



Modeling the Functional Relationship of Cumulative Precipitation in Eastern Iranian Stations with Spatio-Temporal Variables using a Hybrid Machine Learning Approach

Mozaffar Faraji,¹ Mohammad Mirzavand,^{2*}

1. PhD Student, Department of Climatology, University of Tabriz, Tabriz, Iran; Email: mozaffar.faraji@tabrizu.ac.ir

2. Assistant Professor, Department of Environmental Sciences and Technologies, Faculty of Energy Engineering and Sustainable Resources, University of Tehran, Tehran, Iran.; Email: MMirzavand@ut.ac.ir

Article Info	ABSTRACT
<p>Article type: Research Article</p> <p>Article history: Received 10 October, 2025 Revised 22 November, 2025 Accepted 14 December, 2025 Available online 22 December, 2025</p> <p>Keywords: Precipitation modeling, Machine learning, Ward's clustering, EasternIran, Temporal variability, Precipitation.</p>	<p>Subject: Analyzing and modeling the spatio-temporal pattern of cumulative precipitation at synoptic stations in eastern Iran using hybrid machine learning approaches.</p> <p>Objective: The objective of this study is to explain and model the functional relationship between cumulative precipitation at stations in eastern Iran and spatio-temporal variables, aiming to identify dominant weather-related structures and spatial heterogeneity of precipitation through a hybrid machine learning approach.</p> <p>Research Method: In this study, 24-hour cumulative precipitation data ($P_{(24)}$) from 21 synoptic stations located in eastern Iran, including the provinces of Sistan and Baluchestan, South Khorasan, Razavi Khorasan, and North Khorasan, were used for the period 1990–2020. The functional relationship between cumulative precipitation as the dependent variable and monthly temporal variations as the independent variable was evaluated using an estimated linear regression function. To analyze the spatial structure, the stations were classified based on cumulative precipitation data using hierarchical clustering according to Ward's distance criterion.</p> <p>Findings: The results of the linear regression analysis indicated that the adjusted coefficient of determination (Adjusted R^2) was estimated at 0.64. This index demonstrates that the temporal predictor variable (months) was able to explain approximately 64.8% of the variance in the response variable (precipitation amount). Hierarchical cluster analysis identified three distinct climatic zones, including an arid and desert cluster, a semi-arid and transitional cluster, and a humid cluster. Among these, the Quchan station, with the highest mean cumulative precipitation (26.80 mm), emerged as a prominent precipitation hotspot. Overall, these findings indicate the presence of significant spatial variability and highlight the prominent role of temporal fluctuations in shaping precipitation patterns in eastern Iran.</p> <p>Conclusions: The results demonstrate that the hybrid machine learning approach effectively models the spatio-temporal structure of precipitation in eastern Iran and clearly reveals regional weather-related heterogeneities. These findings provide a scientific basis for water resources management and planning in the arid and semi-arid regions of eastern Iran.</p>

Cite this article: Faraji, M., Mirzavand, M. (2026). Modelling the Functional Relationship of Cumulative Precipitation in Eastern Iranian Stations with Spatio-Temporal Variables using a Hybrid Machine Learning Approach. *Journal of ECOHYDROLOGY*, 12(4), 1005-1024. <https://doi.org/10.22059/ije.2026.410789.1906>



© Mozaffar Faraji, Mohammad Mirzavand.

Publisher: University of Tehran Press.

DOI: <https://doi.org/10.22059/ije.2026.410789.1906>

Introduction

Precipitation is a key hydro-meteorological variable controlling water resources, ecosystem stability, and socio-economic activities, particularly in arid and semi-arid regions. Eastern Iran is characterized by strong spatial and temporal rainfall variability due to complex topography, elevation contrasts, and the interaction of different atmospheric circulation systems, including Mediterranean disturbances, monsoonal flows, and local orographic effects. These factors lead to pronounced heterogeneity in rainfall regimes, posing significant challenges for water resource management, drought mitigation, and flood risk reduction.

Conventional rainfall analyses based on regional averaging or single-station statistics often fail to capture the nonlinear behavior and spatial discontinuities of precipitation. Recent advances in data-driven and hybrid modeling approaches have provided new opportunities to better describe spatio-temporal rainfall variability. In this context, integrating statistical methods with machine learning concepts can improve the identification of hidden spatial structures and temporal controls governing precipitation patterns. Analysis of 24-hour cumulative rainfall ($P_{(24)}$) is particularly important, as it is closely linked to extreme hydrological events and short-term water availability. This study therefore applies a hybrid analytical framework to investigate the functional relationship between cumulative rainfall and spatio-temporal variables across eastern Iran.

Research Method

This study analyzes long-term 24-hour cumulative rainfall ($P_{(24)}$) data from 21 synoptic meteorological stations in eastern Iran for the period 1990–2020. The stations cover four provinces—Sistan and Baluchestan, South Khorasan, Razavi Khorasan, and North Khorasan—providing comprehensive spatial and climatic representation. Station elevations range from 8 m at Chabahar to 1,491 m at Birjand, allowing assessment of topographic and orographic influences on rainfall variability.

In Sistan and Baluchestan Province, the stations include Zabol, Zahedan, Iranshahr, Khash, Saravan, and Chabahar. South Khorasan is represented by Nahbandan, Ferdows, Qaen, Boshrouyeh, Birjand, and Tabas. Razavi Khorasan includes Sabzevar, Torbat-e Heydarieh, Quchan, Sarakhs, Gonabad, Mashhad, Kashmar, and Golmakan, while Bojnord represents North Khorasan. Prior to analysis, data preprocessing was conducted, including removal of missing values, error checking, and normalization to ensure data consistency.

Hierarchical cluster analysis using Ward's linkage method and a distance-based criterion was applied to identify spatial similarity and rainfall regimes among stations. One-way analysis of variance (ANOVA) was employed to test for statistically significant differences in mean cumulative rainfall between stations. To evaluate temporal variability and monthly effects, linear regression analysis was conducted, supported by the adjusted coefficient of determination (Adjusted R^2) and the F-test. This integrated framework enabled simultaneous assessment of spatial heterogeneity and temporal controls on rainfall variability.

Findings

Results of Analysis of Variance

One-way ANOVA results indicate statistically significant differences among the mean 24-hour cumulative rainfall values of the studied stations ($P < 0.05$). Accordingly, the null hypothesis of equal mean rainfall across stations is rejected, confirming strong spatial heterogeneity in rainfall characteristics across eastern Iran. This finding highlights the limitations of uniform regional rainfall models and emphasizes the need for location-specific approaches in rainfall simulation and prediction.

Results of Station Clustering Based on Cumulative Rainfall

Hierarchical clustering revealed distinct spatial rainfall patterns and classified the study area into three major zones. The first cluster represents dry and desert regions, including stations such as Zabol, Zahedan, Tabas, Boshrouyeh, Iranshahr, Saravan, and Nahbandan. The second cluster corresponds to semi-arid and transitional regions, comprising stations such as Chabahar, Ferdows, Gonabad, Birjand, Khash, Sabzevar, Kashmar, and Sarakhs. The third cluster represents relatively humid or high-rainfall

regions located mainly in northern and northeastern parts of the study area, including Mashhad, Torbat-e Heydarieh, Bojnord, Golmakan, and Quchan.

At the final clustering level, Quchan station formed a distinct cluster due to its highest mean cumulative rainfall (26.80 mm), reflecting its unique climatic position influenced by orographic effects and synoptic rainfall systems. These results provide valuable insight into the spatial organization of rainfall regimes in eastern Iran.

Results of Linear Regression Analysis

Linear regression analysis shows an Adjusted R^2 value of 0.648, indicating that approximately 64.8% of rainfall variance is explained by monthly temporal variability. The associated F-test is statistically significant ($P < 0.05$), confirming a meaningful relationship between time and rainfall. These results demonstrate the dominant role of seasonal and monthly variations in controlling rainfall dynamics across the region

Conclusion

The results of this study demonstrate that 24-hour cumulative rainfall in eastern Iran exhibits complex and highly heterogeneous spatial and temporal patterns. Significant differences among stations confirmed by ANOVA highlight the importance of local and micro-scale characteristics in rainfall modeling. Hierarchical clustering identified three major rainfall regimes—dry, semi-arid transitional, and relatively humid—each governed by distinct geographical and atmospheric controls.

Furthermore, regression analysis emphasizes the strong influence of temporal variability, particularly at the monthly scale, on rainfall behavior. Integrating spatial and temporal analyses indicates that effective water resource management in eastern Iran requires region-specific, data-driven approaches sensitive to both spatial heterogeneity and seasonal dynamics. Overall, this study provides a robust scientific basis for improving rainfall prediction models, supporting drought and flood risk management, and enhancing sustainable water resource planning in eastern Iran.

Conflict of Interest

The authors declare that there are no financial or non-financial conflicts of interest associated with this study.

Ethical Considerations

The authors adhered to principles of scientific integrity and transparency and avoided any form of data manipulation or misconduct.

Acknowledgments

The authors sincerely acknowledge the Iran Meteorological Organization for providing the meteorological data used in this research.

مدل سازی رابطه تابعی بارش تجمعی ایستگاه های شرق ایران با متغیرهای فضایی - زمانی با

رویکرد هیبریدی مبتنی بر یادگیری ماشین

مظفر فرجی،^۱ محمد میرزاوند،^۲۱. دانشجوی دکتری، گروه آب‌هواشناسی، دانشگاه تبریز، تبریز، ایران. رایانامه: mozaffar.faraji@tabrizu.ac.ir۲. استادیار، گروه علوم و فناوری‌های محیطی، دانشکده مهندسی انرژی و منابع پایدار، دانشگاه تهران، ایران. رایانامه: MMirzavand@ut.ac.ir

چکیده	اطلاعات مقاله
<p>موضوع: بررسی و مدل‌سازی الگوی فضایی - زمانی بارش تجمعی در ایستگاه‌های سینوپتیک شرق ایران با بهره‌گیری از رویکردهای ترکیبی یادگیری ماشین.</p> <p>هدف: هدف این پژوهش، تبیین و مدل‌سازی رابطه تابعی بارش تجمعی ایستگاه‌های شرق ایران با متغیرهای فضایی و زمانی به منظور شناسایی ساختارهای غالب آب‌هوایی و ناهمگنی‌های مکانی بارش، با استفاده از یک رویکرد هیبریدی مبتنی بر یادگیری ماشین است.</p> <p>روش تحقیق: در این پژوهش از داده‌های بارش تجمعی ۲۴ ساعته (P₍₂₄₎) مربوط به ۲۱ ایستگاه سینوپتیک واقع در شرق ایران، شامل استان‌های سیستان و بلوچستان، خراسان جنوبی، خراسان رضوی و خراسان شمالی، طی سال‌های ۱۹۹۰ تا ۲۰۲۰ استفاده شد. رابطه تابعی بارش تجمعی به عنوان متغیر وابسته با تغییرات زمانی ماهانه به عنوان متغیر مستقل با بهره‌گیری از تابع تخمینی رگرسیون خطی مورد ارزیابی قرار گرفت. به منظور تحلیل ساختار فضایی، ایستگاه‌ها با استفاده از خوشه‌بندی سلسله‌مراتبی و بر اساس معیار فاصله در مدل وارد، بر مبنای داده‌های بارش تجمعی طبقه‌بندی شدند.</p> <p>یافته‌ها: نتایج تحلیل رگرسیون خطی داده‌ها نشان داد مقدار ضریب تعیین تعدیل‌شده (Adjusted R²) برابر با ۰/۶۴ برآورد شده است. این شاخص بیانگر آن است که متغیر پیش‌بین زمانی (ماه‌ها) توانسته است حدود ۶۴/۸ درصد از واریانس متغیر ملاک (مقدار بارش) را تبیین کند. تحلیل خوشه‌بندی سلسله‌مراتبی، سه ناحیه آب‌هوایی متمایز شامل خوشه خشک و بیابانی، خوشه نیمه‌خشک و انتقالی و خوشه پربارش را شناسایی کرد. در این میان، ایستگاه قوچان با بیشترین میانگین بارش تجمعی (۲۶/۸۰ میلی‌متر) به عنوان یک کانون شاخص بارشی برجسته شد. این نتایج بیانگر وجود تفاوت‌های مکانی معنا دار و نقش برجسته نوسانات زمانی در الگوی بارش شرق ایران است.</p> <p>نتیجه‌گیری: نتایج این پژوهش نشان داد رویکرد هیبریدی مبتنی بر یادگیری ماشین توانایی مناسبی در مدل‌سازی ساختار فضایی - زمانی بارش در شرق ایران دارد و وجود ناهمگنی‌های آب‌هوایی منطقه را به خوبی آشکار می‌سازد. این یافته‌ها می‌تواند به عنوان مبنایی علمی برای مدیریت و برنامه‌ریزی منابع آب در مناطق خشک و نیمه‌خشک شرق کشور مورد استفاده قرار گیرد.</p>	<p>نوع مقاله: مقاله پژوهشی</p> <p>تاریخ دریافت: ۱۴۰۴/۰۷/۱۸</p> <p>تاریخ بازنگری: ۱۴۰۴/۰۹/۰۱</p> <p>تاریخ پذیرش: ۱۴۰۴/۰۹/۲۳</p> <p>تاریخ انتشار: ۱۴۰۴/۱۰/۰۱</p> <p>کلیدواژه‌ها: مدل‌سازی بارش، یادگیری ماشین، خوشه‌بندی وارد، شرق ایران، تغییرات زمانی، کانون بارشی.</p>

استناد: فرجی، مظفر؛ میرزاوند، محمد. مدل‌سازی رابطه تابعی بارش تجمعی ایستگاه‌های شرق ایران با متغیرهای فضایی-زمانی با رویکرد هیبریدی مبتنی بر یادگیری

ماشین. مجله اکوهیدرولوژی، ۱۲(۴)، ۱۰۰۵-۱۰۲۴.

<https://doi.org/10.22059/ije.2026.410789.1906>

ناشر: انتشارات دانشگاه تهران. © مظفر جعفری، محمد میرزاوند.



مقدمه

تغییرات آب‌وهوایی به عنوان یکی از چالش‌های اصلی قرن بیست‌ویکم، با ایجاد دگرگونی در الگوهای زمانی و مکانی بارش، پیامدهای قابل توجهی برای مدیریت منابع آب، به‌ویژه در مقیاس شهری، به همراه داشته است. افزایش فراوانی رخداد‌های حدی، نوسانات نامنظم بارندگی و عدم قطعیت در پیش‌بینی‌های اقلیمی، ضرورت شناخت دقیق تغییرات آبی بارش و ارزیابی آن تحت سناریوهای مختلف اقلیمی را دوچندان کرده است. در این میان، اگرچه مدل‌های گردش عمومی جو ابزارهای اصلی شبیه‌سازی اقلیم آینده محسوب می‌شوند، اما به دلیل تفکیک مکانی درشت، توان محدودی در بازنمایی دقیق بارش در مقیاس محلی دارند. از این‌رو، به‌کارگیری روش‌های ریزمقیاس‌نمایی، به‌ویژه برای متغیری مانند بارش که ماهیتی غیرخطی و ناهمگن دارد، اهمیت ویژه‌ای یافته است. طی سال‌های اخیر، الگوریتم‌های یادگیری ماشین به دلیل توانایی بالا در مدل‌سازی روابط پیچیده میان متغیرهای اقلیمی، به عنوان رویکردهای کارآمد در ریزمقیاس‌نمایی بارش مورد توجه قرار گرفته‌اند (المزروعی و همکاران، ۲۰۲۲). مطالعات پیشین نشان می‌دهند روش‌هایی نظیر ماشین بردار پشتیبان و شبکه‌های عصبی مصنوعی، در مقایسه با مدل‌های آماری کلاسیک، دقت بیشتری در شبیه‌سازی بارش ماهانه و بازنمایی الگوهای کلی بارندگی در مقیاس محلی دارند (داونپورت و دیفنبا، ۲۰۲۱؛ هو و همکاران، ۲۰۱۹؛ ساچیندرا و همکاران، ۲۰۱۸؛ المزروعی و همکاران، ۲۰۲۲). با این حال، شبیه‌سازی بارش روزانه و رخداد‌های حدی همچنان با عدم قطعیت همراه بوده و بهبود آن مستلزم تلفیق الگوریتم‌های یادگیری ماشین با روش‌های اصلاح آماری نظیر نگاهشت چارکی است. افزون بر این، نتایج پژوهش‌ها نشان می‌دهد برآورد روندهای آینده بارش به نوع الگوریتم ریزمقیاس‌نمایی و مدل اقلیمی مورد استفاده وابستگی زیادی دارد؛ موضوعی که ضرورت استفاده از رویکردهای چندمدلی و سناریومحور را برجسته می‌سازد (جهانگیری و همکاران، ۲۰۲۵). در مجموع، بهره‌گیری از چارچوب‌های سناریومحور تغییر اقلیم و تلفیق آن‌ها با الگوریتم‌های پیشرفته یادگیری ماشین، می‌تواند مبنای علمی معتبری برای پیش‌بینی دقیق‌تر بارش و تدوین راهبردهای سازگاری و مدیریت پایدار منابع آب فراهم آورد (شم و همکاران، ۲۰۲۵). با توجه به اقلیم خشک و نیمه‌خشک شرق ایران و وابستگی شدید سامانه‌های طبیعی و انسانی این منطقه به بارش‌های محدود و نامنظم، مدل‌سازی دقیق رفتار بارش تجمعی در مقیاس ایستگاهی - استانی از اهمیت ویژه‌ای برخوردار است (علیزاده، ۱۴۰۱). پیچیدگی روابط میان بارش، متغیرهای فضایی - زمانی و سامانه‌های گردشی غالب، موجب شده است که رویکردهای کلاسیک آماری به‌تنهایی پاسخ‌گوی نیازهای مدیریتی و برنامه‌ریزی منابع آب نباشند. از این‌رو، ضرورت توسعه چارچوب‌های نوین مدل‌سازی که قادر به تبیین روابط غیرخطی و چندبعدی باشند، بیش از پیش احساس می‌شود. نوآوری اصلی این پژوهش در مدل‌سازی رابطه تابعی بارش تجمعی ایستگاه‌های شرق ایران با متغیرهای فضایی - زمانی، با استفاده از یک رویکرد هیبریدی مبتنی بر یادگیری ماشین نهفته است؛ رویکردی که با تلفیق توان الگوریتم‌های یادگیری ماشین و تحلیل فضایی - زمانی داده‌های ایستگاهی - استانی، می‌تواند عدم قطعیت پیش‌بینی‌ها را کاهش دهد و مبنای علمی قابل اتکایی برای مدیریت پایدار منابع آب و مطالعات اکوهیدرولوژیک در شرایط تغییر اقلیم فراهم آورد.^۱

پیشینه پژوهش

به منظور درک عمیق‌تر الگوهای بارش و ارزیابی کارایی روش‌های آماری و یادگیری ماشین در تحلیل و پیش‌بینی آن، مطالعات متعددی در مقیاس‌های مکانی و زمانی مختلف انجام شده است. این پژوهش‌ها نقش مهمی در تبیین پیچیدگی‌های رفتاری بارش و کاهش عدم قطعیت‌های مرتبط با پیش‌بینی‌های هیدرولوژیکی ایفا کرده‌اند. در پژوهشی مرتبط، فرجی و همکاران (۲۰۲۵: ۱۴۵) به بررسی و پیش‌بینی بارش تجمعی ۲۴ ساعته در ایران با استفاده از الگوریتم‌های یادگیری ماشین، شامل شبکه عصبی پرسپترون چندلایه MLP و درخت تصمیم پرداختند. در این مطالعه، داده‌های بارش روزانه پس از نرمال‌سازی، با استفاده از مدل MLP با تابع فعال‌سازی سیگموئید و درخت تصمیم مبتنی بر معیار آنتروپی مدل‌سازی شدند. نتایج پژوهش یادشده نشان داد مدل MLP با مقدار

1. Al-Mazroui
2. Davenport
3. Hu
4. Sachindra
5. Shim

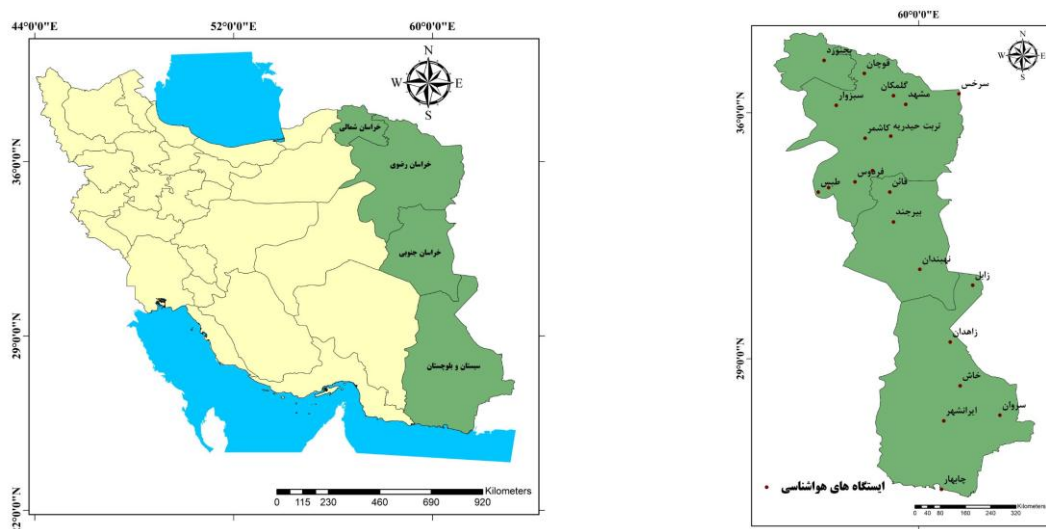
خطای میانگین مربعات $0/04$ عملکرد مناسبی در تخمین بارش ماهانه دارد و تحلیل درخت تصمیم نیز به خوشه‌بندی استان‌ها به هفت ناحیه‌ی بارشی منجر شد که اطلاعات ارزشمندی از توزیع مکانی بارش ارائه می‌دهد. همچنین، نتایج رگرسیون خطی بیانگر تأثیر معنادار عامل زمان بر واریانس بارش با ضریب $0/209$ بود. این پژوهش بر کارایی بالای روش‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی، در تحلیل داده‌های هیدرولوژیکی ایران تأکید دارد. در حوزه‌ی تغییرات اقلیمی، مطالعات متعددی تأثیر این پدیده را بر الگوهای بارش نشان داده‌اند. به عنوان نمونه، ساداتی‌نژاد و همکاران (۲۰۲۴) با استفاده از مدل CanESM2 تحت سناریوهای مختلف RCP، تغییرات اقلیمی ایستگاه کرج را شبیه‌سازی کرده و کاهش قابل توجه بارندگی در دوره‌های آینده‌ی نزدیک و دور را گزارش کردند. این نتایج با یافته‌های حاصل از مدل‌های یادگیری ماشین در پیش‌بینی پارامترهای اقلیمی هم‌راستا بوده و بیانگر توان بالای این مدل‌ها در بازنمایی رفتار بارش تحت شرایط متغیر اقلیمی است. بارش به عنوان یکی از مؤلفه‌های کلیدی سامانه‌ی هیدرولوژیکی، نقشی تعیین‌کننده در مدیریت سیلاب و خشکسالی، برآورد رواناب و رسوب، و برنامه‌ریزی کشاورزی دارد. با این حال، ماهیت غیرخطی، ناپایدار و پیچیده‌ی بارش موجب شده است که مدل‌سازی آن همواره با چالش‌های اساسی همراه باشد (راجاگوپال و استیل، ۲۰۱۷). در دهه‌های اخیر، پیشرفت‌های قابل توجه در حوزه‌ی یادگیری ماشین و سیستم‌های هوشمند، امکان تحلیل داده‌های پیچیده‌ی اقلیمی را بدون نیاز به تعریف صریح روابط فیزیکی فراهم کرده است (سن، ۲۰۲۴). این الگوریتم‌ها که غالباً به عنوان روش‌های «جعبه سیاه» شناخته می‌شوند، به دلیل انعطاف‌پذیری بالا و کاهش وابستگی به فرض‌های سخت‌گیرانه‌ی آماری، نسبت به روش‌های کلاسیک برتری نشان داده‌اند (فاروق و همکاران، ۲۰۲۵). افزون بر این، الگوریتم‌های یادگیری ماشین توانایی مناسبی در مدیریت ناپایداری و نوسانات سری‌های زمانی هیدرولوژیکی دارند و می‌توانند بدون ایستاسازی کامل داده‌ها، الگوهای غالب را استخراج کنند؛ قابلیت‌هایی که در تحلیل بارش تحت تأثیر تغییرات اقلیمی اهمیت ویژه‌ای دارد (ژانگ و همکاران، ۲۰۲۵). در این راستا، مدل‌هایی نظیر درخت تصمیم، ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی و روش‌های یادگیری جمعی به طور گسترده در مطالعات هیدرولوژیکی به کار گرفته شده و کارایی بالایی آن‌ها در شبیه‌سازی متغیرهای اقلیمی گزارش شده است (شمس و همکاران، ۲۰۲۳). با وجود این، انتخاب الگوریتم مناسب، ساختار بهینه‌ی مدل و تعیین متغیرهای ورودی همچنان از چالش‌های اصلی این حوزه محسوب می‌شود و ضرورت انجام پژوهش‌های هدفمند و نظام‌مند را برجسته می‌سازد (داس و همکاران، ۲۰۲۲). از سوی دیگر، افزایش شدت و فراوانی بارش‌های حدی در نتیجه تغییرات آب‌وهوایی، مخاطرات هیدرولوژیکی قابل توجهی را در مناطق شهری ایجاد کرده است. در این میان، منحنی‌های شدت - دوام - فراوانی IDF به عنوان ابزار پایه در طراحی و ارزیابی سامانه‌های زهکشی شهری نقش کلیدی دارند؛ با این حال، بسیاری از این منحنی‌ها بر فرض ایستایی اقلیم استوار بوده‌اند که در شرایط کنونی اعتبار خود را از دست داده است (لانسیوتی و همکاران، ۲۰۲۲). در دهه‌های اخیر، مطالعات متعددی با هدف لحاظ کردن اثرات تغییر اقلیم در برآورد منحنی‌های IDF انجام شده است (سیلوا و همکاران، ۲۰۲۳؛ کورتیس و تسیرینتریس، ۲۰۲۲؛ میتی و مایتی، ۲۰۲۲؛ فیتوزا سیلوا و همکاران، ۲۰۲۱؛ حسین‌زاده‌طلایی و همکاران، ۲۰۲۰). رویکرد غالب این پژوهش‌ها بر تحلیل‌های آماری کلاسیک و تلفیق آن‌ها با خروجی مدل‌های گردش عمومی جو مبتنی بوده است؛ با این حال، وابستگی شدید به فرض‌های ایستایی، شکل تابع توزیع و عدم قطعیت بالای خروجی مدل‌های اقلیمی، قابلیت اتکای این روش‌ها را در کاربردهای مهندسی محدود کرده است (علیزاده، ۲۰۲۲). در مقابل، پیشرفت‌های اخیر در حوزه‌ی یادگیری ماشین، امکان ریزمقیاس‌نمایی دقیق‌تر داده‌های اقلیمی و مدل‌سازی روابط غیرخطی و چندمقیاسی بارش را فراهم کرده است. با وجود تمرکز بسیاری از مطالعات بر ریزمقیاس‌نمایی مکانی بارش (سان و همکاران، ۲۰۲۴؛ یانگ و همکاران، ۲۰۲۴؛ جهانگیری و همکاران، ۲۰۲۵)، بعد زمانی بارش، به‌ویژه تبدیل داده‌ها از مقیاس‌های زمانی بلندمدت به بازه‌های کوتاه‌مدت مورد نیاز برای استخراج منحنی‌های IDF، کمتر به صورت نظام‌مند بررسی شده است؛ در حالی که طراحی سامانه‌های زهکشی شهری به اطلاعات دقیق بارش در مقیاس‌های زمانی کوتاه وابستگی مستقیم دارد (نجفی و همکاران، ۲۰۲۵). با وجود پیشرفت‌های قابل توجه در به‌کارگیری الگوریتم‌های یادگیری ماشین در مدل‌سازی بارش، همچنان چالش‌های اساسی در زمینه‌ی تبیین هم‌زمان تغییرات مکانی و زمانی بارش، به‌ویژه در مناطق خشک و نیمه‌خشک، وجود دارد. بخش عمده‌ای از مطالعات پیشین یا بر مقیاس‌های زمانی خاص تمرکز داشته‌اند و یا ناهمگنی مکانی بارش را به صورت ضمنی و غیرمستقیم لحاظ کرده‌اند؛ در نتیجه، قابلیت تعمیم نتایج آن‌ها به مقیاس‌های مدیریتی محلی و منطقه‌ای محدود بوده است. در شرق ایران، تنوع توپوگرافی، تفاوت‌های ارتفاعی، فاصله از منابع

رطوبتی و تأثیر سامانه‌های گردشی مختلف، موجب شکل‌گیری الگوهای پیچیده و ناهمگن بارش شده است. این شرایط سبب می‌شود که استفاده از مدل‌های ساده و تک‌بعدی، نتواند رفتار واقعی بارش تجمعی را در مقیاس ایستگاهی - استانی به‌درستی بازتاب دهد. افزون بر این، وابستگی شدید برنامه‌ریزی منابع آب، مدیریت خشکسالی و ارزیابی مخاطرات هیدرولوژیکی به برآوردهای دقیق بارش، ضرورت توسعه مدل‌هایی با دقت و پایداری بالاتر را دوچندان می‌سازد. از سوی دیگر، اگرچه الگوریتم‌های یادگیری ماشین در شناسایی روابط غیرخطی عملکرد موفق داشته‌اند، اما فقدان چارچوب‌های هیبریدی که بتوانند به طور هم‌زمان اطلاعات فضایی و زمانی را در مدل‌سازی بارش تجمعی ادغام کنند، همچنان به عنوان یک خلأ پژوهشی مطرح است. این خلأ به‌ویژه در مطالعات اکوهیدرولوژیک شرق ایران، که نیازمند تحلیل‌های دقیق در مقیاس ایستگاهی - استانی هستند، اهمیت بیشتری می‌یابد. بر این اساس، مسئله اصلی پژوهش حاضر آن است که چگونه می‌توان با بهره‌گیری از یک رویکرد هیبریدی مبتنی بر یادگیری ماشین و داده‌های ایستگاهی - استانی، رفتار بارش تجمعی شرق ایران را با دقت بیشتر و عدم قطعیت کمتر مدل‌سازی و تبیین کرد.^۱

داده‌ها و روش‌ها

داده‌ها: تحلیل مکانی - زمانی بارش تجمعی ۲۴ ساعته در ۲۱ ایستگاه سینوپتیک منتخب شرق ایران (دوره ۱۹۹۰-۲۰۲۰) پژوهش حاضر بر تحلیل داده‌های بارش تجمعی ۲۴ ساعته ($P(24)$) طی سال‌های ۱۹۹۰ تا ۲۰۲۰ مبتنی بر مجموعه داده‌های ۲۱ ایستگاه هواشناسی سینوپتیک متمرکز است که پراکندگی آن‌ها نواحی شرقی ایران، شامل استان‌های سیستان و بلوچستان، خراسان جنوبی، خراسان رضوی و خراسان شمالی را پوشش می‌دهد. در این پژوهش، میانگین بارش تجمعی به صورت ماهانه و برای کل دوره آماری (۱۹۹۰-۲۰۲۰)، به طور مستقل برای هر ایستگاه هواشناسی محاسبه و مورد تحلیل قرار گرفته است. این ایستگاه‌ها شامل زابل (۴۸۹/۲ متر)، زاهدان (۱۳۷۰ متر)، ایرانشهر (۵۹۱/۱ متر)، خاش (۱۴۲۷ متر)، سروان (۱۱۸۲ متر) و چابهار (۸ متر) در استان سیستان و بلوچستان هستند. در استان خراسان جنوبی، ایستگاه‌های مورد مطالعه شامل نهبندان (۱۱۸۸ متر)، فردوس (۱۲۹۳ متر)، قائن (۱۴۳۲ متر)، بشرویه (۸۷۹ متر)، بیرجند (۱۴۹۱ متر) و طبس (۷۱۱ متر) هستند. همچنین، در استان خراسان رضوی، ایستگاه‌های سبزوار (۹۶۲ متر)، تربت حیدریه (۱۴۵۱ متر)، قوچان (۱۲۸۷ متر)، سرخس (۲۷۸ متر)، گناباد (۱۰۵۶ متر)، مشهد (۹۹۹/۲ متر)، کاشمر (۱۱۰۹/۷ متر) و گلمکان (۱۱۷۶ متر) حضور دارند. علاوه بر این، ایستگاه بجنورد (۱۰۶۵ متر) از خراسان شمالی در این مجموعه قرار دارد. داده‌های خام بارش ایستگاه‌های مورد مطالعه قبل از ورود به مدل‌های یادگیری ماشین، مراحل پیش‌پردازش لازم را شامل حذف مقادیر ناقص، تشخیص و اصلاح خطاها و نرمال‌سازی داده‌ها پشت سر گذاشته‌اند. ساختار فضایی این ایستگاه‌ها، که تنوع ارتفاعی قابل توجهی را از ۸ متر تا ۱۴۹۱ متر شامل می‌شوند، با استفاده از تابع خوشه‌بندی سلسله‌مراتبی بر مبنای معیار فاصله در مدل‌سازی وارد شده‌اند تا تغییرات زمانی بارش در این گستره مکانی مورد سنجش قرار گیرد (شکل ۱).

6. Rajagopalan
7. Sen
8. Farooq
9. Zhang
10. Das
11. Lanciotti



شکل ۱. موقعیت مکانی ۲۱ ایستگاه سینوپتیک مورد مطالعه در شرق ایران

روش تحقیق

این بخش به ارائه و تفسیر جامع یافته‌های حاصل از تحلیل فضایی - زمانی بارش تجمعی در ایستگاه‌های شرق ایران اختصاص دارد. به منظور استخراج الگوهای معنادار، یک رویکرد هیبریدی مبتنی بر یادگیری ماشین و مدل‌سازی آماری به کار گرفته شد که نتایج آن‌ها از طریق ابزارهای متنوع بصری‌سازی نمایش داده می‌شوند. در این راستا، تحلیل داده‌ها با استفاده از زبان‌های برنامه‌نویسی R و S-PLUS انجام گرفت و ترسیم نمودارها و نمایش گرافیکی نتایج با بهره‌گیری از زبان برنامه‌نویسی Syntax صورت پذیرفت. ابتدا، اعتبار آماری تفاوت‌های فضایی با استفاده از تحلیل واریانس یک‌طرفه مورد تأیید قرار گرفت. در پی آن، تحلیل روند زمانی و پیش‌بینی با بهره‌گیری از مدل رگرسیون خطی مورد بحث قرار می‌گیرد. سپس، ساختار فضایی بارش از منظر خوشه‌بندی مکانی توسط روش خوشه‌بندی سلسله‌مراتبی مورد بررسی قرار گرفته و این نتایج از طریق نمودارهای سرفیس تشریح می‌شود، به گونه‌ای که توزیع مکانی بارش و تفاوت‌های فصلی، در کنار تغییرات زمانی، به صورت شفاف در نمودارهای سری زمانی قابل مشاهده باشد. این رویکرد ترکیبی، درک عمیق‌تری از دینامیک هیدرولوژیکی منطقه ارائه می‌کند.

تابع تحلیل واریانس

در مبحث آزمون برابری میانگین‌ها (شکل ۲)، اگر تعداد جمعیت‌هایی که می‌خواهیم میانگین آن‌ها را باهم مقایسه کنیم بیش از دو تا باشد، از تابع آنالیز واریانس یک‌طرفه استفاده شود. از این تابع anova برای تشکیل جدول آنالیز واریانس ساده و چندطرفه به فرم کلی (object,...) anova استفاده می‌شود (اسماعیلیان، وحدت و حیدردوست، ۱۳۹۵). مقایسه میانگین بارش در ایستگاه‌های مختلف، به تعیین تفاوت احتمالی میانگین‌ها کمک می‌کند. این فرایند از جمع‌آوری داده تا تحلیل آماری (با توجه به سطح معناداری و درجه آزادی)، به اعتبارسنجی مدل و پیش‌بینی دقیق‌تر منجر می‌شود (فرجی و همکاران، ۱۴۰۳).

تابع خوشه‌بندی

در حوزه خوشه‌بندی سلسله‌مراتبی تابع agnes برای گروه‌بندی داده‌ها بر اساس مراتب سلسله‌مراتبی استفاده می‌شود که نیازمند تعیین متریک و روش پیونددهی است (شکل ۳)، این تکنیک‌ها برای یافتن ساختارهای پنهان در داده‌ها، به‌ویژه در تحلیل خوشه‌بندی، کاربرد دارند و چارچوب‌های اصلی آن توسط کافمن و روسو (۱۹۹۰) پایه‌ریزی شده است. همچنین، برای ادغام تکنیک‌های خوشه‌بندی مقاوم در محیط‌های نرم‌افزاری، رویکردهای پیشرفته‌ای مانند آنچه توسط استروف، هوبرت و روسو (۱۹۹۷) ارائه شده، مورد استفاده قرار می‌گیرند. سایر گفت‌وگوهای مرتبط با رگرسیون خطی، مانند رگرسیون گام‌به‌گام و مقایسه مدل‌ها، بخش‌های تکمیلی برای کاربرد عملی این روش در مدل‌سازی آماری هستند. روشی در یادگیری غیرنظارتی برای

خوشه‌بندی داده‌های مشابه است. الگوریتم k-means با انتخاب نقاط تصادفی به عنوان مراکز اولیه، داده‌ها را به نزدیک‌ترین مرکز تخصیص می‌دهد و مراکز را با میانگین داده‌های تخصیص یافته به‌روزرسانی می‌کند. این فرایند تا زمانی که مراکز تغییر نکنند تکرار می‌شود (راهنمای دسترسی به توابع در زبان برنامه‌نویسی، S). تابع هزینه در روش k-means به صورت زیر (رابطه ۱) است. در این معادله x_j نمونه‌های داده است و μ_i مرکز خوشه i است.

$$J = \sum_{i=1}^k \sum_{x_j \in C_i} \|x_j - \mu_i\|^2 \quad (1)$$

تابع رگرسیون خطی

در بحث رگرسیون خطی، این روش به عنوان رایج‌ترین رویه رگرسیون معرفی می‌شود که اصول آن در مراجع کلاسیک آمار مورد تأکید است (چمبرز و هستی، ۱۹۹۱). برای تحلیل‌های پیشرفته‌تر که نیاز به تبدیل متغیرها دارند، مدل Linear Model Linearization (ACE) Regression مطرح می‌شود. این روش رگرسیون غیرخطی، با تبدیل ناپارامتری متغیرهای yyy و xxx به یک مدل افزایشی عمل می‌کند تا همبستگی بین yyy تبدیل شده و مجموع xxx های تبدیل شده را به حداکثر برساند. این مفهوم به طور جامع در کار بریمن و فریدمن (۱۹۸۵) تشریح شده است در مبحث رگرسیون، ما به دنبال یافتن رابطه‌ای بین متغیر وابسته و متغیرهای مستقل هستیم. این رابطه ممکن است از نوع خطی یا غیرخطی باشد. تابعی که ارتباط بین متغیرهای مستقل و وابسته را بیان می‌کند به تابع رگرسیون موسوم است (اسماعیلیان، ۱۳۸۴). تابع مدل رگرسیون خطی به شکل زیر (رابطه ۲) است: در این رابطه، Y مقدار بارش ۲۴ ساعته است X_1, X_2, \dots, X_n . ویژگی‌های ورودی مانند زمان β_0 عرض از مبدأ β_i ضرایب مربوط به هر ویژگی و ϵ خطای مدل است^۱.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \epsilon \quad (2)$$

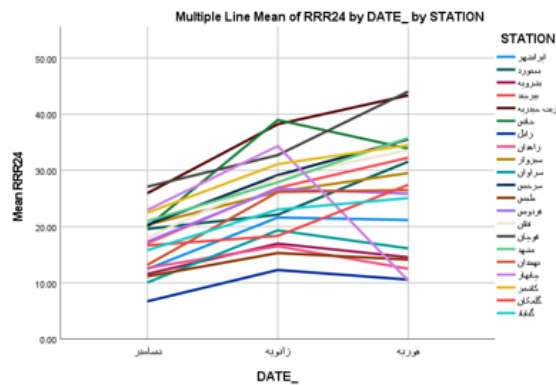
یافته‌ها و نتایج تحقیق

تفسیر سری‌های زمانی بارش فصلی بر اساس داده‌های تفصیلی

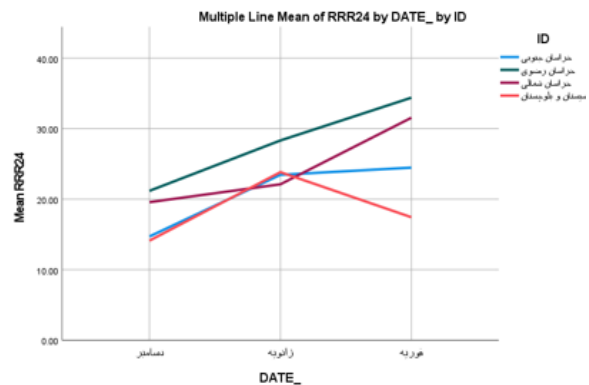
فصل زمستان

نمودارهای سری‌های زمانی فصل زمستان نشان می‌دهند بیشترین و منظم‌ترین بارش سالانه در استان‌های خراسان رضوی و خراسان شمالی رخ می‌دهد. در این فصل، روند زمانی بارش در ایستگاه‌های استان خراسان رضوی مانند قوچان (حداکثر ۴۴/۰۳ میلی‌متر در فوریه)، تربت حیدریه (۴۳/۳۵ میلی‌متر در فوریه) و مشهد (۳۵/۷۹ میلی‌متر در فوریه) بیانگر فعالیت قوی سامانه‌های بارشی غربی - مدیترانه‌ای است. در استان خراسان شمالی، ایستگاه بجنورد نیز با ثبت بیش از ۳۰ میلی‌متر در فوریه، الگوی زمانی مشابهی را نشان می‌دهد. در مقابل، در استان خراسان جنوبی مقادیر بارش کمتر اما پیوسته است (بیرجند و قائن بین ۲۵ تا ۳۲ میلی‌متر). در استان سیستان و بلوچستان، اگرچه میانگین بارش پایین‌تر است، اما ایستگاه‌هایی مانند خاش (۳۸/۹۷ میلی‌متر در ژانویه) و چابهار (۲۲/۹۵ میلی‌متر در دسامبر) نشان می‌دهند تأثیر سامانه‌های زمستانه تا جنوب شرق کشور نیز گسترش می‌یابد، در حالی که زابل کم‌بارش‌ترین شرایط را حفظ می‌کند (شکل ۲ الف و ب).

12. Kaufman
13. Stroustrup
14. Chambers
15. Breiman



شکل ب

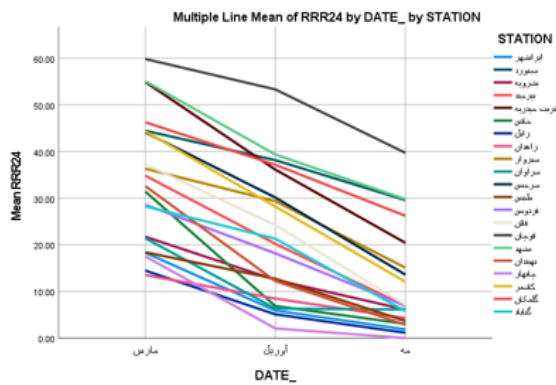


شکل الف

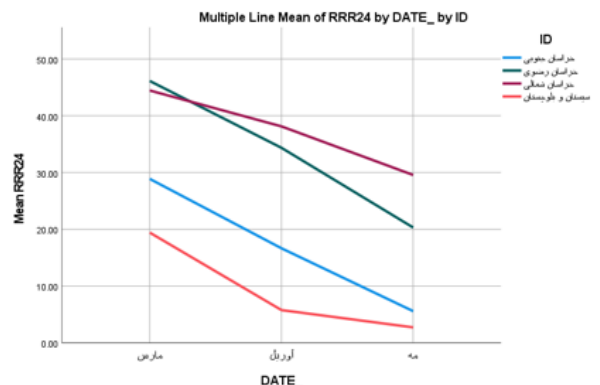
شکل ۲. نمودارهای سری‌های زمانی بارش تجمعی زمستان، شرق ایران

فصل بهار

نمودارهای سری‌های زمانی بهار، به‌ویژه در ماه مارس، بیانگر اوج بارش سالانه در شرق ایران هستند. در استان خراسان رضوی، ایستگاه‌های قوچان (۵۹/۸۳ میلی‌متر)، مشهد (۵۵/۰۷ میلی‌متر) و تربت حیدریه (۵۴/۹ میلی‌متر) بیشترین مقادیر ثبت‌شده سال را نشان می‌دهند بیانگر هم‌زمانی سامانه‌های سینوپتیکی و ناپایداری‌های همرفتی بهاره است. در استان خراسان شمالی، بجنورد با ۴۴/۴۶ میلی‌متر در مارس نقش برجسته‌ای در سری زمانی بارش دارد. استان خراسان جنوبی نیز با مقادیری مانند ۳۷/۲۷ میلی‌متر در قائن و ۳۴/۸۱ میلی‌متر در بیرجند نشان‌دهنده اهمیت ارتفاع و شرایط محلی است. با ورود به آوریل، روند کاهشی ملایم در همه استان‌ها دیده می‌شود و در ماه مه، افت شدید بارش به‌ویژه در استان سیستان و بلوچستان (چابهار ۰ و زابل ۱/۱۴ میلی‌متر) نشان‌دهنده پایان فصل مرطوب و آغاز دوره خشک است (شکل ۳ الف و ب).



شکل ب



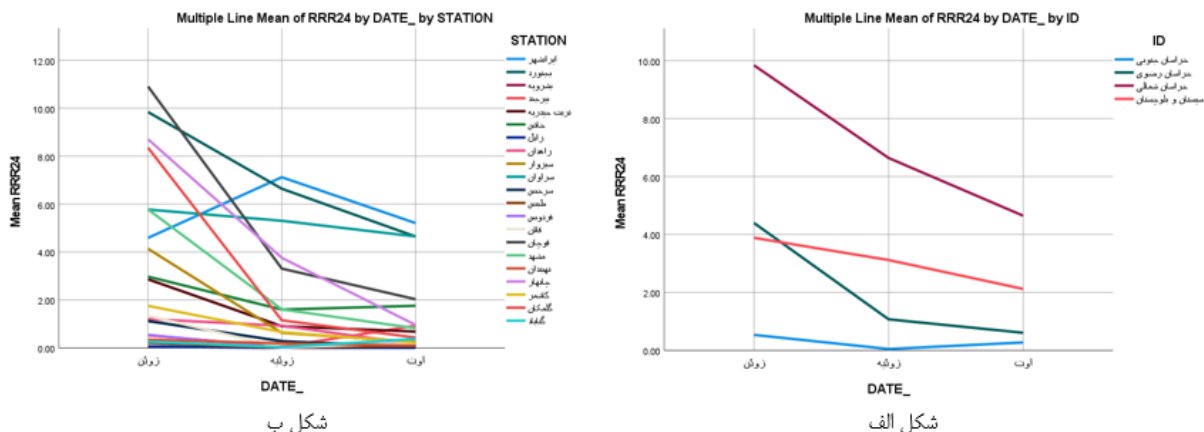
شکل الف

شکل ۳. نمودارهای سری‌های زمانی بارش تجمعی بهار، شرق ایران

فصل تابستان

نمودارهای سری‌های زمانی تابستان بیانگر غلبه کامل شرایط خشک در سراسر منطقه مورد مطالعه هستند. در استان‌های خراسان رضوی و خراسان جنوبی، اغلب ایستگاه‌ها از جمله طبس، نهبندان و فردوس مقادیر بسیار ناچیز یا نزدیک به صفر را ثبت می‌کنند. در استان خراسان شمالی، ایستگاه بجنورد با ثبت ۹/۸۴ میلی‌متر در ژوئن و ۶/۶۴ میلی‌متر در ژوئیه، تنها استثنای نسبی در این فصل به شمار می‌رود. در استان سیستان و بلوچستان، اگرچه خشکی غالب است، اما ثبت مقادیر اندک در ایستگاه‌هایی مانند ایرانشهر (۷/۱۲ میلی‌متر در ژوئیه) و سراوان (۴/۶۵ میلی‌متر در اوت) نشان‌دهنده تأثیر ضعیف و پراکنده ناپایداری‌های محلی یا نفوذ محدود سامانه‌های موسمی است. با این حال، در کل منطقه، تابستان خشک‌ترین فصل سال محسوب می‌شود

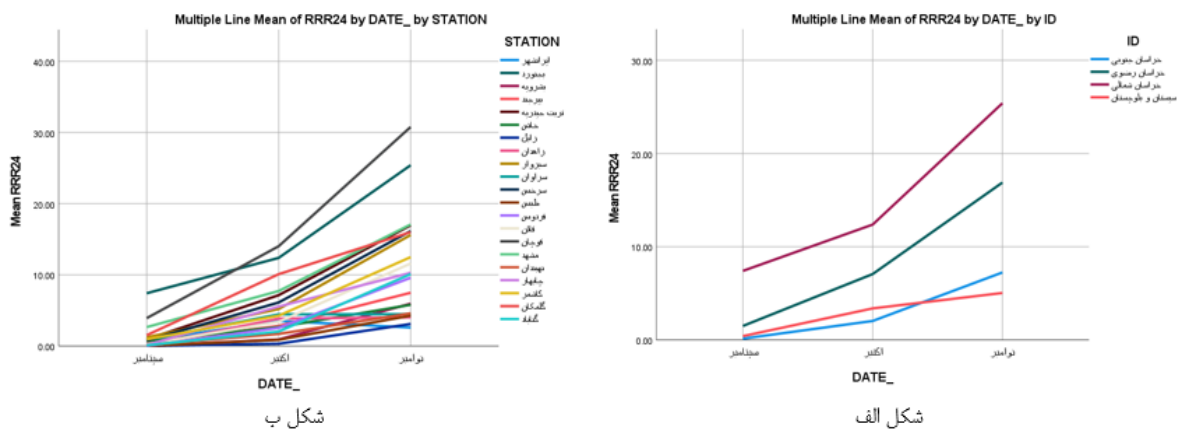
(شکل ۴ الف و ب).



شکل ۴. نمودارهای سری‌های زمانی بارش تجمعی تابستان، شرق ایران

فصل پاییز

نمودارهای سری‌های زمانی پاییز نشان‌دهنده دوره گذار از خشکی تابستان به رطوبت زمستانه هستند. در ماه سپتامبر، بارش‌ها در تمام استان‌ها بسیار محدود است و ساختار زمانی منسجمی مشاهده نمی‌شود، به طوری که تنها در استان خراسان شمالی (بجنورد ۷/۴۱ میلی‌متر) و بخش‌هایی از خراسان رضوی مقادیر اندکی ثبت شده است. در اکتبر، افزایش تدریجی بارش در استان‌های شمال شرقی؛ به‌ویژه در قوچان (۱۴/۰۲ میلی‌متر)، بجنورد (۱۲/۳۸ میلی‌متر) و گلکان (۱۰/۱ میلی‌متر) آغاز می‌شود. در نوامبر، این روند تشدید می‌شود و استان‌های خراسان رضوی و خراسان شمالی چشمگیری را تجربه می‌کنند، به طوری که قوچان (۳۰/۷۷ میلی‌متر) و بجنورد (۲۵/۴ میلی‌متر) به‌وضوح وارد فاز بارشی زمستانه می‌شوند. در استان خراسان جنوبی افزایش ملایم‌تری دیده می‌شود و استان سیستان و بلوچستان همچنان کم‌بارش‌ترین شرایط را حفظ می‌کند، که بیانگر شکل‌گیری تدریجی الگوی فضایی - زمانی بارش در آستانه زمستان است (شکل ۵ الف و ب).



شکل ۵. نمودارهای سری‌های زمانی بارش تجمعی پاییز، شرق ایران

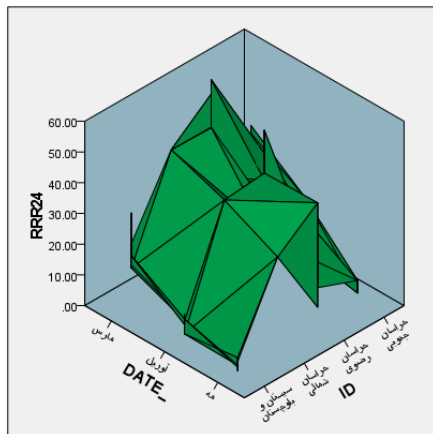
نمودارهای سه‌بعدی Surface استانی شرق ایران زمستان (دسامبر - ژانویه - فوریه)

نمودارهای سه‌بعدی Surface در فصل زمستان بیانگر بیشترین مقادیر بارش تجمعی سالانه و ناهمگنی فضایی بسیار شدید در شرق ایران هستند. در این فصل، خراسان رضوی با تشکیل قله‌های مرتفع و تیز در سطح نمودار، بیشترین ارتفاع سطحی را در محور عمودی به خود اختصاص می‌دهد و به عنوان کانون اصلی بارش زمستانه منطقه ظاهر می‌شود. این الگو نشان‌دهنده

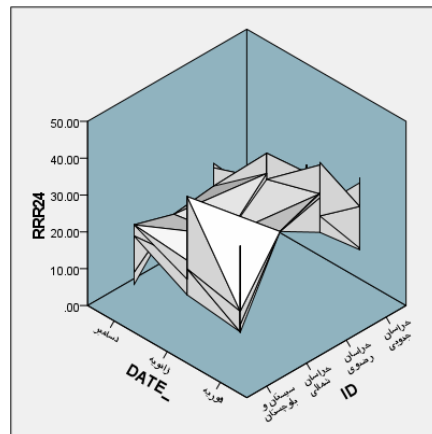
فعالیت قوی سامانه‌های سینوپتیکی زمستانه و نقش توپوگرافی در تمرکز بارش است. پس از آن، خراسان شمالی در رتبه‌ی دوم قرار دارد و اگرچه مقادیر آن کمتر از خراسان رضوی است، اما همچنان سطوح مرتفع و ناپوسته‌ای را در نمودار سه‌بعدی Surface نشان می‌دهد. از نظر ماهانه، در دسامبر آغاز فعالیت سامانه‌های بارشی باعث شکل‌گیری گردان‌های فضایی مشخص در منطقه می‌شود. در ژانویه بیشترین توسعه‌ی عمودی سطح بارش مشاهده می‌شود و نمودار دارای قله‌های تیز و شکست‌های فضایی واضح است که بیانگر تمرکز شدید بارش در استان‌های شمال‌شرقی، به‌ویژه خراسان رضوی، است. در فوریه اگرچه در برخی استان‌ها کاهش نسبی ارتفاع سطحی دیده می‌شود، اما الگوی کلی برتری خراسان رضوی و خراسان شمالی همچنان حفظ شده و ساختار فضایی بارش زمستانه پایدار باقی می‌ماند (شکل ۶ الف).

بهار (مارس - آوریل - مه)

در فصل بهار، نمودارهای سه‌بعدی Surface نشان می‌دهند اگرچه روند کلی بارش نسبت به زمستان کاهش یافته است، اما ناهمگنی فضایی هنوز به طور کامل از بین نرفته است. در این فصل، خراسان رضوی همچنان بالاترین سطح بارش تجمعی را در منطقه حفظ می‌کند و قله‌های مشخصی در سطح نمودار دیده می‌شود، هرچند اختلاف آن با سایر استان‌ها نسبت به زمستان کمتر است. خراسان شمالی نیز سطوح متوسط تا نسبتاً بالایی از بارش را نشان می‌دهد و جایگاه دوم را حفظ می‌کند. در مقیاس ماهانه، مارس اوج اصلی بارش بهاری را نشان می‌دهد و در نمودار سه‌بعدی Surface، قله‌های مرتفع و ناهمگنی فضایی قابل توجهی مشاهده می‌شود. در آوریل کاهش بارش آغاز شده و ارتفاع سطح نمودار در اغلب استان‌ها کمتر می‌شود، اما الگوی فضایی هنوز نامنظم است. در مه افت محسوس بارش در کل منطقه رخ می‌دهد و سطح نمودار، به‌ویژه در استان‌های جنوبی، به مقادیر پایین نزدیک می‌شود. در این فصل، خراسان جنوبی افزایش نسبی اما محدود در برخی ماه‌ها نشان می‌دهد، در حالی که سیستان و بلوچستان در تمام ماه‌های بهار کم‌بارش باقی مانده و سطح سه‌بعدی آن عمدتاً کم‌ارتفاع و نسبتاً یکنواخت است (شکل ۶ ب).



شکل ب



شکل الف

شکل ۶ نمودارهای سه‌بعدی Surface بارش استانی شرق ایران


تابستان (ژوئن - ژوئیه - اوت)

نمودارهای سه‌بعدی Surface فصل تابستان بیانگر حداقل مقادیر بارش تجمعی سالانه در شرق ایران هستند. در این فصل، سطح نمودار در اغلب استان‌ها به شدت افت می‌کند و اختلاف فضایی بارش به حداقل مقدار خود می‌رسد. خراسان رضوی، خراسان شمالی و خراسان جنوبی سطوحی بسیار پایین و نزدیک به یکدیگر را نشان می‌دهند که بیانگر غلبه شرایط پایدار جوی و نبود سامانه‌های بارشی مؤثر است. از نظر ماهانه، در ژوئن آغاز دوره کم‌بارش کاملاً مشخص است. در ژوئیه این وضعیت پایدار باقی مانده و تغییرات فضایی بسیار محدود و ناچیز است. در اوت اگرچه در بخش‌هایی از جنوب شرق منطقه نوسانات بسیار

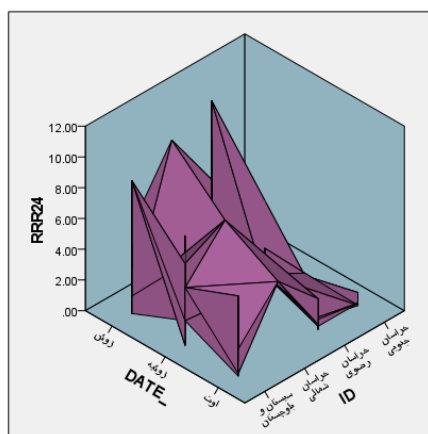
محدود و کوتاه‌دامنه‌ای در سطح نمودار دیده می‌شود، اما این تغییرات از نظر مقدار ناچیز بوده و سطح کلی نمودار همچنان تخت و کم‌ارتفاع باقی می‌ماند. در این میان، سیستان و بلوچستان تنها استانی است که در برخی نقاط نوسانات بسیار ضعیف و موضعی نشان می‌دهد، اما در مقیاس منطقه‌ای، تابستان به‌وضوح کم‌بارش‌ترین فصل سال محسوب می‌شود (شکل ۷ الف).

پاییز (سپتامبر - اکتبر - نوامبر)

در فصل پاییز، نمودارهای سه‌بعدی Surface نشان‌دهنده آغاز مجدد افزایش بارش و شکل‌گیری تدریجی ناهمگنی فضایی در شرق ایران هستند. در این فصل، خراسان رضوی بار دیگر به عنوان استان غالب از نظر ارتفاع سطحی نمودار ظاهر می‌شود و روند افزایشی مشخصی در بارش تجمعی نشان می‌دهد. خراسان شمالی نیز افزایش تدریجی مشابهی را تجربه می‌کند و سطوح نسبتاً مرتفع‌تری نسبت به فصل تابستان تشکیل می‌دهد. در بررسی ماهانه، در سپتامبر افزایش بارش محدود بوده و سطح نمودار همچنان کم‌ارتفاع است. در اکتبر رشد واضح‌تری در ارتفاع سطحی نمودار مشاهده می‌شود و گرادیان فضایی بارش به تدریج شکل می‌گیرد. در نوامبر اختلاف فضایی بین استان‌ها تشدید می‌شود و ساختار فضایی بارش شباهت بیشتری به الگوی زمستانه پیدا می‌کند. خراسان جنوبی در پاییز یک سطح میانی با افزایش ملایم را حفظ می‌کند، در حالی که سیستان و بلوچستان همچنان کم‌بارش‌ترین استان است و پایین‌ترین ارتفاع سطحی را در نمودارهای سه‌بعدی Surface به خود اختصاص می‌دهد (شکل ۷ الف و ب).



شکل ب



شکل الف

شکل ۷. نمودارهای سه‌بعدی Surface بارش استانی شرق ایران

تفسیر نهایی الگوی فصلی بارش شرق ایران بر اساس داده‌های ایستگاهی - استانی و سامانه‌های گردشی غالب زمستان (اوج‌گیری سامانه‌های غربی و جنوبی)

فصل زمستان با تکیه بر فعالیت سامانه‌های کم‌فشار غربی و مدیترانه‌ای، شروع‌کننده اصلی فصل بارشی در شرق ایران است. میانگین تجمعی بارش در این سه ماه در مقادیر بالایی قرار دارد، به‌ویژه در استان‌های خراسان رضوی (مانند تربت‌حیدریه و قوچان) و خراسان شمالی (بجنورد) که به دلیل قرارگیری در مسیر اصلی این سامانه‌ها و تأثیر صعود اوروگرافیک، بیشترین مقادیر را ثبت می‌کنند، به طوری که قوچان با ثبت $44/03$ میلی‌متر در فوریه، بیشینه بارش زمستانه را در میان ایستگاه‌های مورد بررسی نشان می‌دهد. در خراسان شمالی نیز ایستگاه بجنورد با مقادیری بیش از 30 میلی‌متر در ماه فوریه، الگوی مشابهی را بروز می‌دهد. از سوی دیگر، بخش‌های جنوبی استان سیستان و بلوچستان (نظیر خاش با $38/97$ میلی‌متر در ژانویه و چابهار با بیشینه‌ای حدود 23 میلی‌متر در دسامبر) در اوایل فصل زمستان از نفوذ سامانه‌های سودانی و رطوبت دریای عمان بهره‌مند می‌شوند که به ثبت مقادیر قابل توجهی از بارش در این نواحی منجر می‌شود. با این حال، مناطق داخلی و کویری مانند زابل و

طیس، به دلیل قرارگیری در سایه بارشی و محدودیت دسترسی به منابع رطوبتی، کمترین مقادیر بارش زمستانه (عموماً در حدود ۱۰ تا ۱۲ میلی‌متر در ماه) را ثبت می‌کنند. به طور کلی، توزیع فضایی بارش در زمستان نسبتاً یکنواخت‌تر از سایر فصل‌ها است که بیانگر غلبه‌ی سامانه‌های سینوپتیکی گسترده و کاهش نقش فرایندهای محلی است.

بهار (اوج بارش و ناپایداری‌های همرفتی)

فصل بهار نماینده اوج بارش سالانه در شرق ایران است که بیشینه آن عمدتاً در ماه مارس رخ می‌دهد. میانگین بارش در این ماه به بالاترین مقادیر سالانه می‌رسد و هم‌زمان، اختلاف‌های فضایی بارش تشدید می‌شود. به عنوان نمونه، ایستگاه قوچان در خراسان رضوی با ثبت ۵۹/۸۳ میلی‌متر بارش در ماه مارس، قله بارشی فصل بهار و کل سال را نشان می‌دهد؛ همچنین ایستگاه‌هایی مانند مشهد و تربت‌حیدریه نیز با مقادیر بالاتر از ۵۰ میلی‌متر، سهم قابل توجهی در بارش بهار دارند. این افزایش بارش ناشی از تداوم فعالیت سامانه‌های غربی در کنار افزایش دمای سطح زمین و ناپایداری‌های حرارتی است که به تقویت بارش‌های همرفتی (کونوکتیو) منجر می‌شود. در نتیجه، دامنه تغییرات مکانی بارش در این فصل بسیار وسیع بوده و از مقادیر صفر تا بیش از ۶۰ میلی‌متر متغیر است. با این حال، از ماه مه به بعد، با استقرار تدریجی پرفشار جنب‌حاره‌ای، بارش‌ها به سرعت کاهش می‌یابد؛ به‌ویژه در ایستگاه‌های کویری و جنوبی‌تر مانند چابهار (صفر میلی‌متر در مه) و طیس که این روند، عقب‌نشینی سامانه‌های بارشی و آغاز دوره خشکی را به‌خوبی نشان می‌دهد.

تابستان (چیرگی پرفشار جنب‌حاره‌ای و خشکی مطلق)

فصل تابستان خشک‌ترین دوره سال در شرق ایران است که با چیرگی کامل پشته پرفشار جنب‌حاره‌ای بر فلات ایران همراه است. این سامانه جوی با ایجاد فرونشست هوا، افزایش پایداری جو و تضعیف حرکات صعودی، هرگونه فعالیت جبهه‌ای و بارشی مؤثر را متوقف می‌کند. بر این اساس، غالب ایستگاه‌ها در استان‌های خراسان جنوبی و سیستان و بلوچستان مقادیری نزدیک به صفر یا صفر مطلق را ثبت کرده‌اند؛ به گونه‌ای که ایستگاه‌هایی مانند زابل، طیس و فردوس در اغلب ماه‌های تابستان فاقد بارش مؤثر هستند. تنها مقادیر ناچیز بارش که در برخی ایستگاه‌های مرتفع‌تر شمالی مانند قوچان یا در نواحی جنوبی‌تر و تحت تأثیر ضعیف جریان‌های موسمی مانند سراوان و ایرانشهر مشاهده می‌شود (حداکثر در حدود ۷ تا ۱۰ میلی‌متر)، ناشی از رگبارهای محلی و کوتاه‌مدت همرفتی است. این بارش‌ها از نظر اقلیمی سهم بسیار اندکی دارند و در مقایسه با اوج بارش‌های بهاره، کمتر از ۱۵ درصد آن‌ها را تشکیل می‌دهند و نقشی اساسی در تأمین منابع آب منطقه ایفا نمی‌کنند.

پاییز (احیای تدریجی گردش غربی)


با عقب‌نشینی تدریجی پرفشار جنب‌حاره‌ای، فصل پاییز با احیای ضعیف و تدریجی سامانه‌های بارشی غربی آغاز می‌شود. این روند از ماه‌های سپتامبر و اکتبر، که همچنان با بارش‌های بسیار اندک به‌ویژه در مناطق کویری داخلی همراه است، شروع شده و در ماه نوامبر به طور محسوسی تقویت می‌شود. در نوامبر، استان‌های خراسان شمالی و خراسان رضوی نخستین نشانه‌های ورود سامانه‌های بارشی مؤثر را تجربه می‌کنند، به طوری که بجنورد با ثبت ۲۵/۴ میلی‌متر و قوچان با ۳۰/۷۷ میلی‌متر بارش، افزایش قابل توجهی نسبت به ماه‌های قبل نشان می‌دهند. این افزایش بارش بیانگر برقراری مجدد گردش غربی و انتقال رطوبت از نواحی مدیترانه‌ای به شرق ایران است و پاییز را به عنوان یک فصل انتقالی کلیدی میان دوره خشکی تابستان و فصل پربارش زمستان معرفی می‌کند. در مقابل، ایستگاه‌های داخلی و خشک‌تر مانند زابل و طیس همچنان واکنش ضعیف‌تری به این سامانه‌ها نشان می‌دهد و مقادیر بارش آن‌ها نسبتاً پایین باقی می‌ماند.

نتایج تابع تحلیل واریانس

براساس تحلیل انجام‌شده، مقدار آماره F به‌دست‌آمده و همچنین، سطح معناداری P که کمتر از $0/05 <$ گزارش شده است، نشان‌دهنده وجود تفاوت‌های معنادار بین میانگین بارش تجمعی ایستگاه‌های هواشناسی شرق ایران در دوره مشاهده‌شده است. نتایج آزمون آنالیز واریانس یک‌طرفه به‌روشنی مؤید این واقعیت است که میانگین بارش در ایستگاه‌های مختلف تحت بررسی، از نظر آماری به طور معناداری با یکدیگر متفاوت است و می‌توان نتیجه گرفت که فرضیه صفر مبنی بر برابری میانگین‌های بارش تجمعی در ایستگاه‌های مختلف رد می‌شود؛ در نتیجه، این یافته‌ها اهمیت بسزایی در ارزیابی دقت مدل‌های شبیه‌سازی بارش و بررسی کارایی آن‌ها در پیش‌بینی بارش واقعی ایفا می‌کنند. این نتایج، به تحقیقات آینده در زمینه بهبود الگوریتم‌های شبیه‌سازی بارش و تطابق آن‌ها با داده‌های واقعی کمک شایانی خواهد کرد. برای تقویت اعتبار این نتایج، توصیه می‌شود که تحلیل‌های تکمیلی و بررسی‌های بیشتری در زمینه عوامل مؤثر بر بارش و دقت شبیه‌سازی‌ها صورت پذیرد.

ساختار خوشه‌بندی ایستگاه‌های هواشناسی بر اساس بارش تجمعی با استفاده از وارد

تحلیل خوشه‌بندی سلسله‌مراتبی، با استفاده از روش وارد روی داده‌های میانگین بارش تجمعی ایستگاه‌های شرق ایران، ساختار فضایی و الگوهای اقلیمی پنهان در منطقه را در چهار سطح متمایز آشکار می‌سازد و امکان طبقه‌بندی ایستگاه‌ها را بر اساس شباهت‌های بارشی فراهم می‌آورد. در سطح نخست، یعنی بالاترین سطح تفکیک دندروگرام، هر ایستگاه به دلیل ویژگی‌های منحصربه‌فرد و تفاوت‌های ریزاقلیمی، به عنوان یک خوشه مستقل و مجزا در نظر گرفته می‌شود. این تفکیک اولیه، نشان‌دهنده تفاوت‌های ظریف بارشی هر نقطه است که پایه و اساس خوشه‌بندی‌های بعدی را تشکیل می‌دهد و بیانگر این واقعیت است که هیچ دو نقطه‌ای در طبیعت، ویژگی‌های کاملاً یکسان ندارند و هر ایستگاه می‌تواند به تنهایی یک واحد اقلیمی محسوب شود. با حرکت به سمت سطح دوم و ادغام خوشه‌های اولیه، ایستگاه‌ها شروع به تشکیل گروه‌های بزرگ‌تر می‌کنند که نمایانگر سه منطقه اقلیمی اصلی در شرق ایران هستند. این سه خوشه شامل «خوشه خشک و بیابانی» با ایستگاه‌هایی نظیر زابل (۴۷/۴)، زاهدان (۶/۵۱)، طبس (۶/۷۳)، بشرویه (۷/۵۵)، ایرانشهر (۸/۷۵)، سراوان (۸/۷۳) و نهبندان (۱۰/۰۵) است که با میانگین بارش بسیار پایین مشخص می‌شوند. «خوشه نیمه‌خشک و انتقالی» نیز شامل ایستگاه‌هایی با بارش متوسط مانند چابهار (۹/۷۲)، فردوس (۱۱/۳۷) گناباد (۱۱)، بیرجند (۱۲/۵۲)، خاش (۱۲/۴۶)، سبزوار (۱۵/۳۱)، کاشمر (۱۶/۰۸) و سرخس (۱۶/۴۴) است که در مناطق بینابینی قرار دارند. در نهایت، «خوشه پربارش» ایستگاه‌هایی با میانگین بارش بالا، عمدتاً در شمال و شمال شرق، مانند مشهد (۲۰/۳۷)، تربت حیدریه (۲۰/۷۰)، بجنورد (۲۰/۹۷)، گلکان (۱۷/۴۶) و قوچان (۲۶/۸۰) را در بر می‌گیرد که از سامانه‌های مدیترانه‌ای و اوروگرافیک بهره‌مند هستند. در سطح سوم، خوشه‌های اصلی به زیرگروه‌هایی تقسیم می‌شوند که نشان‌دهنده تفاوت‌های منطقه‌ای دقیق‌تر در الگوهای بارش هستند و ناشی از عواملی مانند ارتفاع، جهت‌گیری دامنه‌ها و میزان تأثیرپذیری از سیستم‌های بارشی محلی هستند. برای مثال، در خوشه پربارش، ایستگاه‌های شمالی‌تر از بقیه تفکیک می‌شوند و در مناطق خشک، تفاوت بین مناطق کاملاً بیابانی و مناطقی با اندک بارش فصلی مشخص‌تر می‌شود. در نهایت، در سطح چهارم و پایانی که نمایانگر بیشترین بارش است، ایستگاه قوچان (میانگین ۲۶/۸۰ میلی‌متر) به دلیل داشتن بالاترین میانگین بارش تجمعی در میان تمامی ایستگاه‌ها، به عنوان یک خوشه مستقل یا برجسته‌ترین عضو در گروه پربارش قرار می‌گیرد. این تمایز نشان‌دهنده موقعیت اقلیمی خاص قوچان در مسیر سامانه‌های بارشی و تأثیر اوروگرافیک قوی رشته‌کوه‌های اطراف است که آن را به یک کانون بارشی ویژه تبدیل می‌کند و از نظر اقلیمی از سایر ایستگاه‌ها متمایز می‌سازد. این خوشه‌بندی بینش‌های ارزشمندی را در مورد الگوهای بارش در شرق ایران ارائه می‌دهد و می‌تواند در برنامه‌ریزی منابع آبی، مدیریت ریسک سیلاب، و توسعه مدل‌های پیش‌بینی بارش منطقه‌ای مورد استفاده قرار گیرد (شکل ۸).



شکل ۸. ساختار خوشه‌بندی ایستگاه‌های هواشناسی بر اساس بارش تجمعی با استفاده از وارد

نتایج تابع رگرسیون خطی

بخش اول، تحلیل رگرسیون خطی داده‌ها نشان داد مقدار ضریب تعیین تعدیل شده $Adjusted R^2$ برابر با $0/64$ برآورد شده است. این شاخص به روشنی نشان می‌دهد متغیر پیش‌بین زمانی (ماه‌ها) توانسته است $64/8$ درصد از واریانس متغیر ملاک (مقدار بارش) را تبیین کند. به بیان دیگر، 64 درصد از تغییرات مشاهده شده در بارش‌ها ناشی از تأثیرات متغیر زمان است. این نتایج به ویژه تأکید دارند بر اینکه تغییرات زمانی در سطوح ماهانه به عنوان یک عامل کلیدی در روندهای بارش شناخته می‌شوند و همچنین، بیانگر اهمیت درک الگوهای بارشی در سطوح ماهانه به منظور پیش‌بینی و مدیریت منابع آبی است. بخش دوم، تحلیل واریانس نتایج تحلیل واریانس به منظور ارزیابی معناداری کلی مدل رگرسیونی به دست آمده، بیانگر آن است که سطح معناداری p -value کمتر از $0/05$ است. این یافته‌ها نشان می‌دهند مدل رگرسیونی به لحاظ آماری معنادار است و متغیر پیش‌بین مستقل (ماه‌ها) به طور معناداری توانسته است تغییرات در مقدار بارش را پیش‌بینی کند. معناداری آماری آزمون تحلیل واریانس F -test نشانه‌ای از وجود یک رابطه معنادار میان متغیر پیش‌بین (ماه‌ها) و متغیر ملاک (بارش) است و تأکید بر این نکته دارد که تغییرات فصلی و ماهانه تأثیر مهمی بر الگوهای بارش در شرق ایران دارند. این نتایج نه تنها در جهت درک بهتر الگوهای بارشی و نوسانات آن در سطح ماهانه کمک می‌کنند، بلکه می‌توانند مبنای علمی و عملی برای توسعه راهبردهای مدیریت منابع آب و پیش‌بینی خشکسالی و ترسالی در آینده باشند.

بحث و تفسیر نتایج

یافته‌های این پژوهش نشان می‌دهد الگوی بارش تجمعی در شرق ایران حاصل برهم‌کنش پیچیده عوامل مکانی و زمانی است و این رفتار پیچیده، امکان تبیین دقیق آن را با رویکردهای خطی و تک‌بعدی محدود می‌سازد. تفسیر نتایج بیانگر آن است که ناهمگنی فضایی ایستگاه‌ها، همراه با نوسانات زمانی و فصلی، نقش تعیین‌کننده‌ای در شکل‌گیری رژیم بارندگی منطقه دارد. این مسئله به‌ویژه در مناطقی با تنوع توپوگرافی و شرایط اقلیمی گذار، باعث بروز الگوهای متفاوت بارش در مقیاس‌های محلی می‌شود که نمی‌توان آن‌ها را به صورت یکنواخت تعمیم داد. بررسی ساختار فضایی بارش نشان می‌دهد تفکیک منطقه به پهنه‌های اقلیمی متمایز، نه تنها بازتاب‌دهنده تفاوت‌های اقلیمی ذاتی شرق ایران است، بلکه اهمیت عوامل فیزیوگرافی، به‌ویژه نقش ارتفاع و اثرات اوروگرافیک، را در کنترل توزیع مکانی بارش برجسته می‌سازد. این تفسیر با نتایج بسیاری از مطالعات پیشین همخوانی دارد که بر نقش ناهمگنی مکانی در مناطق خشک و نیمه‌خشک تأکید کرده‌اند و نشان داده‌اند مدل‌سازی بارش بدون در نظر گرفتن ساختار فضایی، به ساده‌سازی بیش از حد فرایندها منجر می‌شود. از منظر زمانی، نتایج بیانگر آن است که تغییرات ماهانه و فصلی سهم قابل توجهی در رفتار بارش تجمعی دارند و نمی‌توان بارش منطقه را به عنوان یک فرایند ایستا در نظر گرفت. این ویژگی با یافته‌های پژوهش‌هایی که بر نایستایی سری‌های زمانی هیدرولوژیکی تأکید دارند، همسو است و نشان می‌دهد استفاده از چارچوب‌های انعطاف‌پذیر، به‌ویژه روش‌های مبتنی بر یادگیری ماشین، برای تحلیل چنین داده‌هایی ضروری است. در مقایسه با مطالعاتی که فقط از مدل‌های آماری کلاسیک استفاده کرده‌اند، رویکرد به‌کاررفته در این تحقیق توانسته است درک جامع‌تری از تغییرات زمانی بارش ارائه دهد. مقایسه کیفی نتایج این پژوهش با مطالعات مبتنی بر یادگیری ماشین نشان می‌دهد اگرچه بسیاری از پژوهش‌های پیشین بر پیش‌بینی بارش یا ارزیابی دقت الگوریتم‌ها تمرکز داشته‌اند، اما تأکید این تحقیق بر تلفیق تحلیل فضایی، زمانی و داده‌محور، به استخراج ساختار اقلیمی منسجم‌تری برای شرق ایران منجر شده است. اختلاف مشاهده‌شده در تعداد و ماهیت خوشه‌های بارشی نسبت به برخی مطالعات قبلی را می‌توان ناشی از تفاوت در مقیاس مکانی، نوع داده‌ها و روش خوشه‌بندی دانست؛ امری که نشان می‌دهد نتایج مدل‌سازی بارش به‌شدت وابسته به چارچوب تحلیلی انتخاب‌شده است. با این حال، هم‌راستایی کلی نتایج با پژوهش‌های داخلی و خارجی، اعتبار رویکرد هیبریدی مبتنی بر یادگیری ماشین را در تحلیل بارش مناطق خشک تقویت می‌کند. در مقایسه با پژوهش فرجی و همکاران (۲۰۲۵)، که از مدل‌های یادگیری ماشین برای پیش‌بینی بارش استفاده کرده‌اند، یافته‌های تحقیق حاضر همسو با کارایی بالای رویکردهای داده‌محور در تحلیل بارش است. با این حال، تفاوت اصلی در آن است که تمرکز این پژوهش صرفاً بر پیش‌بینی نبوده، بلکه بر استخراج و تفسیر ساختار فضایی - اقلیمی بارش تأکید داشته است. اختلاف در تعداد خوشه‌های بارشی استخراج‌شده نسبت به مطالعه فرجی و همکاران را می‌توان ناشی از تفاوت در مقیاس مکانی تحلیل و روش خوشه‌بندی دانست که نشان می‌دهد نتایج خوشه‌بندی بارش به چارچوب فضایی و روش‌شناختی وابستگی بالایی دارد. همچنین، همخوانی نتایج این پژوهش با یافته‌های ساداتی‌نژاد و همکاران (۲۰۲۴) که بر حساسیت بالای رژیم بارش شرق ایران نسبت به تغییرات اقلیمی تأکید کرده‌اند، بیانگر آن است که نوسانات مشاهده‌شده در داده‌های بارش، بازتابی از شرایط ناپایدار اقلیمی منطقه است. این همسویی نشان می‌دهد مدل‌های داده‌محور و تحلیل‌های آماری می‌توانند در کنار مدل‌های اقلیمی، تصویری مکمل از رفتار بارش ارائه دهند و درک بهتری از تغییرپذیری‌های منطقه‌ای فراهم سازند. از منظر روش‌شناختی، نتایج این تحقیق با دیدگاه ژانگ و همکاران (۲۰۲۵) درباره توانایی روش‌های یادگیری ماشین در مدیریت نایستایی سری‌های زمانی هیدرولوژیکی همخوانی دارد. تفسیر نتایج نشان می‌دهد استفاده از چارچوب‌های انعطاف‌پذیر، امکان بازنمایی دقیق‌تری از تغییرات زمانی بارش را فراهم می‌کند و نسبت به رویکردهای کلاسیک، ظرفیت بالاتری در تحلیل داده‌های پیچیده اقلیمی دارد. در مجموع، این مقایسه‌ها نشان می‌دهد رویکرد هیبریدی به‌کاررفته در پژوهش حاضر، ضمن همسویی با ادبیات علمی موجود، در جهت تعمیق تحلیل فضایی - زمانی بارش در شرق ایران گام برداشته است.

نتیجه‌گیری

به طور کلی، نتایج این پژوهش نشان داد بارش تجمعی در شرق ایران دارای رفتاری غیرخطی، ناهمگن و وابسته به ساختار فضایی-زمانی منطقه است؛ امری که تحلیل و تبیین آن را مستلزم استفاده از رویکردهای پیشرفته و ترکیبی می‌سازد. یافته‌ها حاکی از آن است که چارچوب هیبریدی مبتنی بر یادگیری ماشین به‌کاررفته در این تحقیق، توانایی مناسبی در استخراج الگوهای پیچیده و پنهان بارش داشته و نسبت به روش‌های کلاسیک، تفسیر واقع‌بینانه‌تری از نوسانات مکانی و زمانی ارائه می‌دهد. بر این اساس، نتایج پژوهش می‌تواند به عنوان مبنایی علمی برای مطالعات هیدرولوژیکی، پیش‌بینی بارش و برنامه‌ریزی مدیریت منابع آب در مناطق خشک و نیمه‌خشک، به‌ویژه شرق ایران، مورد استفاده قرار گیرد. همچنین، پیشنهاد می‌شود در پژوهش‌های آینده، به منظور کاهش عدم قطعیت مدل‌سازی و ارتقای دقت تحلیل‌ها، از مدل‌های غیرخطی و احتمالاتی پیشرفته، روش‌های مبتنی بر نظریه آشوب و سیستم‌های دینامیکی، و نیز مدل‌های ترکیبی آماری - ریاضی در مقیاس‌های زمانی مختلف بهره گرفته شود تا شناخت جامع‌تری از فرایندهای مؤثر بر رفتار بارش فراهم شود.

تضاد منافع

نویسندگان به‌صراحت اظهار می‌دارند که هیچ‌گونه تضاد منافع مالی یا غیرمالی در ارتباط با نتایج و انتشار این مقاله وجود نداشته است.

ملاحظات اخلاقی

نویسندگان متعهد به حفظ امانت‌داری علمی، عدم جعل و یا تحریف داده‌ها، و همچنین ارائه‌ی صادقانه‌ی نتایج پژوهش حاضر هستند.

سپاسگزاری

نویسندگان مراتب قدردانی خود را از سازمان هواشناسی کشور به دلیل فراهم کردن داده‌های هواشناسی مورد نیاز برای انجام این پژوهش ابراز می‌دارند.

- 1 Esmaeilian, M. (2005). *Comprehensive SPSS guide*. Naghoos Publications. (in Persian).
- 2 Esmaeilian, M., Vahdat, J., & Heydardoust, H. (2016). *R software guide*. University of Mohaghegh Ardabili Press. (in Persian).
- 3 Faraji, M., Rezaei Banafsheh, M., Sari Sarraf, B., & Khorshiddoust, A. (2023). Numerical simulation of climate change variations in Iran using artificial neural network algorithms. *Climate Research Journal*, 4(14), 43–64. (in Persian).
- 4 Sadatinejad, S. J., Soleimani Sardo, F., & Mirzavandi, M. (2024). Modeling and prediction of climatic parameters using CanESM2 model under RCP scenarios (Case study: Karaj Station). *Ecohydrology Journal*, 11(3), 411–426. (in Persian).
- 5 Sattari, M. T., Bagheri, R., Shirini, K., & Allahverdi Pour, P. (2024). Modeling daily and monthly precipitation of Tabriz using ensemble learning and decision tree regression models. *Climate Change Research*, 5(18), 31–48. <https://doi.org/10.30488/ccr.2024.433394.1192>
- 6 Alizadeh, O. (2022). Advances and challenges in climate modeling. *Climatic Change*, 170(1), 18. <https://doi.org/10.1007/s10584-021-03298-4>
- 7 Almazroui, M., Islam, M. N., Saeed, S., Saeed, F., & Ismail, M. (2020). Future changes in climate over the Arabian Peninsula based on CMIP6 multimodel simulations. *Earth Systems and Environment*, 4(4), 611–630. <https://doi.org/10.1007/s41748-020-00183-5>
- 8 Bi, E. G., Gachon, P., Vrac, M., & Monette, F. (2017). Which downscaled rainfall data for climate change impact studies in urban areas? *Theoretical and Applied Climatology*, 127(3–4), 685–699. <https://doi.org/10.1007/s00704-015-1656-y>
- 9 Breiman, L., & Friedman, J. H. (1985). Estimating optimal transformations for multiple regression and correlation. *Journal of the American Statistical Association*, 80, 580–619.
- 10 Chambers, J. M., & Hastie, T. J. (1991). *Statistical Models in S*. Chapman and Hall.
- 11 Das, P., Sachindra, D. A., & Chanda, K. (2022). Machine learning-based rainfall forecasting with multiple nonlinear feature selection algorithms. *Water Resources Management*, 36(15), 6043–6071. <https://doi.org/10.1007/s11269-022-03341-8>
- 12 Davenport, F. V., & Duffenbaugh, N. S. (2021). Using machine learning to analyze physical causes of climate change. *Geophysical Research Letters*, 48(15), e2021GL093787. <https://doi.org/10.1029/2021GL093787>
- 13 Farooq, R., Imteaz, M. A., & Mekanik, F. (2025). Deterministic rainfall forecasting using machine learning. *Earth Science Informatics*, 18(2), 224. <https://doi.org/10.1007/s12145-025-01724-0>
- 14 Feitoza Silva, D., Simonovic, S. P., Schardong, A., & Goldenfum, J. A. (2021). Introducing non-stationarity into IDF curves. *Water*, 13(8), 1008. <https://doi.org/10.3390/w13081008>
- 15 Hosseinzadeh-Talaei, P., Tabari, H., & Willems, P. (2020). Climate change impact on short-duration precipitation extremes. *Journal of Hydrology*, 590, 125249.
- 16 Hu, H., & Ayyub, B. M. (2019). Machine learning for projecting extreme precipitation. *Geosciences*, 9(5), 209. <https://doi.org/10.3390/geosciences9050209>
- 17 Jahangiri, M., Asghari, M., Niksokhan, M. H., & Nikoo, M. R. (2025). BiLSTM-Kalman framework for precipitation downscaling. *Scientific Reports*, 15(1), 24354. <https://doi.org/10.1038/s41598-025-08264-z>
- 18 Kaufman, L., & Rousseeuw, P. J. (1990). *Finding Groups in Data: An Introduction to Cluster Analysis*. Wiley.
- 19 Kourtis, I. M., & Tsihrintzis, V. A. (2022). Update of IDF curves under climate change. *Water Supply*, 22(5), 4951–4974. <https://doi.org/10.2166/ws.2022.152>
- 20 Lanciotti, S., Ridolfi, E., Russo, F., & Napolitano, F. (2022). IDF curves in a data-rich era. *Water*, 14(22), 3705. <https://doi.org/10.3390/w14223705>
- 21 Maity, S. S., & Maity, R. (2022). Changing pattern of IDF relationships. *Water Resources Management*, 36(14), 5371–5399. <https://doi.org/10.1007/s11269-022-03313-y>
- 22 Najafi, H., Lagerwall, G. L., Obeysekera, J., & Liu, J. (2025). Machine learning in climate downscaling: A critical review. *Preprints*. <https://doi.org/10.20944/preprints202511.1538.v1>

- 23 Neelin, J. D., et al. (2022). Precipitation extremes and water vapor. *Current Climate Change Reports*, 8(1), 17–33. <https://doi.org/10.1007/s40641-021-00177-z>
- 24 Rajagopal, S., & Steele, C. M. (2017). Hydrologic processes and prediction needs. *Hydrology and Earth System Sciences*, 21(1), 1–22. <https://doi.org/10.5194/hess-21-1-2017>
- 25 Sachindra, D. A., et al. (2018). Statistical downscaling using machine learning. *Atmospheric Research*, 212, 240–258. <https://doi.org/10.1016/j.atmosres.2018.05.022>
- 26 Struyf, A., Hubert, M., & Rousseeuw, P. J. (1997). Integrating robust clustering techniques in S-PLUS. *Computational Statistics & Data Analysis*, 26, 17–37.
- 27 Sun, T., et al. (2024). ML-based downscaling of GPM precipitation. *Heliyon*, 10(17), e36368. <https://doi.org/10.1016/j.heliyon.2024.e36368>
- 28 Yang, F., et al. (2024). Transformer-based precipitation downscaling. *Remote Sensing*, 16(22), 4292. <https://doi.org/10.3390/rs16224292>
- 29 Zhang, L., et al. (2023). Non-stationary runoff modeling using ML. *Advances in Water Science*, 34(1), 42–52. <https://doi.org/10.14042/j.cnki.32.1309.2023.01.005>