

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

EFICIÊNCIA DE CINCO MODELOS DO CMIP 6 NA PREVISÃO DE TENDÊNCIA DE CHUVAS PARA A BACIA DO RIO JORDÃO, EM PERNAMBUCO

Pedro Benjamin Carreiro Lima Monteiro¹; Jaime Joaquim da Silva Pereira Cabral²

Abstract: The study aimed to evaluate the performance of five climate models in forecasting the climate of the Jordão River basin, in Pernambuco, Brazil. The quantile mapping method was used for bias correction, along with four precipitation indices: Rx1day, Rx5day, CWD, and PRCPTOT. Model efficiency was assessed using three statistical error metrics: RSR, NSE, and PBIAS. The results showed that for RSR and NSE, although there was a considerable improvement in model efficiency after bias correction, the overall performance remained unsatisfactory. In contrast, PBIAS indicated very good performance, especially for the Rx1day and PRCPTOT indices.

Resumo: O artigo objetivou avaliar o desempenho de cinco modelos climáticos na previsão do clima da bacia do rio Jordão, em Pernambuco. Foi utilizado o método do quantil mapping para correção de vies e quatro índices pluviométrico (Rx1day, Rx5day, CWD, PRCPTOT). A eficiência dos modelos foi averiguada a partir de três erros estatísticos: RSR, NSE e PBIAS. Os resultados mostraram que para o RSR e NSE, embora haja uma melhora considerável da eficiência dos modelos, os seus desempenhos ainda se mostram insatisfatório. Caso oposto se revela para o PBIAS cujo resultados mostram desempenhos muito bons principalmente para os índices Rx1day e PRCPTOT.

Palavras-Chave – eventos extremos de chuvas, índices pluviométricos, modelos climáticos

1 INTRODUÇÃO

Mudanças climáticas referem-se às mudanças de longo prazo que ocorre no clima da Terra. Essas mudanças podem ser derivadas de eventos naturais como a atividade solar ou grandes erupções vulcânicas (United Nations, 2023). Entretanto desde 1800, com a revolução industrial, as atividades humanas têm contribuído para essas mudanças.

O sexto relatório do Painel Intergovernamental das Mudanças Climáticas (IPCC, 2021) é categórico ao afirmar que as mudanças climáticas estão sendo provocadas pela atividade humana. É também o primeiro relatório com uma visão pessimista, afirmando que em todos os cenários há o aumento de temperatura até a metade do século XXI. A não ser que medidas drásticas sejam tomadas para reduzir as emissões dos gases do efeito estufa, o aumento médio da temperatura poderá ultrapassar os 1,5 °C a 2,0 °C (IPCC, 2021), as metas acordadas pelo Acordo de Paris.

Uma das formas dos pesquisadores simular o clima e projetarem as mudanças para cenários futuros é através dos modelos climáticos. Todavia, esses modelos não pretendem prever o clima em um dia específico, mas sim a tendência dele para um determinado período. Assim, o desempenho dos modelos climáticos deve ser avaliado a partir da sua capacidade em prever tendências climáticas e não eventos específicos.

1) Doutorando em Engenharia Civil (Recursos Hídricos) pelo PPGE/UFPE. Email: pedro.benjamin@ufpe.br

2) Professor Doutor na UFPE e Poli/UPE. Email: jaime.cabral@ufpe.br

A utilização de índices é, portanto, uma das formas de averiguar o desempenho dos modelos climáticos. A Organização Mundial de Meteorologia (WMO) propôs o uso de 27 índices climáticos (temperatura e precipitação) a fim de padronizar as análises e possibilitar a comparação entre diversas regiões do globo em 1999, dentre eles dos quais destacam-se: (i) Rx1day – apresenta a precipitação máxima em um único dia para o período analisado, geralmente um ano; (ii) Rx5day – apresenta a precipitação máxima em cinco dias consecutivos para o período analisado; (iii) CWD – número máximo de dias consecutivos úmidos; (iv) PRCCPTOT – volume total precipitado em um ano.

Um outro ponto importante é que embora os modelos climáticos tendem a representar o clima global de maneira satisfatória, em escalas menores, isso não tendem a acontecer, devido a escala grosseira com que são calculados, produzindo um viés significativo e incertezas (Anil & Raj, 2022; Wang et al., 2022; Xavier et al., 2022; Xue et al., 2022).

Nesse ponto é fundamental que haja um processo de correção de viés dos modelos climáticos. Existem diversas metodologias para isso, sem haver uma mais correta que outra. Na verdade, dependendo a aplicação, das estatísticas utilizada e do intuito da pesquisa poderá haver um método mais adequado que outro. Por exemplo, o quantil mapping mostra-se um método mais adequado para escalas diárias de precipitação, mas não se justificando para escalas mensais (SHRESTHA; ACHARYA e SHRESTHA, 2017).

O mapeamento de quantil (QM) assume que a distribuição dos dados simulados é a mesma que os dados observados. Um dado simulado com uma determinada probabilidade é substituído pelo quantil dos dados observados com a mesma probabilidade (Heo et al., 2019). A vantagem do uso do QM é devido a sua simplicidade, sua característica não-paramétrica e boa eficiência em corrigir os vieses na média, desvio padrão e quantis (Song et al., 2021).

Os dados são agrupados de acordo com uma função de distribuição acumulada, em que é calculada a probabilidade desse valor ser menor ou igual a um determinado valor. O valor quantil é então obtido pelo inverso dessa função. As funções de distribuição acumulada e suas inversas são calculadas para o período histórico dos dados observados e do modelo climático. A correção de viés para os dados futuros é corrigida a partir de uma função de transferência considerando as funções anteriormente calculadas (Qian & Chang, 2021).

Nesse interim, esse artigo tem o objetivo de avaliar o desempenho de cinco modelos climáticos para a bacia do rio Jordão, situada no estado de Pernambuco entre os municípios de Recife e Jaboatão dos Guararapes. A bacia possui uma população de 196.772 habitantes, o que corresponde a 13% da população recifense (Monteiro & Cabral, 2024). Além disso, a bacia ainda sofre com a influência das marés e grande parte do seu solo está impermeabilizado devido a grande urbanização da bacia.

Identificar qual modelo melhor representa o clima da bacia pode no prognóstico futuro do seu clima, principalmente do regime pluviométrico e, conseqüentemente, estabelecer técnicas de engenharia que possam aumentar a resiliência da bacia quanto às mudanças climáticas.

2 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A bacia do rio Jordão tem 16,64 km² e possui três rios principais: o rio Jordão, Setúbal e Borborema. É uma bacia completamente urbana cujos limites estão entre os municípios de Jaboatão dos Guararapes (25%) e Recife (75%), ambos da região metropolitana do Recife (RMR) e litorâneos. A bacia tem um formato alongado, sofre influência do mar e todos os seus rios estão canalizados, pelo menos em grande parte dos trechos.

O relevo da bacia apresenta cotas muito baixas. 42,1% da bacia possui cotas de 5,0 m e somente 17,2% com cotas acima de 20,0 m. Por ser uma bacia urbana, grande parte do seu solo está impermeabilizado, com a construção de moradias, vias, condomínios e lojas. Segundo dados do MAPBIOMAS (Brasil, 2023), 87,0% da bacia é considerada como infraestrutura urbana, o restante está distribuído entre água, agropecuária, mineração e mangue.

As áreas com água e mangue concentram-se na foz da bacia, dentro do Parque dos Manguezais, enquanto as áreas de agropecuária e mineração encontram-se na cabeceira da bacia onde se situa o Parque Histórico Nacional dos Guararapes. A figura 1 apresenta os limites da bacia, bem como a cobertura do solo.

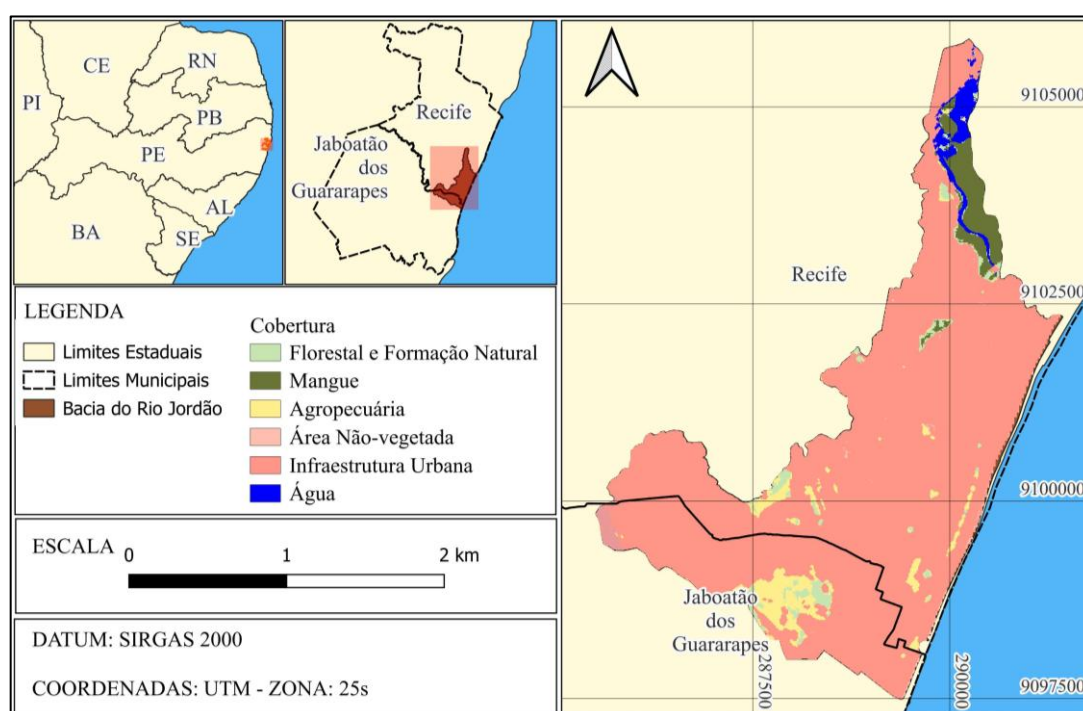


Figura 1 - Uso e Ocupação do Solo da bacia do rio Jordão

O regime pluviométrico da bacia é bastante influenciado pelo Distúrbios Ondulatórios do Leste (DOL). Os meses mais chuvosos são abril, maio, junho e julho, com totais mensais que podem superar os 600 mm. Já os meses mais secos são setembro, outubro, novembro e dezembro com volumes inferiores a 50 mm.

3 METODOLOGIA

Nessa pesquisa foram utilizados cinco modelos do CMIP6: ACCESS-ESM1-5, ACCESS-CM2, KIOST-ESM, NESM3, TaiESM1. Os modelos foram escolhidos a partir do trabalho de Ballarin et al. (2023), que recortou o Brasil para 19 modelos climáticos, promovendo a redução de escala deles para uma grade de 27,0 km de resolução.

Foram baixados os dados brutos para o período de 1980-2010 e feito a correção de viés pelo método do quantil mapping. Foi utilizado a linguagem R, o pacote 'qmap' - idealizado por Gudmundsson et al. (2012) – e o código disponibilizado por Shrestha, Acharya e Shrestha (2017) – que realiza um looping para correção de viés para diversos pontos, variáveis climáticas e modelos.

Para a correção de viés, utilizou-se os dados coletados pela estação do Curado, que contém dados de 1980, monitorada pelo INMET.

Após a correção de viés, foi feito a comparação entre os dados brutos dos modelos, os dados corrigidos e os dados observados a partir de quatro índices pluviométricos: Rx1day, Rx5day, CWD e PRCPTOT. Essa comparação deu-se através de três erros estatísticos: PBIAS, NSE e RSR.

O NSE é uma estatística normalizada que indica a magnitude relativa da variância residual (ruído) comparado com a variância dos dados observados. É uma indicação de quão bem os dados simulados se encaixam com os dados observados (Moriasi et al., 2007). A equação 18 apresenta a fórmula usada, enquanto a tabela 4, a classificação da simulação baseado nos índices de erro calculados.

O RSR é obtido a partir da padronização do erro da média quadrada (RMSE), que expressa acurácia dos resultados numéricos na mesma dimensão da variável analisada (Hallak & Pereira Filho, 2011). O PBIAS mede a tendência dos dados simulados de serem maiores ou menores do que os dados observados. Para valores positivos, o PBIAS indica uma subestimação e valores negativos uma superestimação.

As equações seguintes apresentam o método de cálculo de cada um dos erros:

$$NSE = 1 - \left[\frac{\sum_i^n (Y_i^{obs} - Y_i^{sim})^2}{\sum_i^n (Y_i^{obs} - Y^{média})^2} \right] \quad (1)$$

$$RSR = \left[\frac{\sqrt{\sum_i^n (Y_i^{obs} - Y_i^{sim})^2}}{\sqrt{\sum_i^n (Y_i^{obs} - Y^{média})^2}} \right] \quad (2)$$

$$PBIAS = \frac{\sum_i^n (Y_i^{obs} - Y_i^{sim})}{\sum_i^n (Y_i^{obs})} \times 100 \quad (3)$$

Onde,

Y^{obs} = são os dados observados

Y^{sim} = são os dados simulados

$Y^{média}$ = é a média dos dados observados

Para o ranqueamento dos modelos foi utilizado o trabalho de Moriasi et al. (2007) que apresentou faixa de valores para cada um dos erros estatísticos supracitados classificando a simulação de muito bom a insatisfatório (tabela 1).

Tabela 1 - Desempenho da Simulação baseado nos índices de erro

Desempenho	RSR	NSE	PBIAS
Muito Bom	Até 0,50	Acima de 0,75	Menor que (+/-)10%
Bom	Até 0,60	Até 0,75	Menor que (+/-)15%
Satisfatório	Até 0,70	Até 0,65	Menor que (+/-) 25%
Insatisfatório	Acima de 0,70	Até 0,50	Igual ou superior a (+/-) 25%

FONTE: Moriasi et al (2007), adaptado

4 RESULTADOS E DISCUSSÃO

A figura 2 apresenta a comparação dos modelos com os dados observados para cada índice antes e após a correção de viés. É perceptível que após a correção os modelos tendem a representar melhor o clima para o período analisado. É o caso, por exemplo, do índice Rx1day em que os modelos subestimam os valores, mas após a correção ficam na mesma ordem de grandeza. Contudo, há ainda alguns desvios. No ano de 1986, para Rx1day, na estação do Curado registrou 235 mm em um único dia, mas para os modelos ACCESS-CM2 e ACCESS-ESM1-5 foram registrados apenas 47 e 63 mm respectivamente para o mesmo ano, mesmo após a correção.




Figura 2 - Comparação entre os modelos climáticos e os dados observados antes e após a correção

O KIOST foi outro modelo que apresentou uma melhora considerável, principalmente para o índice CWD. O modelo tende a superestimar os valores, mas após a correção se aproxima dos dados observados. Contudo, apesar dessa melhora, a análise das métricas de erros mostra que o modelo ainda apresenta um desempenho ruim para o índice (figura 3).

O gráfico da figura 3 mostra que apenas o PBIAS apresentou resultados “Satisfatório” ou “Muito Bom” para os modelos e índices analisados. Em todas as situações o Rx1day e o PRCPTOT apresentaram desempenhos “Muito Bom”, enquanto os demais índices apresentaram resultados “Satisfatório”. Contudo os modelos KIOST-ESM e o NESM3, para os índices Rx5day e CWD, continuaram com um desempenho “Insatisfatório”.

Houve situações em que o desempenho do modelo piorou após a correção de viés. É o caso do ACCESS-CM2, que apresentou resultados piores para CWD, para o PBIAS.

	Dados Brutos				Dados Corrigidos				
RSR	2.03	1.54	3.95	1.68	1.39	1.88	1.59	1.71	ACCESS.M2
pbias	-0.56	-0.35	1.33	-0.22	0	0.21	0.26	0.02	
NSE	-3.25	-1.45	-15.09	-1.93	-1.01	-2.64	-1.6	-2.01	
RSR	2.89	2.72	1.42	4.01	1.49	1.81	1.88	1.95	ACCESS.M5
pbias	-0.88	-0.81	-0.23	-0.83	-0.08	0.23	0.35	0.01	
NSE	-7.61	-6.65	-1.07	-15.6	-1.3	-2.38	-2.66	-2.93	
RSR	2.54	2.12	17.19	1.88	1.3	2.1	1.87	1.55	KIOST.E5M
pbias	-0.75	-0.58	6.98	-0.33	0	0.37	0.5	0.01	
NSE	-5.66	-3.65	-304.42	-2.67	-0.74	-3.58	-2.61	-1.49	
RSR	2.37	1.66	3.75	1.35	1.37	2.25	1.77	1.25	NESM3
pbias	-0.7	-0.43	1.49	-0.18	0	0.34	0.34	0.01	
NSE	-4.78	-1.85	-13.51	-0.88	-0.94	-4.24	-2.23	-0.6	
RSR	2.46	1.95	7.8	1.68	1.33	1.85	1.43	1.89	TaiESM1
pbias	-0.73	-0.54	3.18	-0.26	-0.03	0.24	0.22	0.01	
NSE	-5.24	-2.94	-61.91	-1.93	-0.83	-2.55	-1.1	-2.7	
	Rx1day	Rx5day	CWD	PRCPTOT	Rx1day	Rx5day	CWD	PRCPTOT	
Classificação: ■ Insatisfatório ■ Muito Bom ■ Satisfatório									

Figura 3 – Comparação dos modelos através dos erros estatísticos antes e após a correção de viés

Essa divergência entre o desempenho dos modelos quando comparado as métricas de erros pode ser justificada pelo próprio objetivo do erro estatístico aplicado. Enquanto o RSR e NSE verificam a acurácia dos dados simulados, o PBIAS apenas indica a tendência desses dados em superestimar ou subestimar os valores em relação aos dados observados.

A dificuldade dos modelos em preverem o clima na escala local pode estar relacionado a própria concepção do que é o modelo climático. Como explanado anteriormente, os modelos tendem a prever tendências e não o clima num determinado dia. Como os modelos são estocásticos, eles procuram representar as propriedades estatísticas dos dados observados, mas a geração dos eventos é dada de forma aleatória.

Chen et al. (2021) explicam também que os modelos climáticos performam melhor a temperatura do que a precipitação, pois essa apresenta uma variabilidade espacial e temporal maior. Os autores supracitados ainda supõem que em regiões de climas quentes os modelos têm uma performance pior do que em climas mais frios, pois as chuvas tendem a ter maior influência na geração do hidrograma do que a neve. Chen et al. (2013) já haviam mencionado isso, sugerindo que dependendo do tipo de clima, região e relevo os modelos poderiam apresentar uma performance melhor ou pior.

Oliveira et al. (2023) também sugerem que dependendo da sazonalidade os modelos poderão responder melhor ou não. Os autores compararam a performance de 50 modelos para as regiões sul da Amazonia e sudeste do Brasil para cada trimestre do ano. A performance dos modelos variou bastante entre as duas regiões e para o trimestre, na grande maioria dos casos os modelos conseguiram simular adequadamente dois trimestres.

Por último, o próprio método utilizado para a correção de vies pode também ser a causa da eficiência dos modelos. Embora o quantil mapping (QM) seja um método adequado para correção de períodos em escala diária, ele não considera a influência de outras variáveis no processo de correção e repete a tendência dos dados observados para os dados futuros (Chen et al., 2021).

Disso posto e considerando apenas o PBIAS, os modelos, de maneira geral, tendem a prever de maneira satisfatória o clima da bacia do Rio Jordão. Os modelos apresentaram um bom desempenho para os índices Rx1day e PRCPTOT, inclusive com resultados bastante semelhantes. Com relação a Rx5day e CWD, os modelos apresentam um resultado apenas satisfatório, sendo que os modelos NESM3 e KIOST-ESM continuaram não apresentando um bom desempenho mesmo após a correção de vies. O modelo com melhor desempenho foi o TaiESM1.

5 CONCLUSÃO

Da análise dos modelos climáticos feita, conclui-se que mesmo após a correção de vies, para os NSE e RSR os modelos continuam apresentando um desempenho ruim, ainda que haja uma melhora na sua eficiência após a correção de vies. Porém, o PBIAS indica que, após a correção de vies, os modelos apresentam um bom desempenho, embora tendam a superestimar os dados observados.

As possíveis causas para isso vão desde a própria formulação do modelo até mesmo quando com questões relacionadas a sazonalidade, localização geográfica ou até mesmo o método de correção de vies.

REFERENCIAS

- Anil, S., & Raj, P. A. (2022). Deciphering the projected changes in CMIP-6 based precipitation simulations over the Krishna River Basin. *Journal of Water and Climate Change*, 13(3), 1389–1407. <https://doi.org/10.2166/wcc.2022.399>
- Ballarin, A. S., Sone, J. S., Gesualdo, G. C., Schwambach, D., Reis, A., Almagro, A., & Wendland, E. C. (2023). CLIMBra - Climate Change Dataset for Brazil. *Scientific Data*, 10(1). <https://doi.org/10.1038/s41597-023-01956-z>
- Brasil. (2023). *Projeto MAPBIOMAS - Coleção 7.1 da Série Anual de Mapas de Cobertura e Uso do Solo do Brasil*. <https://mapbiomas.org/estatisticas>
- Chen, J., Arsenault, R., Brissette, F. P., & Zhang, S. (2021). Climate Change Impact Studies: Should We Bias Correct Climate Model Outputs or Post-Process Impact Model Outputs? *Water Resources Research*, 57(5). <https://doi.org/10.1029/2020WR028638>
- Chen, J., Brissette, F. P., Chaumont, D., & Braun, M. (2013). Finding appropriate bias correction methods in downscaling precipitation for hydrologic impact studies over North America. *Water Resources Research*, 49(7), 4187–4205. <https://doi.org/10.1002/wrcr.20331>

- Gudmundsson, L., Bremnes, J. B., Haugen, J. E., & Engen-Skaugen, T. (2012). Technical Note: Downscaling RCM precipitation to the station scale using statistical transformations – a comparison of methods. *Hydrology and Earth System Sciences*, 16(9), 3383–3390. <https://doi.org/10.5194/hess-16-3383-2012>
- Hallak, R., & Pereira Filho, A. (2011). As análises preliminares para o desempenho deste índice indicam adequação de sua formulação para o tipo de simulação efetuada. Palavras-chave: tempestades, simulações numéricas de mesoescala, erros de fase e amplitude, índices de acurácia. *Revista Brasileira de Meteorologia*, 591–608.
- Heo, J. H., Ahn, H., Shin, J. Y., Kjeldsen, T. R., & Jeong, C. (2019). Probability distributions for a quantile mapping technique for a bias correction of precipitation data: A case study to precipitation data under climate change. *Water (Switzerland)*, 11(7). <https://doi.org/10.3390/w11071475>
- IPCC. (2021). Technical Summary. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. In *Climate Change 2021: The Physical Science Basis*.
- Monteiro, P. B. C. L., & Cabral, J. J. S. P. (2024). CARACTERIZAÇÃO DA BACIA DO RIO JORDÃO QUANTO A VULNERABILIDADE SOCIAL EM RELAÇÃO ÀS MUDANÇAS CLIMÁTICAS. *Anais XVII Simpósio de Recursos Hídricos Do Nordeste*.
- Moriasi, D. N., Arnold, J. G., Liew, M. W. Van, Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *American Society of Agricultural and Biological Engineers*, 50(3), 885–900.
- Oliveira, D. M., Ribeiro, J. G. M., Faria, L. F., & Reboita, M. S. (2023). Performance dos modelos Climáticos CMIP6 em Simular a Precipitação em Subdomínios da América do Sul no Período Histórico. *Revista Brasileira de Geografia Física*, 16(01), 116–133. <https://climatedataguide.ucar.edu/climate-data/>
- Qian, W., & Chang, H. H. (2021). Projecting health impacts of future temperature: A comparison of quantile-mapping bias-correction methods. *International Journal of Environmental Research and Public Health*, 18(4), 1–12. <https://doi.org/10.3390/ijerph18041992>
- Shrestha, M., Acharya, S. C., & Shrestha, P. K. (2017). Bias correction of climate models for hydrological modelling – are simple methods still useful? *Meteorological Applications*, 24(3), 531–539. <https://doi.org/10.1002/met.1655>
- Song, Z., Xia, J., She, D., Li, L., Hu, C., & Hong, S. (2021). Assessment of meteorological drought change in the 21st century based on CMIP6 multi-model ensemble projections over mainland China. *Journal of Hydrology*, 601. <https://doi.org/10.1016/j.jhydrol.2021.126643>
- United Nations. (2023, June 5). *United Nations - Climate Action*. What Is Climate Change? <https://www.un.org/en/climatechange/what-is-climate-change>
- Wang, X., Yang, J., Xiong, J., Shen, G., Yong, Z., Sun, H., He, W., Luo, S., & Cui, X. (2022). Investigating the Impact of the Spatiotemporal Bias Correction of Precipitation in CMIP6 Climate Models on Drought Assessments. *Remote Sensing*, 14(23). <https://doi.org/10.3390/rs14236172>

- Xavier, A. C. F., Martins, L. L., Rudke, A. P., de Moraes, M. V. B., Martins, J. A., & Blain, G. C. (2022). Evaluation of Quantile Delta Mapping as a bias-correction method in maximum rainfall dataset from downscaled models in São Paulo state (Brazil). *International Journal of Climatology*, 42(1), 175–190. <https://doi.org/10.1002/joc.7238>
- Xue, P., Zhang, C., Wen, Z., Park, E., & Jakada, H. (2022). Climate variability impacts on runoff projection under quantile mapping bias correction in the support CMIP6: An investigation in Lushi basin of China. *Journal of Hydrology*, 614. <https://doi.org/10.1016/j.jhydrol.2022.128550>