

Statistical Post-processing of the Data-Driven Model for Estimating Spatial Precipitation Changes in the Middle Zagros

Mohammad Saeed Najafi

Assistant Professor, Water Research Institute, Ministry of Energy, Tehran, Iran, Email: ms.najafi@wri.ac.ir

Article Info	ABSTRACT
Article type: Research Full Paper	This study aims to spatially estimate precipitation in the Central Zagros region based on the relationship between precipitation and geographical factors, using data-driven models, and highlighting the importance of statistical post-processing in model outputs. To model precipitation, the Artificial Neural Network (ANN) method was employed. The most suitable network structure was determined using the LM training algorithm. The resulting model demonstrates an explanatory power of 50% ($R^2=0.5$) for the spatial estimation of precipitation in the Central Zagros. To enhance model accuracy, various error correction methods were used for post-processing the model outputs. This stage resulted in an optimization of the simulations by 5 to 10 percent. Among the methods investigated, the Quantile Mapping (QM) method exhibited the best performance, increasing the final correlation between the model simulations and observational values to 0.81. This optimization confirms the necessity of post-processing for correcting the systematic error of data-driven models to achieve the required accuracy in precipitation estimation and water resource management in complex mountainous regions. The results of this study indicated that elevation is the most important controlling factor of precipitation in the Central Zagros region, with a strong and positive relationship between precipitation and elevation. However, the analysis of elevational profiles revealed that the maximum precipitation occurs at an elevation of approximately 2500 meters up to the ridge line, and does not exactly coincide with the maximum elevation at the ridge line. This pattern emphasizes that the most effective orographic condensation processes occur at a level below the summit and may extend up to the ridge line.
Article history: Received: 2025-08-24 Accepted: 2025-11-10	
Keywords: Precipitation Elevation Data-driven model Bias correction Middle Zagros	

Cite this article: Najafi, M.S. (2025). Statistical Post-processing of the Data-Driven Model for Estimating Spatial Precipitation Changes in the Middle Zagros. Journal of the Climate Change research, 6 (24), 89-107.



©The author(s)

Publisher: Golestan University

DOI: [10.30488/ccr.2025.555716.1310](https://doi.org/10.30488/ccr.2025.555716.1310)



نشریه پژوهش‌های تغییرات آب و هوایی



فصلنامه علمی دانشگاه گلستان

سال ششم / شماره مسلسل بیست و چهارم / زمستان ۱۴۰۴ / صفحات: ۸۹-۱۰۷

پس پردازش آماری مدل داده محور برآورد تغییرات مکانی بارش در زاگرس میانی

محمدسعید نجفی

استادیار پژوهشکده مطالعات و تحقیقات منابع آب، مؤسسه تحقیقات آب، وزارت نیرو، تهران، ایران، رایانامه: ms.najafi@wri.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله کامل علمی تاریخ دریافت: ۱۴۰۴/۸/۵ تاریخ پذیرش: ۱۴۰۴/۸/۲۰ واژه‌های کلیدی: بارش ارتفاع مدل داده محور تصحیح خطا زاگرس میانی	این مطالعه با هدف برآورد مکانی بارش در منطقه زاگرس میانی بر اساس روابط بین بارش و عوامل جغرافیایی، استفاده از مدل‌های داده محور و همچنین اهمیت پس‌پردازش آماری در برون‌داد مدل‌ها انجام شده است. برای مدل‌سازی بارش از روش شبکه‌های عصبی مصنوعی استفاده شد. مناسب‌ترین ساختار شبکه (آرایش دو لایه پنهان ۸-۸-۱) با قانون آموزش مارکوات-لونبرگ تعیین شد و میزان تبیین واریانس بارش توسط مدل ارائه شده برای برآورد مکانی بارش در زاگرس میانی ۵۰ درصد ($R^2=0.5$) است. به منظور افزایش دقت مدل، از روش‌های مختلف تصحیح خطا جهت پس‌پردازش خروجی‌های مدل استفاده شد. این مرحله باعث بهینه‌سازی شبیه‌سازی‌ها به میزان ۵ تا ۱۰ درصد شد. در این میان، روش نگاشت چندک (QM) با ارتقاء همبستگی نهایی شبیه‌سازی‌های مدل با مقادیر مشاهداتی از ۰/۷۱ به ۰/۸۱، بهترین عملکرد را در بین روش‌های مورد بررسی داشت. این بهینه‌سازی، ضرورت پس‌پردازش را در تصحیح خطای سیستماتیک مدل‌های داده‌محور برای رسیدن به دقت مورد نیاز در تخمین بارش و مدیریت منابع آب در مناطق کوهستانی پیچیده را تأیید می‌کند. نتایج این مطالعه نشان داد که ارتفاع، مهم‌ترین عامل کنترل‌کننده بارش در منطقه زاگرس میانی است و یک رابطه قوی و مثبت بین بارش و ارتفاع وجود دارد. با این حال، تحلیل نیمرخ‌های ارتفاعی آشکار کرد که حداکثر بارش در ارتفاعی حدود ۲۵۰۰ متر تا خط الرأس رخ می‌دهد و عیناً منطبق با حداکثر ارتفاع در خط الرأس نیست؛ این امر فرضیه تکمیل فرایند تخلیه رطوبت توده‌های هوا قبل از رسیدن به خط الرأس اصلی را تأیید می‌کند.

استناد: نجفی، محمدسعید (۱۴۰۴). پس پردازش آماری مدل داده محور برآورد تغییرات مکانی بارش در زاگرس میانی. نشریه پژوهش‌های تغییرات آب و هوایی، ۶ (۲۴)، ۸۹-۱۰۷.

DOI: [10.30488/ccr.2025.555716.1310](https://doi.org/10.30488/ccr.2025.555716.1310)

ناشر: دانشگاه گلستان

© نویسندگان



مقدمه

رشته کوه زاگرس به عنوان طولانی ترین و پر بارش ترین سامانه کوهستانی ایران، نقش محوری در تأمین منابع آب، شکل دهی به اکوسیستم ها، و مدیریت ریسک های هیدرولوژیکی کشور دارد (مرادی فر و مجرد، ۱۳۸۲). بارش، به عنوان حیاتی ترین عنصر اقلیمی، در این منطقه به شدت تحت تأثیر اثرات اوروگرافیک قرار می گیرد، جایی که توپوگرافی پیچیده و ناهمواری های گسترده، توزیع فضایی آن را به شکلی غیر یکنواخت و دشوار برای مدل سازی درآورده است (Saeidabadi et al., 2016). درک و مدل سازی دقیق توزیع بارش، به ویژه ارتباط آن با ارتفاع، برای مطالعات منابع آب، کشاورزی، و پیش بینی بلایای طبیعی نظیر سیلاب و خشکسالی در این منطقه حیاتی است.

تئوری های کلاسیک در حوزه آب و هواشناسی فرض می کنند که بارش با افزایش ارتفاع، به دلیل صعود آدیاباتیک توده های هوا و تراکم بخار آب، افزایش می یابد؛ اما این رابطه در عمل و در کوهستان های وسیعی مانند زاگرس پیچیده و غیر خطی است (غیور و مسعودیان و همکاران ۱۳۷۵؛ عزیزی و همکاران ۱۳۸۹). مطالعات منطقه ای نشان داده اند که جهت گیری دامنه ها (جهت رو به باد یا پشت به باد)، اثرات سایه باران، و نیز وجود ارتفاع بهینه بارش که پس از آن میزان بارش کاهش می یابد، صحت مدل های ساده خطی و رگرسیون های چند متغیره را زیر سوال می برد (Alijani et al., 2008). این ناهمگونی فضایی و زمانی، به ویژه در نبود شبکه کافی ایستگاه های هواشناسی در ارتفاعات بالا، لزوم استفاده از ابزارهای پیشرفته و غیر خطی برای برآورد دقیق نقشه بارش را دوچندان می سازد.

روش های مختلفی برای تخمین بارش در مناطق کوهستانی وجود دارد که (Daly et al., 1994) این روش ها را به سه دسته گرافیکی، توپوگرافی و عددی طبقه بندی کرده اند. مطالعات زیادی وجود دارد که رابطه بین بارش و ارتفاع و همچنین تخمین بارش در مناطق کوهستانی را با استفاده از روش های مختلف مانند روش های زمین آماری (Lloyd, Attorre et al.,

2007; Luo et al., 2024)، روش های رگرسیونی (پودینه و همکاران، ۱۳۹۴؛ Taylor, 1996) و روش های یادگیری ماشین (عساکره و همکاران، ۱۴۰۰؛ Saeidabadi et al., 2016) بررسی کرده اند. از طرف دیگر علی رغم توانایی مدل ها در برآورد بارش، خروجی های خام آن ها همچنان مستعد عدم قطعیت و سوگیری هستند. برای مثال در مدل های داده محور این خطاها می توانند ناشی از آموزش بیش از حد^۱ مدل، کیفیت متغیرهای ورودی یا خطاهای مدل سازی ساختاری باشند. از این رو، پس پردازش به یک گام ضروری برای بهبود کیفیت پیش بینی و برآورد بارش تبدیل می شود (Wang et al., 2025). پس پردازش، شامل تکنیک هایی است که به طور سیستماتیک خطاهای باقیمانده مدل را حذف یا کاهش می دهد و دقت آماری خروجی ها را تقویت می کند. با توجه به طبیعت غیر خطی پدیده بارش، روش های سنتی آماری و دینامیکی اغلب در پیش بینی یا برآورد آن دچار محدودیت های جدی هستند. در دهه های اخیر، شبکه های عصبی مصنوعی^۲ (ANN) به عنوان بخشی از حوزه یادگیری ماشین، به دلیل قابلیت فوق العاده شان در بازنمایی روابط پیچیده و چندبعدی، توجه بسیاری را در علوم آب و هواشناسی به خود جلب کرده اند (Salimi et al., 2019) که می تواند به طور مؤثر روابط پنهان میان متغیرهای توپوگرافیک و جوی (مانند مدل رقومی ارتفاع، طول و عرض جغرافیایی، و پارامترهای ترمودینامیکی) را با داده های بارش ایستگاه های زمینی آموزش دهد و خروجی هایی مکانی-زمانی برای مناطق فاقد داده ارائه دهد (Bouach 2024).

از این رو، اعمال تکنیک های پس پردازش که شامل روش های ریز مقیاس نمایی و اصلاح اریبی است، به عنوان یک مرحله ضروری و پیش نیاز حیاتی برای افزایش قابلیت اطمینان و دقت مدل ها در کاربردهای محلی در نظر گرفته می شود (Schepen et al., 2017; Zhao et al., 2017). فرض اصلی در توجیه فرآیند

1. Overfitting

2. Artificial Neural Networks

پس‌پردازش پیش‌بینی‌ها این است که یک همبستگی آماری قابل اتکا بین مقادیر مدل‌سازی‌شده و مقادیر مشاهداتی وجود دارد و رفتار سیستم در تولید این خطاها در آینده نیز مشابه گذشته باقی خواهد ماند (اصل ایستایی در خطای سیستم) (Khajehi and Moradkhani, 2017). به همین سبب، در فرآیند پس‌پردازش، اغلب از تکنیک‌هایی استفاده می‌شود که توزیع فراوانی خطاهای مشاهده‌شده مدل در دوره آموزش را با روش‌های آماری شناسایی کرده و از این اطلاعات برای حذف خطای سیستماتیک و اصلاح پیش‌بینی‌های جدید مدل در آینده بهره می‌برند. این مرحله به‌ویژه در مدل‌های داده‌محور که ممکن است در تخمین مقادیر حدی دچار سوگیری غیرخطی شوند، اهمیت دوچندان می‌یابد و تعیین می‌کند که آیا خروجی مدل قابلیت استفاده عملیاتی در مدیریت منابع آب را دارد یا خیر.

در خصوص موضوع مورد بررسی مطالعه Marquínez et al., (2003) به برآورد توزیع فضایی میانگین بارش ماهانه برای دوره‌های فصلی و سالانه در یک منطقه کوهستانی در سواحل کانتابریای اسپانیا پرداخته‌اند. در این مطالعه از تکنیک‌های رگرسیون خطی چندگانه و سیستم اطلاعات جغرافیایی برای تخمین بارش استفاده شده است. نتایج آن‌ها نشان داد که رگرسیون خطی چندگانه امکان تخمین بارش در مناطق فاقد داده و همچنین مناطق با توپوگرافی پیچیده را فراهم می‌کند؛ مشابه یافته‌های عزیزی و همکاران برای زاگرس میانی (عزیزی و همکاران ۱۳۸۸). Sasaki & Kurihara (2008) به بررسی رابطه بین بارش و ارتفاع شبیه‌سازی شده توسط مدل منطقه‌ای غیرهیدرواستاتیک (NHRCM) می‌پردازند. هدف اصلی این تحقیق، بررسی توانمندی مدل در شبیه‌سازی تأثیر عوارض زمین (توپوگرافی) در تخمین بارش را در مناطق مرکزی ژاپن طی ماه‌های ژوئن و ژوئیه بود. نتایج آن نشان داد که مدل NHRCM توانسته است رابطه بین بارش و ارتفاع را به خوبی بازتولید کند، اگرچه با افزایش ارتفاع، پیچیدگی محاسبات افزایش می‌یابد و دقت مدل کاهش پیدا می‌کند.

کند. صفرراد و همکاران (۱۳۹۳) با به‌کارگیری روش زمین‌آمار، تغییرات مکانی بارش سالانه را در ناحیه کوهستانی زاگرس میانی مدل‌سازی و تشریح کردند. نتایج آن‌ها حاکی از دقت بالاتر روش کریجینگ معمولی با متغیرهای کمکی عرض جغرافیایی و فاصله از خط‌الرأس در تخمین بارش بود. همچنین، این پژوهش تأکید کرد که ناهمواری‌ها نقش مانع را در مسیر توده‌های هوا ایفا کرده، اما بیشینه بارش دقیقاً بر حداکثر ارتفاعات منطبق نیست. عساکره و همکاران (۱۳۹۸) با استفاده از روش‌های زمین‌آمار و رگرسیون جغرافیایی وزن‌دار، الگوی بارش‌های بهار شمال غرب ایران را در دوره ۱۳۷۲-۱۳۹۲ بررسی کردند. نتایج آن‌ها نشان داد که ناهمواری‌ها بیشترین کنترل را بر بارش در کل این منطقه دارند. همچنین، کاهش توزیع مکانی بارش از آوریل به ژوئن، نشان‌دهنده کاهش وسعت عملکرد سامانه‌های بزرگ‌مقیاس و افزایش نقش عوامل محلی در اواخر بهار است. Gan et al., (2024) به منظور رفع مشکل کمبود داده‌های بارش با کیفیت و تفکیک مکانی بالا در مناطق کوهستانی با توپوگرافی پیچیده، بر روی ریز مقیاس‌گردانی محصول بارش ماهواره‌ای GPM در یک منطقه کوهستانی در چین متمرکز شدند. روش کار شامل کالیبراسیون اولیه با ایستگاه‌ها و سپس ریز مقیاس‌سازی محصول GPM (از ۰/۱ درجه به ۰/۰۱ درجه) با استفاده از الگوریتم‌های $^{1}L_{F}$ ، $^{2}XGBoost$ و $^{3}LSTM$ بود. نتایج نشان داد که الگوریتم LSTM پتانسیل بیشتری برای ریز مقیاس‌سازی محصول بارش GPM در این منطقه نشان داد. این تحقیق یک طرح امیدوارکننده برای تولید داده‌های بارش با کیفیت بالا برای مناطق کوهستانی با پوشش ایستگاهی پراکنده و ناهمواری‌های پیچیده ارائه داد.


این مطالعه با هدف اصلی ارائه یک چارچوب روش‌شناختی بهینه و قابل تعمیم برای برآورد مکانی بارش در مناطق کوهستانی پیچیده، به طور نمونه ارتفاعات زاگرس میانی، تدوین شده است. نوآوری

1. Random Forest
2. Extreme Gradient Boosting
3. Long Short-Term Memory

نظر مختصات جغرافیایی، بین طول‌های جغرافیایی ۴۵/۲۴ تا ۵۱ درجه غربی و عرض‌های ۳۲/۰۲ تا ۳۶/۰۴ درجه شمالی واقع شده است. مهم‌ترین ویژگی این منطقه، ناهمواری شدید توپوگرافی است که دامنه ارتفاعی گسترده‌ای از کمینه ۲۸ متر تا بیشینه ۴۰۴۹ متر را در بر می‌گیرد. این دامنه ارتفاعی وسیع، منجر به ایجاد گرادیان‌های شدید اقلیمی و تغییرات سریع در توزیع مکانی بارش می‌شود. بر اساس داده‌های مشاهده‌ای، متوسط بارش نقطه‌ای این ناحیه ۴۶۹ میلیمتر است. با این حال، تأثیرات کوهساری بر سیستم‌های بارشی مدیترانه‌ای، توزیع مکانی بارش را بسیار متغیر و غیرخطی می‌سازد. بنابراین، این منطقه از نظر مدل‌سازی بارش و اعتبار سنجی مدل‌های داده‌محور در شرایط توپوگرافی پیچیده، یک نمونه چالش‌برانگیز محسوب می‌شود.

محوری این پژوهش، تأکید و اثبات ضرورت مطلق پس‌پردازش آماری برای دستیابی به دقت عملیاتی در خروجی مدل‌های داده‌محور است. نتایج این تحقیق، نه تنها با اثبات لزوم پس‌پردازش، یک چارچوب عملی و قابل تعمیم را برای استفاده مؤثر از مدل‌های داده محور در اقلیم‌شناسی منطقه‌ای و هیدرولوژی ارائه خواهد داد، بلکه به تصمیم‌گیرندگان منابع آب کمک می‌کند تا در کنار سایر منابع، برآوردهای دقیق‌تری از آب قابل دسترس در مناطق کوهستانی داشته باشند.

منطقه مورد مطالعه: منطقه مورد مطالعه در این پژوهش، بخش میانی رشته کوه زاگرس در غرب ایران را در بر می‌گیرد (شکل ۱)، که از نظر هیدرولوژیک به‌عنوان اصلی‌ترین منبع تأمین آب حوضه‌های مرکزی و غربی کشور شناخته می‌شود. این ناحیه وسیع، استان‌های کردستان، کرمانشاه، ایلام، لرستان، همدان و بخش‌هایی از اصفهان و مرکزی را شامل شده و از



شکل ۱: موقعیت ایستگاه‌ها، منطقه مورد مطالعه و نیم‌رخ‌های ارتفاعی مورد بررسی در این مطالعه

داده‌ها و روش‌ها

بمنظور انجام این تحقیق از داده‌های ۱۹۶ ایستگاه ثبت بارش شامل ایستگاه‌های باران سنجی و همدید سازمان هواشناسی و وزارت نیرو در یک دوره آماری ۲۲ ساله (۱۹۹۵-۲۰۱۶) استفاده شده است. به منظور افزایش تعداد ورودی‌های مدل مورد بررسی و همچنین در نظر گرفتن تغییرات بارش در منطقه در فصول مختلف، مقیاس داده‌های مورد استفاده بارش ماهانه در نظر گرفته شد. در انتخاب داده‌های آموزشی، ایستگاه‌هایی که دارای نقص بودند، از فرایند این تحقیق خارج شدند و در نهایت ۱۹۶ ایستگاه که فاقد داده‌های ناقص بودند، برای این مطالعه انتخاب شد. موقعیت ایستگاه‌ها در شکل ۱ نشان داده شده است. بمنظور آزمون نرمال بودن داده‌های بارش از آزمون ناپارامتری کولموگروف اسمیرنوف استفاده شده است. فرضیه‌های مورد بررسی در این بخش عبارتند از:

فرض H_0 مبنی بر اینکه داده‌ها دارای توزیع نرمال هستند؛

فرض H_1 (مبنی بر اینکه داده‌ها دارای توزیع نرمال نیستند)؛

همچنین برای مدل‌سازی مکانی بارش در زاگرس میانی از روش شبکه‌های عصبی مصنوعی استفاده شده است.

شبکه عصبی مصنوعی و ورودی‌ها: مدل‌های داده‌محور که زیرمجموعه‌ای از یادگیری ماشین هستند، به‌عنوان یک راه‌حل مناسب برای مدل‌سازی پدیده‌های زیست‌محیطی پیچیده مطرح هستند که روابط حاکم بر آن‌ها، مانند رابطه بارش و توپوگرافی، غیرخطی، یا فاقد یک معادله فیزیکی صریح و ساده هستند. برخلاف مدل‌های فیزیکی که نیاز به پارامترهای متعدد و ورودی‌های دقیق دارند، مدل‌های داده‌محور مانند شبکه‌های عصبی مصنوعی (ANN)، ماشین‌های بردار پشتیبان (SVM/SVR) و جنگل تصادفی^۱ (Random Forest)، بر اساس الگوهایی عمل می‌کنند که مستقیماً از داده‌های ورودی و خروجی استخراج کرده‌اند. این روش‌ها در حوزه هیدرولوژی، به‌ویژه در

تخمین مکانی بارش در مناطق ناهموار، کارایی بالایی دارند؛ زیرا می‌توانند تأثیرات پیچیده عوامل جغرافیایی (مانند ارتفاع، شیب و جهت شیب) بر الگوی بارش را با دقت بالایی فرا بگیرند.

شبکه عصبی مصنوعی به عنوان یکی از روش‌های یادگیری ماشین، در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و غیرمماندگار فرایندهایی که برای شناخت و توصیف دقیق آن‌ها راه‌حل و رابطه صریح وجود ندارد، عملکرد خوبی از خود نشان داده است (Akponi et al., 2025). این روش در قیاس با دیگر روش‌ها، حساسیت کمتری نسبت به وجود خطا در اطلاعات ورودی دارد. مدل‌های شبکه عصبی مصنوعی بر اساس روابطی که بین ورودی‌ها و خروجی‌ها در دوره آموزش استخراج می‌کنند (۸۰ درصد ورودی‌ها)، رفتار سیستم را پیش‌بینی می‌کنند. از ۲۰ درصد باقی مانده نیز برای آزمون کارایی خروجی‌ها استفاده می‌شود. بر اساس مطالعه (Gardner & Dorling, 1998) در علوم جو معمولاً از شبکه عصبی مصنوعی پرسپترون چند لایه با الگوریتم پس انتشار خطا استفاده می‌شود. این شبکه اساساً جزء شبکه‌های پیش‌خور^۲ شمرده می‌شود که معمولاً به وسیله مدل انتشار به عقب^۳ آموزش داده می‌شود. در این مدل، خطای خروجی شبکه برآورد و به عقب به داخل سیستم انتشار یافته و بر این اساس وزن‌های انتخاب شده در مدل اصلاح می‌شود. این فرایند مربوط به اصلاح وزن‌ها، در تمامی عناصر سیستم ادامه میابد تا بهترین وزن‌ها که صحیح‌ترین خروجی را برای سیستم ایجاد می‌کنند، شناسایی و انتخاب شوند. همچنین در شبکه عصبی چند لایه، ارتباط بین عناصر ورودی در لایه اول (X) و خروجی در لایه آخر (Y)، به کمک وزن‌های نرونی (W)، بایاس و تابع عضویت (F) در لایه‌های میانی است. روش آموزش شبکه نیز بر پایه قوانین لونیگ مارکوات، مومنتوم، دلتا بار دلتا، استپ، گرادینان مزدوج و تند انتشار بوده (عیسی زاده، ۱۳۹۶)

2. Feed Forward
3. Backpropagation

1. Random Forest

و از تابع محرک سیگموئید نیز بواسطه عملکرد مناسب آن برای مدل سازی مکانی بارش استفاده شد. جهت گزینش ساختار بهینه، از شبکه عصبی مصنوعی با دو و سه لایه پنهان و از تعداد نرون های متفاوت در لایه (های) میانی استفاده شد. تعداد گام های پیش فرض (Epoch) در آموزش شبکه عصبی مصنوعی

(۱)

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (S_i - \bar{S})^2}}$$

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (S_i - \bar{S})^2}} \right)^2 \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (S_i - O_i)^2}{n}} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |S_i - O_i|}{n} \quad (4)$$

که در این روابط O_i مقادیر مشاهداتی، S_i مقادیر برآورد شده، $\bar{O}$ میانگین مقادیر مشاهده شده و $\bar{P}$ میانگین مقادیر پیش بینی شده، n تعداد داده ها می باشد. ورودی های مدل علاوه بر بارش عبارتند از:

- ارتفاع، شیب و جهت شیب: متغیر ارتفاع به عنوان عامل صعود اجباری توده های هوا در مناطق کوهستانی و از مهمترین عوامل تأثیرگذار بر بارش های هر منطقه، مخصوصاً در مناطق کوهستانی است (عزیزی و همکاران، ۱۳۸۹) بطوریکه بسیاری از مطالعات، وجود همبستگی مثبت و منفی بین ارتفاع و میزان بارش در مناطق کوهستانی را ثابت کرده اند (ساری صراف و همکاران، ۱۳۸۸). جهت شیب، با توجه به موقعیت جغرافیایی ارتفاعات مورد مطالعه، جهت قرارگیری کوهستان در مسیر توده های هوای باران آور یا در سمت خلاف آن، در میزان بارش تأثیر گذار است. میزان شیب نیز بیانگر نحوه تغییرات مکانی ارتفاع در منطقه مورد نظر است و معمولاً شیب های تندتر می توانند به بارش های بیشتری منجر شوند. این مسئله برای منطقه زاگرس میانی نیز به اثبات رسیده و میزان شیب با بارش دریافتی دارای ارتباط مثبت و معنادار می باشد (عزیزی و همکاران، ۱۳۸۹).

- فاصله تا منبع تأمین کننده رطوبت منطقه: که به صورت کوتاه ترین فاصله مستقیم بین ایستگاه و

۱۰۰۰ گام و تغییرات نرون های لایه های میانی بین ۱ تا ۱۲ نرون در نظر گرفته شد. معیار ارزیابی ساختار بهینه شبکه عصبی مصنوعی نیز عبارتند از ضریب همبستگی (رابطه ۱) و ضریب تعیین (R^2) (رابطه ۲)، مجذور میانگین مربعات خطا (RMSE) (رابطه ۳)، میانگین قدر مطلق خطا (MAE) (رابطه ۴).

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (S_i - \bar{S})^2}}$$

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (S_i - \bar{S})^2}} \right)^2$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (S_i - O_i)^2}{n}}$$

$$MAE = \frac{\sum_{i=1}^n |S_i - O_i|}{n}$$

منبع تأمین کننده رطوبت اندازه گیری شده است. در این مطالعه منابع تأمین کننده رطوبت بارش های منطقه زاگرس، دریای مدیترانه (علیچانی، ۲۰۰۸، دریای سرخ و خلیج فارس در نظر گرفته شده است.

- فاصله از خط الرأس: فاصله از خط الرأس مبین فاصله از محور مرتفع ناهمواری ها به عنوان عامل صعود توده های هوا است که با نگاه کلی چنین فرض می شود که نقطه بیشینه بارش در بسیاری از مناطق کوهستانی در خط الرأس ها اتفاق می افتد.

- فاصله از نقطه ارتفاعی ۲۳۰۰ متر: عزیزی و همکاران (۱۳۸۹) نشان می دهند که نقطه بیشینه بارش در زاگرس میانی در ارتفاعات بین ۱۳۰۰ تا ۲۳۰۰ متر و قرار دارد و این میزان در ستیغ کوه ها نیست. بنابراین در این مطالعه فاصله از بیشینه ارتفاعی دریافت حداکثر بارش مورد نظر قرار گرفته شده است. همچنین این عامل می تواند در صعود اروگرافیک و جذب رطوبت در منطقه مؤثر باشد.

- فاصله از مانع کوهستانی که ارتفاع آن ۵۰۰ متر بیشتر از ارتفاع ایستگاه است: عامل می تواند به عنوان یک مانع توپوگرافیک و پدیده باز دارنده در جذب رطوبت عمل کند و باعث ایجاد حالت بادپناهی و کاهش بارش ایستگاه شود.

• **طول و عرض جغرافیایی:** رضیئی و عزیزی (۱۳۸۶) عرض جغرافیایی را به عنوان یک عامل تأثیر گذار در مرزبندی مناطق بارشی زاگرس تشخیص داده و در مطالعه‌ای دیگر عزیزی و همکاران (۱۳۸۹) نشان می‌دهند در منطقه زاگرس میانی بین طول و عرض جغرافیایی و میزان بارش دریافتی رابطه معنادار وجود دارد. طول و عرض جغرافیایی مبین دوری و نزدیکی به منابع رطوبتی است. همچنین عرض جغرافیایی می‌تواند بیانگر این فرضیه باشد که با افزایش عرض جغرافیایی میزان متوسط دما کاهش پیدا کرده و در نتیجه ظرفیت رطوبتی هوا کاهش یافته و میزان بارش افزایش پیدا می‌کند.

در نهایت مقادیر هریک از متغیرهای اشاره شده برای خطوط تعیین شده در ۵ نیمرخ ارتفاعی (شکل ۱) در محیط GIS استخراج و برآورد بارش بر اساس شبکه عصبی مصنوعی برای آن‌ها انجام شد.

روش‌های پس‌پردازش: در این مطالعه از روش‌های نگاشت چندک، مقیاس‌دهی خطی، مقیاس‌دهی واریانس و نگاشت توزیع گاما برای پس‌پردازش خروجی‌های بارش حاصل از شبکه عصبی مصنوعی استفاده شد. لازم به توضیح است که بارش برآورد شده برای پروفایل‌های تعیین شده در شکل ۲، به وسیله مناسب‌ترین روش که در بخش آزمون تعیین گردید، پس‌پردازش شده است. همچنین ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده به عنوان آزمون بر اساس تابع برازش شده در دوره آموزش، پس‌پردازش شد. برای ارزیابی روش‌های پس‌پردازش، از رابطه (۱) و در غالب نمودارهای تیلور استفاده شد.

روش نگاشت چندک^۹ (QM): روشی ساده در پس‌پردازش و اصلاح اریبی‌های توزیع سیستماتیک در خروجی‌های بارش از مدل‌های آب و هوایی است که قابلیت خوبی در حذف اریبی گشتاورهای اول و دوم آماری (میانگین و انحراف معیار) دارد (Ajaaj et al., 2015). هدف اصلی این روش تطبیق کامل توابع توزیع تجمعی^{۱۰} متغیر مورد مطالعه است و بر این فرضیه

زیربنایی استوار است که اگرچه مدل در شبیه‌سازی مقادیر مطلق دارای اریبی است، اما در رتبه‌بندی یا تولید چندک‌ها^{۱۱} دارای مهارت مناسبی است. این روش با جایگزین کردن مقدار پیش‌بینی شده با مقدار مشاهداتی در چندک مشابه موجب حذف اریبی می‌شود (Li et al., 2017). با این رویکرد، اریبی مدل در سراسر توزیع - از مقادیر پایین تا مقادیر حدی - تصحیح می‌شود و این تضمین‌کننده بهبود قابل توجه در دقت آماری و هیدرولوژیکی پیش‌بینی‌ها برای متغیری مانند بارش است (Voisin et al., 2010). در این روش با استفاده از معادله خط بین داده‌های مشاهداتی و پیش‌بینی‌های خام، یک تابع تبدیل $h(x)$ به دست می‌آورد. بر اساس این تابع میتوان توزیع روزانه بارش‌های پیش‌بینی شده P_F را با توزیع روزانه بارش‌های ثبت شده در ایستگاه‌ها P_O ، تنظیم و تعدیل کرد. تابع تبدیل h بر اساس رابطه ۱ فرمول‌بندی می‌شود (Gudmundsson et al., 2012):

$$P_O = h(P_F)$$

در صورتی که متغیر مورد نظر دارای یک توزیع شناخته شده باشد، رابطه‌ی آن به شرح زیر بیان می‌شود:

$$P_F = F_O^{-1}(F_F(P_F))$$

که در آن تابع توزیع تجمعی F_F تابع توزیع تجمعی^{-۱} (CDF) متغیر P_F و F_O^{-1} معکوس CDF متغیر P_O است.

در این مطالعه برای اجرای این روش از بسته نرم افزاری qmap (Gudmundsson, 2016) در نرم افزار R استفاده شد. همچنین از تکنیک ارزیابی Leave-One-Out Cross Validation (LOOCV) استفاده شد. این تکنیک حالت خاصی برای leave-K-out cross-validation است که در آن K برابر با ۱ در نظر گرفته می‌شود. در این حالت، به عنوان مثال برای ارزیابی یک دوره ۲۰ ساله، مدل ۲۰ مرتبه و هر مرتبه با ۱۹ داده آموزش داده می‌شود و داده‌هایی که بیرون نگه داشته شده پیش‌بینی می‌گردد. این روش امکان شرکت کلیه مقادیر در فرآیند آموزش را فراهم می‌کند (کلاچیان و همکاران، ۱۳۹۹).

1. Quantile Mapping

2. Cumulative Distribution Functions - CDFs

3. Quantile

توزیع شبیه سازی مدل را به طور مؤثرتری به سمت توزیع مشاهدات سوق می دهد و در نتیجه، نوسانات و پراکندگی مقادیر (Variability) مدل را نیز اصلاح می کند. این روش اهمیت بالایی در مطالعات اقلیمی و هیدرولوژیکی دارد و VS با تنظیم واریانس، توانایی مدل را در شبیه سازی رویدادهای حدی می تواند بهبود بخشد.

فرایند تصحیح اریبی با استفاده از روش مقیاس دهی واریانس شامل دو مرحله است. ابتدا، اریبی میانگین حذف می شود و در گام دوم، انحراف معیار داده های مدل با مشاهدات تطبیق داده می شود. تابع تصحیح نهایی به شکل زیر تعریف می شود (Fang et al., 2015):

$$Z_i = (X_i - \mu_{model}) \times \frac{\sigma_{obs}}{\sigma_{model}} + \mu_{obs}$$

که در آن Z_i پیش بینی تصحیح شده پارامتر هواشناسی (بارش) در هر ماه، X_i پیش بینی خام پارامتر هواشناسی در همان ماه، μ_{obs} متوسط بارش مشاهداتی در دوره آموزش، μ_{model} متوسط بارش پیش بینی شده در دوره آموزش، σ_{obs} واریانس بارش مشاهداتی در دوره آموزش، σ_{model} واریانس بارش پیش بینی شده در دوره آموزش می باشد (Fang et al., 2015). برای اجرای روش (VS) از بسته نرم افزاری Climate4R در نرم افزار R استفاده شد (Frías et al., 2018).

روش نگاشت توزیع گاما^{۱۶} (GDM): یک تکنیک تصحیح اریبی پارامتری است که به طور خاص برای پس پردازش متغیرهای اقلیمی با توزیع های نامتقارن و نامنفی، مانند بارش روزانه یا ماهانه، طراحی شده است. توزیع گاما به خوبی با توزیع آماری بارش سازگاری دارد و برای این تصحیح اریبی پیش بینی های این متغیر معمولاً استفاده می شود (Aminyavari and Saghafian, 2019). نگاشت توزیع گاما فرض می کند که هم داده های شبیه سازی مدل و هم داده های مشاهداتی را می توان با این توزیع پارامتری برازش داد. این روش با برآورد پارامترهای توزیع گاما برای هر دو مجموعه داده در دوره کالیبراسیون و سپس استفاده از این توابع برای ایجاد تابع نگاشت، اریبی را در سراسر

روش مقیاس دهی خطی^{۱۲} (LS): این روش یکی از ساده ترین و پرکاربردترین تکنیک های تصحیح اریبی آماری است که عمدتاً برای تنظیم میانگین مدل های اقلیمی یا پیش بینی های عددی استفاده می شود تا با میانگین مشاهدات تاریخی مطابقت یابد. این روش بر پایه این فرض عمل می کند که اریبی سیستماتیک مدل در یک دوره کالیبراسیون، یک عامل افزایشی ثابت^{۱۳} برای متغیرهایی مانند دما یا یک عامل ضربی ثابت^{۱۴} برای متغیرهایی مانند بارش است. سادگی محاسباتی و عدم نیاز به برازش توزیع های پیچیده، مقیاس دهی خطی را به یک انتخاب اولیه و مؤثر تبدیل کرده است؛ به طوری که در بسیاری از مطالعات ارزیابی پس پردازش مدل های اقلیمی و پیش بینی در حوزه های آب و هوایی مختلف ایران، به ویژه برای تصحیح اریبی دمای روزانه و فصلی، نتایج قابل قبولی را نشان داده اس (نوبخت و همکاران، ۱۴۰۱؛ شعبانپور و همکاران، ۱۳۹۹). معادله روش روش مقیاس دهی خطی صورت زیر است:

$$Z_i = X_i \times \frac{\mu_{obs}}{\mu_{model}}$$

که در آن Z_i پیش بینی پس پردازش شده بارش یا دما و X_i پیش بینی خام، μ_{obs} متوسط بارش (یا دما) مشاهداتی در دوره آموزش و μ_{model} متوسط بارش (یا دما) پیش بینی خام در دوره آموزش است. برای اجرای روش (LS) از بسته نرم افزاری Climate4R در نرم افزار R استفاده شد (Frías et al., 2018).

روش مقیاس دهی واریانس^{۱۵} (VS): این روش که گاهی به آن مقیاس دهی و انحراف معیار نیز گفته می شود، یک تکنیک پس پردازش آماری است که به عنوان یک گام پیشرفته تر نسبت به روش مقیاس دهی خطی (LS) عمل می کند. در حالی که LS تنها اریبی میانگین مدل را تصحیح می کند، روش VS با هدف حذف اریبی در هر دو گشتاور اول و دوم توزیع، یعنی میانگین (μ) و انحراف معیار (σ)، مورد استفاده قرار می گیرد. با تنظیم این دو پارامتر کلیدی، روش VS

1. Linear Scaling
2. Additive Bias
3. Multiplicative Bias
4. Variance Scaling

Frias et al.,) در نرم افزار R استفاده شد (2018).

یافته‌ها

کارایی مدل داده محور و روش‌های تصحیح خطا:
بمنظور دستیابی به مدل تغییرات مکانی بارش ابتدا نرمال بودن متغیر بارش با استفاده از آزمون کولموگروف-اسمیرنوف آزمون شد و فرض H_0 مبنی بر اینکه داده‌ها دارای توزیع نرمال هستند در مقابل فرض H_1 (مبنی بر اینکه داده‌ها دارای توزیع نرمال نیستند) پذیرفته می‌شود (جدول ۱). نتایج حاصل از آزمون کولموگروف-اسمیرنوف نشان می‌دهد که مقدار معناداری (Sig) داده‌های بارش برابر با ۰/۰۳۲ است که نشان از نرمال بودن داده‌های بارش است. همچنین بمنظور بررسی رابطه بین متغیرها و میزان بارش از آزمون همبستگی پیرسون استفاده شد که نتایج آن در جدول ۲ آورده شده است.

توزیع تصحیح می‌کند. توزیع گاما با دو پارامتر α و β دارای تابع توزیع احتمال زیر است:

$$f_x(x|\alpha\beta) = \frac{\beta}{\Gamma(\alpha)} \beta(X)$$

تابع توزیع گاما، $\Gamma(\alpha)$ برای مقادیر صحیح α برابر با $(\alpha - 1)!$ است. پارامتر مثبت α شکل توزیع را نشان می‌دهد و مقدار α و β از روابط زیر محاسبه می‌شوند:

$$\alpha = \frac{\bar{x}^2}{S_x^2} \quad \beta = \frac{\bar{x}}{S_x^2}$$

که در رابطه فوق $\bar{x}$ میانگین و S_x انحراف معیار مقادیر بارش است. اگر P_{cor} و P_{raw} به ترتیب بارش خام و تصحیح شده در هر ماه باشند، و F_{obs} و F_{raw} به ترتیب نشان دهنده CDFهای پیش‌بینی خام و مشاهداتی باشند، رابطه زیر روند مورد استفاده برای تصحیح بارش پیش‌بینی شده را نشان می‌دهد:

$$P_{cor} = F_{obs}^{-1}[F_{raw}(P_{raw})]$$

برای اجرای روش (GDM) از بسته نرم‌افزاری

جدول ۱: نتایج آزمون کولموگروف-اسمیرنوف

بارندگی		تعداد
۱۹۶		
Normal Parameters	میانگین	۴۶۹/۰۹
	انحراف معیار	۱۵۵/۹۹
Most Extreme Differences	مقدار مطلق	۰/۱۰۸
	مثبت	۰/۱۰۸
	منفی	-۰/۰۷۸
Kolmogorov-Smirnov Z		۱/۴۳۸
Asymp. Sig. (2-tailed)		۰/۰۳۲

جدول ۲: همبستگی متغیرهای مورد استفاده و بارش (**در سطح ۹۹ درصد اطمینان و *در سطح ۹۵ درصد اطمینان)

متغیر	بارش	معناداری (Sig)
طول جغرافیایی	-۰/۱۹۳**	۰/۰۰۱
عرض جغرافیایی	۰/۱۲۹*	۰/۰۲۷
ارتفاع	-۰/۱۱۳*	۰/۰۴۹
جهت شیب	-۰/۰۱۵	۰/۷۹۲
میزان شیب	۰/۴۲۸**	۰/۰۰۰
فاصله از خط بیشینه بارش (۲۳۰۰ متر)	-۰/۲۴۲**	۰/۰۰۰
فاصله از مانع با ارتفاع ۵۰۰ متر بیش از ارتفاع ایستگاه	-۰/۰۸۷	۰/۱۳
فاصله از خط الرأس	-۰/۲۶۴**	۰/۰۰۰
فاصله از دریای سرخ	-۰/۰۴۳	۰/۴۵۸
فاصله از خلیج فارس	-۰/۱۱۹*	۰/۰۳۹
فاصله از دریای مدیترانه	-۰/۱۱۵*	۰/۰۴۴

و ۳ لایه پنهان، در جدول ۲ ارائه شده است. آرایش‌های پیشنهادی به صورت ۳-۱-۱ و ۴-۱-۱ در ساختار دو لایه میانی و ۳-۱-۱ و ۴-۱-۱-۱ در ساختار سه لایه میانی هستند که n و m به عنوان تعداد نرون‌ها در لایه (های) میانی می‌باشند. لازم به ذکر است که بمنظور ایجاد ساختار متقارن، تعداد نرون‌ها در لایه‌های میانی یکسان در نظر گرفته شدند (زارع ابیانه و همکاران، ۱۳۹۰).

برای تعیین نوع ورودی‌ها به شبکه، پس از آزمون ورودی‌ها، ابتدا کلیه متغیرها (اعم از متغیرهای معنی دار و بی معنی) به عنوان ورودی به شبکه معرفی شدند ولی نتایج شبکه چندان رضایت بخش نبود. سپس متغیرهای بی معنی از ورودی‌های حذف گردید و ۸ متغیر معنادار به شبکه معرفی شد که نتایج حاصل از عملکرد شبکه در این بخش رضایت بخش تر بود. بنابراین در مدلسازی شبکه‌های عصبی مصنوعی همانند رگرسیون چند متغیره، اگر متغیرهای با همبستگی معنادار به شبکه معرفی شوند، نتایج عملکرد شبکه به واقعیت نزدیکتر می‌باشد. نتایج بکارگیری شبکه‌های عصبی مصنوعی در میان آرایش‌های موجود برای برآورد مکانی بارش، آرایش دو لایه میانی یعنی ۸-۸-۱ دارای بهترین عملکرد بوده و میزان همبستگی حاصل شده بین داده‌های مشاهداتی و شبیه‌سازی شده در بخش آزمون ۰/۷۱ و میزان خطا (RMSE) ۲/۵۸ بوده است (شکل ۲). همچنین میزان ضریب تعیین مدل ارائه شده حاصل از شبکه‌های عصبی مصنوعی جهت برآورد مکانی بارش، ۰/۵ می‌باشد.


در این تحقیق از مدل شبکه عصبی مصنوعی پرسپترون چند لایه با ساختار پس انتشار خطا، برای برآورد مکانی بارش در منطقه زاگرس میانی استفاده گردید. سپس برای انتخاب پارامترهای قابل تنظیم و در نتیجه تعیین بهترین ساختار شبکه عصبی، تعداد زیادی شبکه عصبی با ساختار مختلف طراحی و ارزیابی گردید. این شبکه‌ها با تغییر پارامترهای قابل تنظیم شامل (توابع انتقال، قانون یادگیری، تعداد لایه‌های میانی، تعداد نرون‌های لایه میانی، تعداد الگوها و متغیرهای ورودی) ساخته و اجرا شدند. دقت این شبکه‌ها به وسیله معیارهای آماری محاسبه شده در مرحله آزمون، بررسی گردید و در نهایت شبکه ای که در آن داده‌های شبیه سازی شده با داده‌های تجربی دارای بیشترین همبستگی بود به عنوان شبکه اصلی انتخاب شد. در ابتدا بمنظور یافتن بهترین قانون آموزش از بین قوانین لونبرگ مارکوات، مومنتوم، دلتا بار دلتا، استپ، گرادیان مزدوج و تند انتشار، عملکرد شبکه آزمون شد (جدول ۱). در بین قوانین آموزش ذکر شده قانون مارکوات لونبرگ با بیشترین ضریب همبستگی (۰/۷۱) و کمترین خطا (۲/۵۸) دارای مناسب ترین عملکرد در برآورد مکانی بارش در زاگرس میانی بود. همچنین روش آموزش Step با خطای (RMSE) ۳/۱۶۶ پس از روش LM دارای مناسب ترین عملکرد و روش مومنتوم با مجذور میانگین مربعات خطای ۹/۳۱۳ دارای نامناسب ترین عملکرد در بین قوانین آموزش شبکه‌های عصبی پرسپترون چند لایه بود. آرایش‌های بهینه شبکه عصبی پرسپترون چند لایه با قانون آموزش LM از میان تمامی حالات مورد بررسی در شبکه ۲ لایه پنهان

جدول (۳): نتایج عملکرد قوانین آموزش مختلف در شبکه عصبی پرسپترون چند لایه


قانون آموزش	RMSE	MAE	R	R^2
Step	۳/۱۶۶	۵۹/۰۷	۰/۶۶	۰/۴۳
D.B.D	۴/۲۴	۸۱/۲	۰/۶۱	۰/۳۷
CG	۶/۱۸۴	۱۰۲/۰۲	۰/۵۴	۰/۲۹
Quickprop	۳/۷۵۳	۵۵/۰۶۹	۰/۶۴	۰/۴
Momentum	۹/۳۱۳	۱۱۹/۱۱	۰/۴۵	۰/۲
LM	۲/۵۸	۳۷/۰۳	۰/۷۱	۰/۵

این روش نسبت به سایر روش‌ها محسوس است. در این روش ضریب تعیین بین مشاهدات و پیش‌بینی‌ها افزایش یافته و درصد بیشتری از نقاط حول خط نیمساز متمرکز شده‌اند.

همانطور که در شکل (۲) مشاهده می‌شود، هر چهار روش پس‌پردازش تا حدودی قادر به اصلاح آریبی داده‌های بارش استاندارد شده بوده‌اند. هرچند که با توجه به مقادیر بالاتر نمایه R^2 در روش QM، برتری



شکل ۲: تأثیر پس‌پردازش بر مقدار میانگین پیش‌بینی‌های بارش ماهانه در داده‌های آزمون عملکرد مدل



شکل (۳): مقایسه مقادیر پیش‌بینی شده و شبیه‌سازی شده برای بارش سالانه در زاگرس میانی (مقادیر بارش استاندارد شده هستند). پراش‌نگار نیز مقادیر همبستگی برای شبیه‌سازی خام را نشان می‌دهد و نمودارهای تیلور و رادار مقادیر همبستگی برای داده‌های پس‌پردازش شده را نشان می‌دهند.

اولیه، بهینه‌سازی کرده‌اند. در این بین روش نگاشت چندک (GM) با ضریب همبستگی ۰/۸۱ دارای

بر اساس شکل ۳، روش‌های پس‌پردازش مورد بررسی، شبیه‌سازی‌ها را به میزان ۵ تا ۱۰ درصد از مقادیر

بهترین عملکرد در بین روش‌های مورد بررسی است و پس از آن روش‌های GMD، VS و در انتها LS با مقادیر همبستگی ۰/۷۸، ۰/۷۷ و ۰/۷۴ قرار دارند. بنابراین خروجی‌های بارش مدل داده محور در مقاطع عرضی مورد بررسی بر اساس روش نگاشت چندک بهینه‌سازی شده‌اند.

رابطه بارش و ارتفاع در زاگرس بر اساس مدل

مورد بررسی: در ادامه به بررسی مقادیر بارش برآورد شده توسط مدل و تصحیح شده بر اساس رش نگاشت چندک در ۵ نیمرخ ارتفاعی پرداخته می‌شود. بررسی نیمرخ‌های ارتفاعی زاگرس میانی (شکل ۴) الگوی گردان بارش-ارتفاع را در دو حوزه بادگیر و بادپناه تأیید می‌کند. در سمت بادگیر، با افزایش ارتفاع، بارش قویاً افزایش می‌یابد؛ این امر نشان‌دهنده نقش اصلی صعود اوروگرافیک توده‌های هوا و تخلیه رطوبت آن‌ها است. با این حال، در بخش عمده نیمرخ‌های (از جمله ۱ و ۲)، حداکثر بارش منطبق با حداکثر ارتفاع کوهستان نیست، بلکه پیش از خط الرأس اتفاق می‌افتد و تا خط الرأس ادامه دارد. معمولاً بیشینه بارش در ارتفاعی در حدود ۲۵۰۰ متر رخ می‌دهد و تا ارتفاع ۳۰۰۰ متری ادامه می‌یابد. این رفتار بیانگر این است که مؤثرترین فرآیندهای تراکم و ریزش بارش اغلب در سطحی پایین‌تر از خط الرأس رخ می‌دهند و تا خط الرأس ادامه می‌یابند. صفرارد و همکاران (۱۳۹۳) نشان دادند که با وجود هماهنگی نسبی بین بارش و ناهمواری در زاگرس میانی، بیشینه بارش بر حداکثر ارتفاع ناهمواری‌ها منطبق نیست و در فاصله بین ۱۵ تا ۳۵ کیلومتری خط الرأس اتفاق می‌افتد که نشان می‌دهد محتوای رطوبتی توده‌های هوای وارد شده به منطقه به اندازه ای نیست که بتواند در کل فرایند صعود تا خط الرأس همچنان سبب تداوم افزایش بارش گردد.

علیچانی و همکاران (۲۰۰۸) نشان دادند که دامنه‌های غربی رشته کوه زاگرس (دامنه‌های رو به باد)، که به‌صورت شمالی-جنوبی امتداد دارد، یکی از مناطقی است که بیشترین فراوانی رویدادهای بارش حدی را در کل کشور تجربه می‌کند. در واقع این


منطقه در گروه مناطق با بالاترین ریسک بارش‌های نامنظم و شدید قرار می‌گیرد که نشان دهنده پیچیدگی هیدرولوژیکی و چالش‌های مدل‌سازی بارش در زاگرس است، زیرا سهم بزرگی از بارش سالانه آن در زمان کوتاهی و با شدت زیاد رخ می‌دهد. یافته‌های کمی نشان می‌دهند که رابطه بارش-ارتفاع در سمت بادگیر قویاً مثبت و معنی‌دار است ($P=0.00$ در همه موارد). این مخالف با شرایطی است که در دامنه‌های شمالی البرز وجود دارد، یعنی در این ناحیه با افزایش ارتفاع بارش کاهش می‌یابد، البته این رابطه در دامنه‌های شمالی البرز غیر خطی است (هادیانی و همکاران، ۱۳۹۰). در پروفایل‌های ۱ و ۲، ضریب تعیین (R^2) به ترتیب ۰/۵۸ و ۰/۶ به دست آمده است. این ارقام نشان‌دهنده آن است که ارتفاع، قدرت توضیحی بالایی برای تغییرات بارش در بخش بادگیر دارد. با این حال، میانگین بارش در این بخش‌ها متغیر است (مانند ۴۵۶ میلیمتر در نیمرخ ارتفاعی شماره یک و ۴۳۸ میلیمتر در نیمرخ شماره ۲). الگوی رفتاری در این نیمرخ‌ها تأکیدی بر این مشاهده است که صعود هوا و افزایش بارش تا ارتفاع ۲۵۰۰ متری به آرامی پیش می‌رود و پس از آن، حجم بارش تا ارتفاعات بالاتر ثابت می‌ماند یا تغییرات جزئی دارد. غیور و مسعودیان (۱۳۷۵) نشان دادند که محدودیت رطوبتی توده‌های هوای رسیده به دامنه‌های بادگیر سبب پیدایش پدیده عدم انطباق بیشینه بارش بر خط الرأس را بیان کرده‌اند.

بررسی نیمرخ‌های جنوبی‌تر (مانند ۴) اهمیت میانگین ارتفاع منطقه را در تعیین حجم کلی بارش دریافتی روشن می‌سازد. پروفایل شماره ۴ در سمت بادگیر، میانگین بارش قابل توجه ۵۳۸ میلیمتر را نشان می‌دهد که عمدتاً ناشی از میانگین ارتفاع بالاتر در این پروفایل (۲۲۹۴ متر) در مقایسه با پروفایل‌های شمالی‌تر است. رابطه بارش-ارتفاع در این منطقه مشابه سایر نیمرخ‌ها بسیار قوی و مثبت است ($R^2=0.57$ در دامنه‌های بادگیر). این یافته تأکید می‌کند که هرچند مکان اوج بارش ثابت است، اما میانگین ارتفاع پایه و خط الرأس در طول رشته‌کوه

مستقیماً بر تراکم و رطوبت‌گیری توده‌های هوا در آن بخش تأثیر می‌گذارد.

در مناطقی مانند نیمرخ شماره ۳، که ویژگی‌های پیچیده‌تری از لحاظ توپوگرافی دارند، یک افزایش بارش با اولین مانع کوهستانی اصلی (در ارتفاع ۲۳۰۰ متر) اتفاق می‌افتد و در دامنه‌های بادپناهی کاهش می‌یابد، اما این کاهش مانند توده اصلی و خط الرأس اصلی نیست که افت بسیار محسوسی را نشان دهد. در بخش بادگیر این نیمرخ ارتفاعی، قبل از رسیدن به


این مانع، میانگین بارش کم است (۳۳۴ میلیمتر)، اما با عبور از آن تا خط الرأس، به ۵۹۰ میلیمتر افزایش می‌یابد. رابطه بارش-ارتفاع در این بخش بادگیر بسیار قوی است ($R^2=0.73$). این الگو نشان‌دهنده آن است که در مناطقی با موانع کوهستانی چندگانه، اولین مانع اصلی ممکن است در وادار کردن توده‌های هوا به صعود و ریزش بارش اثر گذار باشد اما بخش عمده فرآیند تخلیه رطوبت در دامنه‌های پیش از خط الرأس رخ می‌دهد.



شکل (۴): نیمرخ تغییرات بارش (خطوط سبز) و ارتفاع (خطوط قهوه‌ای) در نیمرخ‌های ارتفاعی ۵ گانه تعیین شده در زاگرس میانی

دقیقاً بر روی خطالرأس، بلکه دامنه‌های پیش از آن رخ می‌دهد. با این حال، همان‌طور که انتظار می‌رود، این روند پربارش تا خطالرأس کوه ادامه می‌یابد، اگرچه ممکن است با شیب بسیار کمی کاهش و یا حتی افزایش یابد. این پدیده فیزیکی مهم نشان می‌دهد که مؤثرترین فرآیند صعود اوروگرافیک و تخلیه توده‌های هوای ورودی، پیش از رسیدن به بالاترین ارتفاعات کوهستان تکمیل می‌شود، مشابه یافته‌های سعید آبادی و همکاران (۲۰۱۶). در مقابل، در دامنه‌های سایه بارانی، حجم بارش با کاهش ارتفاع به‌صورت بسیار سریع‌تری افت می‌کند و اثرات خشکی ناشی از پدیده سایه کوه حاکم است؛ به‌طوری‌که افزایش ارتفاع در این سمت تنها منجر به افزایش ناچیزی در مقدار بارش می‌شود. این نتایج، توانایی مناسب مدل‌های داده محور بهینه‌شده را در برآورد روابط غیرخطی بارش و ارتفاع در یک محیط توپوگرافی پیچیده تأیید می‌کند. همانند مطالعه Katipoğlu et al., (2024) که نشان می‌دهند روش‌های داده محور مانند W-LVSM می‌توانند کارایی قابل توجهی در برآورد بارش در نواحی فاقد داده و با توپوگرافی پیچیده داشته باشند.

در نیمرخ شماره ۵، که نماینده رفتار بخش جنوبی زاگرس میانی است، یک انحراف مهم از الگوی میانی نشان می‌دهد، در این نیمرخ، حداکثر بارش با حداکثر ارتفاع (۳۰۰۰ متر) منطبق است. این تغییر رفتار نشان‌دهنده آن است که فرآیندهای اوروگرافیک و تاثیر آن بر افزایش بارش در این بخش علی‌رغم کاهش ارتفاع در دامنه‌های بادپناهی و تا خطالرأس بعدی، با کاهش ناچیزی ادامه دارد و در خطالرأس بعدی که حدود ۳۰۰۰ متر ارتفاع دارد باز هم بیشینه بارش اتفاق می‌افتد. رابطه بارش-ارتفاع در دامنه‌های بادگیر نیمرخ شماره ۵ با $R^2=0.86$ قوی‌ترین رابطه مشاهده شده در بین نیمرخ‌های مورد بررسی است. در مجموع، با وجود این تغییر در جنوب، نتیجه اصلی پابرجاست: ارتفاع مهم‌ترین عامل کنترل‌کننده بارش است، هرچند مکان دقیق اوج بارش تحت تأثیر عوامل محلی و جغرافیایی (مانند عرض جغرافیایی و میانگین ارتفاع) ممکن است دچار تغییراتی جزئی شود. در نهایت، با استفاده از مدل شبکه عصبی مصنوعی پس‌پردازش‌شده، نقشه نهایی تغییرات مکانی بارش در ارتفاعات مختلف (شکل ۵) تولید شد. این نقشه تأیید می‌کند که بیشترین حجم بارش، بر روی دامنه‌های بادگیر رشته‌کوه زاگرس متمرکز است. همچنین حداکثر حجم بارش نه



شکل (۵): پراکندگی فضایی بارش در زاگرس میانی

نتیجه‌گیری

این مطالعه با هدف اولیه دستیابی به برآورد مکانی تغییرات بارش در منطقه زاگرس میانی، بر اساس رابطه پیچیده بارش و توپوگرافی انجام شده است. به این منظور از مدل داده محور شبکه عصبی مصنوعی پرسپترون چندلایه (MLP-ANN) استفاده شد. ساختار بهینه شبکه (با آرایش چند لایه پنهان) و الگوریتم آموزش مارکوات-لونبرگ برای مدل‌سازی موثر روابط غیرخطی بین بارش و عوامل جغرافیایی منطقه‌ای انتخاب شد. نتایج اولیه مدل ANN نشان داد که مدل با یک ضریب تعیین حدود ۵۰ درصدی، توانایی مناسبی در تبیین نیمی از واریانس مکانی بارش بر اساس متغیرهای جغرافیایی مورد بررسی دارد. با این حال، ضریب تبیین ۵۰ درصدی نشان‌دهنده وجود سوگیری سیستماتیک در برآوردهای مدل است که لزوم استفاده از روش‌های پس‌پردازش و اصلاح اریبی آماری، را برای ارتقاء دقت مدل به سطح مورد نیاز جهت کاربردهای هیدرولوژیکی، توجیه می‌کند.

در ابتدا نقش پس‌پردازش در ارتقای دقت مدل‌سازی بررسی شد و نتایج نشان داد که انجام این مرحله در مدل‌های داده محور برای تصحیح خطا، حیاتی است. خروجی‌های اولیه مدل داده‌محور (شبکه عصبی) که همبستگی ۰/۷۱ را در بخش آزمون نشان داد، با اعمال روش‌های مختلف پس‌پردازش مورد بررسی قرار گرفتند. نتایج به وضوح نشان داد که روش‌های پس‌پردازش، شبیه‌سازی‌ها را به میزان ۵ تا ۱۰ درصد از مقادیر اولیه بهینه‌سازی کرده‌اند. در میان

روش‌های ارزیابی‌شده، روش نگاشت چندک با افزایش ضریب همبستگی مدل به ۰/۸۱، بهترین عملکرد را داشت. این بهبود، مؤید آن است که پس‌پردازش نه تنها یک مرحله اختیاری برای ارتقاء دقت، بلکه یک ضرورت آماری و عملیاتی است تا خطاهای سیستماتیک باقی‌مانده در خروجی‌های مدل‌های داده‌محور را تصحیح کند و دقت برآورد مکانی بارش را برای استفاده‌های کاربردی در مناطق کوهستانی پیچیده را به سطح قابل قبول برساند.

نتایج بررسی گرادیان بارش-ارتفاع در نیمرخ‌های زاگرس میانی، تأکید کرد که ارتفاع مهم‌ترین عامل کنترل‌کننده بارش در این منطقه است و این رابطه در دامنه‌های بادگیر مثبت و معنی‌دار است (با بالاترین R^2 مشاهده شده برابر با ۰/۸۶ در بخش جنوبی منطقه مورد مطالعه). با این حال، یک یافته کلیدی و ثابت، عدم انطباق حداکثر بارش با حداکثر ارتفاع کوهستان بود، بلکه این اتفاق پیش از خط الرأس اتفاق می‌افتد اما تا خط الرأس ادامه می‌یابد. در بیشتر نواحی، بیشینه بارش نه در خط الرأس، بلکه در ارتفاعی حدود ۲۵۰۰ متر رخ می‌دهد و تا خط الرأس ادامه می‌یابد. این رفتار نشان می‌دهد که مؤثرترین فرآیندهای تراکم و تخلیه رطوبت توده‌های هوا اغلب در سطح چگالش پایین‌تری از حداکثر ارتفاع کوهستان به اتمام می‌رسد. همچنین، تفاوت در میانگین ارتفاع منطقه به‌طور مستقیم بر حجم کلی بارش دریافتی تأثیر می‌گذارد و هرچه میانگین ارتفاع پایه بالاتر باشد، حجم بارش میانگین نیز بیشتر است.

منابع

۱. پودینه، ام البنین؛ دلبری، معصومه؛ حقیقت جو، پرویز و امیری، میثم. ۱۳۹۴. تحلیل مکانی تغییرات بارش با در نظر گرفتن متغیرهای ارتفاع و فاصله تا دریا (مورد مطالعه: استان سیستان و بلوچستان). پژوهش‌های جغرافیای طبیعی، ۴۷(۴)، ۶۰۷-۶۳۶.
۲. رضیئی، طیب و عزیزی، قاسم. ۱۳۸۶. منطقه بندی رژیم بارشی غرب ایران با استفاده از روش‌های تحلیل مولفه‌های اصلی و خوشه بندی. تحقیقات منابع آب ایران، ۳(۲)، ۶۲-۶۵.
۳. زارع ابیانه، حمید؛ بیات ورکشی، مریم؛ معروفی، صفر و ایلدرومی، علیرضا. ۱۳۹۰. شبیه سازی سطح ایستابی دشت ملایر براساس داده‌های هواشناسی با استفاده از شبکه‌ی عصبی مصنوعی. پژوهش‌های جغرافیای طبیعی، ۴۳(۷۸)، ۱۷-۲۸.

۴. ساری صراف، بهروز، و رجایی، عبدالحمید و مصری علمداری، پرچهر. ۱۳۸۸. بررسی رابطه بین بارش و توپوگرافی در دامنه‌های شرقی و غربی منطقه کوهستانی تالش. جغرافیا و برنامه ریزی محیطی (مجله پژوهشی علوم انسانی دانشگاه اصفهان)، ۲۰(۳) (پیاپی ۳۵)، ۶۳-۸۴.
۵. شعبان پور، فاطمه؛ بذرافشان، جواد و عراقی نژاد، شهاب. ۱۳۹۹. ارزیابی تاثیر روش‌های تصحیح اریبی بر مهارت پیش‌بینی فصلی بارش مدل اقلیمی CFSv2. تحقیقات آب و خاک ایران، ۵۱، ۱۲، ۳۰۱۷-۳۰۳۲.
۶. صفرراد، طاهر؛ عزیزی، قاسم؛ فرجی سبکبار، حسنعلی؛ عباسپور، رحیم‌علی. ۱۳۹۲. تحلیل مکانی تغییرات بارش در زاگرس میانی از طریق روش‌های زمین آمار (۱۹۹۵-۲۰۰۴). مجله جغرافیا و توسعه، ۱۱(۳۱)، ۱۴۹-۱۶۴.
۷. عزیزی، قاسم؛ فرجی سبکبار، حسنعلی؛ عباسپور، رحیم‌علی و صفرراد، طاهر. ۱۳۸۹. مدل تغییرات مکانی بارش در زاگرس میانی، پژوهش‌های جغرافیای طبیعی، ۴۲(۷۲)، ۳۵-۵۱.
۸. عساکره، حسین؛ بارزمان، سپیده؛ شاهبایی کوتنایی، علی. ۱۳۹۹. واکاوی الگوی مکانی بارش‌های بهاره شمال غرب ایران با روش‌های تحلیل فضایی. جغرافیا و برنامه‌ریزی، ۲۴(۷۴)، ۱۵۳-۱۶۴.
۹. عیسی زاده، محمد؛ منیر، شیرزاد؛ رضایی بنفشه، مجید. ۱۳۹۶. ارزیابی عملکرد شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) در تخمین مقادیر روزانه تبخیر (مطالعه موردی: ایستگاه‌های هواشناسی تبریز و مراغه). پژوهش‌های جغرافیای طبیعی، ۴۹(۱)، ۱۵۱-۱۶۸.
۱۰. غیور، حسنعلی و مسعودیان، سید ابوالفضل. ۱۳۷۵. بررسی مکانی رابطه بارش با ارتفاع در ایران زمین، تحقیقات جغرافیای، ۴۱، ۱۲۴-۱۴۳.
۱۱. کلاچیان، رویا؛ ثقفیان، بهرام؛ معظمی، صابر. ۱۳۹۹. ارزیابی کارایی روش‌های پس پردازش و اصلاح اریبی بر پیش‌بینی‌های ماهانه بارش و دما در حوضه کارون. تحقیقات منابع آب ایران، ۱۶(۴)، ۹۸-۱۱۱.
۱۲. مجرد، فیروز و مرادی فر، حاجیمراد. ۱۳۸۲. مدل‌سازی رابطه بارش با ارتفاع در منطقه زاگرس، مدرس، ۷(۱)، ۱۶۳-۱۸۱.
۱۳. نویخت، مسعود؛ ثقفیان، بهرام و امین یآوری، صالح. ۱۴۰۱. ارزیابی تأثیر پس‌پردازش بر بهبود مهارت پیش‌بینی‌های همادی فصلی بارش و دما پایگاه داده C3S در ایران. تحقیقات منابع آب ایران، ۱۸(۴)، ۱۶۲-۱۷۸.
۱۴. هادیانی، میر امید؛ جهانبخش، سعید؛ رضایی بنفشه، مجید؛ دین پژوه، یعقوب. ۱۳۹۰. نقش شرایط توپوگرافی در برآورد گردادیان بارندگی طبقات ارتفاعی مناطق کوهستانی: مطالعه موردی دامنه شمالی البرز مرکزی. علوم و فنون منابع طبیعی، ۶(۲)، ۱۵-۲۵.
15. Ajaaj, A., Mishra, A.K., Khan, A.A. 2015. Comparison of bias correction techniques for GPCC rainfall. Stochastic Environmental Research and Risk Assessment, 30(6), 1659-1675.
16. Akponi, F. P., Moumouni, S., Zahiri, E.-P., Kacou, M., & Gosset, M. 2025. Using an Artificial Neural Network to Assess Several Rainfall Estimation Algorithms Based on X-Band Polarimetric Variables in West Africa. Atmosphere, 16(4), 371.
17. Alijani, B., O'Brien, J., Yarnal, B. 2008. Spatial analysis of precipitation intensity and concentration in Iran. Theoret. Appl. Climatol. 94 (1), 107-124.
18. Aminyavari, S., Saghaian, B., Delavar, M. 2018. Evaluation of TIGGE ensemble forecasts of precipitation in distinct climate regions in Iran. Advances in Atmospheric Sciences, 35(4), 457-468.
19. Attorre, F., Alfo, M., De Sanctis, M., Francesconi, F., and Bruno, F. 2007. Comparison of interpolation methods for mapping climatic and bioclimatic variables at regional scale, International Journal of Climatology. DOI:10. 1002/joc. 1495.
20. Bouach, A. 2024. Artificial neural networks for monthly precipitation prediction in north-west Algeria: a case study in the Oranie-Chott-Chergui basin. Journal of Water and Climate Change, 15(2), 582-592.
21. Daly, C., Nelson, R.P., Phillips, D.L.. 1994. A Statistical-Topographic model for Mapping Climatological Precipitation over Mountainous Terrain, Journal of Applied Meteorology, 33, 140-158.

22. Fang, G. H., Yang, J., Chen, Y. N., Zammit, C. 2015. Comparing bias correction methods in downscaling meteorological variables for a hydrologic impact study in an arid area in China. *Hydrology and Earth System Sciences*, 19(6), 2547–2559.
23. Frías, M. D., Iturbide, M., Manzananas, R., Bedia, J., Fernández, J., Herrera, S. 2018. An R package to visualize and communicate uncertainty in seasonal climate prediction. *Environmental Modelling & Software*, 101, 99-110.
24. Gan, Y., Li, Y., Wang, L., Zhao, L., Fan, L., Xu, H., & Yin, Z. (2024). Machine-learning downscaling of GPM satellite precipitation products in mountainous regions: A case study in Chongqing. *Atmospheric Research*, 311, 107698.
25. Gardner, M.W. and Dorling, S.R. 1998. Artificial neural networks (the multilayer perceptron) – a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32: 2627-2636.
26. Gudmundsson, L. 2016. Statistical transformations for post-processing climate model output. <https://cran.rproject.org/web/packages/qmap/>.
27. Gudmundsson, L., Bremnes, J.B., Haugen, J.E., Engen-Skaugen, T. 2012. Technical note: Downscaling RCM precipitation to the station scale using statistical transformations- A comparison of methods. *Hydrology and Earth System Sciences*, 16, 383-3390
28. Katipoğlu, O. M., & Koblouti, M. 2024. Comparative analysis of data-driven models and signal processing techniques in the monthly maximum daily precipitation prediction of El Kerma station Northeast of Algeria. *Soft Computing*, 28(17), 10751-10765.
29. Khajehei, S., & Moradkhani, H. 2017. Towards an improved ensemble precipitation forecast: A probabilistic post-processing approach. *Journal of Hydrology*, 546, 476-489.
30. Li, Y., Jiang, Y., Lei, X., Tian, F., Duan, H., and Lu, H. 2017. Comparison of precipitation and streamflow correcting for ensemble streamflow forecasts. *Water*, 10(2), 177
31. Lloyd, C, D. 2005. Assessing the Effect of Integrating Elevation data into the Estimation of Monthly Precipitation in Great Britain, *Journal of Hydrology*, 308, 128-150.
32. Luo, L., Zhao, Y., Duan, Y., Dan, Z., Acharya, S., Jimi, G., Bai, P., Yan, J., Chen, L., Yang, B., & Xu, T. 2024. Relationships between Precipitation and Elevation in the Southeastern Tibetan Plateau during the Active Phase of the Indian Monsoon. *Water*, 16(18), 2700. <https://doi.org/10.3390/w16182700>
33. Marquinez, J., Lastra, J., & García, P. 2003. Estimation models for precipitation in mountainous regions: the use of GIS and multivariate analysis. *Journal of hydrology*, 270(1-2), 1-11.
34. Saeidabadi, R., Najafi, M. S., Roshan, G., Fitchett, J. M., & Abkharabat, S. 2016. Modelling spatial, altitudinal and temporal variability of annual precipitation in mountainous regions: The case of the Middle Zagros, Iran. *Asia-Pacific Journal of Atmospheric Sciences*, 52(5), 437-449.
35. Salimi, A. H., Masoompour Samakosh, J., Sharifi, E., Hassanvand, M. R., Noori, A., & von Rautenkranz, H. 2019. Optimized artificial neural networks-based methods for statistical downscaling of gridded precipitation data. *Water*, 11(8), 1653.
36. Sasaki, H., & Kurihara, K. 2008. Relationship between precipitation and elevation in the present climate reproduced by the non-hydrostatic regional climate model. *Sola*, 4, 109-112
37. Schepen, A., Zhao, T., Wang, Q. J., & Robertson, D. E. 2017. A new method for post-processing daily sub-seasonal to seasonal rainfall forecasts from GCMs and evaluation for 12 Australian catchments. *Hydrol Earth Syst Sci Discuss*, 1-27.
38. Taylor, W.G, 1996. Statistical Relationships between Topography and precipitation in Mountainous Area, *Northwest Science*, 70(2), 164-178.
39. Voisin, N., Schaake, J. C., & Lettenmaier, D. P. 2010. Calibration and downscaling methods for quantitative ensemble precipitation forecasts. *Weather and Forecasting*, 25(6), 1603-1627.

40. Wang, J., Chen, J., Shen, P., Guan, X., Liu, X., Massari, C. & Yong, B. 2025. Regional-scale intelligent optimization and topography impact in restoring global precipitation data gaps. *Communications Earth & Environment*, 6(1), 671.
41. Zhao, T., Bennett, J. C., Wang, Q. J., Schepen, A., Wood, A. W., Robertson, D. E., & Ramos, M. H. 2017. How suitable is quantile mapping for postprocessing GCM precipitation forecasts?. *Journal of Climate*, 30(9), 3185-3196.

