



<https://gep.ui.ac.ir/?lang=en>
Geography and Environmental Planning
E-ISSN: 2252- 0910
Document Type: Research Paper
Vol. 33, Issue 3, No.87, Autumn 2022, pp. 1- 6
Received: 28/02/2022 Accepted: 12/03/2022

Investigating the Application of Artificial Intelligence Approaches for Studying the Impacts of Large-Scale Climate Drivers on Precipitation in Balochistan, Pakistan

Sapna Mohammad Tajbar¹, Ali Mohammad Khorshiddoust^{2*}, Saeed Jahanbaksh Asl³

1- PhD Candidate, Department of Climatology, Faculty of Planning and Environmental Sciences, University of Tabriz, Tabriz, Iran

sapnatajbar@gmail.com

2- Professor, Department of Climatology, Faculty of Planning and Environmental Sciences, University of Tabriz, Tabriz, Iran

khoshid@tabrizu.ac.ir

3- Professor, Department of Climatology, Faculty of Planning and Environmental Sciences, University of Tabriz, Tabriz, Iran

s_jahan@tabrizu.ac.ir

Abstract

The Balochistan province of Pakistan is mostly affected by severe drought events due to little amount of precipitation. "Several Large Scale Climate Drivers (LSCDs) are known for their effects on precipitation worldwide but studies in the region are missing; a wide variety of LSCDs and lagged associative information". The current study aimed to identify the significant LSCDs in the Balochistan province of Pakistan and improve the prediction skill of monthly precipitation by employing the Principal Component Analysis, Artificial Neural Network (ANN), Bayesian Regularization Neural Network (BRNN), and Multiple Regression (MR) Analysis using the 12 months lagged LSCDs such as Nino-1+2, Nino-3, Nino-3.4, Nino-4, QBO at 30 and 50hpa (QBOI and QBOII), Sea Surface Temperature (SST), 2m air temperature (T2M), 500hpa and 850hpa geopotential heights (H500 and H850), 500hpa zonal velocity (U500), 500hpa and 850hpa meridional velocity (V500 and V850), Latent and Sensible Heat Fluxes Over Land (LHFOL and SHFOL), and Surface Specific Humidity (SSH). To collect the data, Global Land Data Assimilation System, Tropical Rainfall Measuring Mission, MERRA-2, NOAA, Freie University Berlin, and HadISST datasets were used. The results of the study showed that significant LSCDs with a 99% confidence level were SSH, SST, LHFOL, SHFOL, T2M, U500, Nino-3.4, and Nino-4. During the test period, compared with MR models of 0.15 to 0.49 and principal components of -0.16 to 0.43, the ANN and BRNN models had better predictive skills with correlation coefficients of 0.40 to 0.74 and 0.34 to 0.70, respectively. It can be

*Corresponding Author

Mohammad Tajbar, S., Khorshiddoust, A., Jahanbaksh Asl, S. (2022). Artificial Intelligence Approaches for Studying the Impacts of Large Scale Climate Drivers on Precipitation in Balochistan, Pakistan. *Geography and Environmental Planning*, 33 (3), 1-6.



This work is licensed under a [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/)



<http://dx.doi.org/10.22108/gep.2022.132899.1497>



20.1001.1.20085362.1401.33.3.1.

concluded that the ANN and BRNN models enable us to predict monthly precipitation in the Balochistan region with lagged LSCDs.

Extended Abstract

Introduction

Pakistan is one of the most vulnerable countries due to climate change. According to the Global Climate Risk Index (GCRI) report, with the passage of time, its vulnerability is increasing. The main threats consist of a rise in temperature, irregular patterns of rainfall, a rise in the sea level, and extreme events such as droughts, floods, and heatwaves.

Precipitation plays an important role in the economy of Pakistan as an agricultural country that has experienced variations, particularly in a recent couple of decades when a sharp jump in global atmospheric temperatures was noticed. The southern part of Pakistan which comprises the Sindh and Balochistan provinces has an arid climate and is mostly affected by severe drought events due to less amount of rainfall throughout the year as compared to other parts of the country. This study's main focus is Balochistan province which has a long history of severe droughts and is an important province in terms of agriculture. Less than 250mm is the annual average rainfall received by the region. It is predicted that throughout the 21st century if adaptation measures are not taken, there will be a continuous increase in droughts and scarcity of water which will adversely affect the lives of people and the economy.

Globally, precipitation and droughts are strongly linked with the large-scale climate drivers through atmospheric associations but there are no detailed studies in Balochistan province that consider a wide variety of large-scale climate drivers and their lagged association with precipitation. The main objective of the present study is to identify the significant large-scale climate drivers in the Balochistan province of Pakistan and improve the prediction skill of monthly precipitation by applying the principal component analysis, artificial neural network, Bayesian regularization neural network, and multiple regression analysis considering the lagged association of climate drivers.

Methodology

In the present study, first, large-scale climate drivers from NOAA HadISST, MERRA-2, and Freie University Berlin in NetCDF files were processed using the ArcGIS model builder along with the precipitation data from GLDAS and TRMM. The data were first normalized in the range of 0 and 1 using the min-max normalization formula. For showing the 12 months' lagged association between the large-scale climate drivers and precipitation, a cross-correlation method was employed and the heatmaps were created in Origin 2021b software to show significant lagged correlations. Principal component analysis was applied and the variances and Eigenvalues for each of the components were calculated. Multi-layer feed-forward neural network with a back propagation algorithm was used for the prediction of monthly precipitation with the first two PCs in most cases, three and one in some cases as the predictors. Bayesian Regularization Neural Network (BRNN) was applied which is a version of Artificial Neural Networks (ANN) and is a more powerful method as compared to conventional ANN. MATLAB R2015a environment was used for this purpose. Then, Multiple

Regression Analysis (MRA) was carried out and was used as a benchmark for comparing ANN and BRNN models using significantly lagged climate indices in one case and in another case the selected PCs. To validate the performance of all developed models, the TRMM dataset was used. Finally, time series graphs and Radar charts were prepared for comparison.

Discussions

The findings of cross-correlations between monthly precipitation and large-scale climate drivers in Balochistan province showed the most dominant climate drivers as surface specific humidity, sea surface temperature, latent and sensible heat fluxes over land, 500hpa zonal velocity, 2m air temperature, Nino-3.4 and Nino-4, and the highest correlations were noticed for surface specific humidity, sea surface temperature, latent and sensible heat fluxes over land, 500hpa zonal velocity, 2m air temperature. It is noteworthy that in each district, the lagged correlation of maximum climate indices with precipitation was distinct at distinct lags. The multiple regression best models were selected on the basis of no violation of the limits of statistical significance and lower errors. The MLR model's performance was low in the region where some of the districts had low correlations. The results from ANN and BRNN models showed that the BRNN models were on a lower side than the ANN models with higher values of correlation coefficient showing their capability of finding the pattern and trend of the GLDAS precipitation. The results of the evaluation of the generalization capability of all models on the TRMM dataset showed that both ANN and BRNN models relatively performed well as correlation and error values were closer to each other.

Conclusions

The results of this study showed that, first, significant LSCDs with 99% confidence level were surface specific humidity (SSH), sea surface temperature (SST), latent and sensible heat fluxes over land (LHFOL and SHFOL), 2m air temperature (T2M), 500hpa zonal velocity (U500), Nino-3.4, and Nino-4. Second, to predict the monthly precipitation using lagged LSCDs and principal components, MR models were developed. MR models' performance was low. The highest Pearson correlation in MR models during the training set was observed for Musakhel district as 0.65 and during the test as 0.49 for Musakhel and Zhob. In MR-PC models, the highest correlation was recorded for Awaran (0.50) during the training and for Quetta (0.43) during the test. Third, ANN and BRNN models were developed using the selected PC components and gave higher correlations as compared to regression models indicating their capability of finding the pattern and trend of the observations. They generally manifested lower errors and are more reliable for the purpose of prediction in the region. Maximum correlations during training were 0.77 and 0.73 in both ANN and BRNN models, respectively, for the Lasbela district. In the test case, they were 0.74 and 0.70 for Awaran. Their generalization ability was tested on the TRMM dataset. In conclusion, this study divulged the possibility of monthly precipitation prediction using ANN and BRNN and lagged LSCDs for the study region. It is explicit that the response of precipitation to climatic factors is delayed. Comparing the results of the ANN, BRNN, and MLR, it can be concluded that the artificial intelligence approaches such as ANN and BRNN are reliable nonlinear statistical options that can generate similar and in some cases better

forecasts and could be useful for the agriculture and water management in the Balochistan region as it is a very important part of Pakistan in terms of agriculture. In the future, this research will be extended by developing the prediction models by including more LSCDs and can be improved by the approaches of genetic algorithm for the best input selection and the use of observed station-based precipitation data sets.

Keywords: Artificial Neural Network, Bayesian Regularization Neural Network, LSCD, Multiple Regression Analysis, Precipitation, Sea Surface Temperature, Balochistan Province-Pakistan.

References

- Aamir, E., & Hassan, I. (2020). The impact of climate indices on precipitation variability in Baluchistan, Pakistan. *Tellus A: Dynamic Meteorology and Oceanography*, 72(1), 1-46.
- Adamowski, J., & Sun, K. (2010). Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. *Journal of Hydrology*, 390(1-2), 85–91.
- Ahmed, K., Shahid, S., Haroon, S. B., & Xiao-Jun, W. (2015). Multilayer perceptron neural network for downscaling rainfall in arid region: A case study of Baluchistan, Pakistan. *Journal of Earth System Sciences*, 124(6), 1325–1341.
- Ailikon, B., & Yasunari, T. (2001). ENSO and Asian summer monsoon: Persistence and transitivity in the seasonal march. *Journal of the Meteorological Society of Japan*, 79(1), 145–159.
- Awan, J. A., & Maqbool, O. (2010). Application of artificial neural networks for monsoon rainfall prediction. *2010 6th International Conference on Emerging Technologies (ICET)*, 27-32.
- Beale, M. H., Hagan, M. T., & Demuth, H. B. (2011). *Neural network toolbox TM7: User's guide*. (n.p).
- Begum, B., Tajbar, S., Khan, B., & Rafiq, L. (2021). Identification of relationships between climate indices and precipitation fluctuation in Peshawar City-Pakistan. *Journal of Research in Environmental Earth Sciences*, 10, 264–278.
- Canchala, T., Alfonso-Morales, W., Ceron, W. L., Carvajal-Escobar, Y., & Caicedo-Bravo, E. (2020). Teleconnections between monthly rainfall variability and large-scale climate indices in southwestern Columbia. *Water*, 12(7), 1863.
- Chand, A., & Nand, R. (2009). Rainfall prediction using artificial neural network in the south pacific region. *2019 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)*, Melbourne, VIC, Australia, 1-7.
- Choubin, B., Khalighi-Sigaroodi, S., Malekian, A., & Kisi, O. (2014). Multiple linear regression, multi-layer perceptron network and adaptive neuro-fuzzy inference system for forecasting precipitation based on large-scale climate signals. *Hydrological Sciences Journal*, 61(6), 1001-1009.
- Davey, M. K., Brookshaw, A., & Ineson, S. (2014). The probability of the impact of ENSO on precipitation and near-surface temperature. *Journal of Climate Risk Management*, 1, 5–24.
- De Silva, T. M., & Hornberger, G. M. (2019). Identifying El Niño-Southern Oscillation influences on rainfall with classification models: Implications for water resource management of Sri Lanka. *Journal of Hydrology and Earth System Sciences*, 23(4), 1905-1929.

- Doranalu Chandrashekar, V., Shetty, A., & Patel, G. C. M. (2019). Estimation of monsoon seasonal precipitation teleconnection with El Niño-Southern Oscillation sea surface temperature indices over the Western Ghats of Karnataka, Asia-Pacific. *Journal of Atmospheric Sciences*, 1-15. Retrieved from: <https://doi.org/10.1007/s13143-019-00133-w>.
- Field, A. (2009). *Discovering statistics using SPSS*. Third Edition. London: Sage Publication Ltd.
- Ghasemiyeh, H., Bazrafshan, O., & Bakhshayesh Manesh, K. (2017). Artificial neural network for monthly rainfall forecasting using teleconnection patterns (case study: Central Plateau Basin of Iran). *Journal of Earth Space Physics*, 43(2), 405-418.
- Global, C. (2020). *China-Pakistan economic corridor: CPEC, CPIC*. Retrieved from: <https://www.cpicglobal.com/pakistan-overview/cpec/>.
- Hossain, I., Rasel, H. M., Imteaz, M. A., & Pourakbar, S. (2015). Effects of climate indices on extreme rainfall in Queensland, Australia. *Proceeding of 21st International Congress on Modelling and Simulation, MODSIM*.
- Iqbal, M. F., & Athar, H. (2018). Variability, trends, and teleconnections of observed precipitation over Pakistan. *Journal of Theoretical and Applied Climatology*, 134(1), 613–632.
- Jamro, S., Channa, F. N., Dars, G. H., Ansari, K., & Krakauer, N. Y. (2020). Exploring the evolution of drought characteristics in Balochistan, Pakistan. *Journal of Applied Sciences*, 10(3), 913.
- Khan, N., Sachindra, D. A., Shahid, S., Ahmed, K., Shiru, M. S., & Nawaz, N. (2020). Prediction of droughts over Pakistan using machine learning algorithms. *Journal of Advances in Water Resources*, 139, 103562.
- LDAS. (2021). *GLDAS: Project Goals*. Retrieved from: https://ldas.gsfc.nasa.gov/gldas_
- Lee, J. H., & Julien, P. Y. (2016). Teleconnections of the ENSO and South Korean precipitation patterns. *Journal of Hydrology*, 534, 237–250.
- Lin, F. J. (2008). Solving multicollinearity in the process of fitting regression model using the nested estimate procedure. *Journal of Quality & Quantity*, 42(3), 417–426.
- Li, X., & Ting, M. (2015). Recent and future changes in the Asian monsoon-ENSO relationship: Natural or forced?. *Journal of Geophysical Research Letters*, 42(9), 3502-3512.
- Maier, H. R., & Dandy, G. C. (2000). Neural networks for the prediction and forecasting of water resources variables: A review of modelling issues and applications. *Journal of Environmental Modelling & Software*, 15(1), 101–124.
- Mekanik, F., Imteaz, M. A., Gato-Trinidad, S., & Elmahdi, A. (2013). Multiple regression and Artificial neural network for long-term rainfall forecasting using large scale climate modes. *Journal of Hydrology*, 503, 11–21.
- Menke, W., & Menke, J. (2009). *Environmental data analysis with MATLAB*. First Edition. UK: Elsevier.
- Naz, F., Dars, G. H., Ansari, K., Jamro, S., & Krakauer, N. Y. (2020). Drought trends in Balochistan. *Water*, 12(2), 470.
- Pachauri, R. K., Allen, M. R., Barros, V. R., Broome, J., Cramer, W., Christ, R., ... & van Ypersele, J. P. (2014). Climate change 2014: Synthesis report. In *Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* (eds. Core Writing Team, R. K. Pachauri and L. A. Meyer]. IPCC, Geneva, Switzerland, 151 pp.

- Rasul, G., Afzal, M., Zahid, M., & Bukhari, S. A. A. (2012). *Climate Change in Pakistan Focused on Sindh Province*. Technical Report PMD 25/2012 55, Pakistan Meteorological Department, Islamabad, Pakistan. Retrieved from: <https://doi.org/10.13140/2.1.2170.6560>.
- Shukla, R. P., Tripathi, K. C., Pandey, A. C., & Das, I. M. L. (2011). Prediction of Indian summer monsoon rainfall using Niño indices: A neural network approach. *Journal of Atmospheric Research*, 102(1-2), 99–109.
- Taweessin, K., & Seeboonruang, U. (2019). The relationship between the climatic indices and the rainfall fluctuation in the lower central plain of Thailand. *International Journal of Innovative Computing, Information and Control*, 15(1), 107–127.
- Ye, L., Jabbar, S. F., Zahra, M. M. A., & Tan, M. L. (2021). Bayesian regularized neural network model development for predicting daily rainfall from sea level pressure data: Investigation on solving complex hydrology problem. *Complexity*, (Special Issue). Retrieved from: <https://doi.org/10.1155/2021/6631564>.
- Zuecco, F., Facco, P., Hoerer, S. R., Fogli, M. R., Ciccotti, M., Bezzo, P., & Barolo, M. (2020). Troubleshooting an industrial batch process for the manufacturing of specialty chemicals using data analytics. *Journal of Computer Aided Chemical Engineering*, 48, 1129-1134.





جغرافیا و برنامه‌ریزی محیطی

سال ۳۳، پیاپی ۸۷، شماره ۳، پاییز ۱۴۰۱، ص ۲۰-۱

وصول: ۱۴۰۰/۱۲/۹ پذیرش: ۱۴۰۰/۱۲/۲۱

مقاله پژوهشی

کاربرد رویکرد هوش مصنوعی در مطالعه تأثیر محرک‌های بزرگ‌مقیاس آب‌وهوایی بر بارش بلوچستان پاکستان

ساپنا محمدتاجبار، دانشجوی دکتری گروه آب و هواشناسی، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز، تبریز، ایران

sapnatajbar@gmail.com

علی محمد خورشیددوست*، استاد گروه آب و هواشناسی، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز، تبریز، ایران

khoshid@tabrizu.ac.ir

سعید جهانبخش‌اصل، استاد گروه آب و هواشناسی، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز، تبریز، ایران

s_jahan@tabrizu.ac.ir

چکیده

استان بلوچستان در کشور پاکستان اغلب به دلیل بارندگی کم در معرض خشکسالی‌های شدید قرار دارد. چندین نوع محرک آب‌وهوایی بزرگ‌مقیاس (LSCD) به دلیل تأثیرشان بر بارندگی در سراسر جهان شناخته شده‌اند، اما در منطقه بلوچستان مطالعاتی در این زمینه وجود ندارد. این مطالعه با هدف شناسایی LSCDهای معنادار در بلوچستان و بهبود مهارت پیش‌بینی بارش ماهانه با استفاده از تجزیه و تحلیل مؤلفه اصلی (PCA)، شبکه عصبی مصنوعی (ANN)، شبکه عصبی منظم‌شده بیزین (BRNN) و تحلیل رگرسیون چندگانه (MRA) انجام شد. LSCDهای ۱۲ ماهه مانند Nino-3، Nino-1+2، Nino-3.4، Nino-4، QBO، در ۳۰ و ۵۰ هکتوپاسکال (QBOI و QBOII)، دمای سطح دریا (SST)، دمای هوا (T2M)، ارتفاعات ژئوپتانسیل ۵۰۰ و ۸۵۰ هکتوپاسکال، سرعت مداری (U500) و نصف‌النهاری (۵۰۰V و ۸۵۰V)، شار گرمای نهان و محسوس (LHFOL و SHFOL) و رطوبت ویژه در سطح (SSH) بررسی شدند. همچنین از مجموعه داده‌های سیستم جهانی جمع‌آوری داده‌های زمین (GLDAS)، اندازه‌گیری بارندگی استوایی (TRMM)، MERRA-2، NOAA و HadISST استفاده شد. نتایج نشان داد LSCDهای معنادار در سطح اطمینان ۹۹٪ شامل SST، SSH، Nino-3.4، Nino-4، T2M، SHFOL، LHFOL، U500، Nino-3.4 و Nino-4 بودند. در طول دوره آزمون، در مقایسه با مدل‌های MR با ضریب همبستگی ۰،۱۵ تا ۰،۴۹ و مؤلفه‌های اصلی با ضریب همبستگی ۰،۱۶ تا ۰،۴۳، مدل‌های ANN و BRNN به ترتیب مهارت‌های پیش‌بینی بهتری با ضرایب همبستگی ۰،۴۰ تا ۰،۷۴ و ۰،۳۴ تا ۰،۷۰ داشتند. نتایج بیانگر توان مدل‌های ANN و BRNN در پیش‌بینی بارش ماهانه بلوچستان با استفاده از LSCDهای دارای تأخیر است.

واژه‌های کلیدی: شبکه عصبی مصنوعی، شبکه عصبی منظم‌شده بیزین، محرک آب‌وهوایی بزرگ‌مقیاس، تحلیل رگرسیون‌ندگانه، بارش، دمای سطح دریا، استان بلوچستان - پاکستان

*نویسنده مسئول

محمدتاجبار، ساپنا، خورشیددوست، علی محمد، جهانبخش‌اصل، سعید. (۱۴۰۰). کاربرد رویکرد هوش مصنوعی در مطالعه تأثیر محرک‌های بزرگ‌مقیاس آب و هوایی بر بارش بلوچستان پاکستان. *جغرافیا و برنامه‌ریزی محیطی*، ۳۳ (۳)، ۲۰-۱.



This work is licensed under a [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/)



<http://dx.doi.org/10.22108/gep.2022.132899.1497>



20.1001.1.20085362.1401.33.3.1.3

مقدمه

پاکستان یکی از آسیب‌پذیرترین کشورها در برابر تغییرات آب‌وهوایی است و براساس گزارش شاخص جهانی خطر آب‌وهوا (GCRI)^۱، با گذشت زمان آسیب‌پذیری آن افزایش می‌یابد. تهدیدهای اصلی عبارت‌اند از: افزایش دما، الگوهای نامنظم بارندگی، افزایش سطح دریا و رویدادهای شدید مانند خشکسالی، سیل و موج گرما (Naz et al., 2020). گزارش GCRI 2020 حاکی از مواجه شدن کشور با خسارت مالی ۳٫۸ میلیارد دلاری، جان‌باختن ۹۹۸۹ نفر و ۱۵۲ رویداد شدید از سال ۱۹۹۹ تا ۲۰۱۸ است، اما هنوز اقدامات مقامات ذی‌ربط برای مقابله با چالش‌ها و خطرات مرتبط کافی نیست.

بارش نقش مهمی در اقتصاد پاکستان به‌عنوان کشوری با اقتصاد متکی بر بخش کشاورزی دارد (Aamir and Hassan, 2020) و به‌ویژه در چند دهه اخیر که جهش شدید دمای اتمسفر جهانی مشاهده شده، تغییراتی را تجربه کرده است (Rasul et al., 2012). بخش جنوبی پاکستان که از استان سند و بلوچستان تشکیل شده است، آب‌وهوای خشک دارد و به دلیل میزان بارندگی کمتر در طول سال در مقایسه با سایر نقاط کشور از خشکسالی شدیدتری تأثیر می‌پذیرد. تمرکز اصلی این پژوهش بر استان بلوچستان است که سابقه‌ای طولانی در خشکسالی شدید دارد و از نظر تولیدات کشاورزی، مهم‌ترین استان است. میانگین بارندگی سالانه منطقه کمتر از ۲۵۰ میلی‌متر است. پیش‌بینی می‌شود در طول قرن بیست‌ویکم در صورتی که اقدامات سازگاری انجام نشود، خشکسالی‌ها و کمبود آب به‌طور مداوم افزایش یابد که این رویداد تأثیر نامطلوبی بر زندگی مردم و اقتصاد خواهد داشت. گفتنی است که طول چشمگیری از کریدور اقتصادی چین-پاکستان (CPEC) و بندر گوادر نیز در این استان واقع شده و غفلت کردن ممکن است بندر گوادر، CPEC و سرمایه‌گذاری خارجی ۶۲ میلیارد دلاری و زیرساخت‌ها را در معرض خطر قرار دهد (CPIC Global, 2020).

در سطح جهانی بارندگی و خشکسالی از طریق پیوندهای جوی به‌شدت با شاخص‌های اقلیمی مرتبط است. این شاخص‌های اقلیمی مناطق نزدیک‌تر را عمدتاً از طریق امواج شبه‌ساکن جوی راسبی در مقیاس بزرگ به هم مرتبط می‌کنند؛ در نتیجه بعضی از مناطق بارندگی بیشتری دریافت می‌کنند، در حالی که بعضی از آنها بارش کمتری دریافت می‌کنند (IPCC, 2014).

مطالعات مختلفی در سرتاسر جهان انجام شده است که ارتباط محرک‌های آب‌وهوایی در مقیاس بزرگ (LSCDs) را با تغییرات بارندگی بررسی کرده‌اند (Ailikun and Yasunari, 2001; Davey et al., 2014; Li and Ting, 2015; Lee and Julien, 2016; Ghasemiye et al., 2017; De Silva and Hornberger, 2019; Chanchala et al., 2020)، اما چنین مطالعاتی در منطقه بلوچستان اندک است. آنها از آزمون من-کنندال برای شناسایی روندهای معنادار بارندگی استفاده کردند (Jamro et al., 2020; Naz et al., 2020). استفاده از من-کنندال جزئی، تابع متعامد تجربی، تجزیه و تحلیل مؤلفه‌های اصلی و تکنیک‌های همبستگی با در نظر گرفتن نوسانات اقیانوس اطلس شمالی، نوسان قطب شمال، نوسان چند دهه اقیانوس اطلس، شاخص حالت دوقطبی، شاخص ENSO چندمتغیره، نوسان ده‌ساله اقیانوس آرام، دمای سطح دریا، فشار سطح دریا، بادهای منطقه‌ای در سطح، ارتفاعات ژئوپتانسیل در سطح ۵۰۰ میلی‌بار، و تابش موج بلند خروجی (Aamir and Hassan, 2020)، شیب سن با آزمون روند من-کنندال با

استفاده از شاخص استاندارد تبخیر و تعرق بارندگی (Jamro et al., 2020)، شبکه عصبی پرسپترون چندلایه با استفاده از بیست و شش تحلیل مجدد جوئی در مقیاس بزرگ (مرکز ملی پیش‌بینی متغیرهای محیطی (NCEP)) (Ahmed et al., 2015)، ماشین بردار پشتیبان، شبکه عصبی مصنوعی و k - نزدیک‌ترین همسایه با استفاده از دمای هوا، ارتفاع ژئوپتانسیل، رطوبت نسبی، باد U ، باد V در سطوح مختلف فشار و فشار سطح دریا (Khan et al., 2020)، از جمله این پژوهش‌هاست.

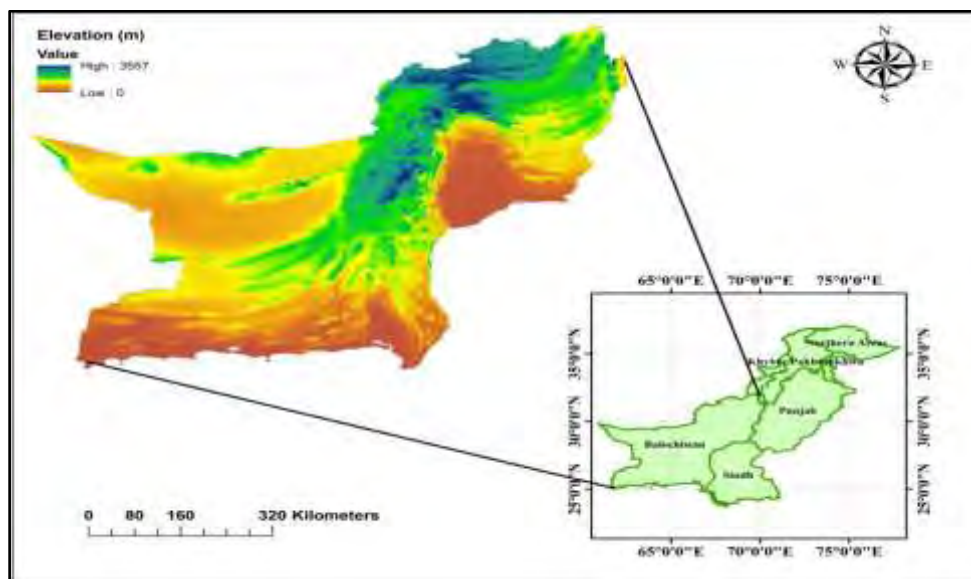
براساس بررسی نویسندگان، تاکنون هیچ پژوهش دقیقی در استان بلوچستان برای بررسی ارتباط LSCDs با بارش انجام نشده است. پژوهش‌های گذشته در منطقه، ارتباط همزمان را نشان دادند، اما برای پیش‌بینی بارش، دانستن بازه زمانی‌ای که LSCDs بر بارش ماهانه تأثیر می‌گذارد، بسیار مهم است؛ بنابراین به پژوهش‌های بیشتری نیاز است. رویکردهای هوش مصنوعی مانند شبکه عصبی مصنوعی و شبکه عصبی منظم‌شده بیزین برای هدف پیش‌بینی بسیار مفیدند؛ زیرا از نظر توانایی در یافتن ارتباطات غیرخطی پیچیده بین پارامترهای ورودی و خروجی شناخته شده‌اند. از آنجایی که فرایندهای مؤثر بر بارندگی، غیرخطی و بسیار پیچیده‌اند، در حل پیچیدگی کمک می‌کنند (Adamowski and Sun, 2010).

هدف اصلی پژوهش حاضر، شناسایی LSCDهای معنا دار در استان بلوچستان واقع در کشور پاکستان و بهبود مهارت پیش‌بینی بارش ماهانه با استفاده از تحلیل مؤلفه‌های اصلی، شبکه عصبی مصنوعی، شبکه عصبی منظم‌شده بیزین و تحلیل رگرسیون چندگانه با در نظر گرفتن ارتباط همراه با تأخیر LSCDهاست.

مواد و روش‌ها

منطقه مطالعه شده

بلوچستان ۴۴ درصد از کل خشکی پاکستان را دربرمی‌گیرد و بزرگ‌ترین استان از پنج استان واقع در پاکستان است. این منطقه بین ۲۵ درجه تا ۳۲ درجه عرض شمالی و ۶۱ درجه تا ۷۱ درجه طول شرقی واقع شده است و به‌عنوان منطقه خشک و کوهستانی پاکستان شناخته می‌شود (Naz et al., 2020) که در شکل ۱ نشان داده شده است. مرز جنوبی آن حدود دوسوم خط ساحلی پاکستان را شامل می‌شود. به‌عنوان بخشی از منطقه خشک، تغییرات جزئی در متغیرهای اقلیمی به وقوع پیامدهای فاجعه‌بار به شکل خشکسالی و سیلاب‌های ناگهانی منجر می‌شود. میانگین بارندگی سالانه در سراسر منطقه کمتر از ۲۵۰ میلی‌متر است. این منطقه به چهار ناحیه جغرافیایی دشت، بیابان، ارتفاعات شمالی و ارتفاعات پایین طبقه بندی شده است. بارندگی تابستان ناشی از وزش بادهای موسمی است و عامل بارندگی زمستان، ناآرامی‌های غربی است. دمای استان نوسانات جالب توجهی دارد. در مناطق بیابانی و دشتی، دمای هوا در تابستان تا ۵۰ درجه سانتی‌گراد افزایش می‌یابد، در حالی که ارتفاعات شمالی تابستان‌های گرم و زمستان‌های سرد دارند. در نواحی ارتفاعات پایین شمالی، زمستان‌ها بسیار سرد است، در حالی که تابستان‌ها گرم و خشک است (Jamro et al., 2020).



شکل ۱. نقشه ارتفاعی بلوچستان

Figure 1. Elevation map of Balochistan

داده‌های استفاده‌شده

بارش

برای دستیابی به هدف پژوهش، از مجموعه داده‌های سیستم جهانی همسان‌سازی داده‌های زمینی (GLDAS) به همراه سرویس اندازه‌گیری بارندگی حاره‌ای (TRMM) استفاده شد. GLDAS را به‌طور مشترک اداره ملی هوانوردی و فضایی (ناسا) و مرکز پرواز فضایی گودارد (GSFC)^۱ و NCEP که نسلی از تحلیل مجدد است، توسعه دادند که این داده‌ها را در وضوح ۱ درجه و ۰٫۲۵ درجه برای دوره ۱۹۴۸ تاکنون ارائه می‌دهد (LDAS, 2021). داده‌های مربوط به میزان بارندگی ماهانه مدل GLDAS با وضوح فضایی ۰٫۲۵×۰٫۲۵ از پورتال جیووانی ناسا برای دوره ۱۹۸۳-۲۰۲۰ به دست آمده است. داده‌ها از kgm-2s-1 به میلی‌متر تبدیل شد. داده‌های TRMM برای دوره ۱۹۹۸-۲۰۱۹ با وضوح فضایی ۰٫۲۵×۰٫۲۵ دانلود شد. سامانه بیان شده، داده‌ها را با استفاده از سه ابزار ثبت می‌کند: رادار بارش (PR)، تصویر مایکروویو (TMI) و اسکنر مادون قرمز قابل مشاهده (VIRS) (Begum et al., 2021).

شاخص‌های آب‌وهوا

دمای هوای اندازه‌گیری شده در ارتفاع ۲ متری (T2M)، ارتفاعات ژئوپتانسیل در سطوح ۵۰۰ و ۸۵۰ هکتوپاسکال (H500 و H850)، فشار سطح دریا (SLP)، سرعت مداری ۵۰۰ هکتوپاسکال (U500)، سرعت نصف‌النهاری ۵۰۰ و ۸۵۰ هکتوپاسکال (V500 و V850 روی زمین)، جریان حرارت محسوس روی زمین (SHFOL) و رطوبت ویژه سطح (SSH) از مدل تحلیل گذشته‌نگر برای تحقیقات و برنامه‌های کاربردی نسخه ۲ (MERRA-2) در پورتال جیووانی ناسا دانلود شدند.

شکل ۲ دامنه‌های آب‌وهوا را نشان می‌دهد که از داده‌های پیش‌بینی‌کننده بالقوه از MERRA-2 استخراج شدند. از

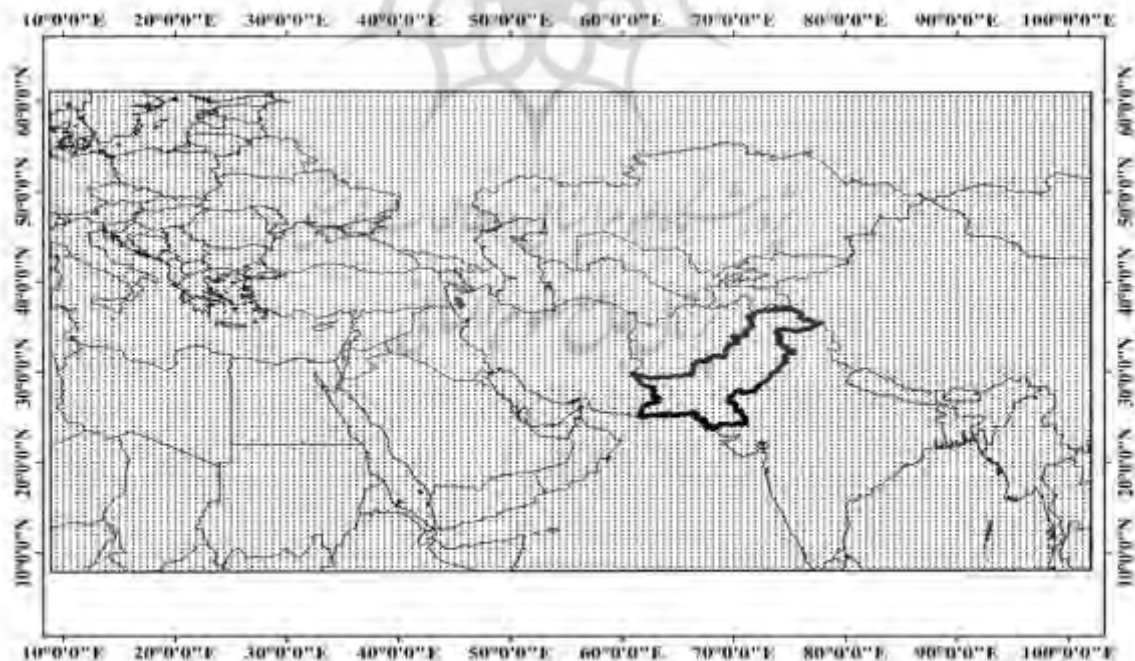
1. National Aeronautics and Space Administration (NASA) Goddard Space Flight Center (GSFC)

مدل MERRA-2، متغیرهای مختلف برای مناطق مختلف و براساس همبستگی آنها با بارش انتخاب شدند (جدول ۱). داده‌های دمای سطح دریا (SST) و درونیابی بهینه ماهانه NOAA (OI) NOAA از آزمایشگاه علوم فیزیکی NOAA دانلود شدند. شاخص QBO دانشگاه فری برلین در سه ایستگاه رادیوسوند نزدیک تر به خط استوا یعنی جزیره کانتون، گان/مالدیو و سنگاپور با سرعت ۳۰ و ۵۰ هکتوپاسکال به دست آمد. Nino-1+2، Nino-3، Nino-3.4 و Nino-4 از گروه کاری NOAA Global Climate GCOS (Observing System) درباره فشار سطحی (WG-SP) تهیه شدند. در این مطالعه، تمامی مجموعه داده‌ها برای دوره زمانی ۱۹۸۲ تا ۲۰۲۰ دانلود شدند.

جدول ۱. متغیرهای انتخاب شده برای مناطق متمایز بلوچستان از مدل MERRA-2

Table 1. Selected variables for distinct districts of Balochistan from MERRA-2 model

متغیرها	ناحیه	متغیرها	ناحیه
V850, SSH, LHFOL and SHFOL	خزدار	SLP, H850, LHFOL and SHFOL	آواران
V500, SSH, LHFOL and SHFOL	مستونگ	V850, SSH, LHFOL and SHFOL	لسبیل
SLP, H500, LHFOL and SHFOL	پنجگور	SLP, H500, H850, LHFOL and SHFOL	کچ
SSH, LHFOL and SHFOL	کوتا	SSH, LHFOL and SHFOL	بولان
SSH, LHFOL and SHFOL	درابوگتی	SSH, LHFOL and SHFOL	کوهلو
SSH, LHFOL and SHFOL	سبی	SSH, T2M, LHFOL and SHFOL	زیارت
U500, SSH, T2M, LHFOL and SHFOL	بارخان	SSH, LHFOL and SHFOL	لورالای
SSH, LHFOL and SHFOL	قلا سیف‌الله	U500, H850, T2M, LHFOL and SHFOL	موسی خیل
SSH, T2M, LHFOL and SHFOL	کلات	U500, H500, H850, SSH, LHFOL and SHFOL	ذوب



شکل ۲. حوضه‌های آب و هوایی که نقاطی را نشان می‌دهد که از داده‌های پیش‌بینی بالقوه از MERRA-2 استخراج می‌شوند.

Figure 2. Climate domains depicting the points where potential predictor data are extracted from MERRA-2.

روش شناسی

پیش‌پردازش داده‌ها برای تجزیه و تحلیل دقیق ضروری است؛ زیرا داده‌ها را به معنادارترین روش آماده می‌کند (Zuecco et al., 2020). داده‌ها در محدوده ۰ و ۱ با استفاده از رابطه (۱) که فرمول min-max است، نرمال‌سازی شد. \bar{x}_i نشان‌دهنده مقادیر نرمال‌شده، x_i مقادیر داده‌شده، x_{min} نشان‌دهنده مقدار حداقل و x_{max} نشان‌دهنده مقدار حداکثر است.

$$\bar{x}_i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

برای نشان‌دادن ارتباط تأخیر ۱۲ ماهه بین محرک‌های اقلیمی و بارش در مقیاس بزرگ، از روش همبستگی متقاطع استفاده شد. این روش زمانی مفید است که بخواهیم دو سری زمانی را به گونه‌ای تراز کنیم که یکی نسبت به دیگری به تعویق بیفتد و نقطه اوج آنها در یک بازه تأخیری رخ دهد که در آن هر دو سری به بهترین وجه مطابقت دارند (همبستگی خوبی دارند) (Menke and Menke, 2009). معادله این است:

$$r_m = \frac{\sum(x_i - \bar{x})(y_i - m - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - m - \bar{y})^2}} \quad (2)$$

در حالی که r_m زمان تأخیر m را نشان می‌دهد (Taweessin and Seeboonruang, 2019). در مرحله آخر، نقشه‌های حرارتی در نرم‌افزار Origin 2021b ایجاد شد تا همبستگی‌های با تأخیر معنادار را در مناطق مختلف نشان دهد.


تحلیل مؤلفه اصلی (اساسی)، روشی برای استخراج متغیرهای مهم به شکل مؤلفه از مجموعه بزرگی از متغیرهای موجود در یک مجموعه داده است (Shukla et al., 2011; Doranalu Chandrashekar et al., 2019). تحلیل مؤلفه اصلی در واقع یک مجموعه با بُعد پایین از ویژگی‌ها را از یک مجموعه دارای بُعد بالا استخراج می‌کند تا به ثبت اطلاعات بیشتر با تعداد کمتری از متغیرها کمک کند. در پژوهش حاضر ۷ ناحیه ۱۰ پیش‌بینی‌کننده، ۷ ناحیه ۱۱، ۳ ناحیه ۱۲ و ۱ ناحیه ۱۳ عدد داشتند، بنابراین تعداد نوروں‌های لایه ورودی به ترتیب ۱۰، ۱۱، ۱۲ و ۱۳ عدد بود. لایه خروجی فقط یک نوروں داشت. مجموعه داده‌های ۴۵۶ امتیازی به دو بخش ۷۵ درصد برای آموزش و ۲۵ درصد برای تست تقسیم شد. بردار ویژه که مطابق با بالاترین مقدار ویژه ماتریس کوواریانس پیش‌بینی‌کننده است، تعیین شد. سپس از مؤلفه‌های انتخاب‌شده برای نمایش داده‌ها در فضای یک، دو و سه بُعدی استفاده شد (موقعیت مؤلفه‌های انتخاب‌شده از نظر تعداد متفاوت بودند). در منطقه مطالعه شده، دو مؤلفه اصلی اول، حداکثر واریانس را برای بیشینه نواحی تبیین می‌کنند و مؤلفه سوم در بعضی مناطق در نظر گرفته شده است، در حالی که در بعضی مناطق فقط مؤلفه اصلی اول در نظر گرفته شده است. ۱۱۴ نقطه همچنان در فضاهای ۱۰، ۱۱، ۱۲ و ۱۳ بُعدی بود؛ آنها یک‌به‌یک روی بردار خاص مشخص شده نشان داده شدند که نقاط آزمایش را در فضای یک، دو و سه بُعدی ارائه داد. جدول ۲ به همراه شکل ۳ واریانس‌ها و مقادیر ویژه را برای هر یک از اجزای محاسبه‌شده توسط PCA نشان می‌دهد.

جدول ۲. مقادیر ویژه تحلیل مؤلفه‌های اصلی برای استان بلوچستان

Table 2. Eigen values of principal component analysis for Balochistan province

ناحیه	PC۱	PC۲	PC۳	PC۴	PC۵	PC۶	PC۷
آواران	۲/۰۹۲۴	۱/۲۳۹۳	۰/۷۵۷۶	۰/۵۷۳۱	۰/۳۸۵۱	-	-
	مقدار خاص						
	تغییرپذیری (%)	۴۱/۴۵۳۳	۲۴/۵۵۱۹	۱۵/۰۰۹۳	۱۱/۳۵۵۴	۷/۶۲۹۸	-
	انباشته (%)	۴۱/۴۵۳۳	۶۶/۰۰۵۳	۸۱/۰۱۴۶	۹۲/۳۷۰۱	۱۰۰	-
بارخان	۲/۴۴۶۰	۱/۰۰۰۰	۰/۵۷۰۲	۰/۰۹۳۰	-	-	-
	مقدار خاص						
	تغییرپذیری (%)	۵۹/۵۲۳۳	۲۴/۳۳۵۷	۱۳/۸۷۶۵	۲/۲۶۴۴	-	-
	انباشته (%)	۵۹/۵۲۳۳	۸۳/۸۵۹۰	۹۷/۷۳۵۵	۱۰۰	-	-
بولان	۴/۵۳۶۱	۱/۳۳۴۱	۰/۱۳۹۸	۰/۰۳۳۶	۰/۰۱۰۸	۰/۰۰۸۶	-
	مقدار خاص						
	تغییرپذیری (%)	۷۴/۸۱۱۹	۲۲/۰۰۳۵	۲/۳۰۷۱	۰/۵۵۵۴	۰/۱۷۸۸	۰/۱۴۳۱
	انباشته (%)	۷۴/۸۱۱۹	۹۶/۸۱۵۴	۹۱/۱۲۲۶	۹۹/۶۷۸۰	۹۹/۸۵۶۸	۱۰۰
درايوگتی	۳/۳۲۵۸	۰/۳۶۱۷	۰/۱۹۴۵	۰/۰۳۹۱	-	-	-
	مقدار خاص						
	تغییرپذیری (%)	۸۴/۸۱۴۹	۹/۲۲۵۱	۳/۹۶۰۴	۰/۹۹۹۴	-	-
	انباشته (%)	۸۴/۸۱۴۹	۹۴/۰۴۰۱	۹۹/۰۰۰۵	۱۰۰	-	-
کلات	۲/۴۵۲۳	۱/۰۰۹۹	۰/۵۱۴۶	۰/۱۲۶۲	-	-	-
	مقدار خاص						
	تغییرپذیری (%)	۵۹/۷۶۷۱	۲۴/۶۱۳۲	۱۲/۵۴۱۷	۳/۰۷۷۸	-	-
	انباشته (%)	۵۹/۷۶۷۱	۸۴/۳۸۰۳	۹۶/۹۲۲۱	۱۰۰	-	-
کچ	۲/۴۹۸۱	۱/۰۸۸۸	۰/۹۳۸۵	۰/۵۰۹۷	۰/۰۷۵۴	-	-
	مقدار خاص						
	تغییرپذیری (%)	۴۸/۸۸۱۱	۲۱/۳۰۵۰	۱۸/۳۶۳۵	۹/۹۷۳۴	۱/۴۷۶۷	-
	انباشته (%)	۴۸/۸۸۱۱	۷۰/۱۸۶۲	۸۸/۵۴۹۸	۹۸/۵۲۳۲	۱۰۰	-
خذدار	۲/۷۹۹۹	۱/۲۸۹۸	۰/۵۳۴۵	۰/۲۱۸۶	۰/۱۵۳۳	-	-
	مقدار خاص						
	تغییرپذیری (%)	۵۶/۰۴۰۲	۲۵/۸۱۶۸	۱۰/۶۹۸۲	۴/۳۷۸۰	۳/۰۶۸۸	-
	انباشته (%)	۵۶/۰۴۰۲	۸۱/۸۵۷۰	۹۲/۵۵۵۳	۹۶/۹۳۱۱	۱۰۰	-
کوهلو	۲/۱۵۷۰	۱/۰۹۸۹	۰/۷۹۷۵	۰/۰۸۰۲	-	-	-
	مقدار خاص						
	تغییرپذیری (%)	۵۲/۱۸۰۷	۲۶/۵۸۴۳	۱۹/۲۹۲۵	۱/۹۴۲۳	-	-
	انباشته (%)	۵۲/۱۸۰۷	۷۸/۷۶۵۰	۹۸/۰۵۷۶	۱۰۰	-	-
لسیلا	۲/۷۲۹۲	۱/۲۲۲۷	۰/۶۵۰۳	۰/۴۰۶۳	۰/۰۷۰۵	-	-
	مقدار خاص						
	تغییرپذیری (%)	۵۳/۷۳۴۲	۲۴/۰۷۳۲	۱۲/۸۰۴۰	۸/۰۰۰۲	۱/۳۸۸۱	-
	انباشته (%)	۵۳/۷۳۴۲	۷۷/۸۰۷۵	۹۰/۶۱۱۶	۹۸/۶۱۱۸	۱۰۰	-
لورالای	۲/۳۶۶۷	۱/۳۰۷۴	۱/۰۴۶۳	۰/۲۸۰۷	۰/۱۵۶۳	-	-
	مقدار خاص						
	تغییرپذیری (%)	۴۵/۸۸۸۶	۲۵/۳۴۹۵	۲۰/۲۸۶۵	۵/۴۴۳۴	۳/۰۳۱۸	-
	انباشته (%)	۴۵/۸۸۸۶	۷۱/۲۳۸۱	۹۱/۵۲۴۷	۹۶/۹۶۸۱	۱۰۰	-
مستونگ	۲/۵۷۴۴	۰/۸۰۸۸	۰/۴۸۷۶	۰/۱۶۸۲	-	-	-
	مقدار خاص						
	تغییرپذیری (%)	۶۳/۷۳۵۸	۲۰/۰۲۵۳	۱۲/۰۷۳۹	۴/۱۶۴۸	-	-
	انباشته (%)	۶۳/۷۳۵۸	۸۳/۷۶۱۱	۹۵/۸۳۵۱	۱۰۰	-	-

۰/۰۵۸۲	۰/۲۸۵۲	۰/۴۴۵۶	۰/۷۶۱۷	۱/۰۶۷۴	۱/۸۴۳۰	۲/۷۷۶۴	مقدار خاص	موسی خیل
۰/۸۰۴۶	۳/۹۴۰۵	۶/۱۵۷۸	۱۰/۵۲۵۱	۱۴/۷۴۷۹	۲۵/۴۶۳۵	۳۸/۳۶۰۲	تغییرپذیری (%)	
۱۰۰	۹۹/۱۹۵۳	۹۵/۲۵۴۷	۸۹,۰۹۶۹	۷۸/۵۷۱۷	۶۳/۸۲۳۸	۳۸/۳۶۰۲	انباشته (%)	
-	-	-	-	۰/۶۳۰۸	۱/۰۵۵۶	۱/۴۱۹۱	مقدار خاص	پنجگور
-	-	-	-	۲۰/۳۱۲۳	۳۳/۹۹۰۶	۴۵/۶۹۷۰	تغییرپذیری (%)	
-	-	-	-	۱۰۰	۷۹/۶۸۷۶	۴۵/۶۹۷۰	انباشته (%)	
-	-	۰/۰۹۲۹	۰/۳۲۱۵	۱/۰۹۰۰	۱/۳۸۱۳	۲/۲۸۸۸	مقدار خاص	کوتا
-	-	۱/۷۹۷۱	۶/۲۱۳۱	۲۱/۰۶۴۶	۲۶/۶۹۳۳	۴۴/۲۳۱۶	تغییرپذیری (%)	
-	-	۱۰۰	۹۸/۲۰۲۸	۹۱/۹۸۹۷	۷۰/۹۲۵۰	۴۴/۲۳۱۶	انباشته (%)	
-	-	-	-	۰/۱۱۱۷	۰/۴۱۰۸	۲/۵۳۴۹	مقدار خاص	ذوب
-	-	-	-	۳/۶۵۵۷	۱۳/۴۳۷۳	۸۲/۹۰۶۸	تغییرپذیری (%)	
-	-	-	-	۱۰۰	۹۶/۳۴۴۲	۸۲/۹۰۶۸	انباشته (%)	
-	-	-	۰/۰۴۳۶	۰/۱۹۶۰	۰/۶۶۹۴	۳/۲۱۷۸	مقدار خاص	زیارت
-	-	-	۱/۰۵۷۳	۴/۷۵۰۵	۱۶/۲۲۱۵	۷۷/۹۷۰۵	تغییرپذیری (%)	
-	-	-	۱۰۰	۹۸/۹۴۲۶	۹۴/۱۹۲۱	۷۷/۹۷۰۵	انباشته (%)	
-	-	-	۰/۱۳۵۳	۰/۳۶۹۲	۰/۹۲۹۳	۲/۶۶۷۳	مقدار خاص	قلا سیف‌الله
-	-	-	۳/۳۰۰۸	۹/۰۰۳۶	۲۲/۶۵۹۱	۶۵/۰۳۶۲	تغییرپذیری (%)	
-	-	-	۱۰۰	۹۶/۶۹۹۱	۸۷/۶۹۵۴	۶۵/۰۳۶۲	انباشته (%)	
-	-	۰/۰۹۴۷	۰/۲۳۲۹	۱/۰۴۶۳	۱/۲۷۳۳	۲/۴۹۲۷	مقدار خاص	سی
-	-	۱/۸۴۲۴	۴/۵۳۲۳	۲۰/۳۵۶۲	۲۴/۷۷۳۱	۴۸/۴۹۵۸	تغییرپذیری (%)	
-	-	۱۰۰	۹۸/۱۵۷۵	۹۳/۶۲۵۲	۷۳/۲۶۸۹	۴۸/۴۹۵۸	انباشته (%)	



شکل ۳. توضیح تنوع (%) اجزای اصلی (PC1, PC2, PC3, PC4, PC5, PC6 و PC7)

Figure 3. Explained variability (%) of the principal components (PC1, PC2, PC3, PC4, PC5, PC6 and PC7)

تحلیل رگرسیون چندگانه (MRA) انجام شد و به‌عنوان معیاری برای مقایسه با مدل‌های شبکه عصبی مصنوعی

(ANN) و شبکه عصبی منظم شده بیزین (BRNN) با استفاده از شاخص‌های آب‌وهوایی تأخیری معنادار در یک مورد، و مؤلفه‌های منتخب در موردی دیگر استفاده شد (جدول ۳ و ۴). مناطق مختلف راستی‌آزمایی چندخطی در این نوع مدل‌سازی که درباره پیش‌بینی‌کننده‌های بسیار همبسته مشاهده می‌شود، مهم است و می‌تواند به تغییرات زیادی در برآورد پارامتر در پاسخ به تغییرات کوچک در داده‌ها یا مدل منجر شود. شاخص‌های استفاده‌شده عبارت‌اند از: تاب‌آوری (T) و ضریب تورم واریانس (VIF):

$$\text{Tolerance} = 1 - R^2 \text{ VIF} = \frac{1}{\text{Tolerance}} \quad (3)$$

R^2 نشان‌دهنده ضریب تعیین چندگانه است. مقدار تاب‌آوری کمتر از ۰٫۲۰-۰٫۱۰ یا مقدار VIF بزرگ‌تر از ۵-۱۰، مشکل چندخطی بودن را نشان می‌دهد (Lin, 2008). از آزمون دوربین واتسون (DW) استفاده شد که به دنبال سری همبستگی بین خطاها و محدوده ۰-۴ است. مقادیر > 3 یا < 1 مشکل ایجاد می‌کند (Field, 2009).

جدول ۳. خلاصه‌ای از بهترین مدل‌های رگرسیون چندگانه

Table 3. Summary of the best multiple regression models

DW	VIF	r	معادله	ناحیه
۲٫۰۲	۱٫۳۶	۰٫۵۲	$Y_t = -0.036 + 0.085H850_{t-9} + 0.063H850_{t-4} + 0.275SST_{t-1} - 0.102H850_{t-12} + 0.089H850_{t-3}$	آواران
۲٫۱۹	۱٫۲۷	۰٫۴۶	$Y_t = 0.087 + 0.331SST_{t-11} - 0.018SST_{t-9} - 0.302SST_{t-3} - 0.016SHFOL_{t-12}$	بارخان
۲٫۱۹	۱٫۱۳	۰٫۳۴	$Y_t = 0.018 - 0.116SHFOL_{t-12} + 0.244SST_{t-11} + 0.163LHFOL_{t-9}$	بولان
۲٫۱۸	۱٫۳۶	۰٫۵۲	$Y_t = 0.459 + 0.644SST_{t-11} - 0.346SST_{t-10} - 0.453SSH_{t-5} - 0.491SHFOL_{t-1}$	درايوگنی
۲٫۰۴	۱٫۱۸	۰٫۳۹	$Y_t = 0.123 - 0.093QBOI_{t-11} + 0.729SST_{t-7} - 0.353SST_{t-8} + 0.067SHFOL_{t-8}$	کلات
۱٫۹۸	۱٫۱۹	۰٫۴۰	$Y_t = 0.201 + 0.149H850_{t-3} + 0.081Nino4_{t-1} - 0.157H850_{t-12} - 0.170SHFOL_{t-2} - 0.141SHFOL_{t-9}$	کچ
۲٫۱۱	۱٫۲۳	۰٫۴۳	$Y_t = 0.122 - 0.116SHFOL_{t-1} + 0.319SST_{t-1} - 0.033SST_{t-10} - 0.171V850_{t-12} + 0.110SHFOL_{t-11}$	خذدار
۲٫۱۴	۱٫۳۹	۰٫۵۳	$Y_t = -0.095 + 0.465SST_{t-11} + 0.496LHFOL_{t-9} - 0.565SST_{t-9} + 0.290SST_{t-3}$	کوهلو
۲٫۰۵	۱٫۶۱	۰٫۶۱	$Y_t = 0.146 + 0.172SST_{t-11} + 0.387SST_{t-1} - 0.045V850_{t-7} - 0.372SST_{t-8} - 0.210SHFOL_{t-3}$	لسببلا
۲٫۱۶	۱٫۴۵	۰٫۵۶	$Y_t = -0.121 + 0.330SHFOL_{t-11} + 0.265SST_{t-11} + 0.147Nino4_{t-1} - 0.550SST_{t-9} + 0.704SST_{t-7}$	لورالای
۲٫۱۴	۱٫۲۳	۰٫۴۴	$Y_t = 0.143 + 0.313LHFOL_{t-8} - 0.229V500_{t-8} + 0.056LHFOL_{t-10} - 0.311SST_{t-8}$	مستونگ
۲٫۱۲	۱٫۷۳	۰٫۶۵	$Y_t = -0.148 + 0.599SST_{t-11} + 0.139Nino4_{t-4} - 0.193H850_{t-8} - 0.704SST_{t-9} + 0.576LHFOL_{t-9} + 0.277SST_{t-2} + 0.163H850_{t-7}$	موسی خیل
۲٫۱۵	۱٫۱۴	۰٫۳۵	$Y_t = -0.047 + 0.298SST_{t-6} + 0.100SST_{t-11} + 0.068Nino4_{t-1}$	پنجگور
۲٫۰۸	۱٫۳۱	۰٫۴۹	$Y_t = 0.016 + 0.222SSH_{t-7} - 0.270SST_{t-8} + 0.459SST_{t-7}$	کوتا
۲٫۱۲	۱٫۳۹	۰٫۵۳	$Y_t = 0.072 + 0.557U500_{t-3} - 0.429SST_{t-9} + 0.525SST_{t-7} - 0.254U500_{t-1}$	ذوب
۲٫۰۹	۱٫۴۰	۰٫۵۴	$Y_t = 0.147 - 0.406SHFOL_{t-3} + 0.153Nino4_{t-1} - 0.466SST_{t-9} + 0.529SST_{t-7} + 0.386SSH_{t-12}$	زیارت
۲٫۱۳	۱٫۴۶	۰٫۵۶	$Y_t = 0.048 + 0.153Nino34_{t-3} - 0.650SST_{t-9} + 0.781SST_{t-7} + 0.471SSH_{t-11} - 0.236SSH_{t-2}$	قلا سیف‌الله
۲٫۰۹	۱٫۳۱	۰٫۴۹	$Y_t = -0.067 + 0.089LHFOL_{t-3} - 1.363SST_{t-8} + 1.365SST_{t-7} + 0.567LHFOL_{t-10}$	سبی

جدول ۴. خلاصه‌ای از بهترین مدل‌های رگرسیون چندگانه مبتنی بر PC

Table 4. Summary of the best PC based multiple regression models

DW	VIF	r	معادله	ناحیه
۲,۰۶	۱,۳۰	۰,۴۸	$Y_t = 0.048 + 0.002PC1 + 0.036PC2 - 0.025PC3$	آواران
۲,۲۲	۱,۱۹	۰,۴۰	$Y_t = 0.156 + 0.050PC1 - 0.001PC2$	بارخان
۲,۱۸	۱,۰۶	۰,۲۵	$Y_t = 0.107 + 0.018PC1 + 0.004PC2$	بولان
۲,۱۹	۱,۱۴	۰,۳۵	$Y_t = 0.104 + 0.031PC1$	درايوگنی
۲,۰۵	۱,۱۰	۰,۳۰	$Y_t = 0.132 - 0.029PC1 + 0.034PC2$	کلات
۲,۰۴	۱,۱۰	۰,۳۱	$Y_t = 0.076 + 0.024PC1 + 0.019PC2$	کچ
۲,۰۴	۱,۱۰	۰,۳۰	$Y_t = 0.054 - 0.015PC1 - 0.014PC2$	خذدار
۲,۲۲	۱,۱۰	۰,۳۰	$Y_t = 0.122 - 0.032PC1 + 0.021PC2$	کوهلو
۲,۰۷	۱,۱۴	۰,۳۵	$Y_t = 0.032 + 0.014PC1 + 0.017PC2$	لسبیللا
۲,۱۷	۱,۱۷	۰,۳۸	$Y_t = 0.157 + 0.042PC1 - 0.009PC2 - 0.026PC3$	لورالای
۲,۲۱	۱,۱۱	۰,۳۲	$Y_t = 0.148 + 0.037PC1 - 0.023PC2$	مستونگ
۲,۱۷	۱,۱۳	۰,۳۴	$Y_t = 0.162 + 0.036PC1 - 0.003PC2 + 0.021PC3$	موسی خیل
۲,۰۵	۱,۰۳	۰,۱۶	$Y_t = 0.055 + 0.001PC1 + 0.016PC2$	پنجگور
۲,۱۲	۱,۱۸	۰,۳۹	$Y_t = 0.129 - 0.047PC1$	کوتا
۲,۱۵	۱,۱۲	۰,۳۳	$Y_t = 0.166 + 0.036PC1 + 0.012PC2$	ذوب
۲,۱۵	۱,۱۷	۰,۳۸	$Y_t = 0.131 - 0.037PC1 + 0.009PC2 - 0.031PC3$	زیارت
۲,۰۹	۱,۱۶	۰,۳۷	$Y_t = 0.148 - 0.036PC1 + 0.003PC2 - 0.031PC3$	قلا سیف‌الله
۲,۱۶	۱,۰۶	۰,۲۵	$Y_t = 0.119 + 0.022PC1$	سبی

شبکه عصبی پیش‌خور چندلایه با الگوریتم انتشار برگشتی برای پیش‌بینی بارش ماهانه با دو مؤلفه اول در بیشتر موارد و سه و یک در بعضی موارد استفاده شد. مدل شامل سه لایه بود که لایه ورودی دارای دو نورون، سه و یک نورون در موارد مختلف، لایه خروجی دارای یک نورون و یک لایه پنهان انتخاب و تعداد نورون‌ها به روش آزمون و خطا تعیین شد. مدل‌های ANN با استفاده از تکنیک Levenberg-Marquardt آموزش داده شدند و رویکرد توقف زودهنگام برای جلوگیری از احتمال تطبیق بیش از حد در حین آموزش و اعتبارسنجی استفاده شد. می‌توان آن را به صورت ریاضی بیان کرد:

$$y_j = f_2 \left[\sum_{j=1}^J w_j f_1 \left(\sum_{i=1}^I w_i x_i \right) \right] \quad (4)$$

در جایی که خروجی شبکه با y_j نشان داده می‌شود، ورودی با w_i, x_i و w_j وزن بین نورون‌های ورودی و لایه پنهان و بین لایه پنهان و نورون‌های خروجی به ترتیب نشان‌دهنده توابع فعال‌سازی برای لایه پنهان و خروجی است. لایه‌ها به ترتیب f_1 و f_2 هستند (Maier and Dandy, 2000). f_1 تابع سیگموئید بود که اساساً یک تابع غیرخطی است و f_2 تابع خطی خالص بود:

$$f_1 = \frac{1}{1+e^{-x}} \quad (5)$$

$$f_2(x) = x \quad (6)$$

شبکه عصبی منظم شده بیزین (BRNN) استفاده شد که نسخه شبکه‌های عصبی مصنوعی (ANN) است و در

مقایسه با ANN معمولی روش قدرتمندتری است. همگرایی ناقص شبکه های عصبی مصنوعی به برآزش بیش از حد منجر می‌شود. تنظیم آن با استفاده از تکنیک بیزین به بهینه‌سازی پارامترهای ANN با استفاده از مقادیر قبلی آنها کمک می‌کند. این تکنیک ترکیبی از مجذور خطاها و وزن‌ها را کاهش می‌دهد و ترکیب دقیق را مشخص می‌کند، به مجموعه اعتبارسنجی نیازی ندارد و به‌طور بالقوه الگوریتم مناسبی برای داده‌های محدود است (Beale et al., 2011). در مطالعه حاضر، همان مؤلفه‌های استفاده‌شده در ANN و BRNN به کار رفتند. برای این منظور از محیط MATLAB R2015a استفاده شد.

برای اعتبارسنجی عملکرد همه مدل‌های توسعه‌یافته، از مجموعه داده TRMM استفاده شد که به‌طور مشابه نرمال شد و مؤلفه‌ها با نمایش نقاط داده روی بردارهای خاص مشخص‌شده قبلی محاسبه شدند. در آخر، نمودارهای سری زمانی و نمودارهای رادار برای مقایسه تهیه شد.

مدل‌های ساخته‌شده با استفاده از سه معیار عملکرد مانند ریشه میانگین مربعات خطا (RMSE)، میانگین خطای مطلق (MAE) و ضریب همبستگی (R) بین مقادیر بارش GLDAS و مقادیر پیش‌بینی شده مدل و همچنین بین مقادیر و مدل‌های بارش TRMM ارزیابی شدند. مقادیر پیش‌بینی شده:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - X_i)^2}{n}} \quad (7)$$

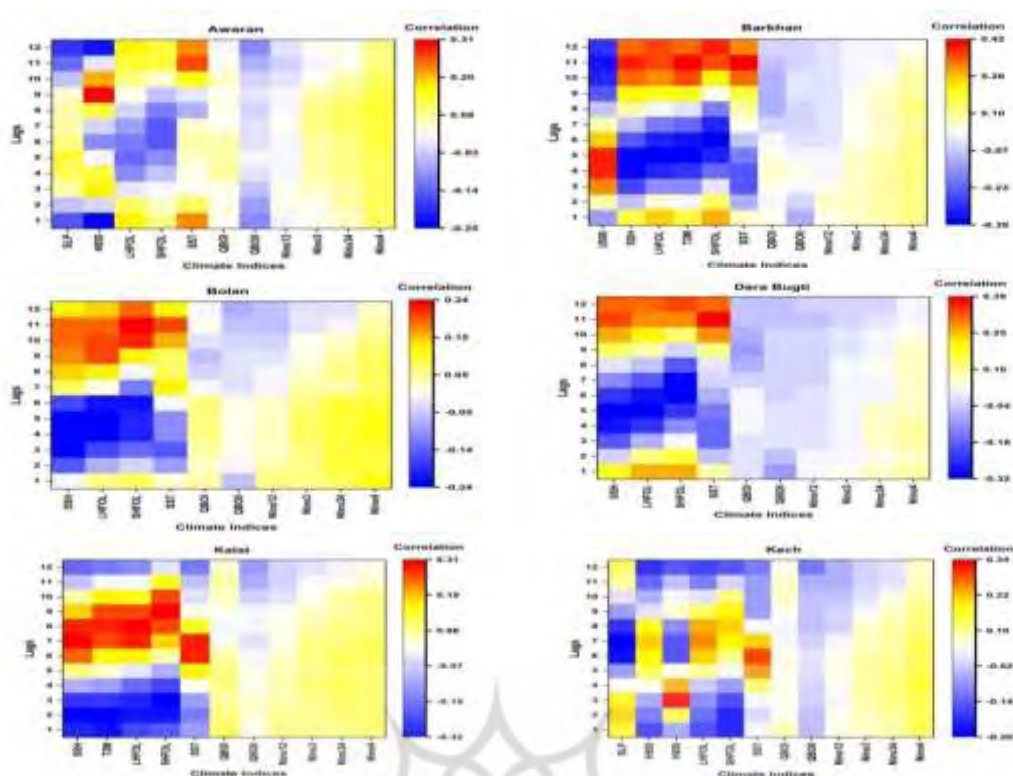
$$MAE = \frac{\sum_{i=1}^n |Y_i - X_i|}{n} \quad (8)$$

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (9)$$

یافته‌های پژوهش

ارزیابی و شناسایی ارتباط LSCD با بارش

همبستگی متقابل بین بارش ماهانه و LSCD در شکل ۴ برای شش منطقه استان بلوچستان ارائه شده است. غالب‌ترین شاخص‌های اقلیمی در منطقه بلوچستان SST، SSH، LHFOL، SHFOL، T2M، U500، Nino-3.4 و Nino-4 بودند و بیشترین همبستگی برای SSH، SST، LHFOL، SHFOL، T2M و U500 مشاهده شد. گفتنی است که در هر ناحیه، همبستگی تأخیری حداکثر شاخص‌های اقلیمی با بارش در زمان‌های متمایز مشخص بود؛ برای نمونه در ناحیه LHFOL در ناحیه بولان همبستگی مثبت در وقفه‌های ۱ و ۷ تا ۱۲ و همبستگی منفی در ۲ تا ۶ داشت و در ناحیه درابوگتی در ۱، ۲ و ۹ تا ۱۲ مثبت و در ۳ تا ۸ منفی بود و این مناطق به هم نزدیک تر هستند. نتایج مشابه در سایر مناطق برای سایر شاخص‌ها مشاهده شده است. (Aamir and Hassan (2020) در مطالعه خود روی منطقه بلوچستان دریافتند که شاخص نوسان جنوبی آل نینو (ENSO) با بعضی از شاخص‌های دیگر بر بارش ماه ژوئن تأثیر می‌گذارد. برای یافتن رابطه بین بارش ژوئن و شاخص‌های اقلیمی همبستگی تأخیر زمانی انجام شد. (Iqbal and Athar (2018) دریافتند که در منطقه سند، QBO و همچنین ENSO با بارندگی ماهانه ایستگاه‌های استان سند همبستگی نشان نمی‌دهند، در حالی که در استان بلوچستان این مورد برعکس است؛ اما آنها ارتباط تأخیری را در نظر نمی‌گیرند.



شکل ۴. همبستگی شاخص‌های آب‌وهوایی تأخیری با بارش ماهانه برای شش ناحیه استان بلوچستان

Figure 4. Lagged climate indices correlations (r) with monthly precipitation for the 6 districts of Balochistan province

تحلیل رگرسیون چندگانه

در مطالعه حاضر، معادلات MLR با استفاده از LSCDهای معنادار شناسایی شده در زمان‌های تأخیری مشخص، برای پیش‌بینی بارش ماهانه در استان بلوچستان توسعه داده شد. بهترین مدل‌ها براساس عدم تخطی از حدود معناداری آماری و خطاهای کمتر انتخاب شدند. جدول‌های ۳ و ۴، بهترین مدل‌های توسعه‌یافته رگرسیون چندگانه (MR) را با استفاده از LSCDهای تأخیری و مؤلفه‌های اصلی برای هر ناحیه با ضریب تورم واریانس (VIF)، همبستگی پیرسون (r) و آمار دوربین-واتسون (DW) نشان می‌دهند. از جدول‌ها می‌توان دریافت که مقادیر VIF بیشتر از یک هستند و این امر نشان می‌دهد که در بین پیش‌بینی‌کننده‌ها هیچ‌گونه هم‌خطی وجود ندارد و همچنین آمار DW برازندگی مدل‌ها را تأیید می‌کند؛ زیرا باقی‌مانده‌ها هیچ خودهمبستگی‌ای ندارند.

جدول ۵ عملکرد مدل‌های MR و MR-PC توسعه‌یافته را از نظر همبستگی، مقادیر RMSE و MAE در طول آموزش و آزمایش نشان می‌دهد. بیشترین همبستگی پیرسون در مدل‌های MR در طول آموزش برای موسی خیل ۰/۶۵ و در حین آزمون برای موسی خیل و زوب ۰/۴۹ مشاهده شد. در مدل‌های MR-PC بیشترین همبستگی برای آواران (۰/۵۰) در حین آموزش و برای کوتا (۰/۴۳) در طول آزمون ثبت شد. می‌توان مشاهده کرد که عملکرد مدل‌های MLR در منطقه‌ای که بعضی از نواحی همبستگی کمی داشتند، کم بود.

مطالعات انجام‌شده در سرتاسر جهان شاخص‌های آب‌وهوای اقیانوسی و جوی را به‌عنوان پیش‌بینی‌کننده بارندگی در

دوره چندماهه با تأخیر ارزیابی کردند که در اینجا برای بحث با نتایج به دست آمده بیان شده‌اند. Taweessin and Seeboonruang (2019) در پژوهش‌های خود برای تایلند، مدل‌های MR را با و بدون LSCD تأخیری تهیه کردند و متوجه شدند که واکنش بارندگی به عوامل اقلیمی به تأخیر افتاده است و مدل‌ها قادر به پیش‌بینی دقیق بارش ماهانه هستند. Choubin et al. (2014) همچنین از MR با ANN و مدل‌های سیستم استنتاج فازی عصبی تطبیقی (ANFIS) استفاده کردند و دریافتند که نوسانات یا انحراف استاندارد داده‌های ایستگاه مشاهده شده را نمی‌توان با مدل MR پیش‌بینی کرد، بنابراین قادر به پیش‌بینی خشکسالی و سال‌های مرطوب نیست. بعضی مطالعات دیگر نیز انجام شد.

جدول ۵. عملکرد مدل‌های رگرسیون: مجموعه آموزشی و آزمون

Table 5. Performance of the regression models: Training and test set

آزمون						آموزش						ناحیه
میانگین خطای مربع مطلق		ریشه میانگین مربعات خطا		همبستگی		میانگین خطای مربع مطلق		ریشه میانگین مربعات خطا		همبستگی		
MR-PC	MR	MR-PC	MR	MR-PC	MR	MR-PC	MR	MR-PC	MR	MR-PC	MR	
۰/۰۵	۰/۰۶	۰/۰۸	۰/۰۹	۰/۳۵	۰/۳۰	۰/۰۵	۰/۰۶	۰/۰۹	۰/۰۹	۰/۵۰	۰/۵۱	آواران
۰/۱۳	۰/۱۳	۰/۱۹	۰/۱۸	۰/۳۴	۰/۴۲	۰/۱۳	۰/۱۳	۰/۱۹	۰/۱۸	۰/۴۰	۰/۴۶	بارخان
۰/۱۱	۰/۱۰	۰/۱۷	۰/۱۶	۰/۱۷	۰/۲۳	۰/۱۱	۰/۰۹	۰/۱۶	۰/۱۵	۰/۲۵	۰/۳۴	بولان
۰/۱۱	۰/۱۰	۰/۱۸	۰/۱۷	۰/۲۸	۰/۴۵	۰/۱۰	۰/۰۹	۰/۱۶	۰/۱۴	۰/۳۵	۰/۵۱	دراپوگتی
۰/۱۴	۰/۱۳	۰/۲۰	۰/۲۰	۰/۲۷	۰/۳۳	۰/۱۳	۰/۱۳	۰/۱۸	۰/۱۸	۰/۳۱	۰/۳۹	کلات
۰/۰۷	۰/۰۸	۰/۱۰	۰/۱۱	۰/۳۴	۰/۴۰	۰/۰۹	۰/۰۸	۰/۱۳	۰/۱۳	۰/۳۳	۰/۴۰	کچ
۰/۰۸	۰/۰۸	۰/۱۱	۰/۱۱	۰/۱۶	۰/۱۵	۰/۰۷	۰/۰۶	۰/۱۰	۰/۱۰	۰/۲۸	۰/۴۳	خزدار
۰/۱۱	۰/۱۱	۰/۱۸	۰/۱۷	۰/۲۱	۰/۴۱	۰/۱۱	۰/۱۰	۰/۱۷	۰/۱۵	۰/۳۱	۰/۵۳	کوهلو
۰/۰۴	۰/۰۵	۰/۰۸	۰/۰۸	۰/۳۶	۰/۴۱	۰/۰۴	۰/۰۴	۰/۰۸	۰/۰۸	۰/۳۶	۰/۶۲	لسببلا
۰/۱۳	۰/۱۳	۰/۱۸	۰/۱۷	۰/۲۴	۰/۴۴	۰/۱۲	۰/۱۱	۰/۱۸	۰/۱۶	۰/۳۸	۰/۵۶	لورالای
۰/۱۴	۰/۱۴	۰/۲۰	۰/۱۹	۰/۲۳	۰/۳۸	۰/۱۴	۰/۱۳	۰/۱۹	۰/۱۸	۰/۳۳	۰/۴۴	مستونگ
۰/۱۳	۰/۱۳	۰/۱۸	۰/۱۷	۰/۲۲	۰/۴۹	۰/۱۳	۰/۱۰	۰/۱۸	۰/۱۴	۰/۳۴	۰/۶۵	موسی خیل
۰/۰۷	۰/۰۷	۰/۰۹	۰/۰۹	۰/۰۸	۰/۲۷	۰/۰۷	۰/۰۶	۰/۱۱	۰/۱۰	۰/۱۸	۰/۳۶	پنجگور
۰/۱۳	۰/۱۲	۰/۱۸	۰/۱۷	۰/۴۳	۰/۵۰	۰/۱۰	۰/۱۲	۰/۱۸	۰/۱۷	۰/۴۰	۰/۴۸	کوتا
۰/۱۲	۰/۱۲	۰/۱۷	۰/۱۶	۰/۲۹	۰/۴۹	۰/۱۳	۰/۱۱	۰/۱۸	۰/۱۶	۰/۳۳	۰/۵۳	ذوب
۰/۱۲	۰/۱۱	۰/۱۸	۰/۱۷	۰/۲۷	۰/۴۱	۰/۱۱	۰/۱۰	۰/۱۷	۰/۱۵	۰/۳۸	۰/۵۳	زیارت
۰/۱۳	۰/۱۱	۰/۱۷	۰/۱۵	۰/۲۴	۰/۴۷	۰/۱۲	۰/۰۷	۰/۱۶	۰/۱۴	۰/۳۸	۰/۵۷	قلا سیف‌الله
۰/۱۴	۰/۱۱	۰/۱۹	۰/۱۵	-۰/۱۶	۰/۴۰	۰/۱۵	۰/۰۹	۰/۲۰	۰/۱۴	-۰/۲۵	۰/۴۹	سی

شبکه‌های عصبی مصنوعی و تحلیل شبکه‌های عصبی منظم‌شده بیزین

جدول ۶ عملکرد مدل‌های ANN و BRNN را براساس همبستگی، خطاهای RMSE و MAE برای موارد آموزشی و آزمایشی در استان بلوچستان نشان می‌دهد. حداکثر همبستگی در طول آموزش در هر دو مدل ANN و BRNN به ترتیب ۰,۷۷ و ۰,۷۳ برای منطقه لسببلا بود. در مورد آزمون، مقادیر به ترتیب ۰,۷۴ و ۰,۷۰ برای آواران بود. همبستگی بین ۰,۲۱- و ۰,۷۷ برای مدل‌های ANN و ۰,۲۸- و ۰,۷۳ برای RMSE. BRNN بین ۰,۰۶- و ۰,۱۸ و ۰,۰۶- و ۰,۱۹؛ در حالی که مقدار MAE بین ۰,۰۳- و ۰,۱۳ و ۰,۰۴- و ۰,۱۴ به ترتیب برای هر دو مجموعه مدل بود. در طول دوره آزمون، همبستگی بین ۰,۴۰- و ۰,۷۴ و

۰,۷۰-۰,۳۳ RMSE بین ۰,۱۹-۰,۰۶ و ۰,۱۷-۰,۰۶، و MAE بین ۰,۱۳-۰,۰۴ و ۰,۱۲-۰,۰۴ به ترتیب برای ANN و BRNN بود. از جدول‌ها مشخص می‌شود که مدل‌های BRNN در سمت پایین‌تر از مدل‌های ANN با مقادیر ضریب همبستگی بیشتر قرار داشتند که نشان‌دهنده توانایی آنها در یافتن الگو و روند بارش GLDAS است.

بعضی مطالعات در پاکستان و سراسر جهان برای بحث با نتایج مطالعه حاضر بیان شده است. Ahmed et al. (2015) از MLP برای ریزمقیاس نمایی بارندگی در منطقه بلوچستان پاکستان استفاده و بیان کردند که ریزمقیاس نمایی آماری بارندگی در چنین مناطق خشکی به دلیل الگوی نامنظم بارندگی و درک ضعیف از ارتباط بین متغیرهای گردش جوی اقیانوس و بارش محلی، اغلب دشوار است. آنها دریافتند که بارش مشاهده شده و ریزمقیاس تطابق خوبی را نشان می‌دهد؛ در حالی که مشاهده شد که مدل ریزمقیاس شده، واریانس بارندگی را کمتر پیش‌بینی می‌کند. Awan and Maqbool (2010) درباره اسلام‌آباد پاکستان عملکرد بهتری از رویکردهای شبکه عصبی را از نظر دقت، زمان هدایت بیشتر و نیاز کمتر به منابع نشان دادند. (Ye et al. (2021) از تکنیک‌های مختلف یادگیری ماشین استفاده کردند و دریافتند که BRNN در مقایسه با مدل‌های دیگر عملکرد خوبی داشت، اما قادر به بازتولید بارندگی شدید نیست؛ به این معنی که نمی‌توان از آن برای پیش‌بینی بارش شدید و سیل احتمالی استفاده کرد. در مطالعه دیگری Chand and Nand (2009) BRNN را با سایر تکنیک‌های یادگیری ماشین به کار بردند و دریافتند که مقادیر خطای مدل BRNN در مقایسه با سایر تکنیک‌های یادگیری ماشین پایین است.

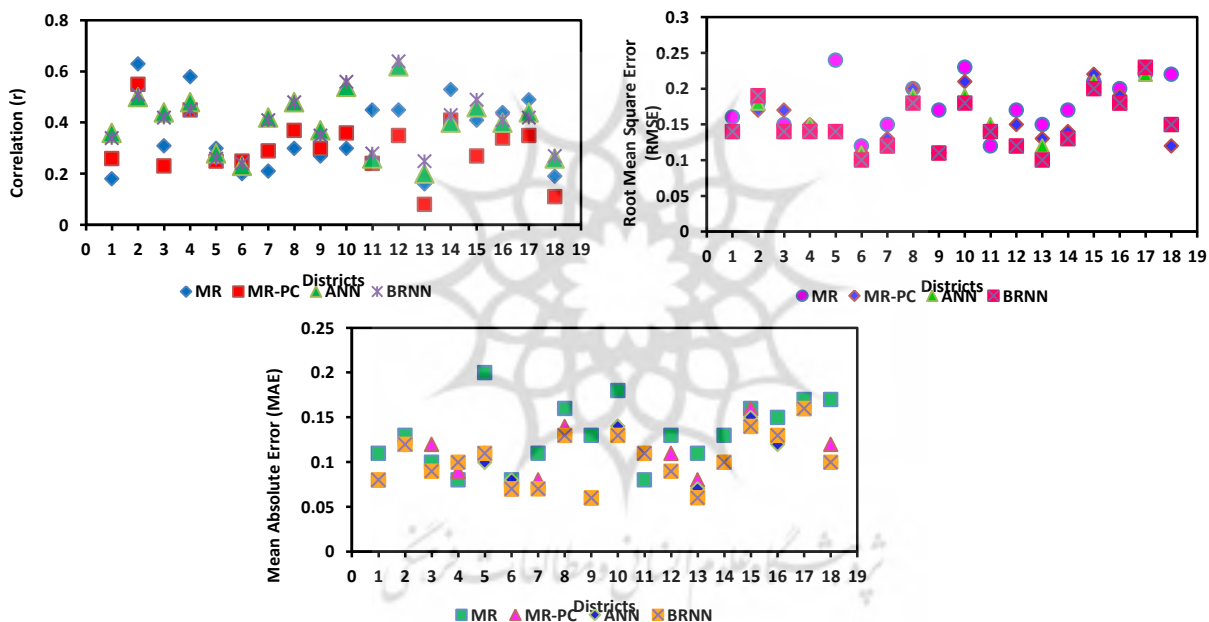
جدول ۶. عملکرد مدل‌های ANN و BRNN. مجموعه آموزشی و آزمایشی

Table 6. Performance of ANN and BRNN models: Training and test set

آزمون		آموزش										ناحیه
میانگین خطای مربع مطلق		ریشه میانگین مربعات خطا		همبستگی		میانگین خطای مربع مطلق		ریشه میانگین مربعات خطا		همبستگی		
BRNN	ANN	BRNN	ANN	BRNN	ANN	BRNN	ANN	BRNN	ANN	BRNN	ANN	
۰/۰۵	۰/۰۴	۰/۰۸	۰/۰۶	۰/۷۰	۰/۷۴	۰/۰۵	۰/۰۵	۰/۰۷	۰/۰۶	۰/۴۷	۰/۷۱	آواران
۰/۱۲	۰/۱۰	۰/۱۷	۰/۱۴	۰/۵۵	۰/۶۶	۰/۱۱	۰/۱۱	۰/۱۶	۰/۱۶	۰/۵۶	۰/۵۴	بارخان
۰/۰۹	۰/۰۹	۰/۱۴	۰/۱۴	۰/۴۹	۰/۵۳	۰/۰۹	۰/۰۹	۰/۱۴	۰/۱۴	۰/۴۸	۰/۵۰	بولان
۰/۱۱	۰/۰۹	۰/۱۶	۰/۱۵	۰/۳۶	۰/۵۷	۰/۱۱	۰/۱۱	۰/۱۶	۰/۱۶	۰/۳۸	۰/۳۱	درايوگتی
۰/۱۲	۰/۱۳	۰/۱۵	۰/۱۶	۰/۳۳	۰/۵۲	۰/۱۴	۰/۱۳	۰/۱۹	۰/۱۸	۰/۳۰	۰/۳۶	کلات
۰/۰۸	۰/۰۸	۰/۱۲	۰/۱۰	۰/۳۸	۰/۴۰	۰/۰۸	۰/۰۹	۰/۱۲	۰/۱۳	۰/۲۸	۰/۲۹	کچ
۰/۰۵	۰/۰۵	۰/۱۰	۰/۰۹	۰/۵۵	۰/۶۴	۰/۰۵	۰/۰۵	۰/۰۸	۰/۰۷	۰/۵۱	۰/۵۲	خزدار
۰/۰۹	۰/۱۰	۰/۱۳	۰/۱۴	۰/۵۲	۰/۶۱	۰/۱۰	۰/۱۰	۰/۱۴	۰/۱۵	۰/۵۸	۰/۵۴	کوهلو
۰/۰۴	۰/۰۵	۰/۰۶	۰/۰۹	۰/۶۶	۰/۶۳	۰/۰۴	۰/۰۳	۰/۰۶	۰/۰۶	۰/۷۳	۰/۷۷	لسببلا
۰/۱۱	۰/۱۱	۰/۱۶	۰/۱۶	۰/۶۲	۰/۷۱	۰/۱۱	۰/۱۰	۰/۱۵	۰/۱۳	۰/۵۸	۰/۵۹	لورالای
۰/۱۳	۰/۱۲	۰/۱۸	۰/۱۷	۰/۳۹	۰/۴۰	۰/۱۳	۰/۱۳	۰/۱۸	۰/۱۸	۰/۳۸	۰/۴۰	مستونگ
۰/۱۲	۰/۱۰	۰/۱۷	۰/۱۳	۰/۶۳	۰/۶۷	۰/۱۰	۰/۱۰	۰/۱۳	۰/۱۴	۰/۶۶	۰/۶۵	خیل موسی
۰/۰۶	۰/۰۶	۰/۰۹	۰/۰۸	۰/۳۴	۰/۴۶	۰/۰۶	۰/۰۶	۰/۱۰	۰/۱۰	۰/۲۹	۰/۲۱	پنجگور
۰/۱۹	۰/۱۳	۰/۱۲	۰/۱۹	۰/۴۸	۰/۵۰	۰/۱۲	۰/۱۲	۰/۱۷	۰/۱۷	۰/۴۳	۰/۴۱	کوتا
۰/۰۹	۰/۰۹	۰/۱۲	۰/۱۲	۰/۶۵	۰/۶۳	۰/۱۱	۰/۱۰	۰/۱۵	۰/۱۴	۰/۵۷	۰/۶۲	ذوب
۰/۱۱	۰/۱۱	۰/۱۶	۰/۱۶	۰/۴۰	۰/۶۱	۰/۱۰	۰/۱۱	۰/۱۵	۰/۱۶	۰/۵۳	۰/۴۹	زیارت
۰/۱۱	۰/۰۹	۰/۱۵	۰/۱۲	۰/۵۸	۰/۶۶	۰/۱۰	۰/۱۰	۰/۱۴	۰/۱۴	۰/۵۴	۰/۵۶	قلا سیف‌الله
۰/۱۰	۰/۱۱	۰/۱۴	۰/۱۵	۰/۳۷	۰/۴۳	۰/۱۰	۰/۱۰	۰/۱۵	۰/۱۵	۰/۳۹	۰/۳۹	سبی

ارزیابی قابلیت تعمیم همه مدل‌ها

پس از کالیبراسیون و اعتبارسنجی مدل‌ها، به منظور ارزیابی قابلیت تعمیم مدل‌های MR، MR-PC، ANN و BRNN ساخته شده، از مجموعه داده‌های TRMM برای دوره زمانی ۱۹۹۸-۲۰۱۹ استفاده شد (شکل ۵). مشاهده می‌شود که مدل‌های MR و MR-PC در مقایسه با ANN و BRNN عملکرد نسبتاً کمی از خود نشان می‌دهند. مقادیر ضریب همبستگی برای مدل‌های مبتنی بر MR و MR-PC به ترتیب بین ۰,۱۶-۰,۶۳ و ۰,۰۸-۰,۵۵ بود. RMSE بین ۰,۲۴-۱,۲ و ۰,۱۱-۰,۲۲ بود. MAE بین ۰,۲۰-۰,۰۸ و ۰,۰۶-۰,۱۶ متغیر بود. می‌توان مشاهده کرد که هر دو مدل ANN و BRNN نسبتاً خوب عمل کردند و مقادیر همبستگی و خطا به یکدیگر نزدیک تر بودند. مقادیر همبستگی بین ۰,۲۰-۰,۶۲ و ۰,۲۴-۰,۶۴، RMSE بین ۰,۱۱-۰,۲۲ و ۰,۱۰-۰,۲۳ به ترتیب برای ANN و BRNN، در حالی که MAE از ۰,۰۶-۰,۱۶ برای هر دو مدل متغیر بود. با بررسی قابلیت تعمیم، می‌توان دریافت که هر دو مدل مجموعه داده TRMM را به خوبی شبیه‌سازی کرده‌اند.




شکل ۵. عملکرد مدل‌های BRNN، ANN و رگرسیون چندگانه برای مجموعه داده TRMM

Figure 5. Performance of ANN, BRNN and multiple regression models for the TRMM dataset

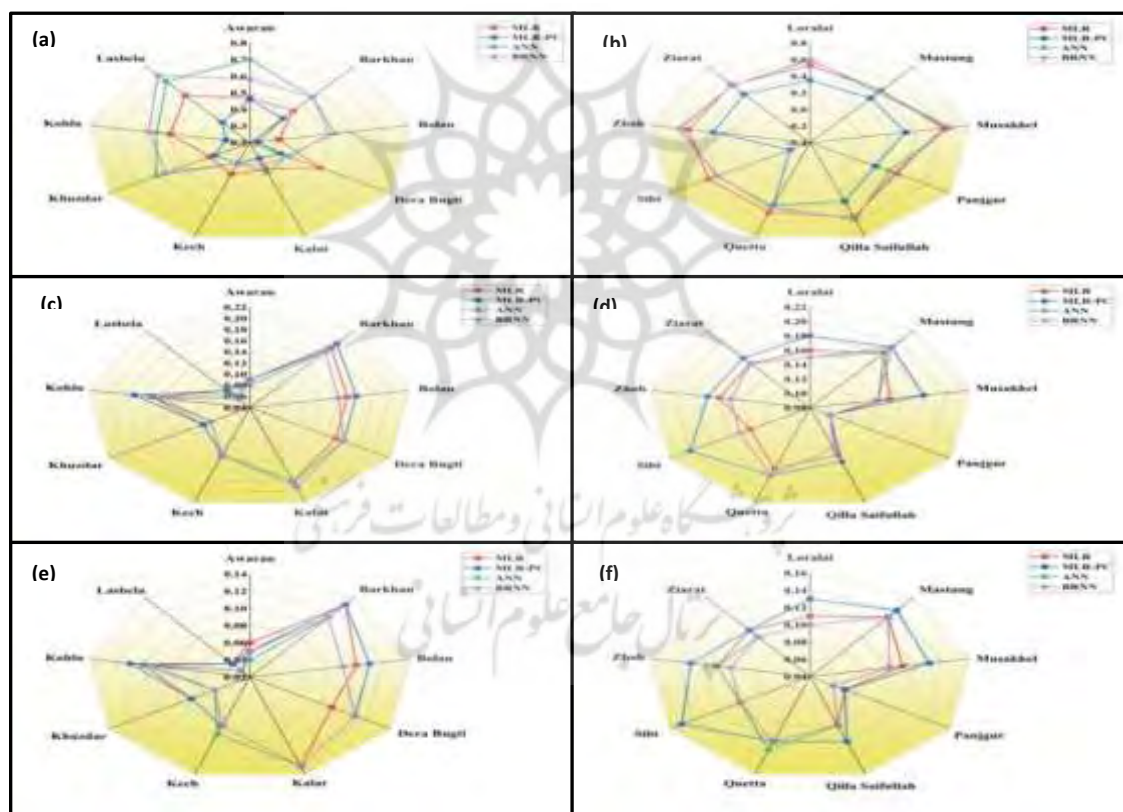
مقایسه مدل‌ها

در این بخش عملکرد کلی مدل‌های MR، MR-PC، ANN و BRNN مقایسه شد. به طور خلاصه فقط یک منطقه به صورت گرافیکی نشان داده شده است (شکل ۶). می‌توان دریافت که عملکرد مدل‌های ANN و BRNN نسبت به مدل‌های رگرسیونی برتر بود؛ زیرا بارش GLDAS که بعداً Mekanik et al. (2013) بررسی کردند، کمتر برآورد شد؛ با این حال اشاره می‌شود که این مدل‌ها قادر به پیش‌بینی بارش شدید نبودند؛ به این معنا که برای پیش‌بینی بارش شدید قابل استفاده نیستند. این مطابق با یافته‌های Ye et al. (2021) است. نمودارهای رادار مقادیر همبستگی کلی (شکل a و b)، RMSE (شکل c و d) و MAE (شکل e و f) را نشان می‌دهند.



شکل ۶. مقایسه مدل‌های ANN و BRNN با مدل‌های MR و MR-PC در منطقه آواران

Figure 6. Comparison of ANN and BRNN models with MR and MR-PC models in Awaran district



شکل ۷. GLDAS و مقادیر بارش پیش‌بینی شده توسط MR، MR-PC، ANN و BRNN در استان بلوچستان از طریق نمودارهای رادار طی سال‌های ۱۹۸۳-۲۰۲۰. (a, b) همبستگی (r)، (c, d) ریشه میانگین مربعات خطا (RMSE) و (e, f) میانگین خطای مطلق (MAE)

Figure 7. GLDAS and predicted precipitation values by MR, MR-PC, ANN, and BRNN over Balochistan province through Radar charts during 1983-2020; (a & b) correlation (r), (c & d) root mean square error (RMSE), and (e & f) mean absolute error (MAE)

نتیجه‌گیری

این مطالعه با هدف شناسایی LSCD های معنادار در بلوچستان و بهبود مهارت پیش‌بینی بارش ماهانه با استفاده از تجزیه و تحلیل مؤلفه اصلی (PCA)، شبکه عصبی مصنوعی (ANN)، شبکه عصبی منظم شده بیزین (BRNN) و تحلیل رگرسیون چندگانه (MRA) انجام شد. نواحی Nino-1+2، Nino-3، Nino-3.4، Nino-4، SST، SHFOL، LHFOL، V850، V500، U500، H850، H500، T2M، SLP، QBOII، QBOI به‌عنوان LSCD انتخاب شدند. نتایج تجزیه و تحلیل همبستگی متقاطع، LSCD های معنادار در سطح اطمینان ۹۹٪ را شناسایی کرد که عبارت‌اند از: SSH، SST، SHFOL، LHFOL، U500، T2M، Nino-3.4، Nino-4، و بیشترین همبستگی برای SSH، SST، SHFOL، LHFOL، T2M و U500 بوده است. برای پیش‌بینی بارش ماهانه با استفاده از LSCD های تأخیری و اجزای اصلی، مدل‌های MR توسعه داده شدند. مدل‌هایی که محدودیت‌های آماری معناداری و چندخطی بودن را نقض نکرده بودند و خطای کمتری داشتند، انتخاب شدند. مدل‌های MR بهتر از MR-PC عمل کردند. بیشترین همبستگی پیرسون در مدل‌های MR در طول مجموعه برای موسی خیل ۰/۶۵ و در حین آزمون برای موسی خیل و زوب ۰/۴۹ مشاهده شد. در مدل‌های MR-PC بیشترین همبستگی در طول آزمون برای آواران (۰،۵۰) و برای کوتا (۰،۴۳) ثبت شد. مدل‌های ANN و BRNN با استفاده از اجزای PC منتخب استفاده شدند و همبستگی‌های بیشتری نسبت به مدل‌های رگرسیونی نشان دادند که حاکی از توانایی آنها در یافتن الگوها و روند مشاهدات است. این مدل‌ها به‌طور کلی خطاهای کمتری را نشان می‌دهند و برای هدف پیش‌بینی در منطقه قابل اعتمادتر هستند. حداکثر همبستگی در طول آموزش در هر دو مدل ANN و BRNN به ترتیب ۰،۷۷ و ۰،۷۳ برای منطقه لسبیل و برای آواران به ترتیب ۰،۷۴ و ۰،۷۰ بود. توانایی تعمیم آنها روی مجموعه داده TRMM نیز آزمایش شد. در نتیجه، این مطالعه امکان پیش‌بینی بارش ماهانه با استفاده از ANN و BRNN و LSCD های همراه با تأخیر را برای منطقه مطالعه شده آشکار کرد. واضح است که واکنش بارش به عوامل اقلیمی با تأخیر مواجه می‌شود. با مقایسه نتایج ANN، BRNN و MLR می‌توان نتیجه گرفت که رویکردهای هوش مصنوعی مانند ANN و BRNN گزینه‌های آماری غیرخطی قابل اعتمادی هستند که می‌توانند پیش‌بینی‌های مشابه و در بعضی موارد بهتر ایجاد کنند و در نهایت می‌توانند برای اهداف و برنامه‌ریزی‌های کشاورزی و مدیریت منابع آب مفید باشند؛ به‌ویژه در منطقه بلوچستان که از نظر فعالیت‌های کشاورزی، منطقه بسیار مهمی در پاکستان است.

این پژوهش این قابلیت را ایجاد کرد که در آینده با توسعه مدل‌های پیش‌بینی و با گنجاندن محرک‌های آب‌وهوایی در مقیاس بزرگ‌تر مطالعات گسترش یابد. همچنین می‌توان با بهره‌گیری از رویکردهای الگوریتم ژنتیک برای انتخاب بهترین ورودی و استفاده از مجموعه داده‌های بارش مبتنی بر ایستگاه مشاهده شده اقدام کرد.

سپاسگزاری

این مطالعه بخشی از کار پژوهشی نویسنده اول در مقطع دکتری است که در دانشگاه تیریز انجام شده است. نویسندگان مایل‌اند از مرکز خدمات اطلاعاتی علوم زمین گودارد ناسا (GES DISC) برای دسترسی به داده‌های

بارش ماهواره‌ای مدل GLDAS و MERRA-2، دانشگاه فری برلین و گروه کاری سیستم مشاهده آب‌وهوای جهانی NOAA GCOS) برای ارائه رایگان داده‌های سطحی فشار (WG-SP) و داده‌های HadISST سپاسگزاری کنند. همچنین بر خود لازم می‌دانند از سرکار خانم زهرا پاشایی، دانشجوی دکتری آب‌وهواشناسی دانشگاه تبریز، به دلیل همکاری در ویرایش مقاله و ارائه پیشنهادهاى ارزشمند تشکر کنند.

منابع

- Ahmed, K., Shahid, S., Haroon, S.B., Wang, X.J., (2015). Multilayer perceptron neural network for downscaling rainfall in arid region: A case study of Baluchistan, Pakistan, *Journal of Earth System Sciences*, (124), 1325-1341.
- Aamir, E., Hassan, I., (2020). The impact of climate indices on precipitation variability in Baluchistan, Pakistan, *Tellus A: Dynamic Meteorology and Oceanography*, 72, 1-46.
- Rasul, G., Afzal, M., Zahid, M., Bukhari, S.A.A., (2012). Climate Change in Pakistan Focused on Sindh Province, Technical Report PMD 25/2012 55, Pakistan Meteorological Department, Islamabad, Pakistan, <https://doi.org/10.13140/2.1.2170.6560>.
- Khan, N., Sachindra, D.A., Shahid, S., Ahmed, K., Shiru, M.S., Nawaz, N., (2020). Prediction of droughts over Pakistan using machine learning algorithms, *Advances in Water Resources*, 139.
- Adamowski, J., Sun, K., (2010). Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds, *Journal of Hydrology*, 390, 85-91.
- LDAS. (2021). GLDAS: Project Goals [Online]. Available: <https://ldas.gsfc.nasa.gov/gldas>.
- Begum, B., Tajbar, S., Khan, B., Rafiq, L., (2021). Identification of relationships between climate indices and precipitation fluctuation in Peshawar City-Pakistan, *Journal of Research in Environmental Earth Sciences*, 10, 264-278.
- Zuecco, F., Facco, P., Hoesser, S.R., Fogli, M.R., Ciccotti, M., Bezzo, P., Barolo, M., (2020). Troubleshooting an Industrial Batch Process for the Manufacturing of Specialty Chemicals using Data Analytics, *Computer Aided Chemical Engineering*, 48, 1129-1134.
- Menke, W., Menke, J., (2009). *Environmental data analysis with MATLAB*, 1st edn, UK, Elsevier.
- Taweessin, K., Seeboonruang, U., (2019). The relationship between the climatic indices and the rainfall fluctuation in the lower central plain of Thailand, *International Journal of Innovative Computing, Information and Control*, 15, 107-127.
- Lin, F.J., (2008). Solving multicollinearity in the process of fitting regression model using the nested estimate procedure, *Quality & Quantity*, 42, 417-426.
- Field, A., (2009). *Discovering statistics using SPSS*, Eds. 3, London, Sage Publications Ltd.
- Maier, H.R., Dandy, G.C., (2000). Neural networks for the prediction and forecasting of water resources variables: A review of modelling issues and applications, *Environmental Modelling & Software*, 15, 101-124.
- Beale, M.H., Hagan, M.T., Demuth, H.B., (2011). *Neural network toolbox TM7: User's guide*.
- Iqbal, M.F., Athar, H., (2018). Variability, trends, and teleconnections of observed precipitation over Pakistan, *Theoretical and Applied Climatology*, 134, 613-632.
- Choubin, B., Khalighi-Sigaroodi, S., Malekian, A., Kisi, O., (2014). Multiple linear regression, multi-layer perceptron network and adaptive neuro-fuzzy inference system for forecasting precipitation based on large-scale climate signals, *Hydrological Sciences Journal*, 61, 1001-1009.
- Awan, J.A., Maqbool, O., (2010). Application of Artificial Neural Networks for monsoon rainfall prediction, 2010 6th International Conference on Emerging Technologies (ICET), 27-32.
- Ye, L., Jabbar, S.F., Zahra, M.M.A. Tan, M.L., (2021). Bayesian regularized neural network model development for predicting daily rainfall from sea level pressure data: Investigation on solving complex hydrology problem, *Complexity*, <https://doi.org/10.1155/2021/6631564>.
- Chand, A., Nand, R., (2009). Rainfall prediction using Artificial Neural Network in the South Pacific region, 2019 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE),

- Melbourne, VIC, Australia, 1-7.
- Mekanik, F., Imteaz, M.A., Gato-Trinidad, S., Elmahdi, A., (2013). Multiple regression and Artificial neural network for long-term rainfall forecasting using large scale climate modes, *Journal of Hydrology*, 503, 11-21.
- Jamro, S., Channa, F.N., Dars, G.H., Ansari, K., Krakauer, N.Y., (2020). Exploring the Evolution of Drought Characteristics in Balochistan, Pakistan, *Applied Sciences*, 10.
- IPCC. (2014). Climate change 2014: synthesis report. In Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change (eds. Core Writing Team, R. K. Pachauri and L. A. Meyer]. IPCC, Geneva, Switzerland, 151 p.
- Naz, F., Dars, G.H., Ansari, K., Jamro, S., Krakauer, N.Y., (2020). Drought trends in Balochistan, *Water*, 12, 470. DOI:10.3390/w12020470.
- Global, C., (2020). China-Pakistan economic corridor: CPEC - CPIC. CPIC Global. Available: <https://www.cpicglobal.com/pakistan-overview/cpec/>.
- Shukla, R.P., Tripathi, K.C., Pandey, A.C., Das, I.M.L., (2011). Prediction of Indian summer monsoon rainfall using Niño indices: A neural network approach, *Atmospheric Research*, 102, 99-109.
- Doranal ChandraShekar, V., Shetty, A., Patel, G.C.M., (2019). Estimation of monsoon seasonal precipitation teleconnection with El Niño-Southern Oscillation sea surface temperature indices over the Western Ghats of Karnataka, *Asia-Pacific Journal of Atmospheric Sciences*, <https://doi.org/10.1007/s13143-019-00133-w>.
- Hossain, I., Rasel, H.M., Imteaz, M.A., Pourakbar, S., (2015). Effects of climate indices on extreme rainfall in Queensland, Australia, *Proceeding of 21st International Congress on Modelling and Simulation, MODSIM*.
- Ghasemiyeh, H., Bazrafshan, O., Manesh, K.B., (2017). Artificial Neural Network for monthly rainfall forecasting using teleconnection patterns (Case Study: Central Plateau Basin of Iran), *Journal of Earth Space Physics*, 43, 405-418.
- Li, X., Ting, M., (2015). Recent and future changes in the Asian monsoon-ENSO relationship: Natural or forced?, *Geophysical Reserach Letters*, 42, 3502-3512.
- Lee, J.H., Julien, P.Y., (2016). Teleconnections of the ENSO and South Korean precipitation patterns, *Journal of Hydrology*, 534, 237-250.
- Ailikun, B., Yasunari, T., (2001). ENSO and Asian Summer Monsoon: Persistence and Transitivity in the Seasonal March, *Journal of the Meteorological Society of Japan*, 79, 145-159.
- Canchala, T., Alfonso-Morales, W., Ceron, W.L., Carvajal-Escobar, Y., Caicedo-Bravo, E., (2020). Teleconnections between Monthly Rainfall Variability and Large-Scale Climate Indices in Southwestern Columbia, *Water*, 12.
- De Silva, T.M., Hornberger, G.M., (2019). Identifying El Niño-Southern Oscillation influences on rainfall with classification models: Implications for water resource management of Sri Lanka, *Hydrology and Earth System Sciences*, 23, 1905-1929.
- Davey, M.K., Brookshaw, A., Ineson, S., (2014). The probability of the impact of ENSO on precipitation and near-surface temperature, *Climate Risk Management*, 1, 5-24.



پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی