



Improving Precipitation Accuracy: A Rescaling Method for PERSIANN Using NDVI, LST, and DEM Data

Zahra Shirmohammadi-Aliakbarkhani ¹ 

1. Department of Water Science and Engineering, Faculty of Agriculture and Animal Sciences, University of Torbat-e Jam, Iran. E-mail: shirmohammadi@tjamcaas.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Nov. 5, 2024

Revised: Dec. 11, 2024

Accepted: Feb. 3, 2025

Published online: May. 2025

Keywords:

Machine Learning,
PERSIANN-CDR,
Precipitation,
Spatial Resolution Enhancement.

ABSTRACT

This study is based on the rain gauge data from Torbat-e Jam over a 23-year period (2001–2023). PERSIANN satellite rainfall data with a spatial resolution of 27 kilometers were enhanced to a 1-kilometer resolution using NDVI, land surface temperature (LST), and digital elevation model (DEM) data, aided by the random forest (RF) algorithm. To evaluate the accuracy of satellite rainfall downscaling compared to ground station data, statistical metrics such as correlation coefficient (CC), root mean square error (RMSE), and mean absolute error (MAE) were utilized. Additionally, a residual correction method was implemented to refine model predictions further. Results demonstrated that integrating spatial datasets with the RF algorithm significantly improved rainfall modeling accuracy. Applying the residual correction method led to substantial improvements in forecasting accuracy across all studied stations on both monthly and annual timescales. On the monthly scale, the correlation coefficient increased by 22-29%, while RMSE and MAE decreased by 61-64% and 60-68%, respectively. On an annual scale, the correlation coefficient showed an increase of 7-35%, with RMSE and MAE reductions of 69-74% and 69-76%, respectively. This study underscores the effectiveness of the applied method in enhancing prediction accuracy across various temporal scales within the studied region. Additionally, the practical implications of this research provide valuable insights for hydrological modeling and water resource management, especially in regions with limited ground station data. The findings of this research can significantly aid in better water resource management and climatic planning, particularly in arid and semi-arid areas.

Cite this article: Shirmohammadi-Aliakbarkhani, Z. (2025). Improving Precipitation Accuracy: A Rescaling Method for PERSIANN Using NDVI, LST, and DEM Data, *Iranian Journal of Soil and Water Research*, 56 (3), 735-751. <https://doi.org/10.22059/ijswr.2025.384891.669827>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2025.384891.669827>



EXTENDED ABSTRACT

Introduction

Precipitation plays a critical role in the global water cycle and in processes involving material and energy exchanges. High-resolution precipitation data are essential for accurate hydrological, meteorological, and ecological studies, especially at regional scales. Traditionally, rain gauges provide precise point data, but their irregular distribution and the high spatial-temporal variability of precipitation make them insufficient for generating fine-resolution datasets. Satellite observations offer valuable insights into water and energy exchanges between land and atmosphere. They are particularly effective in estimating precipitation across vast areas, including mountainous and sparsely gauged regions. For example, remotely sensed data such as the PERSIANN-CDR product are widely used in hydrological and meteorological studies. However, the 27 km spatial resolution of PERSIANN data often limits its applicability in detailed hydrological simulations and environmental assessments at local scales. To address this limitation, this study introduces a novel approach by combining land surface temperature (LST), normalized difference vegetation index (NDVI), and digital elevation model (DEM) data with the Random Forest (RF) algorithm to downscale annual PERSIANN precipitation data. The study focuses on southeastern Khorasan Razavi from 2000 to 2023—a region with limited ground-based observations and complex topography. To the best of our knowledge, this combination of variables and techniques has not been applied in this region before. The outcomes of this research have significant practical implications. High-resolution precipitation maps generated by this method can improve water resource management, enhance flood prediction accuracy, and support sustainable development in arid and semi-arid regions. By addressing the limitations of traditional precipitation datasets, this study provides a foundation for more reliable hydrological and environmental analyses.

Method

Data Collection

This study utilizes data from the Torbat Jam rain gauge stations over a 23-year period (2001–2023). The time period of 2001–2023 was chosen due to the availability of continuous data and to capture long-term climatic trends. While some data gaps and noise were present, they were addressed through preprocessing techniques to ensure the robustness of the analysis. The PERSIANN dataset, accessible on Google Earth Engine as `ee.ImageCollection("NOAA/PERSIANN-CDR")`, provided precipitation data for the period from 2001 to 2023. To obtain NDVI data, MOD13Q1 data (16-day NDVI at 250-meter resolution) was accessed through Google Earth Engine under the code `ee.ImageCollection("MODIS/061/MOD13Q1")`. For land surface temperature, the study used MOD11A2 data, which includes 8-day LST at a 1 km resolution, available since 2000 as `ee.ImageCollection("MODIS/061/MOD11A2")`. Elevation data was sourced from the SRTM version 3 (SRTM Plus) product, with an approximate 30-meter accuracy, accessible via `ee.Image("USGS/SRTMGL1_003")`.

Preprocessing

The study focuses on downscaling PERSIANN satellite precipitation data, originally at a 27 km resolution, to a finer 1 km resolution. This scaling was achieved using NDVI (Normalized Difference Vegetation Index), LST (Land Surface Temperature), and DEM (Digital Elevation Model) data, applying the Random Forest (RF) machine learning algorithm.

Modeling

The Random Forest algorithm implemented in Google Earth Engine was chosen for its robustness and ability to handle complex datasets. This platform provides optimized parameters for the algorithm, making it efficient for large-scale environmental data processing.

Residual Correction

To correct the residuals, the difference between the actual precipitation values (ground data) and the predicted values from the microscaling model (using NDVI, LST, and DEM data) was first calculated. Next, a machine learning method called Random Forest was applied to model these residuals, as it is capable of identifying and modeling complex patterns in the residual data. Finally, the residuals predicted by the machine learning models were added to the initial predicted values to obtain the adjusted predictions. The residual correction technique offers significant advantages:

Enhanced Model Accuracy

The residual correction technique offers significant advantages: by addressing the differences (residuals) between observed and predicted values, the model's accuracy is significantly improved. This method reduces

both systematic and random errors in the initial predictions, leading to more reliable results. Additionally, the Random Forest algorithm, used for residual correction, is capable of capturing complex relationships within the residuals that simpler models might miss.

Evaluation

The model's performance, before and after the modification, was evaluated using root mean square error (RMSE), mean absolute error (MAE), and correlation coefficient (CC) metrics. The residual correction technique significantly improved model performance, highlighting its utility in enhancing prediction accuracy. Specifically, it led to reductions in RMSE and MAE, and increases in CC, demonstrating the method's effectiveness in refining precipitation predictions.

Results

Statistical analyses indicate that precipitation downscaling yielded favorable results at Firouzkouh and Robat Samanegan stations on monthly and annual scales, and at Torbat-e Jam station on an annual scale. The limited improvement in monthly downscaling at Torbat Jam can be attributed to the high spatial-temporal variability of precipitation in this region, which makes accurate downscaling more challenging. Similarly, studies by Cho et al. (2013) on the Korean Peninsula achieved improved local precipitation accuracy by downscaling TRMM precipitation data to a resolution of 1 km, while Zhang et al. (2018) demonstrated that 1 km maps in mountainous areas offer higher precision. Research by Ghorbanpour et al. (2021) also found that finer resolutions, such as 1 km, are beneficial in arid regions like Lake Urmia, especially where ground stations are sparse. Noor et al. (2023) confirmed that using 1 km downscaling improved precipitation accuracy in downstream regions of the Indus River. In Torbat Jam, the residual correction method was applied due to the lack of significant improvement in monthly downscaling, leading to enhanced model accuracy across all stations and time scales. Overall, residual correction proved highly effective in improving downscaling models' accuracy, especially in areas with limited data or spatial anomalies. This technique enables models to correct for initial downscaling errors, resulting in better rainfall prediction by incorporating real data. Several studies support the efficacy of residual correction with machine learning methods like Random Forest (RF) and Kriging. For example, Zhan et al. (2018) demonstrated enhanced accuracy in semi-arid regions, and Chen et al. (2020) highlighted RF's ability to reduce errors in arid environments. Zhao (2021) showed that residual correction led to a significant reduction in MAE and RMSE errors by 19% and 21%, respectively, in mountainous areas. In this study, applying the residual correction method significantly improved prediction accuracy across all studied stations and time scales. At Torbat Jam station, monthly correlation increased by 22% and annual correlation by 34%, with RMSE and MAE reductions of 64% and 66% on a monthly scale, and 71% and 69% on an annual scale, respectively. At Firouzkouh station, monthly correlation improved by 29% and annual correlation by 35%, with RMSE reductions of 63% monthly and 69% annually, and MAE reductions of 68% monthly and 76% annually. At Robat Samanegan station, monthly correlation increased by 26% and annual correlation by 7%, with RMSE reductions of 61% monthly and 74% annually, and MAE reductions of 60% monthly and 74% annually. These results underscore the efficacy of residual correction in enhancing model accuracy and reducing prediction errors across varying temporal and spatial scales. Consequently, combining RF downscaling with residual correction provides a suitable method for achieving high-resolution precipitation data (1 km), especially when using auxiliary variables like NDVI, LST, and DEM data. Satellite data offers extensive spatial and temporal coverage, making it valuable for precipitation modeling and climate analysis. Downscaling and residual correction techniques improve model accuracy significantly, supporting more precise hydrological and climate studies.

Conclusions

High-resolution precipitation maps at 1 km provide more precise insights into precipitation distribution, allowing for the identification of local patterns, climate anomalies, and precipitation-sensitive areas. These finer maps are instrumental in water resource management, flood and drought mitigation, and agricultural and urban planning, while 27 km maps are more suitable for regional-scale analyses. Machine learning techniques, particularly when paired with residual correction, significantly enhance precipitation prediction accuracy in regions with sparse ground data or complex topographies. However, this study has certain limitations. The effectiveness of downscaling methods can be sensitive to the quality and availability of input data, such as auxiliary variables (e. g. , NDVI, LST, DEM). Additionally, computational challenges in training advanced machine learning models must be considered. Future research should focus on improving machine learning models, incorporating newer and higher-resolution satellite data, and testing these methods across diverse regions with varying climatic and topographical characteristics. Addressing these areas can further enhance the robustness and applicability of downscaling approaches for hydrological, ecological, and climate studies.



Author Contributions

The author contributed to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

Data available on request from the author.

Acknowledgements

We acknowledge the financial support received from the University of Torbat-e Jam.

Ethical considerations

The author avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

افزایش دقت داده‌های بارش ماهواره‌ای: روش ریزمقیاس‌سازی داده‌های PERSIANN با استفاده از DEM، LST و NDVI

زهرا شیرمحمدی-علی اکبرخانی^۱^۱. نویسنده مسئول، گروه علوم و مهندسی آب، مجتمع آموزش عالی تربت جام، تربت جام، ایران. رایانامه: shirmohammadi@tjamcaas.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	این مطالعه بر پایه داده‌های بارانسنجی شهرستان تربت جام و طی یک دوره آماری ۲۳ ساله (۲۰۰۱ تا ۲۰۲۳) انجام شده است. در این پژوهش، داده‌های بارش ماهواره‌ای PERSIANN با وضوح مکانی ۲۷ کیلومتر با استفاده از داده‌های NDVI، دمای سطح زمین (LST) و مدل ارتفاعی (DEM) و با کمک الگوریتم یادگیری ماشین جنگل تصادفی (RF) به وضوح مکانی یک کیلومتر ارتقا یافت. برای ارزیابی دقت ریزمقیاس‌سازی داده‌های بارش ماهواره‌ای نسبت به داده‌های ایستگاه‌های زمینی، از معیارهای آماری شامل ضریب همبستگی (CC)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) استفاده شد. علاوه بر این، روش تصحیح باقیمانده‌ها برای افزایش دقت پیش‌بینی مدل به کار گرفته شد. نتایج نشان داد که روش تغییر مقیاس همراه با داده‌های کمکی مکانی و الگوریتم جنگل تصادفی، دقت مدلسازی بارش را به طور چشمگیری بهبود بخشیده است. نتایج نشان داد که در تمامی ایستگاه‌های مورد مطالعه و در مقیاس‌های زمانی ماهانه و سالانه استفاده از روش اصلاح باقیمانده باعث بهبود قابل توجهی در دقت پیش‌بینی‌ها شد. به طوری که در مقیاس بارش ماهیانه بعد از اصلاح باقیمانده ضریب همبستگی از ۶۸-۶۰ درصد افزایش، ریشه میانگین مربعات خطا از ۶۴-۶۱٪ کاهش و میانگین مطلق خطا به میزان ۶۸-۶۰ درصد کاهش نشان داد. در مقیاس سالانه ضریب همبستگی از ۷۵-۷۳ درصد، ریشه میانگین مربعات خطا از ۷۴-۶۹ درصد کاهش و میانگین مطلق خطا به میزان ۷۶-۶۹ درصد کاهش نشان داد. این مطالعه بر اثربخشی روش مذکور در بهبود دقت پیش‌بینی در مقیاس‌های زمانی مختلف در منطقه مورد بررسی تأکید دارد. علاوه بر این، مفاهیم عملی این پژوهش بینش‌های ارزشمندی را برای مدلسازی هیدرولوژیکی و مدیریت منابع آب، به ویژه در مناطقی که داده‌های ایستگاه زمینی محدود است، ارائه می‌دهد. یافته‌های این تحقیق می‌تواند به بهبود مدیریت منابع آبی و برنامه‌ریزی‌های اقلیمی، به خصوص در مناطق خشک و نیمه خشک، کمک قابل توجهی نماید.

واژه‌های کلیدی:

افزایش وضوح مکانی،

بارش،

داده‌های ماهواره پرشین،

یادگیری ماشین.

استناد: شیرمحمدی-علی اکبرخانی؛ زهرا، (۱۴۰۴) افزایش دقت داده‌های بارش ماهواره‌ای: روش ریزمقیاس‌سازی داده‌های PERSIANN با استفاده از LST، NDVI و

DEM، مجله تحقیقات آب و خاک ایران، ۵۶ (۳)، ۷۵۱-۷۳۵. <https://doi.org/10.22059/ijswr.2025.384891.669827>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2025.384891.669827>


مقدمه

بارش نقش مهمی در تبادل مواد و انرژی در چرخه آب جهانی ایفا می‌کند و بر رطوبت خاک، رشد گیاهان و رواناب سطحی تأثیر می‌گذارد (Ma et al. , 2017; Shaodan Chen et al. , 2019). در نتیجه، بارش به‌عنوان پارامتر کلیدی در مدل‌های مختلف هیدرولوژیکی مطرح است و کیفیت داده‌های بارش به‌طور مستقیم بر نتایج شبیه‌سازی‌های مدل تأثیر می‌گذارد (Guanghua Xu et al. , 2015). بنابراین، کیفیت این داده‌ها از اهمیت زیادی برای مطالعه تغییرات اقلیمی جهانی، ارزیابی شرایط رواناب سطحی و ارائه برآوردهای زیست‌توده برخوردار است. به دست آوردن داده‌های بارش با وضوح مکانی بالا برای انجام تحقیقات در زمینه‌های بوم‌شناسی، محیط‌زیست و هیدرولوژی در مقیاس جهانی ضروری است (Shaodan Chen et al. , 2019). به‌طور کلی، ایستگاه‌های مشاهده بارش در مقیاس محلی دقت بالاتری دارند، اما به دلیل توزیع مکانی پراکنده یا نامتناسب ایستگاه‌های هواشناسی، بازتولید کامل توزیع زمانی و مکانی بارش دشوار است. در سال‌های اخیر، مجموعه‌ای از محصولات سنجش‌ازدور بارش ماهواره‌ای مانند پروژه نقشه‌برداری جهانی بارش ماهواره‌ای (GSMaP) با وضوح $1^\circ \times 1^\circ$ ، پروژه اقلیم‌شناسی جهانی بارش (GPCP) با وضوح $2.5^\circ \times 2.5^\circ$ ، مأموریت اندازه‌گیری بارش مناطق گرمسیری (TRMM) و مأموریت اندازه‌گیری بارش جهانی (GPM) با وضوح 10×10 کیلومتر مشاهدات جدیدی در مقیاس جهانی و منطقه‌ای ارائه کرده‌اند (Shaodan Chen et al. , 2019). با این حال، هنگامی که در تحقیقات هیدرولوژی، بوم‌شناسی، اقلیم و غیره در مقیاس منطقه‌ای مورد استفاده قرار می‌گیرند، مدل‌های مختلف نیاز به داده‌های بارش با وضوح بالاتر به‌عنوان پارامترهای ورودی دارند تا نتایج شبیه‌سازی دقیق‌تری به دست آورند؛ بنابراین، توسعه یک الگوریتم کاهش مقیاس برای محصولات بارش ماهواره‌ای به‌منظور به دست آوردن داده‌های دقیق با وضوح مکانی بالا ضروری است. در دهه‌های اخیر، تلاش‌های زیادی برای تهیه نقشه‌های بارش با وضوح مکانی بالا از داده‌های بارش ماهواره‌ای صورت گرفته است. این تلاش‌ها بر بهبود الگوریتم‌های کاهش مقیاس مکانی مبتنی بر رابطه بین بارش و ویژگی‌های سطح زمین متمرکز بوده‌اند. (Immerzeel et al. (2009 روشی برای کاهش مقیاس داده‌های بارش سالانه TRMM از 0.25° درجه به 1 کیلومتر با استفاده از تابع نمایی بین بارش و شاخص تفاضلی نرمال‌شده پوشش گیاهی (NDVI) ارائه کردند. (Jia et al. (2011 این روش را با افزودن مدل رگرسیون خطی چندگانه و استفاده از NDVI و مدل ارتفاع دیجیتال (DEM) به‌عنوان متغیرهای مستقل بهبود دادند و توانستند داده‌های بارش سالانه TRMM 3B43 را در حوضه چایدام به‌وضوح 1 کیلومتر در 1 کیلومتر کاهش دهند. Shi et al. (2015) با استفاده از الگوریتم جنگل‌های تصادفی (RF) برای کشف روابط پیچیده بین بارش، NDVI و DEM الگوریتمی ارائه کردند که نسبت به مدل‌های رگرسیون خطی و نمایی عملکرد بهتری داشت. این پیشرفت‌ها باعث بهبود دقت کاهش مقیاس بارش ماهواره‌ای شده و کاربرد این روش‌ها را گسترش داده است. با این حال، چالش‌هایی همچنان باقی است؛ چرا که این مدل‌ها عمدتاً به رابطه بین شاخص پوشش گیاهی و توپوگرافی با بارش وابسته‌اند و در مناطقی که چنین رابطه‌ای وجود ندارد، مانند بیابان‌ها، کارآمد نیستند (Xu et al. , 2015). چندین مطالعه نشان داده‌اند که استفاده از NDVI در مدل‌های کاهش مقیاس بهبود معناداری در وضوح مکانی داده‌های بارش ایجاد می‌کند. به‌عنوان مثال، یک مطالعه در حوضه رودخانه یانگ‌تسه نشان داد که استفاده از NDVI در مدل‌های کاهش مقیاس، به‌ویژه در مناطقی که همبستگی قوی با بارش دارد، نتایج بهتری ایجاد می‌کند (Shaodan Chen et al. , 2019). تحقیقات نشان داده‌اند که ترکیب NDVI با سایر متغیرهای محیطی مانند مدل ارتفاع دیجیتال (DEM) و دمای سطح زمین (LST) در الگوریتم‌های یادگیری ماشین، دقت کاهش مقیاس را به‌طور قابل‌توجهی افزایش می‌دهد. مطالعات انجام‌شده بر روی فلات تبت تأیید کرده‌اند که مدل‌های شامل NDVI نسبت به مدل‌های رگرسیون ساده، در تولید داده‌های بارش با وضوح بالا عملکرد بهتری دارند (Jing et al. , 2016b). اثربخشی کاهش مقیاس مبتنی بر NDVI می‌تواند بسته به منطقه جغرافیایی و شرایط اقلیمی متفاوت باشد. به‌عنوان مثال، تحقیقی در شمال چین نشان داد که افزودن NDVI به مدل‌های کاهش مقیاس، دقت برآوردهای بارش را به‌ویژه در مناطق مرطوب و نیمه مرطوب به‌طور قابل‌توجهی بهبود می‌بخشد (Zheng & Zhu, 2015). مطالعه‌ای در شبه‌جزیره ایبری نشان داد که NDVI به‌عنوان یک شاخص مناسب برای بارش در مقیاس‌های مکانی خاص ($75-100$ کیلومتر) عمل می‌کند. محققان روشی برای کاهش مقیاس توسعه دادند که از برآورد های بارش TRMM با مقیاس درشت و الگوهای NDVI با مقیاس دقیق استفاده می‌کرد و نتایج آن بهبود قابل‌توجهی در همبستگی و دقت برآوردهای بارش کاهش‌یافته نشان داد (Immerzeel et al. , 2009). روش دیگری شامل استفاده از رگرسیون وزنی جغرافیایی (GWR) برای در نظر گرفتن ناهمگنی فضایی در رابطه بین بارش و NDVI/DEM است. این روش نشان داده است که نسبت به روش های سنتی برتری دارد و وضوح و دقت داده‌های مقیاس‌بندی شده را به‌ویژه در مناطق پیچیده مانند فلات تبت بهبود می‌بخشد (Xu et al. , 2015). تکنیک‌های مقیاس‌بندی که شامل NDVI، LST و DEM هستند، به‌طور موفقیت‌آمیزی در مناطق مختلف، از مناطق

خشک در چین تا مناطق کوهستانی، مورد استفاده قرار گرفته‌اند و تخمین‌های بارشی با وضوح بالا ارائه می‌دهند که برای مطالعات هیدرولوژیکی و محیطی محلی ضروری است (Karbalaye Ghorbanpour et al., 2021). ترکیب چندین مدل، مانند ادغام یادگیری ماشینی با GWR نیز امیدبخش بوده است. یک مطالعه نشان داد که ترکیب این روش‌ها می‌تواند روابط غیرخطی را به‌طور مؤثرتری به دست آورد و عملکرد مقیاس‌بندی را در مناطق وسیعی مانند حوضه رودخانه لانگانگ در چین بهبود بخشد (Lima et al., 2012). استفاده از شبکه‌های عصبی مصنوعی (ANN) و جنگل تصادفی (RF) را در ریزمقیاس‌سازی بارش بررسی کرده و بهبود قابل توجهی در کاهش خطا و افزایش دقت مشاهده کردند. آن‌ها تأکید کردند که این روش‌ها در مقایسه با روش‌های پارامتریک عملکرد بهتری دارند. مطالعات نشان داده‌اند که ادغام NDVI، LST و DEM با الگوریتم‌های یادگیری ماشینی مانند ماشین‌های بردار پشتیبان (SVM) و جنگل‌های تصادفی (RF) می‌تواند به‌طور قابل‌توجهی دقت داده‌های بارش مقیاس‌بندی شده را نسبت به مدل‌های رگرسیون سنتی افزایش دهد (Jing et al., 2016b). این تحقیق با هدف ارائه نقشه‌های بارش ماهانه و سالانه با وضوح مکانی بالا برای مناطق جنوب شرقی خراسان رضوی انجام شد و از داده‌های PERSIANN با کمک الگوریتم RF استفاده کرد. روش پیشنهادی برای نخستین بار در این منطقه با ترکیب DEM، NDVI و LST اجرا شده است. برای دستیابی به این هدف، ما یک روش کاهش مقیاس مکانی بر اساس تحقیقات (Immerzeel et al., 2009)، Shi et al. (2015) و Jia et al. (2011) پیشنهاد کردیم. در این تحقیق، دمای سطح زمین را به عنوان یک عامل مهم برای بهبود رابطه بین بارش و ویژگی‌های سطح زمین در فرآیند کاهش مقیاس بارش معرفی کردیم. مطالعات نشان داده‌اند که رابطه‌ای قوی بین دمای سطح زمین و بارش وجود دارد، حتی در مناطقی که رابطه‌ای بین بارش و NDVI مشاهده نمی‌شود (Trenberth & Shea, 2005). بارش می‌تواند دمای سطح زمین را در طول روز و شب تغییر دهد؛ به‌طوری‌که بارش باعث خنک شدن محیط می‌شود و خشک‌سالی‌ها اغلب با گرمای شدید همراه هستند (De Kauwe et al., 2013). استفاده از متغیر دمای سطح زمین به عنوان شاخصی مکمل برای رفع محدودیت‌های موجود در مناطقی با ارتباط ضعیف بین NDVI و بارش، این تحقیق را به یک گام نوآورانه در ارائه داده‌های بارش دقیق‌تر برای مناطق جنوب شرقی خراسان رضوی تبدیل کرده است که می‌تواند در مدیریت منابع آبی، پیش‌بینی خشکسالی و برنامه‌ریزی کشاورزی در منطقه استفاده شوند.

مواد و روش‌ها

تربت‌جام یکی از شهرستان‌های استان خراسان رضوی است که در فاصله ۱۶۳ کیلومتری از مرکز استان (مشهد) و در مختصات جغرافیایی طول ۶۰ درجه و ۳۸ دقیقه شرقی و عرض ۳۵ درجه و ۱۳ دقیقه شمالی قرار دارد. مساحت این شهر حدود ۸،۱۸۴،۰۰۰ کیلومترمربع است. در شکل ۱ موقعیت جغرافیایی ایستگاه‌های مورد مطالعه در محدوده تحقیق (منطقه تربت‌جام) نشان داده شده است. نقشه DEM برای نمایش توپوگرافی منطقه استفاده شده است. این مدل ارتفاعی به شناسایی تفاوت‌های مکانی در ارتفاعات و تأثیرات آن بر توزیع بارش کمک می‌کند.



شکل ۱. موقعیت منطقه مورد مطالعه، ارتفاع و ایستگاه‌های باران‌سنجی مورد استفاده برای اعتبارسنجی

ایستگاه‌های باران‌سنجی به‌عنوان نقاط کلیدی برای صحت‌سنجی داده‌های ریزمقیاس‌شده بارش ماهواره‌ای در این پژوهش در نقشه مشخص شده‌اند. همان‌طور که در نقشه مشاهده می‌شود، ایستگاه‌ها در نواحی با ارتفاعات متنوع پراکنده شده‌اند که نشان‌دهنده تنوع مکانی در داده‌ها است.

این مطالعه بر اساس داده‌های بارش ایستگاه‌های باران‌سنجی تربت‌جام در طول یک دوره آماری ۲۳ ساله انجام شده است. جزئیات مربوط به موقعیت جغرافیایی و دوره آماری ایستگاه‌ها در جدول ۱ آورده شده است. میانگین سالانه تبخیر و تعرق به روش فائو پنمن مانیتیت در این منطقه در طول دوره آماری مورد نظر برابر با ۲۱۵۷/۸ میلی‌متر بوده است.

جدول ۱- مشخصات جغرافیایی ایستگاه مورد مطالعه تربت‌جام و تعداد سال‌های آماری مورد استفاده

نام ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع (متر)	میانگین بارش سالانه (میلی‌متر)	سال آماری
رباط سمنگان	۶۰° ۳۵'	۳۵° ۱۶'	۹۵۰/۴	۱۴۹/۷	۲۰۲۳-۲۰۰۱
فیروزکوه	۶۰° ۱۴'	۳۵° ۳۱'	۱۱۴۸	۱۶۷/۶	۲۰۲۳-۲۰۰۱
تربت‌جام	۶۰° ۴۸'	۳۵° ۲۶'	۱۴۰۸	۱۳۳/۹	۲۰۲۳-۲۰۰۱

داده‌های بارش از اداره هواشناسی تربت‌جام برای ایستگاه‌های مورد مطالعه به‌صورت روزانه دریافت گردید. سپس با استفاده از برنامه نویسی در نرم‌افزار پایتون در سامانه گوگل کولب به میانگین ماهانه و سالانه تبدیل گردید.

داده‌های ماهواره‌ای

در این مطالعه داده‌های بارش ماهواره‌ای PERSIANN با تفکیک مکانی ۲۷ کیلومتری از سامانه گوگل ارث انجین دریافت و به کمک داده‌های NDVI، LST و DEM با استفاده از الگوریتم یادگیری ماشین جنگل‌های تصادفی (RF) به تفکیک مکانی یک کیلومتری، در این سامانه ریزمقیاس گردیدند.

محصول PERSIANN-CDR

PERSIANN-CDR یک مجموعه داده‌ای است که برای تخمین بارش با استفاده از داده‌های ماهواره‌ای طراحی شده است. نام این محصول از عبارت "Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks - Climate Data Record" گرفته شده است. در این محصول، از شبکه‌های عصبی مصنوعی استفاده شده تا بتوان داده‌های مختلف ماهواره‌ای را برای استخراج اطلاعات دقیق و معتبر بارش‌های جهانی به کار برد. این مجموعه داده روزانه بارش در مقیاس جهانی توسط NOAA NCDC و مرکز هیدرومتئورولوژی و سنجش‌ازدور (CHRS) در دانشگاه کالیفرنیا، ایروین، توسعه یافته است. در این محصول، بارندگی روزانه از سال ۱۹۸۳ به بعد با تفکیک مکانی ۲۷ کیلومتری و به‌صورت میلی‌متر (mm) در سامانه گوگل ارث انجین قابل دسترسی است و نواحی بین ۶۰ درجه عرض جنوبی تا ۶۰ درجه عرض شمالی را پوشش می‌دهد. این محصول به‌عنوان یک منبع ارزشمند برای مطالعات الگوهای جهانی بارش و پژوهش‌های مرتبط با اقلیم شناخته می‌شود. سازمان‌ها و پژوهشگران در زمینه‌های مختلف مانند علوم زمین، مدیریت منابع آب، پیش‌بینی سیلاب‌ها و خشک‌سالی‌ها، ارزیابی ریسک‌های بارش، مدیریت بحران و برنامه‌ریزی برای توسعه پایدار از این داده‌ها بهره می‌برند. از ویژگی‌های برجسته این محصول می‌توان به دقت بالا و پوشش جهانی آن اشاره کرد که با استفاده از شبکه‌های عصبی مصنوعی و داده‌های ماهواره‌ای حاصل شده است. این محصول می‌تواند به‌عنوان یک منبع کلیدی در مطالعات آب‌وهوا، تغییرات اقلیمی و مدیریت جهانی منابع آب مورد استفاده قرار گیرد (Sorooshian et al., 2000). این مجموعه داده در سامانه گوگل ارث انجین با کد ee.ImageCollection("NOAA/PERSIANN-CDR") در دسترس می‌باشد. در این مطالعه این داده‌ها از سال ۲۰۰۱ تا سال ۲۰۲۳ از این سامانه دریافت گردید.

شاخص NDVI


شاخص تفاضلی نرمال‌شده پوشش گیاهی (NDVI) یک شاخص سنجش‌ازدور است که برای ارزیابی پوشش گیاهی و سبزی‌نگی در سطح زمین استفاده می‌شود. این شاخص بر اساس تفاوت بین نور مادون قرمز نزدیک (که توسط پوشش گیاهی منعکس می‌شود) و نور مرئی قرمز (که توسط گیاهان جذب می‌شود) محاسبه می‌شود. مقادیر NDVI بین -۱ تا +۱ قرار دارند. مقادیر بالاتر (نزدیک به +۱) نشان‌دهنده

پوشش گیاهی متراکم و سالم است، درحالی که مقادیر نزدیک به ۰ یا منفی نشان‌دهنده مناطق بدون پوشش گیاهی (مانند آب یا زمین بایر) هستند. شاخص‌های پوشش گیاهی MODIS طراحی شده‌اند تا مقایسه‌های مکانی و زمانی پیوسته‌ای از سبزیگی تاج پوشش گیاهی که خاصیتی مرکب از سطح برگ، کلروفیل و ساختار تاج است، فراهم کنند (Zheng & Zhu, 2015). مطالعات بسیاری رابطه بین NDVI و بارش را بررسی کرده‌اند (Ding et al., 2007; Fensholt et al., 2009; Martiny et al., 2006). این رابطه برای کاربرد در تخمین بارش بسیار حیاتی است زیرا NDVI که نشان‌دهنده سبزیگی و سلامت پوشش گیاهی است، می‌تواند اطلاعات مهمی درباره میزان و توزیع بارش فراهم کند. در مقایسه با داده‌های بارش، NDVI حاصل از MODIS دارای پوشش جهانی و وضوح مکانی بالاتری است. به همین دلیل، در این مطالعه از داده‌های MOD13Q1 که شامل NDVI 16 روزه با وضوح مکانی ۲۵۰ متری است، استفاده شد. این داده‌ها با کد ee.ImageCollection("MODIS/061/MOD13Q1") از سامانه گوگل ارث انجین دریافت شدند. انتخاب داده‌های MODIS با وضوح ۲۵۰ متر به دلیل دقت بالاتر در ارزیابی تغییرات مکانی پوشش گیاهی و توانایی در ارائه اطلاعات دقیق‌تر در مورد وضعیت سبزیگی زمین در مناطق مختلف، نسبت به سایر داده‌ها مزیت دارد. این داده‌ها از سال ۲۰۰۰ تاکنون در دسترس می‌باشند.

شاخص تفاضلی نرمال شده پوشش گیاهی (Normalized Difference Vegetation Index) یک ابزار سنجش‌ازدور کلیدی برای ارزیابی پوشش گیاهی و سبزیگی سطح زمین است. این شاخص از اختلاف بازتاب نور مادون قرمز نزدیک (که توسط گیاهان سالم منعکس می‌شود) و نور مرئی قرمز (که توسط گیاهان جذب می‌شود) محاسبه می‌گردد. مقادیر NDVI در بازه‌ای از -۱ تا +۱ قرار دارند، مقادیر بالاتر (نزدیک به +۱) نشان‌دهنده پوشش گیاهی متراکم و سالم است، درحالی که مقادیر نزدیک به ۰ یا منفی نشان‌دهنده مناطق بدون پوشش گیاهی (مانند آب یا زمین بایر) هستند. NDVI به دلیل وضوح مکانی بالا و پوشش جهانی که ارائه می‌دهد، به‌ویژه در مقایسه با داده‌های بارش، ابزاری مؤثر برای بررسی تغییرات مکانی و زمانی سبزیگی و همچنین تخمین بارش است. این شاخص اطلاعات جامعی درباره سطح برگ، کلروفیل و ساختار تاج گیاه ارائه می‌دهد، که همگی متغیرهای کلیدی برای تحلیل‌های اکولوژیکی و هیدرولوژیکی هستند (Zheng & Zhu, 2015). مطالعات متعددی رابطه میان NDVI و بارش را بررسی کرده‌اند و نشان داده‌اند که تغییرات این شاخص می‌تواند به‌خوبی تغییرات بارش را در مناطق مختلف مدل‌سازی کند (Ding et al., 2007; Fensholt et al., 2009; Martiny et al., 2006). در این مطالعه، از داده‌های محصول MOD13Q1 استفاده شده است که شاخص NDVI را با دوره تناوب ۱۶ روزه و وضوح مکانی ۲۵۰ متر ارائه می‌دهد. این داده‌ها از سامانه گوگل ارث انجین با استفاده از کد ee.ImageCollection("MODIS/061/MOD13Q1") دریافت شده‌اند و از سال ۲۰۰۰ تاکنون در دسترس هستند. این مجموعه داده‌ها ابزار مناسبی برای تحلیل ارتباط بارش و پوشش گیاهی در مقیاس‌های زمانی و مکانی مختلف فراهم می‌کند.

دمای سطح زمین (land surface temperature)

در این مطالعه، از داده‌های MOD11A2 که شامل دمای سطح زمین (LST) با دوره ۸ روزه و وضوح ۱ کیلومتری است، استفاده شد. این داده‌ها از طریق کد ee.ImageCollection("MODIS/061/MOD11A2") از سامانه گوگل ارث انجین دریافت شدند. این داده‌ها میانگین دمای سطح زمین را برای هر پیکسل به صورت ۸ روزه ارائه می‌دهند. برای دریافت داده‌های دمای سطح زمین به صورت ماهانه، استفاده از محصول MOD11A2 مناسب‌تر است. این محصول داده‌های دمای سطح زمین را به صورت میانگین ۸ روزه با وضوح ۱ کیلومتر ارائه می‌دهد که باعث کاهش نوسانات روزانه و افزایش دقت برای تحلیل‌های ماهانه می‌شود. همچنین، داده‌های MOD11A2 به دلیل ارائه پیوسته و منظم از سال ۲۰۰۰ تاکنون، برای تحلیل‌های بلندمدت مناسب‌تر هستند. وضوح مکانی ۱ کیلومتری این محصول نیز امکان تحلیل دقیق مکانی را فراهم می‌کند. بنابراین، برای کاربردهای بلندمدت مانند تحلیل ماهانه دمای سطح زمین، MOD11A2 به دلیل میانگین‌گیری داده‌ها و کاهش نویز روزانه، وضوح مکانی بالا، و پوشش زمانی طولانی، انتخاب بهتری است. این داده‌ها در تحلیل‌های اقلیمی و کشاورزی مانند پایش تغییرات دمایی، تحلیل روندهای گرمایش زمین، ارزیابی اثرات تغییر اقلیم، تخمین نیاز آبی گیاهان، و پایش سلامت محصولات کشاورزی کاربرد دارند (Sobrino et al., 2004; Zhengming Wan & Dozier, 1996). در این پژوهش داده‌های MODIS به دلیل وضوح ۲۵۰ متری، دقت در استخراج شاخص‌های زیست‌محیطی مانند NDVI و LST، و دسترسی طولانی‌مدت برای این مطالعه انتخاب شدند.



شکل ۲- تغییرات ماهانه شاخص تفاضلی نورمال شده پوشش گیاهی (NDVI) و دمای سطح زمین (LST) در شهرستان تربت جام در ماه ژانویه سال ۲۰۲۳

مدل ارتفاعی دیجیتالی (DEM)

داده‌های ارتفاع دیجیتالی (DEM) مأموریت توپوگرافی رادار شاتلیک تلاش تحقیقاتی بین‌المللی است که مدل‌های ارتفاع دیجیتالی را در مقیاس جهانی به دست آورده است (Farr et al., 2007). این محصول SRTM نسخه ۳ (SRTM Plus) توسط آزمایشگاه پیش‌رانش جت ناسا (JPL) با دقت ۱ ثانیه قوسی (تقریباً ۳۰ متر) ارائه می‌شود. این مجموعه داده در سامانه گوگل ارث انجین با کد ee. Image("USGS/SRTMGL1_003") در دسترس می‌باشد. داده‌های DEM نقش مهمی در مطالعات مختلف اقلیمی، هیدرولوژیکی و محیط‌زیستی ایفا می‌کنند. این داده‌ها می‌توانند به تحلیل و مدل‌سازی شیب و جهت جریان آب، تعیین مناطق مستعد سیل، و بررسی تغییرات توپوگرافی کمک کنند. ارتباط داده‌های DEM با سایر داده‌های محیطی مانند بارش، دمای سطح زمین (LST) و پوشش گیاهی (NDVI) به محققان اجازه می‌دهد تا روابط پیچیده‌ای بین این متغیرها را شناسایی و مدل‌سازی کنند (Grohmann et al., 2011).

اعتبارسنجی

برای ارزیابی نتایج کاهش مقیاس داده‌های بارش ماهواره‌ای با ایستگاه‌های زمینی از معیارهای آماری ضریب همبستگی (CC)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) استفاده گردید.

$$CC = \frac{\frac{1}{N} \sum_{i=1}^n [(P_i - \bar{P})(O_i - \bar{O})]}{\sqrt{\frac{1}{N} \sum_{i=1}^n (P_i - \bar{P})^2} \sqrt{\frac{1}{N} \sum_{i=1}^n (O_i - \bar{O})^2}} \quad \text{رابطه (۱)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad \text{رابطه (۲)}$$

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad \text{رابطه (۳)}$$

در اینجا، P نشان‌دهنده میزان بارندگی محاسبه‌شده توسط نتایج کاهش مقیاس است و O میزان بارندگی مشاهده‌شده در ایستگاه‌های هواشناسی را نشان می‌دهد. ضریب همبستگی (CC) بیانگر همبستگی بین متغیرهاست؛ هر چه مقدار CC بزرگ‌تر باشد، همبستگی بیشتر است و بالعکس. ریشه میانگین مربعات خطا (RMSE) برای اندازه‌گیری انحراف بین مقدار پیش‌بینی‌شده و مقدار واقعی استفاده می‌شود؛ مقدار بیشتر RMSE نشان‌دهنده سوگیری بیشتر در پیش‌بینی است و برعکس. میانگین خطای مطلق (MAE) میانگینی از خطاهای مطلق است که از حذف تأثیر مثبت و منفی شدن خطاها جلوگیری می‌کند. هر چه مقدار MAE کوچک‌تر باشد، دقت پیش‌بینی مدل بالاتر است.


اصلاح باقیمانده

اصلاح باقیمانده (Residual Correction) یک تکنیک آماری است که برای بهبود دقت پیش‌بینی‌های مدل به کار می‌رود. در مدل‌های

پیش‌بینی، ممکن است خطاها یا باقیمانده‌هایی (Residuals) بین مقادیر پیش‌بینی‌شده و مقادیر واقعی وجود داشته باشد که نشان‌دهنده تفاوت بین نتایج مدل و داده‌های واقعی است. هدف از اصلاح باقیمانده، مدل‌سازی این خطاها و اعمال اصلاحات بر نتایج مدل اصلی است تا دقت نهایی مدل بهبود یابد. این روش به‌ویژه در مواردی مفید است که مدل اصلی به‌تنهایی قادر به توضیح کامل الگوهای داده‌های پیچیده نباشد. در این تحقیق، از روش اصلاح باقیمانده برای بهبود دقت مدل ریزمقیاس‌سازی داده‌های بارش استفاده شده است. این روش باعث کاهش خطای مدل‌های پیش‌بینی، بهبود دقت مکانی، بهینه‌سازی مدل‌سازی داده‌های پیچیده می‌گردد. این روش خطاهای سیستماتیک را که مدل اصلی قادر به توضیح آن‌ها نیست، کاهش می‌دهد. در مدل‌های ریزمقیاس‌سازی، به‌ویژه در مناطق خشک و نیمه خشک، ممکن است مدل اصلی قادر به پیش‌بینی دقیق تغییرات مکانی بارش نباشد. با اصلاح باقیمانده، این تغییرات بهبود یافته و پیش‌بینی‌ها با داده‌های زمینی بهتر هماهنگ می‌شوند همچنین اصلاح باقیمانده امکان بهینه‌سازی مدل‌سازی داده‌های پیچیده و غیرخطی را فراهم می‌آورد و به مدل کمک می‌کند تا الگوهایی که در داده‌ها مخفی هستند، بهتر شناسایی شود (F. Chen et al. , 2020; Lima et al. , 2012). برای اصلاح باقیمانده ابتدا مقادیر باقیمانده‌ها با محاسبه تفاوت بین مقادیر واقعی بارش (داده‌های زمینی) و مقادیر پیش‌بینی شده از مدل ریزمقیاس‌سازی (با استفاده از داده‌های NDVI، LST و DEM) محاسبه شد. سپس از یکی از روش‌های یادگیری ماشین با عنوان جنگل تصادفی (Random Forest) برای مدل‌سازی باقیمانده‌ها استفاده شد. این روش قادر به شناسایی و مدل‌سازی الگوهای پیچیده باقیمانده‌ها می‌باشد. در نهایت، باقیمانده‌های پیش‌بینی‌شده توسط مدل‌های یادگیری ماشین به مقادیر پیش‌بینی‌شده اولیه اضافه شد تا پیش‌بینی‌های اصلاح‌شده به دست آید. عملکرد مدل قبل و بعد از اصلاح با استفاده از معیارهای ریشه میانگین مربعات خطا (RMSE)، میانگین خطای مطلق (MAE) و ضریب همبستگی (CC) مورد ارزیابی قرار گرفت.

نتایج و بحث

تحلیل نقشه‌های بارشی با دو مقیاس ۲۷ کیلومتری و ۱ کیلومتری تفاوت‌های چشمگیری را نشان می‌دهد. نقشه‌های ۱ کیلومتری به دلیل وضوح بالاتر، الگوهای بارشی محلی مانند رگبارهای کوتاه‌مدت و ناهنجاری‌های اقلیمی را با دقت بیشتری نمایش می‌دهند و برای شناسایی مناطق حساس به بارش، مدیریت منابع آب و کاهش خطرات طبیعی مفیدتر هستند. در مقابل، نقشه‌های ۲۷ کیلومتری تن‌ها دیدی کلی در سطح منطقه‌ای ارائه می‌دهند و جزئیات دقیق محلی را نمی‌توانند نشان دهند. در شکل ۲ تغییرات بارش ماهانه در ماه ژانویه ۲۰۲۳ در مقیاس ۲۷ کیلومتری داده‌های PERSIANN و داده‌های بارش ریزمقیاس‌شده در مقیاس ۱ کیلومتری آورده شده است. همان‌طور که در شکل مشاهده می‌گردد الگوهای بارش در دو نقشه با یکدیگر همخوانی دارد؛ اما ریزمقیاس‌سازی باعث گردیده است که نقشه یک کیلومتری از جزئیات بیشتری در بارندگی این شهرستان برخوردار باشد.



شکل ۳- تغییرات بارش ماهانه در مقیاس‌های مختلف در ایستگاه تربت‌جام در ماه ژانویه سال ۲۰۲۳

نتایج آنالیزهای آماری مقایسه بارش ماهواره‌ای یک کیلومتری و ۲۷ کیلومتری در دو مقیاس ماهانه و سالانه در جداول ۲ و ۳ آورده شده است. در مقایسه داده‌های بارش ماهواره‌ای در مقیاس مکانی ۱ و ۲۷ کیلومتری در مقیاس ماهانه همان‌طور که مشاهده می‌گردد در ایستگاه فیروزکوه و رباط سمنگان ریزمقیاس‌سازی توانسته است همبستگی داده‌های بارش را با مقادیر بارش مشاهده‌شده افزایش دهد و ریشه میانگین مربعات خطا و میانگین خطای مطلق را کاهش دهد؛ اما در ایستگاه تربت‌جام با ریزمقیاس‌سازی، داده‌های بارش تفاوت قابل

ملاحظه‌ای را نشان ندادند؛ و در این ایستگاه در داده‌های ریزمقیاس شده فقط ریشه میانگین مربعات خطا کمتر از داده‌های درشت مقیاس بود و بقیه پارامترهای آماری در بارش ماهواره‌ای ۲۷ کیلومتری اندکی بهتر از داده‌های ریزمقیاس شده به دست آمد.

جدول ۲- آنالیزهای آماری مقایسه بارش‌های ماهانه ماهواره‌ای با وضوح مکانی متفاوت در ایستگاه‌های باران‌سنجی با داده‌های زمینی.

ایستگاه	پارامتر آماری	بارش یک کیلومتری	بارش ۲۷ کیلومتری
ترتیب جام	ضریب همبستگی (CC)	۰/۷۸۴	۰/۷۹۰
	ریشه میانگین مربعات خطا (RMSE)	۱۳/۲۲۸	۱۳/۳۸۲
	میانگین خطای مطلق (MAE)	۶/۹۸۷	۶/۹۱۱
فیروزکوه	ضریب همبستگی (CC)	۰/۷۴۳	۰/۷۴۱
	ریشه میانگین مربعات خطا (RMSE)	۱۴/۵۲۶	۱۵/۵۶۸
	میانگین خطای مطلق (MAE)	۸/۲۶۷	۹/۱۵۹
رباط سمنگان	ضریب همبستگی (CC)	۰/۷۵۸	۰/۷۴۷
	ریشه میانگین مربعات خطا (RMSE)	۱۴/۸۱۶	۱۵/۶۲۷
	میانگین خطای مطلق (MAE)	۸/۲۴۳	۸/۳۷۸

در مقایسه داده‌های بارش ماهواره‌ای در مقیاس مکانی ۱ و ۲۷ کیلومتری در مقیاس سالانه همانطور که مشاهده می‌گردد در کلیه ایستگاه‌های مورد مطالعه (رباط سمنگان، فیروزکوه و ترتیب جام) همبستگی داده‌های بارش ۲۷ کیلومتری مقدار بسیار کمی بیشتر از داده‌های بارش یک کیلومتری بوده است، این موضوع می‌تواند به دلیل هموارسازی فضایی (spatial smoothing) در داده‌های ۲۷ کیلومتری باشد که باعث کاهش نویز و افزایش همبستگی با داده‌های مشاهده‌شده می‌شود. هموارسازی فضایی می‌تواند الگوهای کلی بارش را بهتر نمایان کند و در نتیجه همبستگی بهتری با داده‌های زمینی داشته باشد. از سوی دیگر، داده‌های ۱ کیلومتری به دلیل دقت بالاتر و توانایی شناسایی نوسانات محلی، ممکن است نویز بیشتری داشته باشند که باعث کاهش همبستگی با داده‌های زمینی می‌شود. با این حال، این داده‌ها توانسته‌اند ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) کمتری نسبت به داده‌های ۲۷ کیلومتری نشان دهند که نشان‌دهنده دقت بالاتر در پیش‌بینی‌های محلی است.

جدول ۳- آنالیزهای آماری مقایسه بارش‌های سالانه ماهواره‌ای با وضوح مکانی متفاوت در ایستگاه‌های باران‌سنجی با داده‌های زمینی

ایستگاه	پارامتر آماری	بارش یک کیلومتری	بارش ۲۷ کیلومتری
ترتیب جام	ضریب همبستگی (CC)	۰/۷۱۴	۰/۷۱۹
	ریشه میانگین مربعات خطا (RMSE)	۶۴/۳۷۹	۶۷/۰۸۳
	میانگین خطای مطلق (MAE)	۴۶/۹۷۵	۵۰/۲۸۵
فیروزکوه	ضریب همبستگی (CC)	۰/۷۰۸	۰/۷۱۵
	ریشه میانگین مربعات خطا (RMSE)	۷۷/۳۹۴	۸۷/۳۶۴
	میانگین خطای مطلق (MAE)	۶۶/۴۶۳	۷۵/۷۹۱
رباط سمنگان	ضریب همبستگی (CC)	۰/۹۲۳	۰/۹۲۹
	ریشه میانگین مربعات خطا (RMSE)	۵۲/۲۴۷	۵۴/۰۱۲
	میانگین خطای مطلق (MAE)	۳۹/۳۳۱	۴۱/۵۸۶

نتایج جداول ۲ و ۳ مقایسه‌ای دقیق بین داده‌های بارش با وضوح ۲۷ کیلومتر و ۱ کیلومتر ارائه می‌دهند. داده‌های با وضوح ۱ کیلومتر، جزئیات مکانی بیشتری را نشان داده و برای کاربردهای محلی مانند مدیریت منابع آب، برنامه‌ریزی کشاورزی و پایش مناطق حساس اقلیمی مناسب‌تر هستند. در مقابل، داده‌های با وضوح ۲۷ کیلومتر ممکن است در سطوح منطقه‌ای یا جهانی مفید باشند، اما به دلیل از دست دادن جزئیات مکانی، در مقیاس‌های محلی کاربرد محدودتری دارند. Cho, Herin et al. (2013) نیز در شبه‌جزیره کره با استفاده از ریزمقیاس‌سازی محصول بارشی TRMM به وضوح مکانی بالاتر از ۲۵ کیلومتر به ۱ کیلومتر رسیده و دقت الگوهای بارشی محلی را بهبود بخشیده‌اند. Zhang et al. (2018) نیز در تحقیقات خود به بررسی روش‌های آماری و جغرافیایی برای ریزمقیاس‌سازی داده‌های بارشی TRMM پرداخته و نشان دادند که نقشه‌های ۱ کیلومتری در مناطق کوهستانی دقت بالاتری نسبت به نقشه‌های درشت‌تر دارند (Karbalaye Ghorbanpour et al. 2021). نیز در پژوهش خود در حوزه دریاچه ارومیه به مقایسه روش‌های مختلف ریزمقیاس‌سازی پرداخته و تأکید کرده‌اند که روش‌های با وضوح بالاتر، مانند داده‌های ۱ کیلومتری، برای دقت بیشتر بارش در مناطق خشک با شبکه اندازه‌گیری محدود مؤثرتر هستند. این یافته با نتایج پژوهش حاضر هم‌راستا است، جایی که استفاده از داده‌های بارش ماهواره‌ای با وضوح

۱ کیلومتر و متغیرهای کمکی مانند NDVI، LST و DEM، دقت پیش‌بینی‌ها را در منطقه تربت‌جام به‌طور قابل‌توجهی بهبود بخشید. با این حال، نتایج همچنین نشان می‌دهند که در مناطق با شبکه‌های اندازه‌گیری پراکنده یا شرایط اقلیمی خاص، عملکرد داده‌های ریزمقیاس شده ممکن است متفاوت باشد و این امر نیاز به تنظیمات خاص روش‌ها بر اساس ویژگی‌های محلی را نشان می‌دهد. Noor et al. (2023) نیز در تحقیق خود به ترکیب داده‌های بارشی APHRODITE و TRMM در حوزه رودخانه ایندوس به‌منظور افزایش دقت داده‌های بارشی پرداخته و استفاده از روش‌های ریزمقیاس‌سازی ۱ کیلومتری را برای بهبود دقت بارشی در مناطق پایین‌دست تأیید کردند. پس از به دست آوردن نتایج قبلی، تصمیم بر این شد که برای کاهش خطای مدل از تکنیک اصلاح باقیمانده استفاده گردد. روش اصلاح باقیمانده با توجه به اینکه خطاهای پیش‌بینی ناشی از ریزمقیاس‌سازی اولیه را تعدیل می‌کند، تفاوت‌های مکانی و زمانی بارش که به‌طور مستقیم در مدل اولیه شناسایی نشده‌اند، به‌طور مؤثری مدیریت می‌کند. این روش با استفاده از اطلاعات محلی مانند DEM و NDVI و همچنین تغییرات زمانی بارش، ناهمبستگی‌های مکانی و تغییرات زمانی را تصحیح می‌کند. با این حال، احتمال ایجاد همبستگی‌های کاذب در این مرحله وجود دارد، که برای کاهش این خطر، انتخاب دقیق متغیرهای ورودی و ارزیابی‌های آماری مداوم انجام شده تا اطمینان حاصل شود که اصلاحات به‌طور معنادار و بدون ایجاد همبستگی‌های کاذب انجام می‌شوند. این روش با بررسی تفاوت‌های بین مقادیر پیش‌بینی شده و داده‌های مشاهداتی (مانند داده‌های ایستگاه‌های باران‌سنجی)، خطاهای سیستماتیک را شناسایی و اصلاح می‌کند. پس از اصلاح باقیمانده، مدل به‌طور موثرتری می‌تواند انحرافات و ناهنجاری‌های مکانی را تصحیح کند و به این ترتیب نتایج بهتری ارائه دهد. به عبارت دیگر، اصلاح باقیمانده به مدل کمک می‌کند تا نتایجی که از ریزمقیاس‌سازی اولیه حاصل شده، با داده‌های واقعی بهتر تطبیق داده شوند و به‌ویژه در مناطق کم‌داده یا با تغییرات مکانی شدید، خطاها به حداقل برسند. این روش به‌ویژه در مواردی مفید است که مدل اصلی به تنهایی قادر به توضیح کامل الگوهای داده‌های پیچیده نباشد. نتایج اعتبارسنجی ریزمقیاس‌سازی داده‌های بارش در مقیاس ماهانه و سالانه ایستگاه‌های باران‌سنجی شهرستان تربت‌جام بعد از اصلاح باقیمانده در جدول ۴ و ۵ آورده شده است.

جدول ۴- آنالیزهای آماری مقایسه بارش‌های ماهانه ماهواره‌ای با وضوح مکانی متفاوت در ایستگاه‌های باران‌سنجی با داده‌های زمینی بعد از اصلاح باقیمانده

ایستگاه	پارامتر آماری	بارش یک کیلومتری	بارش یک کیلومتری با اصلاح باقیمانده
تربت‌جام	ضریب همبستگی (CC)	۰/۷۸۴	۰/۹۶۰
	ریشه میانگین مربعات خطا (RMSE)	۱۳/۲۲۸	۴/۷۵۳
	میانگین خطای مطلق (MAE)	۶/۹۸۷	۲/۳۹۸
فیروزکوه	ضریب همبستگی (CC)	۰/۷۴۳	۰/۹۶۱
	ریشه میانگین مربعات خطا (RMSE)	۱۴/۵۲۶	۵/۳۳۰
	میانگین خطای مطلق (MAE)	۸/۲۶۷	۲/۶۳۱
رباط سمنگان	ضریب همبستگی (CC)	۰/۷۵۸	۰/۹۵۶
	ریشه میانگین مربعات خطا (RMSE)	۱۴/۸۱۶	۵/۷۱۵
	میانگین خطای مطلق (MAE)	۸/۲۴۳	۳/۲۷۷

جدول ۵- آنالیزهای آماری مقایسه بارش‌های سالانه ماهواره‌ای با وضوح مکانی متفاوت در ایستگاه‌های باران‌سنجی با داده‌های زمینی بعد از اصلاح باقیمانده

ایستگاه	پارامتر آماری	بارش یک کیلومتری	بارش یک کیلومتری با اصلاح باقیمانده
تربت‌جام	ضریب همبستگی (CC)	۰/۷۱۴	۰/۹۵۶
	ریشه میانگین مربعات خطا (RMSE)	۶۴/۳۷۹	۱۸/۵۵۲
	میانگین خطای مطلق (MAE)	۴۶/۹۷۵	۱۴/۴۵۰
فیروزکوه	ضریب همبستگی (CC)	۰/۷۰۸	۰/۹۵۴
	ریشه میانگین مربعات خطا (RMSE)	۷۷/۳۹۴	۲۳/۶۲۱
	میانگین خطای مطلق (MAE)	۶۶/۴۶۳	۱۵/۹۱۰
رباط سمنگان	ضریب همبستگی (CC)	۰/۹۲۳	۰/۹۸۶
	ریشه میانگین مربعات خطا (RMSE)	۵۲/۲۴۷	۱۳/۷۶۸
	میانگین خطای مطلق (MAE)	۳۹/۳۳۱	۱۰/۴۰۲

نتایج نشان داد که در تمامی ایستگاه‌های مورد مطالعه و در مقیاس‌های زمانی ماهانه و سالانه استفاده از روش اصلاح باقیمانده باعث بهبود قابل‌توجهی در دقت پیش‌بینی‌ها شد. در ایستگاه تربت‌جام در مقیاس ماهانه همبستگی بین پیش‌بینی‌های اصلاح‌شده و داده‌های

واقعی به میزان ۲۲ درصد و در مقیاس سالانه به میزان ۳۴ درصد افزایش یافت. مقادیر ریشه میانگین مربعات خطا به میزان ۶۴ درصد در مقیاس ماهانه و ۷۱ درصد در مقیاس ماهانه کاهش نشان داد و همچنین میانگین مطلق خطا نیز به میزان ۶۶ درصد در مقیاس ماهانه و ۶۹ درصد در مقیاس سالانه کاهش داشت که نشان‌دهنده کاهش خطاهای پیش‌بینی است. در ایستگاه فیروزکوه نیز همبستگی بین مقادیر پیش‌بینی‌های اصلاح‌شده و داده‌های واقعی به میزان ۲۹ درصد و در مقیاس سالانه به میزان ۳۵ درصد افزایش یافت. مقادیر ریشه میانگین مربعات خطا به میزان ۶۳ درصد در مقیاس ماهانه و ۶۹ درصد در مقیاس ماهانه کاهش نشان داد و همچنین میانگین مطلق خطا نیز به میزان ۶۸ درصد در مقیاس ماهانه و ۷۶ درصد در مقیاس سالانه کاهش داشت. در ایستگاه رباط سمنگان در مقیاس ماهانه همبستگی بین پیش‌بینی‌های اصلاح‌شده و داده‌های واقعی به میزان ۲۶ درصد و در مقیاس سالانه به میزان ۷ درصد افزایش یافت. مقادیر ریشه میانگین مربعات خطا به میزان ۶۱ درصد در مقیاس ماهانه و ۷۴ درصد در مقیاس ماهانه کاهش نشان داد و همچنین میانگین مطلق خطا نیز به میزان ۶۰ درصد در مقیاس ماهانه و ۷۴ درصد در مقیاس سالانه کاهش داشت. Zhan et al. (2018) نیز در تحقیقات خود نشان دادند که روش‌های اصلاح باقیمانده در مناطق نیمه‌خشک که با استفاده از روش‌های یادگیری ماشین مانند جنگل تصادفی و Kriging صورت گرفته، توانسته دقت پیش‌بینی‌های بارش را در مقیاس‌های کوچک‌تر بهبود بخشد. C. Chen et al. (2020) اشاره کرده‌اند که استفاده از روش‌های یادگیری ماشین مانند جنگل تصادفی برای ریزمقیاس‌سازی بارش، همراه با اصلاح باقیمانده می‌تواند خطاهای سیستماتیک در مناطق خشک و نیمه‌خشک را کاهش دهد و به‌طور قابل‌توجهی دقت پیش‌بینی‌ها را افزایش دهد. Zhu et al. (2023) نیز در پژوهشی که روش‌های مختلف ریزمقیاس‌سازی بارش را بررسی کرده‌اند، اشاره می‌کنند که فرآیند اصلاح باقیمانده به‌ویژه در مناطق کم داده، می‌تواند دقت پیش‌بینی‌ها را بهبود بخشد. آن‌ها از روش‌هایی مانند جنگل تصادفی و Kriging برای اصلاح باقیمانده استفاده کردند که تأثیر مثبتی بر دقت مدل داشتند. Jing et al. (2016a) در مطالعه‌ای که روش‌های مختلف رگرسیون و یادگیری ماشین را برای ریزمقیاس‌سازی بارش مقایسه کرده‌اند، نشان دادند که جنگل تصادفی (RF) و شبکه عصبی مصنوعی (ANN) با استفاده از اصلاح باقیمانده، دقت پیش‌بینی‌های بارش را بهبود داده‌اند. Zhao, 2021 در یک حوزه کوهستانی به بررسی بهبود دقت پیش‌بینی بارش با استفاده از جنگل تصادفی و اصلاح باقیمانده پرداخته است. نتایج نشان داد که پس از اعمال اصلاح باقیمانده، دقت مدل به‌طور قابل‌توجهی افزایش یافت و خطای میانگین مطلق (MAE) و ریشه میانگین مربعات خطا (RMSE) به ترتیب ۱۹٪ و ۲۱٪ کاهش یافت. اصلاح باقیمانده به چندین دلیل موجب بهبود داده‌های بارش می‌شود. اولاً، این روش به کاهش خطاهای سیستماتیک و تصادفی کمک می‌کند. با استفاده از اصلاح باقیمانده، تفاوت‌های بین داده‌های واقعی و پیش‌بینی‌های اولیه شناسایی و تصحیح می‌شوند. این کار باعث کاهش خطاهای سیستماتیک (مانند بایاس‌ها) و خطاهای تصادفی می‌شود که در نتیجه دقت مدل را افزایش می‌دهد. ثانیاً، الگوریتم‌های پیشرفته مانند جنگل تصادفی (Random Forest) که در اصلاح باقیمانده استفاده می‌شوند، قادر به شناسایی و مدل‌سازی الگوهای پیچیده در داده‌های باقی‌مانده هستند. این الگوریتم‌ها به شناسایی وابستگی‌ها و روابط نهفته در داده‌ها کمک می‌کنند که مدل‌های ساده‌تر قادر به شناسایی آن‌ها نیستند. علاوه بر این، اصلاح باقیمانده موجب افزایش دقت پیش‌بینی‌ها می‌شود. با اعمال این اصلاحات، مدل می‌تواند پیش‌بینی‌های دقیق‌تری از بارش ارائه دهد که باعث افزایش اطمینان به نتایج مدل و کاهش ریسک در کاربردهای عملی مانند مدیریت منابع آب و پیش‌بینی‌های کشاورزی می‌شود. این روش به مدل کمک می‌کند تا با شرایط محلی و داده‌های واقعی بهتر تطبیق یابد. نتایج به دست آمده پس از اعمال اصلاحات باقیمانده نشان‌دهنده کاهش خطاها و افزایش دقت پیش‌بینی‌های بارش است که به افزایش اعتماد به کاربردهای عملی این مدل‌ها کمک می‌کند. این امر به ویژه در مناطق با داده‌های ایستگاه‌های زمینی محدود و توپوگرافی پیچیده از اهمیت ویژه‌ای برخوردار است. چنین رویکردی، الگوهای مکانی و زمانی محلی را بهتر شناسایی و پیش‌بینی می‌کند، که به نوبه خود دقت مدل را افزایش می‌دهد.

نتیجه‌گیری

این مطالعه نشان داد که کارایی ریزمقیاس‌سازی داده‌های بارش در ایستگاه‌های مختلف به عوامل محلی و اقلیمی بستگی دارد. در ایستگاه‌های فیروزکوه و رباط سمنگان، ریزمقیاس‌سازی داده‌های بارش در مقیاس‌های ماهانه و سالانه نتایج مطلوبی داشت. در مقابل، در ایستگاه تربت‌جام، نتایج ریزمقیاس‌سازی در مقیاس ماهانه تفاوت قابل‌توجهی با داده‌های ۲۷ کیلومتری نداشت و عملکرد داده‌های اولیه بهتر بود. این تفاوت‌ها می‌توانند ناشی از عوامل مکانی مانند تفاوت در پوشش گیاهی، توپوگرافی یا الگوهای بارشی خاص هر منطقه و یا عدم ایجاد تنظیمات ویژه در مدل برای این منطقه باشند. برای بهبود دقت مدل در تمامی ایستگاه‌ها، از روش اصلاح باقیمانده استفاده شد. این روش توانست خطاهای ناشی از ریزمقیاس‌سازی اولیه را کاهش داده و همبستگی پیش‌بینی‌ها با داده‌های زمینی را بهبود بخشد. به‌ویژه در ایستگاه

تربت‌جام، استفاده از این روش تأثیر چشمگیری بر بهبود نتایج در مقیاس ماهانه داشت. نتایج نشان داد که اصلاح باقیمانده به مدل اجازه می‌دهد تا با استفاده از اطلاعات واقعی‌تر، پیش‌بینی‌های دقیق‌تری ارائه دهد. این روش به‌ویژه در مناطق با داده‌های محدود یا الگوهای مکانی پیچیده، عملکرد مدل را بهینه کرد. استفاده از مدل جنگل تصادفی (RF) برای ریزمقیاس‌سازی داده‌های PERSIANN با وضوح ۱ کیلومتر در منطقه مورد مطالعه رویکردی کارآمد بود. افزوده شدن متغیرهای کلیدی نظیر NDVI، LST، و DEM، دقت پیش‌بینی‌ها را افزایش داد. به طور کلی، داده‌های ماهواره‌ای به دلیل پوشش جغرافیایی گسترده، پیوستگی زمانی، و دسترسی به مناطق دورافتاده، ابزار ارزشمندی برای مدل‌سازی بارش و تحلیل‌های اقلیمی محسوب می‌شوند. ترکیب تکنیک‌های ریزمقیاس‌سازی و اصلاح باقیمانده با داده‌های زمینی می‌تواند دقت تحلیل‌های اقلیمی و هیدرولوژیکی را به طور قابل‌توجهی افزایش دهد. صحت‌سنجی مداوم این مدل‌ها با داده‌های مشاهداتی محلی برای شناسایی و کاهش خطاها، بهبود نتایج، و ارتقای کاربرد عملی مدل ضروری است.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

REFERENCES

- Chen, C. , Chen, Q. , Qin, B. , Zhao, S. , & Duan, Z. (2020). Comparison of Different Methods for Spatial Downscaling of GPM IMERG V06B Satellite Precipitation Product Over a Typical Arid to Semi-Arid Area. *Frontiers in Earth Science*, 8, 536337. <https://doi.org/10.3389/feart.2020.536337>
- Chen, F. , Gao, Y. , Wang, Y. , & Li, X. (2020). A downscaling-merging method for high-resolution daily precipitation estimation. *Journal of Hydrology*, 581, 124414. <https://doi.org/10.1016/j.jhydrol.2019.124414>
- Cho, Herin, Hwang, Seok Hwan, Cho, Yong-Sik, & Choi, Minha. (2013). Analysis of Spatial Precipitation Field Using Downscaling on the Korean Peninsula. *Journal of Korea Water Resources Association*, 46(11), 1129–1140. <https://doi.org/10.3741/JKWRA.2013.46.11.1129>
- De Kauwe, M. G. , Taylor, C. M. , Harris, P. P. , Weedon, G. P. , & Ellis, Richard. J. (2013). Quantifying Land Surface Temperature Variability for Two Sahelian Mesoscale Regions during the Wet Season. *Journal of Hydrometeorology*, 14(5), 1605–1619. <https://doi.org/10.1175/JHM-D-12-0141.1>
- Ding, M. , Zhang, Y. , Liu, L. , Zhang, W. , Wang, Z. , & Bai, W. (2007). The relationship between NDVI and precipitation on the Tibetan Plateau. *Journal of Geographical Sciences*, 17(3), 259–268. <https://doi.org/10.1007/s11442-007-0259-7>
- Farr, T. G. , Rosen, P. A. , Caro, E. , Crippen, R. , Duren, R. , Hensley, S. , Kobrick, M. , Paller, M. , Rodriguez, E. , Roth, L. , Seal, D. , Shaffer, S. , Shimada, J. , Umland, J. , Werner, M. , Oskin, M. , Burbank, D. , & Alsdorf, D. (2007). The Shuttle Radar Topography Mission. *Reviews of Geophysics*, 45(2), 2005RG000183. <https://doi.org/10.1029/2005RG000183>
- Fensholt, R. , Rasmussen, K. , Nielsen, T. T. , & Mbow, C. (2009). Evaluation of earth observation based long term vegetation trends—Intercomparing NDVI time series trend analysis consistency of Sahel from AVHRR GIMMS, Terra MODIS and SPOT VGT data. *Remote Sensing of Environment*, 113(9), 1886–1898. <https://doi.org/10.1016/j.rse.2009.04.004>
- Grohmann, C. H. , Smith, M. J. , & Riccomini, C. (2011). Multiscale Analysis of Topographic Surface Roughness in the Midland Valley, Scotland. *IEEE Transactions on Geoscience and Remote Sensing*, 49(4), 1200–1213. <https://doi.org/10.1109/TGRS.2010.2053546>
- Guanghua Xu, Xu, G. , Xianli Xu, Xu, X. , Meixian Liu, Liu, M. , Alexander Y. Sun, Sun, A. Y. , Kelin Wang, & Wang, K. (2015). Spatial Downscaling of TRMM Precipitation Product Using a Combined Multifractal and Regression Approach: Demonstration for South China. *Water*, 7(6), 3083–3102. <https://doi.org/10.3390/w7063083>
- Immerzeel, W. W. , Rutten, M. M. , & Droogers, P. (2009). Spatial downscaling of TRMM precipitation using vegetative response on the Iberian Peninsula. *Remote Sensing of Environment*, 113(2), 362–370. <https://doi.org/10.1016/j.rse.2008.10.004>
- Jia, S. , Zhu, W. , Lü, A. , & Yan, T. (2011). A statistical spatial downscaling algorithm of TRMM precipitation based on NDVI and DEM in the Qaidam Basin of China. *Remote Sensing of Environment*, 115(12), 3069–3079. <https://doi.org/10.1016/j.rse.2011.06.009>
- Jing, W. , Yang, Y. , Yue, X. , & Zhao, X. (2016a). A Comparison of Different Regression Algorithms for Downscaling Monthly Satellite-Based Precipitation over North China. *Remote Sensing*, 8(10), 835. <https://doi.org/10.3390/rs8100835>
- Jing, W. , Yang, Y. , Yue, X. , & Zhao, X. (2016b). A Spatial Downscaling Algorithm for Satellite-Based

- Precipitation over the Tibetan Plateau Based on NDVI, DEM, and Land Surface Temperature. *Remote Sensing*, 8(8). <https://doi.org/10.3390/rs8080655>
- Karbalaye Ghorbanpour, A. , Hessels, T. , Moghim, S. , & Afshar, A. (2021). Comparison and assessment of spatial downscaling methods for enhancing the accuracy of satellite-based precipitation over Lake Urmia Basin. *Journal of Hydrology*, 596, 126055. <https://doi.org/10.1016/j.jhydrol.2021.126055>
- Li, Y. , Zhang, Y. , He, D. , Luo, X. , & Ji, X. (2019). Spatial Downscaling of the Tropical Rainfall Measuring Mission Precipitation Using Geographically Weighted Regression Kriging over the Lancang River Basin, China. *Chinese Geographical Science*, 29(3), 446–462. <https://doi.org/10.1007/s11769-019-1033-3>
- Lima, A. R. , Cannon, A. J. , & Hsieh, W. W. (2012). Downscaling temperature and precipitation using support vector regression with evolutionary strategy. *The 2012 International Joint Conference on Neural Networks (IJCNN)*, 1–8. <https://doi.org/10.1109/IJCNN.2012.6252383>
- Ma, Z. , Shi, Z. , Zhou, Y. , Xu, J. , Yu, W. , & Yang, Y. (2017). A spatial data mining algorithm for downscaling TMPA 3B43 V7 data over the Qinghai–Tibet Plateau with the effects of systematic anomalies removed. *Remote Sensing of Environment*, 200, 378–395. <https://doi.org/10.1016/j.rse.2017.08.023>
- Martiny, N. , Camberlin, P. , Richard, Y. , & Philippon, N. (2006). Compared regimes of NDVI and rainfall in semi-arid regions of Africa. *International Journal of Remote Sensing*, 27(23), 5201–5223. <https://doi.org/10.1080/01431160600567787>
- Noor, R. , Arshad, A. , Shafeeque, M. , Liu, J. , Baig, A. , Ali, S. , Maqsood, A. , Pham, Q. B. , Dilawar, A. , Khan, S. N. , Anh, D. T. , & Elbeltagi, A. (2023). Combining APHRODITE Rain Gauges-Based Precipitation with Downscaled-TRMM Data to Translate High-Resolution Precipitation Estimates in the Indus Basin. *Remote Sensing*, 15(2), 318. <https://doi.org/10.3390/rs15020318>
- Shaodan Chen, Chen, S. , Liping Zhang, Zhang, L. , Dunxian She, Dunxian She, She, D. , Dunxian She, Jie Chen, & Chen, J. (2019). Spatial Downscaling of Tropical Rainfall Measuring Mission (TRMM) Annual and Monthly Precipitation Data over the Middle and Lower Reaches of the Yangtze River Basin, China. *Water*, 11(3), 568. <https://doi.org/10.3390/w11030568>
- Shi, Y. , Song, L. , Xia, Z. , Lin, Y. , Myneni, R. , Choi, S. , Wang, L. , Ni, X. , Lao, C. , & Yang, F. (2015). Mapping Annual Precipitation across Mainland China in the Period 2001–2010 from TRMM3B43 Product Using Spatial Downscaling Approach. *Remote Sensing*, 7(5), 5849–5878. <https://doi.org/10.3390/rs70505849>
- Sobrino, J. A. , Jiménez-Muñoz, J. C. , & Paolini, L. (2004). Land surface temperature retrieval from LANDSAT TM 5. *Remote Sensing of Environment*, 90(4), 434–440. <https://doi.org/10.1016/j.rse.2004.02.003>
- Sorooshian, S. , Hsu, K. -L. , Gao, X. , Gupta, H. V. , Imam, B. , & Braithwaite, D. (2000). Evaluation of PERSIANN System Satellite–Based Estimates of Tropical Rainfall. *Bulletin of the American Meteorological Society*, 81(9), 2035–2046. [https://doi.org/10.1175/1520-0477\(2000\)081<2035:EOPSSE>2.3.CO;2](https://doi.org/10.1175/1520-0477(2000)081<2035:EOPSSE>2.3.CO;2)
- Trenberth, K. E. , & Shea, D. J. (2005). Relationships between precipitation and surface temperature. *Geophysical Research Letters*, 32(14), 2005GL022760. <https://doi.org/10.1029/2005GL022760>
- Xu, S. , Wu, C. , Wang, L. , Gonsamo, A. , Shen, Y. , & Niu, Z. (2015). A new satellite-based monthly precipitation downscaling algorithm with non-stationary relationship between precipitation and land surface characteristics. *Remote Sensing of Environment*, 162, 119–140. <https://doi.org/10.1016/j.rse.2015.02.024>
- Zhan, C. , Han, J. , Hu, S. , Liu, L. , & Dong, Y. (2018). Spatial Downscaling of GPM Annual and Monthly Precipitation Using Regression-Based Algorithms in a Mountainous Area. *Advances in Meteorology*, 2018, 1–13. <https://doi.org/10.1155/2018/1506017>
- Zhang, Y. , Li, Y. , Ji, X. , Luo, X. , & Li, X. (2018). Fine-Resolution Precipitation Mapping in a Mountainous Watershed: Geostatistical Downscaling of TRMM Products Based on Environmental Variables. *Remote Sensing*, 10(1), 119. <https://doi.org/10.3390/rs10010119>
- Zhao, N. (2021). An Efficient Downscaling Scheme for High-Resolution Precipitation Estimates over a High Mountainous Watershed. *Remote Sensing*, 13(2), 234. <https://doi.org/10.3390/rs13020234>
- Zheng, X. , & Zhu, J. (2015). A methodological approach for spatial downscaling of TRMM precipitation data in North China. *International Journal of Remote Sensing*, 36(1), 144–169. <https://doi.org/10.1080/01431161.2014.995275>
- Zhengming Wan, & Dozier, J. (1996). A generalized split-window algorithm for retrieving land-surface temperature from space. *IEEE Transactions on Geoscience and Remote Sensing*, 34(4), 892–905.

<https://doi.org/10.1109/36.508406>

Zhu, H. , Liu, H. , Zhou, Q. , & Cui, A. (2023). Towards an Accurate and Reliable Downscaling Scheme for High-Spatial-Resolution Precipitation Data. *Remote Sensing*, 15(10), 2640.
<https://doi.org/10.3390/rs15102640>