ماه بین ۰/۲۰ تا ۰/۵ به دست آمد که مقدار همبستگی با افزایش زمان انتظار کاهش می‌یابد. البته استفاده از تصحیح اریبی منجر به بهبود چنین پیش‌بینی‌هایی می‌شود به‌عنوان نمونه Shabanpour et al. (2021) در پژوهش خود نشان دادند روش‌های تصحیح اریبی به خوبی قادرند اریبی موجود در پیش‌بینی‌های فصل پاییز حاصل از مدل CFSv2 در حوزه آبخیز گروگانرود را کاهش دهند. در زمینه ارائه مدل‌های پیش‌بینی بارش با استفاده از روش‌های آماری، پژوهشی با ابزار مفصل انجام نشده است.

حمایت مالی صندوق حمایت از پژوهشگران انجام شده است که بدین‌وسیله از بنیاد ملی علم ایران سپاسگزاری می‌شود.

### دسترسی به داده‌ها

داده‌های این پژوهش از سازمان هواشناسی کشور و سایت‌های مربوط به نمایه‌های دور پیوند (جدول ۲) اخذ شده است.

### تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که، هیچ‌گونه تضاد منافی در رابطه با نویسندگی و یا انتشار این مقاله ندارند.

### References

- Abbasi, F., Mohammadi, H., Bazgeer, S., & Azadi, M. (2019). Estimation of the optimum cultivation date and susceptible growth stages to water stress for major areas of rain-fed wheat in Iran. *Water Irrig. Manag.*, 8(2), 268-287. DOI: [10.22059/jwim.2019.269695.647](https://doi.org/10.22059/jwim.2019.269695.647).
- Abdourahamane, Z. S., Acar, R., & Serkan, Ş. (2019). Wavelet-copula-based mutual information for rainfall forecasting applications. *Hydrol. Process.*, 33(7), 1127-1142. DOI: [10.1002/hyp.13391](https://doi.org/10.1002/hyp.13391).
- Ahmadi, M. (2014). *Analyzing the relationship between Teleconnection Patterns and the occurrence of precipitation in Iran*. Tarbiat Modares University, Iran. [In Persian].
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Trans. Autom. Control*, 19(6), 716-723. DOI: [10.1109/TAC.1974.1100705](https://doi.org/10.1109/TAC.1974.1100705).
- Akhlaghi Yengejeh, N., Pirmoradian, N., Oji, R., & Ashrafzadeh, A. (2021). Performance evaluation of the penalized maximal T and F algorithms in the quality control of monthly and daily climatic time series on the southwest coast of the Caspian Sea. *Geogr. Stud. Coastal Areas J.*, 2(3), 53-77. DOI: [10.22124/gscj.2021.20765.1116](https://doi.org/10.22124/gscj.2021.20765.1116).
- Batani, M. M., Behmanesh, J., Bazrafshan, J., Rezaie, H., & De Michele, C. (2018). Simple short-term probabilistic drought prediction using Mediterranean teleconnection information. *Water Resour. Manage.*, 32(13), 4345-4358. DOI: [10.1007/s11269-018-2056-8](https://doi.org/10.1007/s11269-018-2056-8).

سایر متغیرها مانند دما با استفاده از روش به‌کار رفته انجام پذیرد. از جمله محدودیت‌های این پژوهش، عدم دسترسی به داده‌های بارش با دوره آماری طولانی‌تر بود که در صورت موجود بودن این سری داده، تدوین مدلی با دقت بالاتر میسر خواهد بود.

### سپاسگزاری

این مقاله مستخرج از طرح پژوهشی با عنوان "ارزیابی کارایی مدل‌های آماری مفصل- مینا مبتنی بر نمایه‌های دور پیوند در پیش‌بینی بارش (مطالعه موردی: شمال غرب ایران)" که با

- Brechmann, E. C., & Schepsmeier, U. (2013). Modeling dependence with C- and D-vine copulas: the R package CDVine. *J. Statis. Software*, 52(3), 1-27. DOI: [10.18637/jss.v052.i03](https://doi.org/10.18637/jss.v052.i03).
- Dayal, K. S., Deo, R. C., & Apan, A. A. (2020). Development of copula-statistical drought prediction model using the standardized precipitation-evapotranspiration index. In *Handbook of Probabilistic Models* (pp. 141-178). Butterworth-Heinemann. DOI: [10.1016/B978-0-12-816514-0.00006-0](https://doi.org/10.1016/B978-0-12-816514-0.00006-0).
- Dostan, R. (2018). World teleconnection and regional teleconnections of Iran. *J. Earth Space Phys.*, 44(3), 625-640. DOI: [10.22059/jesphys.2018.238493.1006920](https://doi.org/10.22059/jesphys.2018.238493.1006920).
- Espinosa, L. A., Portela, M. M., Pontes Filho, J. D., & Zelenakova, M. (2021). Bivariate modelling of a teleconnection index and extreme rainfall in a small north Atlantic Island. *Climat.*, 9(5), 86. DOI: [10.3390/cli9050086](https://doi.org/10.3390/cli9050086).
- Farajnia, A., & Moravej, K. (2020). Agro climatic zoning of saffron culture in east Azarbaijan Province. *J. Saffron Res.*, 7(2), 251-267. DOI: [10.22077/jsr.2018.1445.1057](https://doi.org/10.22077/jsr.2018.1445.1057).
- Fatehi Marj, A., Borhani Darian, M., & Mahdian H. (2006). Forecasting seasonal rainfall using teleconnection pattern case Study: Orumiyeh Lake Basin. *J. Crop Product. Process.*, 10(3), 45-58 [In Persian].
- Frotan, M., & Salahi, B. (2023). Climatic zoning of Ardabil province using multivariate methods. *J. Environ.l Sci. Stud.*, 8(1), 6238-6247 [In Persian], DOI: [10.22034/jess.2022.369206.1903](https://doi.org/10.22034/jess.2022.369206.1903).

- Ghaemi, H., Zarin, A., & Khoshakhlagh, F. (2012). *Climatology of Arid Regions*. Publisher: SAMT. 8<sup>th</sup> Print Publication: 2014. 432 pp.
- Ghavidel Rahimi, Y., Farajzadeh Asl, M., & Kakapor, S. (2014). Investigation on North Sea-Caspian Teleconnection Pattern Effect on Autumn Rainfall Fluctuations in West and Northwest Regions of Iran. *Geogra. Plan.*, 18(49), 217-230 [In Persian].
- Jung, J., & Kim, H. S. (2022). Predicting temperature and precipitation during the flood season based on teleconnection. *Geosci. Lett.*, 9(1), 4. DOI: [10.1186/s40562-022-00212-3](https://doi.org/10.1186/s40562-022-00212-3).
- Khedun, C. P., Mishra, A. K., Singh, V. P., & Giardino, J. R. (2014). A copula-based precipitation forecasting model: Investigating the interdecadal modulation of ENSO's impacts on monthly precipitation. *Water Resour. Res.*, 50(1), 580-600. DOI: [10.1002/2013WR013763](https://doi.org/10.1002/2013WR013763).
- Kolmogorov, A. N. (2013). *Foundations of the theory of probability*: Martino Fine Books, Connecticut.
- Madadgar, S., AghaKouchak, A., Shukla, S., Wood, A. W., Cheng, L., Hsu, K. L., & Svoboda, M. (2016). A hybrid statistical-dynamical framework for meteorological drought prediction: application to the southwestern United States. *Water Resour. Res.*, 52(7), 5095-5110. DOI: [10.1002/2015WR018547](https://doi.org/10.1002/2015WR018547).
- Mai, J. F., & Scherer, M. (2017). *Simulating copulas: stochastic models, sampling algorithms, and applications*, 2<sup>nd</sup> Edition (Series in Quantitative Finance, 6). DOI: [10.1142/10265](https://doi.org/10.1142/10265).
- Maity, R., Chanda, K., Dutta, R., Ratnam, J. V., Nonaka, M., & Behera, S. (2020). Contrasting features of hydroclimatic teleconnections and the predictability of seasonal rainfall over east and west Japan. *Meteorol. Appl.*, 27(1), e1881. DOI: [10.1002/met.1881](https://doi.org/10.1002/met.1881).
- Mirhashemi, H., & Hasanvand, Z. (2023). The effect of teleconnection patterns on monthly rainfall in Khorram Abad and Kermanshah stations. *Water Soil Manage. Model.*, 3(4), 133-151. [In Persian]. DOI: [10.22098/mmws.2022.11702.1159](https://doi.org/10.22098/mmws.2022.11702.1159).
- Mirzayi Hasanlo, A., Abghari, H., & Erfanian, M. (2020). Spatial distribution of daily and monthly rainfall concentration indicators in rain gauge stations of West Azerbaijan Province. *Exten. Develop. Watershed Manage.*, 8(30), 44-56 [In persian].
- Modaresi, F., Araghinejad, S., Ebrahimi, K. (2015). Assessment of model fusion strategy for increasing the accuracy of autumn rainfall forecasting. *J. Agri. Meteorol.*, 3(2), 1-13 [In persian].
- Najafi, H., Massah Bavani, A., Irannejad, P., & Robertson, A. (2017). Application of North American multi-model ensemble for Iran's seasonal precipitation forecasts. *Iran Water Resour. Res.*, 13(4), 28-38 [In persian].
- Nelsen, R.B. (2006). *An introduction to copulas*. Springer. 3<sup>th</sup> edition, New York. 269 pp.
- Nguyen-Huy, T., C Deo, R., Mushtaq, Sh., An-Vo, D. A., & Khan, Sh. (2018), Modeling the joint influence of multiple synoptic- scale, climate mode indices on Australian wheat yield using copula-based approach, *Europ. J. Agron.*, 98, 65-81. DOI: [10.1016/j.eja.2018.05.006](https://doi.org/10.1016/j.eja.2018.05.006).
- Nguyen-Huy, T., Deo, R. C., An-Vo, D. A., Mushtaq, S., & Khan, S. (2017). Copula-statistical precipitation forecasting model in Australia's agro-ecological zones. *Agri. Water Manage.*, 191, 153-172. DOI: [10.1016/j.agwat.2017.06.010](https://doi.org/10.1016/j.agwat.2017.06.010).
- Nourani, V., Sattari, M. T., & Molajou, A. (2016). Long-Led precipitation forecasting in Urmia synoptic station by sea surface temperatures of the Black, Mediterranean and Red Seas. One-day Joint Workshop-cum-Seminar on Soft Computing Methods in Water Resources Engineering. Nicosia. ITU-North Cyprus [In Persian].
- Saligheh, M., (2017). *Synoptic Climatology of Iran*. Publisher: SAMT. 280 pp.
- Scholz, F. W., & Stephens, M. A. (1987). K-sample Anderson-Darling tests. *J. Am. Statis. Assoc.*, 82(399), 918-924. DOI: [10.1080/01621459.1987.10478517](https://doi.org/10.1080/01621459.1987.10478517).
- Shabanpour, F., Bazrafshan, J., & Araghinejad, S. (2021). Evaluation of the effect of bias correction methods on the skill of seasonal

- precipitation forecasts of CFSv2 climate model. *Iran. J. Soil Water Res.*, 51(12), 3017-3032. DOI: [10.22059/ijswr.2020.306717.668680](https://doi.org/10.22059/ijswr.2020.306717.668680).
- Sklar, A. (1959). Distribution functions of n dimensions and margins. *Publications of the Institute of Statistics of the University of Paris*, 8, 229-231. [In French].
- Szentimrey, T., Hoffmann, L., & Lakatos, M. (2017). Abstract book. 9<sup>th</sup> Seminar for Homogenization and Quality Control in Climatological Databases and 4th Conference on Spatial Interpolation Techniques in Climatology and Meteorology. DOI: [10.21404/9.SemHQC4.ConfSI.2017](https://doi.org/10.21404/9.SemHQC4.ConfSI.2017).
- Wang, X. L. (2008). Penalized maximal F-test for detecting undocumented mean-shifts without trend-change. *J. Atmos. Oceanic Tech.*, 25(3), 368-384. DOI: [10.1175/2007JTECHA982.1](https://doi.org/10.1175/2007JTECHA982.1).
- Xie, Y., Liu, S., Fang, H., Ding, M., & Liu, D. (2022). A study on the precipitation concentration in a Chinese region and its relationship with teleconnections indices. *J. Hydrol.*, 612, 128203. DOI: [10.1016/j.jhydrol.2022.128203](https://doi.org/10.1016/j.jhydrol.2022.128203).
- Yanto, Rajagopalan, B., & Regonda, S. K. (2023). Linear and copula model for understanding climate drivers of hydroclimatic extremes: a case study of Serayu river basin, Indonesia. *Acta Geophys.*, 1-12. DOI: [10.1007/s11600-023-01078-5](https://doi.org/10.1007/s11600-023-01078-5).