

Climate Projection of the States of the Northeast Region, Minas Gerais, Maranhão and Amapá Simulated up to 2040 by Forcings SSP126/245/370 from CIMP6

Paulo R. M. Francisco*, José H. S. de Sousa**, George do N. Ribeiro***, José N. Silva****

*Dr. em Eng. Agrícola, Universidade Federal de Campina Grande, UFCG, paulomegna@gmail.com

**Mestrando em Eng. Agrícola, Universidade Federal de Campina Grande, UFCG, hugosimplicio123@gmail.com

***Dr. Prof. Associado, Universidade Federal de Campina Grande, UFCG, george.nascimento@professor.ufcg.edu.br

****Dr. Prof. Associado, Universidade Federal de Campina Grande, UFCG, nilton@eq.ufcg.edu.br

Received 9 April; accepted 27 June.

ABSTRACT

Understanding the current and future characteristics of temperature and precipitation is important for planning prevention and mitigation measures, and it is necessary to apply climate projection analyzes to collect information to understand the possible impact of climate change, which can provide useful information for a plan adaptation and mitigation of changes. The objective of this work was to evaluate changes in temperature and precipitation simulated by high-resolution CMIP6 climate models for 3 emissions scenarios for the states of the Northeast region, Minas Gerais, Maranhão and Amapá using geotechnologies. The WordClim® digital database of data between 2021 and 2040 and minimum and maximum temperature and precipitation from the CMIP6 EC-Earth3-Veg global climate model of the SSP1 2.6, SSP2 4.5 and SSP3 7.0 scenarios were used. Using QGIS®, raster files with monthly sublayers were imported and using the raster calculator, maps of annual variable and seasonal averages were generated. In the statistical treatment, zonal statistics were generated using SAGA®. Using RStudio®, the Shapiro-Wilk normality, Kolmogorov-Smirnov adherence, Mann Kendall trend and Pearson correlation coefficient tests were prepared. The results demonstrated a small positive variation of 0.07°C. The maximum temperature tended to remain at 30.7°C. The future precipitation projection showed a tendency to increase by 5mm with minimal variability between the forcings. The normality tests for the precipitation variable showed the highest standard deviation in the summer and autumn seasons with an abnormal distribution. The correlation between precipitation and maximum temperature was strong in the summer season among all forcings and in the others it was weak to negligible. The forcing scenarios did not present significant results.

Keywords: Global climate models, future scenarios, climate variability, zonal statistics.

Projeção Climática dos Estados da Região Nordeste, Minas Gerais, Maranhão e Amapá Simulada até 2040 por Forçantes SSP126/245/370 do CIMP6

RESUMO

A compreensão das características atuais e futuras da temperatura e da precipitação é importante para o planejamento de medidas de prevenção e atenuação, sendo necessário aplicar análises de projeções climáticas para recolher informações para compreender o possível impacto das alterações climáticas, podendo fornecer informações úteis para um plano de adaptação e atenuação das alterações. Objetivo deste trabalho foi avaliar as mudanças de temperatura e precipitação simuladas por modelos climáticos de alta resolução do CMIP6 para 3 cenários de emissões para os Estados da região Nordeste, Minas Gerais, Maranhão e Amapá utilizando geotecnologias. Foi utilizado a base digital da WordClim® de dados entre 2021 a 2040 e temperatura mínima e máxima e precipitação do modelo climático global CMIP6 EC-Earth3-Veg dos cenários SSP1 2.6, SSP2 4.5 e SSP3 7.0. Utilizando o QGIS® foram importados os arquivos *raster* com as subcamadas mensais e utilizando a calculadora *raster* foram gerados os mapas das médias anuais das variáveis e das sazonais. No tratamento estatístico foi gerada a estatística zonal através do SAGA®. Utilizando o RStudio® foram elaborados os testes de normalidade de Shapiro-Wilk, de aderência de Kolmogorov-Smirnov, de tendência de Mann Kendall e coeficiente de correlação Pearson. Os resultados demonstraram pequena variação positiva de 0,07°C. Apresentou tendência de se manter a temperatura máxima em 30,7°C. A projeção futura da precipitação apresentou tendência de aumento de 5mm com mínima variabilidade entre as forçantes. Os testes de normalidade da variável precipitação apresentou o maior desvio padrão na sazonais verão e outono com uma distribuição anormal. A correlação entre a precipitação e a temperatura máxima apresentou forte na sazonal verão entre todas as forçantes e nas demais apresentou-se fraca a desprezível. Os cenários de forçamento não apresentaram resultados significativos.

Palavras-chave: Modelos climáticos globais, cenários futuros, variabilidade climática, estatística zonal.

1 Introdução

Na literatura, foram estudadas mudanças climáticas na América do Sul, em diferentes regiões de interesse (Rivera & Arnould, 2020; Bustos Usta et al., 2021; Ortega et al., 2021), mas nenhuma delas focou em todo o Nordeste Brasileiro, mas apenas em algumas áreas representativas (Almazroui et al., 2021; Alves et al., 2021; Gomes et al., 2022).

O Nordeste do Brasil é uma região caracterizada pela alta variabilidade espaço-temporal da precipitação (Kousky, 1979; Luiz-Silva et al., 2021) devido à atuação de diferentes sistemas atmosféricos, como a Zona de Convergência Intertropical (ZCIT) (Uvo et al., 1998; Utida et al., 2019), Distúrbios Ondulatórios de Leste (DOL) (Gomes et al., 2019), Zona de Convergência do Atlântico Sul (ZCAS) (Kodama, 1992; Zilli et al., 2019), sistemas frontais (Fedorova et al., 2016), Vórtice Ciclônico da Alta Troposfera (VCAT) (Kousky & Gan, 1981; Morais et al., 2021), brisas marítimas e terrestres, entre outros.

De acordo com Oliveira et al. (2017), o Nordeste pode ser dividido em cinco regiões de precipitação homogênea, com precipitação média anual variando de mais de 1.800mm no litoral leste e noroeste a menos de 500mm em muitos locais da porção central. No entanto, em média, a região é caracterizada pela escassez de chuvas e considerada vulnerável à insegurança alimentar, hídrica e energética devido às alterações climáticas (Marengo et al., 2020; Medeiros et al., 2022). Além disso, estudos recentes mostraram que a precipitação está diminuindo no Nordeste nas últimas décadas (Mutti et al., 2020; Medeiros et al., 2020), mas a intensidade da precipitação diária extrema está aumentando (Oliveira et al., 2017; Oliveira & Lima, 2019; Rodrigues et al., 2020), atrelado a isto, destaca-se a seca plurianual na região Nordeste entre 2011-2018 (Marengo et al., 2017; Cunha et al., 2018).

A compreensão das características atuais e futuras da temperatura, precipitação, tempestades, inundações e secas é importante para o planejamento de ações relacionadas com a sociedade, incluindo medidas de prevenção e atenuação (Dantas et al., 2022). Assim, é necessário aplicar análises de projeções climáticas a toda a área para recolher informações que ajudem a compreender o possível impacto das alterações climáticas em diferentes partes da região. Isto pode fornecer informações úteis para a elaboração de um plano de adaptação e atenuação das alterações climáticas para a região (Fan et al., 2020).

Nesta perspectiva, uma das possibilidades de abordar e compreender o comportamento dos eventos extremos de precipitação no clima futuro é utilizar as simulações e projeções climáticas dos Earth System Models (ESMs) do Coupled Model Intercomparison Project (CMIP), que são as principais fontes utilizadas nos relatórios de avaliação do Intergovernmental Panel on Climate Change (IPCC). Atualmente, estão disponíveis três gerações de modelos CMIP: CMIP3 (Meehl et al., 2007), CMIP5 (Taylor et al., 2012) e CMIP6 (Eyring et al., 2016). Estes modelos têm sido constantemente atualizados para fazer avançar sistematicamente a nossa compreensão de todo o sistema terrestre ao longo das gerações do CMIP.

Por exemplo, em comparação com o CMIP3, os ESMs do CMIP5 incluem ciclos interativos de carbono oceânico e terrestre, uma modelação mais abrangente do efeito indireto dos aerossóis e a utilização de forças vulcânicas e solares evolutivas no tempo na maioria dos modelos (Taylor et al., 2012; Knutti & Sedláček, 2013). Para o CMIP6, são esperadas melhorias principalmente nos métodos de inicialização e geração de conjuntos (Eyring et al., 2016).

Além disso, os modelos CMIP6 incluem uma maior resolução espacial, uma vasta gama de cenários, uma maior sensibilidade climática e uma complexidade física adicional (por exemplo, biogeoquímica) em relação às versões CMIP anteriores (Bock et al., 2020). Essa melhoria contínua dos ESMs é enfatizada em alguns estudos, onde demonstram que a evolução ao longo das gerações CMIP reduziu as incertezas do modelo para algumas áreas (Blázquez & Nunez, 2013; Zhu et al., 2020; Srivastava et al., 2020; Gusain et al., 2020; Ukkola et al., 2020; Luo et al., 2021).

Este conjunto de dados permite estudar processos complexos, incluindo a resposta do modelo a diferentes forçamentos, alterações da utilização dos solos, geo-engenharia, um conjunto atualizado de Shared Socioeconomic Pathways (SSP) para análise futura e opções físicas avançadas para nuvens, circulação, fenómenos regionais, oceano, terra e gelo. Os estudos revelaram que os modelos CMIP6 melhoraram as simulações CMIP5 no que respeita a extremos climáticos e respectivos padrões de tendência (Chen et al., 2020); representação da precipitação das monções (Gusain et al., 2020); precipitação média nas escalas temporais anual, de verão, outono, inverno e primavera (Zamani et al., 2020); e índices extremos de precipitação na estação das chuvas (Chen et al., 2021).

Pesquisas também mostram que subconjuntos de modelos CMIP têm melhor

desempenho do que modelos individuais (Gulizia & Camilloni, 2015; Lovino et al., 2018; Rivera & Arnould, 2020; Babausmail et al., 2021), embora Global Climate Models (GCMs) individuais tenham melhor desempenho em certos critérios de avaliação (Gulizia & Camilloni, 2015). Embora os estudos tenham se concentrado em fases passadas do CMIP para todo o continente da América do Sul ou regiões dentro dele, este trabalho expande a análise passada e usa a fase mais atual do CMIP, a fase 6. Além disso, o Nordeste do Brasil representa uma região importante a estudar para manter a segurança hídrica, alimentar e energética, uma vez que a precipitação desempenha um papel em todas estas funções.

Portanto, o objetivo deste trabalho é avaliar as mudanças de temperatura e precipitação simuladas por modelos climáticos de alta resolução do CMIP6 para 3 cenários de emissões para os Estados da região Nordeste, Minas Gerais, Maranhão e Amapá utilizando geotecnologias.

2 Material e métodos

A área de estudo compreende os Estados da região Nordeste, Minas Gerais, Maranhão e Amapá com diversidade de ambientes e clima.

Na realização deste trabalho foi utilizado a base digital da WordClim® v2.1 de dados entre 2021 a 2040 em *downscaling* classificado por *time-slices* do modelo climático global CMIP6 (Eyring et al., 2016) EC-Earth3-Veg (EC-EARTH, 2019) de resolução espacial de $0,7^\circ \times 0,7^\circ$, dos cenários SSP1 2.6, SSP2 4.5 e SSP3 7.0 (2,6; 4,5; e 8,5 W/m², respectivamente). A Representative Concentration Pathways (RCP) (Forçante Radiativa) é expressa na unidade W/m² e representa uma mudança líquida no balanço energético do sistema Terra devido alguma perturbação, sendo uma boa medida de alteração da temperatura de superfície terrestre (van Vuuren et al., 2011). As variáveis climáticas avaliadas foram temperatura mínima média mensal (°C), temperatura máxima média mensal (°C), e precipitação total mensal (mm), todas adquiridas em formato *tif* com resolução de 30s.

Utilizando o QGIS® 3.36 foram importados os arquivos *raster* que contém as subcamadas mensais (12 meses), e utilizando a calculadora *raster* foram gerados os mapas das médias anuais das variáveis. Em seguida foram gerados os mapas sazonais de verão (DJF), outono (MAM), inverno (JJA) e primavera (SON).

No tratamento estatístico foi realizada a análise descritiva dos dados utilizando o QGIS® 3.36 (Hyndman & Fan, 1996) e após foi gerada a

estatística zonal por Estado da Federação através do SAGA® 9.2.0 desenvolvido por Conrad et al. (2015). A estatística zonal de acordo com Barbosa et al. (1998), permite estabelecer relações espaciais entre regiões de mapas distintos. As operações de transformações zonais ou por região operam sobre um mapa de origem e um conjunto de regiões delimitadas por polígonos na forma matricial ou vetorial. Isto permite materializar num SIG os conceitos de unidade de paisagem (Bertrand, 1981; Tricart, 1977; Tricart & Kiewietdejonge, 1992) e área-unidade (Hartshorne, 1978).

Utilizando o RStudio® 2023 e os dados obtidos foram elaborados os testes de normalidade de Shapiro-Wilk (1965) e o teste de aderência de Kolmogorov-Smirnov (1933; 1948). O teste de aderência de Kolmogorov-Smirnov além de não depender do número de classes do agrupamento dos dados, oferece mais vantagens computacionais (Kvam & Vidakovic, 2007). Para a tendência foi realizado o teste de Man Kendall não paramétrico (Mann, 1945; Kendall, 1975). O coeficiente de correlação Pearson (1892), R, foi calculado entre os dados de precipitação e de temperatura máxima.

O desvio padrão (S) é expresso pelas Equações 1 e 2.

$$S_s = \sqrt{\frac{\sum_{i=1}^n (s_i - \bar{s})^2}{n-1}} \quad (\text{Eq.1})$$

$$S_o = \sqrt{\frac{\sum_{i=1}^n (o_i - \bar{o})^2}{n-1}} \quad (\text{Eq.2})$$

Onde: S e O são, respectivamente os dados simulados e observados no período estabelecido, a barra indica a média temporal e é o número de meses do período.

O Testes de aderência de Kolmogorov-Smirnov é usada para testar a hipótese nula $H_0: F=F_0$ versus hipótese alternativa $H_1: F \neq F_0$ (Kvam & Vidakovic, 2007). Esse teste fundamenta-se na discrepância entre as distribuições (Equação 3).

$$D_n = \sqrt{n} \sup x |Fn(x) - F_0(x)| \quad (\text{Eq.3})$$

Em que: $F_n(x)$ denota a distribuição teórica e $F_0(x)$ a distribuição ajustada.

Para a tendência foi realizado o teste de Man Kendall não paramétrico (Mann, 1945; Kendall, 1975) (Equação 4).

$$S = \sum_{i=2}^n \sum_{j=1}^{i-1} \text{sign}(x_j - x_i) \quad (\text{Eq.4})$$

Em que: S é o resultado da soma das contagens de $(x_j - x_i)$; x_j é o primeiro valor após x_i , n é o número de dados da série temporal.

Para cada par de dados são atribuídos os valores conforme a Equação 5.

$$sinal = \begin{cases} +1 & se(x_j - x_i) > 0 \\ 0 & se(x_j - x_i) = 0 \text{ (Eq.5)} \\ -1 & se(x_j - x_i) < 0 \end{cases}$$

A distribuição de probabilidade da estatística S tende à normalidade quando há grandes amostras de observações (n), com média zero e variância é dada pela Equação 6.

$$VAR(S) = \frac{1}{18} [n(n-1)(2n+5) - \sum_{p=1}^q t_p(t_p-1)(2t_p+5)] \text{ (Eq.6)}$$

Em que: t_p é o número de dados com valores iguais em certo grupo; q é o número de grupos contendo valores iguais na série de dados em um grupo p.

A estatística do teste de Mann-Kendall é baseada no valor da variável ZMK, calculado conforme a Equação 7.

$$Z_{MK} = \begin{cases} \frac{S-1}{\sqrt{Var(S)}} & se S > 0 \\ 0, & se S = 0 \text{ (Eq.7)} \\ \frac{S+1}{\sqrt{Var(S)}} & se S < 0 \end{cases}$$

O coeficiente de correlação Pearson, R, foi calculado de acordo com a Equação 8.

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \text{ (Eq.8)}$$

Onde: $x_1, x_2, \dots, x_n$ e $y_1, y_2, \dots, y_n$ são os valores medidos de ambas as variáveis (Equação 9), em que são as médias aritméticas de ambas as variáveis.

$$\hat{x} = \frac{1}{n} \cdot \sum_{i=1}^n x_i \text{ e } \hat{y} = \frac{1}{n} \cdot \sum_{i=1}^n y_i \text{ (Eq.9)}$$

3 Resultados e discussão

Pela Figura 1, pode-se observar o comportamento sazonal anual da projeção da temperatura mínima para a forçante ssp126 é de 20,67°C, para o ssp245 de 20,68°C e ssp370 de 20,74°C, demonstrando uma tendência de uma pequena variação no aquecimento de 0,07°C distribuída por toda a área de estudo, estando de acordo com a Figura 2 da distribuição sazonal da temperatura mínima. Esses resultados são consistentes com os de Dantas et al. (2022), que investigaram mudanças futuras na temperatura e precipitação no Nordeste do Brasil usando o modelo CMIP6, e observaram uma tendência de aumento de pelo menos 1°C na temperatura nos próximos anos em resposta às forças climáticas.

Observa-se que as estações sazonais da temperatura mínima (Figura 2) apresentam-se praticamente sem alteração entre as 3 forçantes estudadas, ssp126, ssp245 e ssp370.

De acordo com a Tabela 1, pode-se verificar que, a temperatura mínima sazonal apresenta menores valores em Minas Gerais em todas as estações e forçantes em estudo. Os maiores valores da estação sazonal do verão localizam-se no Estado do Rio Grande do Norte em todas as forçantes e nas demais estações estão localizados no Amapá.

Tabela 1. Média da temperatura mínima (°C) sazonal do ssp126/245/370

Estado	126V	126O	126I	126P	245V	245O	245I	245P	370V	370O	370I	370P
AL	22,26	21,74	19,43	20,71	22,31	21,78	19,46	20,69	22,37	21,87	19,54	20,69
BA	20,22	19,31	16,47	19,37	20,29	19,31	16,50	19,42	20,33	19,42	16,49	19,42
CE	22,60	22,01	20,80	21,74	22,61	21,99	20,80	21,74	22,67	22,11	20,89	21,74
PB	21,52	21,18	19,22	20,20	21,55	21,17	19,25	20,21	21,63	21,28	19,32	20,21
PE	20,75	20,15	17,77	19,37	20,81	20,16	17,81	19,36	20,84	20,26	17,86	19,36
PI	21,57	20,90	19,14	21,86	21,61	20,88	19,16	21,92	21,58	20,99	19,20	21,92
RN	23,32	22,88	21,18	22,08	23,34	22,89	21,19	22,07	23,43	22,99	21,29	22,07
SE	22,58	22,04	19,52	20,87	22,62	22,10	19,57	20,86	22,71	22,17	19,65	20,86
MA	22,09	21,77	20,51	22,62	22,08	21,75	20,44	22,62	22,08	21,86	20,57	22,62
AP	22,63	23,11	22,80	22,96	22,64	23,12	22,78	22,97	22,67	23,25	22,88	22,97
MG	18,81	16,67	13,02	17,85	18,84	16,66	12,93	17,98	18,96	16,79	13,02	17,98

V=verão; O=outono; I=inverno; P=primavera.




Figura 1. Distribuição sazonal da temperatura média mínima (°C) do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.




Figura 2. Distribuição da temperatura média mínima (°C) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

Conforme as Figuras 3 e 4, representando o comportamento sazonal da temperatura máxima para as forçantes em estudo, observa-se tendência de manter a temperatura máxima em 30,7°C em praticamente toda a área de estudo sem incrementos significativos futuros.

Observando a Figura 4, verifica-se que, as estações sazonais da temperatura máxima apresentam-se praticamente sem alteração entre as 3 forçantes estudadas.

Pela Tabela 2 verifica-se que a temperatura máxima na estação sazonal do ssp126, no verão os menores valores localizam-se em Minas Gerais e maiores no Rio Grande do Norte; no outono em Minas Gerais com os menores valores observados, e maiores valores no Piauí; no inverno ocorre os menores valores em Alagoas e maiores no Maranhão. O mesmo comportamento se estende para as demais projeções ssp245 e ssp370.





Figura 3. Distribuição sazonal da temperatura média máxima (°C) do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.






Figura 4. Distribuição da temperatura média máxima (°C) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.


Tabela 2. Média da temperatura máxima (°C) sazonal do ssp126/245/370

Estado	126V	126O	126I	126P	245V	245O	245I	245P	370V	370O	370I	370P
AL	31,67	29,60	26,29	29,67	31,71	29,62	26,29	29,68	31,66	29,62	26,28	29,68
BA	30,97	29,83	28,67	31,54	30,97	29,80	28,60	31,61	30,91	29,79	28,53	31,61
CE	32,38	30,12	31,37	33,46	32,32	30,09	31,32	33,51	32,26	30,15	31,35	33,51
PB	31,82	29,64	27,79	30,94	31,80	29,61	27,78	31,04	31,78	29,69	27,82	31,04
PE	31,41	29,16	26,77	30,49	31,42	29,17	26,81	30,55	31,36	29,19	26,76	30,55
PI	32,29	31,60	33,01	35,25	32,25	31,57	32,93	35,30	32,13	31,61	32,93	35,30
RN	33,10	31,28	30,15	32,51	33,04	31,26	30,12	32,59	33,04	31,33	30,19	32,59
SE	31,88	30,03	26,81	29,85	31,87	30,06	26,81	29,83	31,82	30,02	26,78	29,83
MA	31,16	31,26	33,36	34,41	31,08	31,22	33,19	34,37	30,99	31,28	33,27	34,37
AP	30,24	30,33	31,83	33,44	30,27	30,44	31,79	33,49	30,27	30,55	31,89	33,49
MG	29,50	28,46	27,19	30,02	29,43	28,37	27,03	30,39	29,53	28,40	27,07	30,39

V=verão; O=outono; I=inverno; P=primavera.

Pelas Figuras 5 e 6, da precipitação média pode-se verificar o comportamento da distribuição sazonal da projeção para o ssp126/245/370 os valores de 91,66; 92,34; e 93,56mm, respectivamente, onde demonstra uma tendência de aumento de somente 5mm na precipitação futura distribuída em toda a região de estudo.

Pela Figura 6 pode-se verificar o comportamento sazonal das estações, em que as forçantes ssp245 e ssp370 da estação do outono se diferencia da ssp126, com pequena variação negativa no Estado do Piauí.






Figura 5. Distribuição sazonal da precipitação média (mm) do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.




Figura 6. Distribuição da precipitação média (mm) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

Na Tabela 3 verifica-se que, a precipitação sazonal no verão, os menores valores se apresentam no Estado de Sergipe e maiores valores no Amapá na projeção ssp126, diferenciando nas demais projeções com os menores valores em Sergipe e maiores em Minas Gerais.

Para a estação sazonal do outono nas forçantes ssp126/245/370 o Estado do Amapá apresenta os maiores valores, e os menores valores no ssp126 apresentam-se em Sergipe alterando para o Estado da Bahia nas demais forçantes. Para

a estação sazonal do inverno se mantem idênticas em todas as forçantes com os menores valores no Piauí e maiores no Amapá. Na estação da primavera em todas as forçantes também se mantem com valores mínimos no Ceará e maiores em Minas Gerais.

Na distribuição anual da temperatura máxima e mínima e da precipitação da área de estudo (Figura 7) pode-se verificar que ocorre mínima variabilidade entre o ssp126/245/370.

Tabela 3. Média da precipitação (mm) sazonal do ssp126/245/370

Estado	126V	126O	126I	126P	245V	245O	245I	245P	370V	370O	370I	370P
AL	43,26	101,67	13,73	38,93	43,88	136,00	137,47	39,44	44,98	143,11	137,22	39,19
BA	118,16	101,70	27,63	58,22	118,81	76,62	27,66	54,17	120,61	79,75	27,56	57,75
CE	89,63	193,62	22,33	6,68	90,96	177,19	22,64	6,68	90,93	180,55	22,49	6,86
PB	64,61	147,28	47,31	12,72	65,41	135,96	47,82	12,77	65,88	139,24	46,86	12,89
PE	65,70	114,65	49,96	19,47	66,44	106,51	50,20	19,59	68,27	110,72	49,90	19,73
PI	152,17	180,72	6,62	42,75	153,42	135,27	6,63	41,31	156,53	138,24	6,60	44,72
RN	56,24	150,52	41,12	6,90	57,01	145,58	41,80	6,88	57,22	147,91	41,37	6,97
SE	42,25	95,92	122,60	41,88	42,90	132,46	122,38	42,03	43,71	139,64	121,66	41,69
MA	204,13	262,63	32,85	48,28	206,92	220,85	32,91	48,00	207,13	222,92	33,03	51,71
AP	228,15	288,07	165,73	59,09	222,20	326,85	167,12	57,52	222,40	322,78	168,00	60,53
MG	121,32	127,92	13,02	104,97	123,41	80,47	13,24	100,04	123,15	81,74	13,03	99,62

V=verão; O=outono; I=inverno; P=primavera.




Figura 7. Distribuição anual média (a, b, c) da temperatura máxima (°C), (d, e, f) temperatura mínima (°C), (g, h, i) precipitação (mm) do ssp126/ssp245/ssp370.

De acordo com Dantas et al. (2022), um dos modelos que apresentaram melhor capacidade de replicar o comportamento espacial das chuvas sobre o NEB foi o EC-Earth3-Veg, o mesmo utilizado neste trabalho. Conforme Firpo et al. (2022), é importante demonstrar que, as simulações de precipitação pelos modelos climáticos são um desafio, devido às incertezas associadas à alta variabilidade espacial e dificuldade de simulação com sistemas como ZCIT e ZCAS.

Pela Tabela 4, dos valores descritivos dos dados sazonais, na curtose verifica-se comportamento regular entre todas as variáveis com valores negativos da temperatura máxima nas forçantes de verão e outono, e na temperatura mínima nas forçantes ssp126/245/370. Os maiores desvio padrão ocorrem nas sazonais de verão e outono em todas as variáveis. Quanto a amplitude e assimetria, estas apresentam maiores valores na precipitação de verão e outono, e o inverso nas variáveis temperatura mínima e máxima.

Pela Tabela 5, dos testes de normalidade, tendência e aderência, verifica-se que o teste de Shapiro-Wilk demonstra que os dados de precipitação não são normalmente distribuídos, ou seja, é uma distribuição diferente da normal, isto devido a área de estudo apresentar diversidade na distribuição da precipitação. Para as temperaturas

máxima e mínima o teste apresenta normalmente distribuído.

No teste de Kolmogorov-Smirnov com *p-valor* em sua maioria $<2,2e^{-16}$ indica uma probabilidade extremamente pequena de se observar os dados, portanto, rejeita-se a hipótese nula.

Tabela 4. Valores descritivos dos dados sazonais da projeção

Variável	Desvio Padrão	Mediana	Mínimo	Máximo	Amplitude Total	Assimetria	Curtose
P126V	116,87	72,74	68,75	42,25	228,15	185,90	0,45
P126O	160,43	65,37	67,58	95,92	288,07	192,15	0,78
P126I	49,35	49,87	25,37	6,62	165,73	159,11	1,29
P126P	39,99	28,93	25,52	6,68	104,97	98,29	0,70
P245V	117,40	72,21	69,80	42,90	223,41	180,51	0,43
P245O	152,16	70,73	43,66	76,62	326,85	250,23	1,22
P245I	60,90	54,90	28,41	6,63	167,12	160,49	0,82
P245P	38,95	27,45	24,03	6,68	100,04	93,36	0,65
P370V	118,26	72,01	68,13	43,71	223,15	179,44	0,42
P370O	155,15	68,82	42,88	79,75	322,78	243,03	1,15
P370I	60,70	55,04	27,99	6,60	168,00	161,40	0,83
P370P	40,15	27,91	27,93	6,86	99,62	92,76	0,52
TM126V	31,49	1,01	0,92	29,50	33,10	3,60	-0,40
TM126O	30,12	0,96	0,64	28,46	31,60	3,14	0,06
TM126I	29,39	2,65	2,82	26,29	33,36	7,07	0,26
TM126P	31,96	1,96	2,51	29,67	35,25	5,58	0,29
TM245V	31,47	1,01	0,90	29,43	33,04	3,61	-0,47
TM245O	30,11	0,96	0,67	28,37	31,57	3,20	-0,03
TM245I	29,33	2,62	2,65	26,29	33,19	6,90	0,25
TM245P	32,03	1,93	2,64	29,68	35,30	5,62	0,27
TM370V	31,43	0,98	0,89	29,53	33,04	3,51	-0,34
TM370O	30,15	0,98	0,79	28,40	31,61	3,21	-0,02
TM370I	29,35	2,65	2,62	26,28	33,27	6,99	0,25
TM370P	32,03	1,93	2,64	29,68	35,30	5,62	0,27
TN126V	21,67	1,30	0,80	18,81	23,32	4,51	-0,82
TN126O	21,07	1,83	1,25	16,67	23,11	6,44	-1,10
TN126I	19,08	2,62	2,03	13,02	22,80	9,78	-0,87
TN126P	20,88	1,57	1,79	17,85	22,96	5,11	-0,40
TN245V	21,70	1,29	0,80	18,84	23,34	4,50	-0,83
TN245O	21,07	1,84	1,29	16,66	23,12	6,46	-1,10
TN245I	19,08	2,64	1,99	12,93	22,78	9,85	-0,91
TN245P	20,89	1,55	1,79	17,98	22,97	4,99	-0,36
TN370V	21,75	1,29	0,87	18,96	23,43	4,47	-0,76
TN370O	21,18	1,83	1,29	16,79	23,25	6,46	-1,09
TN370I	19,16	2,65	2,00	13,02	22,88	9,86	-0,89
TN370P	20,89	1,55	1,79	17,98	22,97	4,99	-0,36

P=precipitação; TM=temperatura máxima; TN=temperatura mínima; V=verão; O=outono; I=inverno; P=primavera.

Quanto ao teste Pearson os resultados demonstram uma correlação de moderada a fraca na temperatura mínima e máxima, seguida de correlação desprezível quanto a precipitação.

Quanto ao teste Mann-Kendall, verifica-se que o *p-valor* nas estações sazonais do inverno e primavera da precipitação ssp245 e ssp370 apresentam tendência significativa na série da projeção. Quanto a temperatura máxima apresenta tendência nas estações do outono e primavera nas 3 forçantes em estudo. Já na temperatura mínima, somente apresenta tendência na sazonal verão na ssp126 e ssp370.

Através das Figuras 8, 9 e 10 dos boxplots, pode-se observar o comportamento das variáveis

em que apresentam mínima variabilidade entre as forçantes ssp126, ssp245 e a ssp370.

No teste de normalidade da temperatura mínima sazonal (Figura 11), observa-se que a distribuição apresenta maior regularidade na variável ssp370, nas demais segue a regularidade. Pela Figura 12, da temperatura máxima verifica-se distribuição com regularidade nas projeções. Na Figura 13, pode-se verificar a irregularidade na estação do outono e inverno das forçantes ssp245 e ssp370, da precipitação sazonal

Tabela 5. Testes de normalidade, tendência e aderência

Variável/Teste	Shapiro-Wilk		Kolmogorov-Smirnov		Pearson		Mann-Kendall	
	W	p-valor	D	p-valor	P	p-valor	tau	p-valor
P126V	0,856	0,051	1	$< 2,2e^{-16}$	2,636	0,451	0,345	0,161
P126O	0,870	0,077	1	$< 2,2e^{-16}$	3,727	0,293	0,309	0,213
P126I	0,767	0,003	1	$< 2,2e^{-16}$	10,273	0,016	0,236	0,350
P126P	0,905	0,212	1	$< 2,2e^{-16}$	1,546	0,672	0,455	0,062
P245V	0,849	0,041	1	$< 2,2e^{-16}$	2,636	0,451	0,382	0,119
P245O	0,837	0,028	1	$< 2,2e^{-16}$	8,091	0,044	0,127	0,640
P245I	0,827	0,021	1	$< 2,2e^{-16}$	8,091	0,044	-0,018	1,000
P245P	0,907	0,226	1	$< 2,2e^{-16}$	4,818	0,186	0,491	0,043
P370V	0,849	0,041	1	$< 2,2e^{-16}$	2,636	0,451	0,382	0,119
P370O	0,847	0,040	1	$< 2,2e^{-16}$	8,091	0,044	0,200	0,436
P370I	0,826	0,020	1	$< 2,2e^{-16}$	8,091	0,044	-0,018	1,000
P370P	0,923	0,349	1	$< 2,2e^{-16}$	2,636	0,451	0,455	0,062
TM126V	0,974	0,922	1	$< 2,2e^{-16}$	1,546	0,672	-0,273	0,276
TM126O	0,955	0,704	1	$< 2,2e^{-16}$	2,636	0,451	0,091	0,756
TM126I	0,893	0,151	1	$< 2,2e^{-16}$	1,546	0,672	0,236	0,350
TM126P	0,921	0,324	1	$< 2,2e^{-16}$	1,546	0,672	0,091	0,756
TM245V	0,967	0,859	1	$< 2,2e^{-16}$	1,546	0,672	-0,273	0,276
TM245O	0,960	0,766	1	$< 2,2e^{-16}$	3,727	0,293	0,055	0,876
TM245I	0,885	0,121	1	$5,58e^{-10}$	3,727	0,293	0,220	0,390
TM245P	0,932	0,427	1	$< 2,2e^{-16}$	1,546	0,672	0,091	0,756
TM370V	0,976	0,943	1	$< 2,2e^{-16}$	1,546	0,672	-0,273	0,276
TM370O	0,958	0,751	1	$< 2,2e^{-16}$	2,636	0,451	0,091	0,756
TM370I	0,886	0,126	1	$< 2,2e^{-16}$	1,546	0,672	0,236	0,350
TM370P	0,932	0,427	1	$< 2,2e^{-16}$	1,546	0,672	0,091	0,756
TN126V	0,913	0,266	1	$< 2,2e^{-16}$	3,727	0,293	0,091	0,756
TN126O	0,875	0,089	1	$< 2,2e^{-16}$	1,546	0,672	0,164	0,533
TN126I	0,916	0,286	1	$< 2,2e^{-16}$	5,909	0,116	0,164	0,533
TN126P	0,956	0,718	1	$5,58e^{-10}$	3,727	0,293	0,294	0,241
TN245V	0,912	0,257	1	$< 2,2e^{-16}$	3,727	0,293	0,127	0,640
TN245O	0,877	0,095	1	$< 2,2e^{-16}$	1,546	0,672	0,127	0,640
TN245I	0,910	0,247	1	$< 2,2e^{-16}$	5,909	0,116	0,164	0,533
TN245P	0,958	0,750	1	$< 2,2e^{-16}$	2,636	0,451	0,273	0,276
TN370V	0,923	0,341	1	$5,58e^{-10}$	3,727	0,293	0,037	0,938
TN370O	0,879	0,101	1	$< 2,2e^{-16}$	1,546	0,672	0,127	0,640
TN370I	0,914	0,275	1	$< 2,2e^{-16}$	5,909	0,116	0,164	0,533
TN370P	0,958	0,750	1	$< 2,2e^{-16}$	2,636	0,451	0,273	0,276w

P=precipitação; TM=temperatura máxima; TN=temperatura mínima; V=verão; O=outono; I=inverno; P=primavera.




Figura 8. Boxplot da temperatura mínima (°C) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.




Figura 9. Boxplot da temperatura máxima (°C) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.




Figura 10. Boxplot da precipitação (mm) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.




Figura 11. Quantis da temperatura mínima média sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.




Figura 12. Quantis da temperatura máxima média sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.




Figura 13. Quantis da precipitação média sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

De acordo com a Tabela 6 e a Figura 14, verifica-se a correlação entre a precipitação e a temperatura máxima, em que se apresenta forte na sazonal verão entre todas as forçantes.

No sazonal outono, a correlação apresenta-se fraca, e as estações inverno e primavera apresenta-se desprezível.




Figura 14. Correlação de Pearson entre a precipitação e temperatura máxima sazonal do ssp126 (a, b, c, d), ssp245 (e, f, g, h), ssp370 (i, j, k, l).

Tabela 6. Correlação entre precipitação e temperatura máxima

Parâmetro 1	Parâmetro 2	<i>rho</i>	95% CI	S	<i>p</i>
P126V	TM126V	-0,63	[-0,90, -0,02]	358	>0,999
P126O	TM126O	0,61	[-0,01, 0,89]	86	>0,999
P126I	TM126I	-0,10	[-0,67, 0,55]	242	>0,999
P126P	TM126P	-0,009	[-0,56, 0,19]	222	>0,999
P245V	TM245V	-0,64	[-0,90, -0,04]	360	>0,999
P245O	TM245O	0,57	[-0,06, 0,88]	94	>0,999
P245I	TM245I	-0,42	[-0,82, 0,26]	313	>0,999
P245P	TM245P	-0,09	[-0,67, 0,55]	240	>0,999
P370V	TM370V	-0,34	[-0,79, 0,35]	294	>0,999
P370O	TM370O	0,54	[-0,11, 0,86]	102	>0,999
P370I	TM370I	-0,42	[-0,82, 0,26]	312	>0,999
P370P	TM370P	-0,009	[-0,62, 0,61]	222	>0,999

P=precipitação; TM=temperatura máxima; TN=temperatura mínima; V=verão; O=outono; I=inverno; P=primavera. Obs: *p*-value ajustada pelo método Holm (1979).

Knutti e Sedláček (2013) afirmam que, as estimativas dos impactos das alterações climáticas antropogênicas baseiam-se em projeções de modelos climáticos. As incertezas nesses domínios têm sido frequentemente um fator limitante, em particular à escala local. Os autores argumentam que, definir o progresso na modelagem climática em termos de redução das incertezas é demasiado limitado. Os modelos melhoram, representando mais processos com mais detalhes. Isto implica uma maior confiança nas suas projeções, mas a convergência poderá permanecer lenta e as incertezas não devem impedir a tomada de decisões.

Knutti et al. (2008) concluíram que, apesar das melhorias substanciais nos modelos climáticos, as projeções para determinados cenários, em média, não mudaram muito nos últimos anos. Os progressos recentes aumentaram, no entanto, a confiança nas estimativas de incerteza permitem agora uma melhor separação das incertezas introduzidas pelos cenários, feedbacks físicos, ciclo do carbono e incerteza estrutural. As incertezas das projeções são agora limitadas pelas observações e, portanto, consistentes com tendências e padrões observados no passado.

As incertezas na resposta do sistema climático a um determinado cenário de emissões, dominadas por incertezas na sensibilidade climática e na taxa de absorção de calor dos oceanos, são determinadas pela nossa compreensão incompleta dos processos físicos e pelas limitações dos modelos climáticos. A força dos feedbacks climáticos relevantes não pode ser significativamente influenciada pelas atividades humanas. As incertezas nas emissões, por outro lado, são uma incerteza relacionada com as ações e decisões humanas e, nesse sentido, são uma escolha e não uma incerteza intrínseca. É, portanto, importante considerar a incerteza na resposta climática

separadamente para cada cenário de emissões (Knutti et al., 2002; Wigley, 2004).

Para projeções de longo prazo, onde a sensibilidade climática se torna cada vez mais importante, o estudo de Stott et al. (2006) tende a atribuir menor probabilidade a um aquecimento muito elevado. Estando de acordo com este trabalho.

A semelhança das projeções de curto prazo não deve ser mal interpretada como um argumento de que a escolha do cenário não é importante para as alterações climáticas. Pelo contrário, destaca as longas escalas de tempo do sistema climático, implicando que as escolhas de cenários atuais terão um efeito num futuro distante (Hansen et al., 1988; Wigley et al., 1996; Knutti et al., 2002; Stott & Kettleborough, 2002).

As incertezas tendem a ser ligeiramente assimétricas em muitos estudos, sendo o limite inferior do aumento de temperatura esperado comparativamente bem restringido e o limite superior mais incerto. A maior incerteza no limite superior é causada por incertezas nos feedbacks ciclo do carbono-clima (Plattner et al., 2008).

Conclusão

Pelos resultados obtidos neste trabalho observou-se pequena variação positiva de 0,07°C.

Apresentou tendência de se manter a temperatura máxima em 30,7°C.

A projeção futura da precipitação apresentou tendência de aumento de 5mm com mínima variabilidade entre as forçantes.

Os testes de normalidade da variável precipitação apresentou o maior desvio padrão na sazonais verão e outono com uma distribuição anormal.

A correlação entre a precipitação e a temperatura máxima apresentou forte na sazonal verão entre todas as forçantes e nas demais apresentou-se fraca a desprezível.

Os cenários de forçamento não apresentaram resultados significativos.

Referências

- Almazroui, M.; Ashfaq, M.; Islam, M.N. 2021. Assessment of CMIP6 performance and projected temperature and precipitation changes over South America. *Earth Syst Environ* 5 155–183.
- Almazroui, M.; Ashfaq, M.; Islam, M.N.; Rashid, I.U.; Kamil, S.; Abid, M.A.; O'brien, E.; Ismail, M.; Reboita, M.S.; Sorensson, A.A.; Arias, P.A.; Alves, L.M.; Tippet, M.K.; Saeed, S.; Haarsma, R.; Doblas-Reys, F.J.; Saeed, F.; Kucharski, F.;

- Nadeem, I.; Silva-Vidal, Y.; Rivera, J.A.; Ehsan, M.A.; Martínez-Castro, D.; Muñoz, A. G.; Ali, M. A.; Coppola, E.; Sylla, M.B. 2021. Assessment of CMIP6 performance and projected temperature and precipitation changes over South America. *Earth Systems and Environment* 5(2) 155-183.
- Alves, L.M.; Chadwick, R.; Moise, A.; Brown, J.; Marengo, J.A. 2021. Assessment of rainfall variability and future change in Brazil across multiple timescales. *International Journal of Climatology* 41 e1875-1888.
- Babaousmail, H.; Hou, R.; Ayugi, B.; Ojara, M.; Ngoma, H.; Karim, R.; Rajasekar, A.; Ongoma, V. 2021. Evaluation of the performance of CMIP6 models in reproducing rainfall patterns over North Africa. *Atmosphere* 12(4) 475.
- Barbosa, C.C.; Câmara, G.; Medeiros, J.S. de; Crepani, E.; Novo, E.; Cordeiro, J.P.C. 1998. Operadores zonais em álgebra de mapas e sua aplicação no Zoneamento Ecológico Econômico. In: Simpósio Brasileiro de Sensoriamento Remoto, 9, 1998, Santos. Anais...Santos.
- Bertrand, G. 1981. Paisagem e Geografia Física Global: Esboço Metodológico. Caderno de Ciências da Terra, 13. Inst. de Geografia-USP. São Paulo.
- Blázquez, J.; Nunez, M.N. 2013. Analysis of uncertainties in future climate projections for South America: comparison of WCRP-CMIP3 and WCRP-CMIP5 models. *Climate Dynamics* 41(3) 1039-1056.
- Bock, L.; Lauer, A.; Schlund, M.; Barreiro, M.; Bellouin, N.; Jones, C.; Meehl, G.A.; Predoi, V.; Roberts, M.J.; Eyring, V. 2020. Quantifying progress across different CMIP phases with the ESMValTool. *Journal of Geophysical Research: Atmospheres* 125(21) e2019JD032321.
- Bustos Usta, D.F.; Teymour, M.; Chatterjee, U. 2021. Projections of temperature changes over South America during the twenty-first century using CMIP6 models. *GeoJournal* 87 1-25.
- Chen, C.A.; Hsu, H.H.; Liang, H.C. 2021. Evaluation and comparison of CMIP6 and CMIP5 model performance in simulating the seasonal extreme precipitation in the Western North Pacific and East Asia. *Weather and Climate Extremes* 31 e100303.
- Chen, H.; Sun, J.; Lin, W.; Xu, H. 2020. Comparison of CMIP6 and CMIP5 models in simulating climate extremes. *Science Bulletin* 65(17) 1415-1418.
- Conrad, O.; Bechtel, B.; Bock, M.; Dietrich, H.; Fischer, E.; Gerlitz, L.; Wehberg, J.; Wichmann, V.; Böhner, J. 2015. System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. *Geosci. Model Dev.* 8 1991-2007.
- Cunha, A.P.M.A.; Tomasella, J.; Ribeiro Neto, G.G.; Brown, M.; Garcia, S.R.; Brito, S.B.; Carvalho, M.A. 2018. Changes in the spatial-temporal patterns of droughts in the Brazilian Northeast. *Atmospheric Science Letters* 19(10) 1-8.
- Dantas, L.G.; Santos, C.A.; Santos, C.A.; Martins, E.S.; Alves, L.M. 2022. Future changes in temperature and precipitation over northeastern Brazil by CMIP6 model. *Water* 14(24) e4118.
- EC-EARTH CONSORTIUM. 2019. ECEarth-Consortium EC-Earth3-Veg model output prepared for CMIP6 ScenarioMIP. Earth System Grid Federation.
- Eyring, V.; Bony, S.; Meehl, G.A.; Senior, C.A.; Stevens, B.; Stouffer, R.J.; Taylor, K.E. 2016. Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geoscientific Model Development* 9(5) 1937-1958.
- Fan, X.; Duan, Q.; Shen, C.; Wu, Y.; Xing, C. 2020. Global surface air temperatures in CMIP6: Historical performance and future changes. *Environmental Research Letters* 15(10) e104056.
- Fan, X.; Miao, C.; Duan, Q.; Shen, C.; Wu, Y. 2020. The Performance of CMIP6 versus CMIP5 in simulating temperature extremes over the global land surface. *Journal of Geophysical Research: Atmospheres* 125(18) 1-16.
- Fedorova, N.; Levit, V.; Cruz, C.D. 2016. On frontal zone analysis in the tropical region of the Northeast Brazil. *Pure and Applied Geophysics* 173 1403-1421.
- Firpo, M.A.F.; Guimarães, B.S.; Dantas, L.G.; Silva, M.G.B.; Alves, L.M.; Chadwick, R.; Llopart, M.P.; Oliveira, G.S. 2022. Avaliação do desempenho dos modelos CMIP6 na simulação do clima atual no Brasil. *Frente. Clim.* 4 e948499.
- Gomes, H.B.; Ambrizzi, T.; Silva, B.F.P.; Hodges, K.; Dias, P.L.S.; Herdies, D.L.; Silva, M.C.L.; Gomes, H.B. 2019. Climatology of easterly wave disturbances over the tropical South Atlantic. *Climate Dynamics* 53 1393-1411.
- Gomes, H.B.; Silva, M.C.L.; Barbosa, H.D.M. J.; Ambrizzi, T.; Baltaci, H.; Gomes, H.B.; Silva, F.D.S.; Costa, R.L.; Figueroa, S.N.; Herdies, D.L.; Pauliquevis Júnior, T.M. 2022. WRF Sensitivity for Seasonal Climate Simulations of Precipitation Fields on the CORDEX South America Domain. *Atmosphere* 13(1) e107.
- Gulizia, C.; Camilloni, I. 2015. Comparative analysis of the ability of a set of CMIP3 and

- CMIP5 global climate models to represent precipitation in South America. *International Journal of Climatology* 35(4) 583-595.
- Gusain, A.; Ghosh, S.; Karmakar, S. 2020. Added value of CMIP6 over CMIP5 models in simulating Indian summer monsoon rainfall. *Atmospheric Research* 232 e104680.
- Hansen, J.; Fung, I.; Lacis, A.; Rind, D.; Lebedeff, S.; Ruedy, R.; Russell, G.; Stone, P. 1988. Global climate changes as forecast by Goddard Institute for Space Studies 3-dimensional model. *Journal Geophys. Res.* 93 9341-9364.
- Hartshorne, R. 1978. *Propósitos e Natureza da Geografia*. São Paulo. HUCITEC/EDUSP.
- Hyndman, R.J.; Fan, Y. 1996. Sample Quantiles in Statistical Packages. *The American Statistician* 50(4) 361-365.
- Kendall, M.A.; Stuart, A. 1967. *The advanced theory of statistics*. 2.a ed. Londres: Charles Griffin.
- Knutti, R.; Allen, M.R.; Friedlingstein, P.; Gregory, J.M.; Hegerl, G.C.; Meehl, G.A.; Meinshausen, M.; Murphy, J.M.; Plattner, G.-K.; Raper, S.C.B.; Stocker, T.F.; Stott, P. A.; Teng, H.; Wigley, T.M.L. 2008. A Review of Uncertainties in Global Temperature Projections over the Twenty-First Century. *Journal of Climate* 21(11) 2651–2663.
- Knutti, R.; Sedláček, J. 2013. Robustness and uncertainties in the new CMIP5 climate model projections. *Nature Climate Change* 3 369–373.
- Knutti, R.; Stocker, T.F.; Joos, F.; Plattner, G.K. 2002. Constraints on radiative forcing and future climate change from observations and climate model ensembles. *Nature* 416 719-723.
- Kodama, Y. 1992. Large-scale common features of subtropical precipitation zones (the Baiu frontal zone, the SPCZ, and the SACZ) Part I: Characteristics of subtropical frontal zones. *Journal of the Meteorological Society of Japan*. Ser. II 70(4) 813-836.
- Kolmogorov, A. 1933. Sulla determinazione empirica di una legge di distribuzione. *Giornale dell'Istituto Italiano Degli Attuari* 4 83-91.
- Kousky, V.E. 1979. Frontal influences on northeast Brazil. *Monthly Weather Review* 107(9) 1140-1153.
- Kousky, V.E.; Gan, A.M. 1981. Upper tropospheric cyclonic vortices in the tropical South Atlantic. *Tellus* 33(6) 538-551.
- Kvam, P.H.; Vidakovic, B. 2007. *Nonparametric statistics with applications to science and engineering*. New York: Wiley.
- Lilliefors, H.W. 1967. On the Kolmogorov-Smirnov test for normality with mean and variance unknown. *Journal of the American Statistical Association* 62(318) 399-402.
- Lovino, M.A.; Müller, O.V.; Berbery, E.H.; Müller, G.V. 2018. Evaluation of CMIP5 retrospective simulations of temperature and precipitation in northeastern Argentina. *International Journal of Climatology* 38 1158-1175.
- Luiz-Silva, W.; Oscar-Júnior, A.C.; Cavalcanti, I.F.A.; Treistman, F. 2021. An overview of precipitation climatology in Brazil: space-time variability of frequency and intensity associated with atmospheric systems. *Hydrological Sciences Journal* 66(2) 289-308.
- Luo, N.; Guo, Y.; Chou, J.; Gao, Z. 2022. Added value of CMIP6 models over CMIP5 models in simulating the climatological precipitation extremes in China. *International Journal of Climatology* 42(2) 1148-1164.
- Mann, H.B. 1945. Non-parametric tests against trend. *Econometrica* 13(3) 245-259.
- Marengo, J.A.; Cunha, A.P.; Nobre, C.A.; Ribeiro Neto, G.G.; Magalhaes, A.R.; Torres, R.R.; Sampaio, G.; Alexandre, F.; Alves, L.M.; Cuartas, L.A.; Deusdará, K.R.L.; Alvalá, R.C.S. 2020. Assessing drought in the drylands of northeast Brazil under regional warming exceeding 4 C. *Natural Hazards* 103 2589-2611.
- Marengo, J.A.; Torres, R.R.; Alves, L.M. 2017. Drought in northeast Brazil-past, present, and future. *Theoretical and Applied Climatology* 129(3-4) 1189-1200.
- Medeiros, F.J.; Gomes, R.D.S.; Coutinho, M.D.L.; Lima, K.C. 2022. Meteorological droughts and water resources: Historical and future perspectives for Rio Grande do Norte state, Northeast Brazil. *International Journal of Climatology* 42(13) 6976-6995.
- Medeiros, F.J.; Oliveira, C.P.; Torres, R.R. 2020. Climatic aspects and vertical structure circulation associated with the severe drought in Northeast Brazil (2012–2016). *Climate Dynamics* 55 2327-2341.
- Meehl, G.A.; Covey, C.; Delworth, T.; Latif, M.; Mcavane, B.; Mitchell, J.F.; Stouffer, R.J.; Taylor, K.E. 2007. The WCRP CMIP3 multimodel dataset: A new era in climate change research. *Bulletin of the American Meteorological Society* 88(9) 1383-1394.
- Morais, M.D.C.; Gan, M A.; Yoshida, M.C. 2021. Features of the upper tropospheric cyclonic vortices of Northeast Brazil in life cycle stages. *International Journal of Climatology* 41 e39-58.
- Mutti, P.R.; Dubreuil, V.; Bezerra, B.G.; Arvor, D.; Oliveira, C.P.; Santos e Silva, C.M. 2020. Assessment of gridded CRU TS data for long-term climatic water balance monitoring over the São Francisco Watershed, Brazil. *Atmosphere* 11(11) e1207.

- Oliveira, D.H.M.C.; Lima, K.C. 2019. What is the return period of intense rainfall events in the capital cities of the northeast region of Brazil? *Atmospheric Science Letters* 20(10) e934.
- Oliveira, P.D.; Santos e Silva, C.M.; Lima, K.C. 2017. Climatology and trend analysis of extreme precipitation in subregions of Northeast Brazil. *Theoretical and Applied Climatology* 130 77-90.
- Ortega, G.; Arias, P.A.; Villegas, J.C.; Marquet, P.A.; Nobre, P. 2021. Present-day and future climate over central and South America according to CMIP5/CMIP6 models. *International Journal of Climatology* 41(15) 6713-6735.
- Pearson, K. 1892. *The grammar of science*. London, J. M. Dent and Company.
- Plattner, G.K.; Knutti, R.; Joos, F.; Stocker, T. F.; Von Bloh, W.; Brovkin, V.; Cameron, D.; Driesschaert, E.; Dutkiewicz, S.; Eby, M.; Edwards, N.R.; Fichet, T.; Hargreaves, J.C.; Jones, C.D.; Loutre, M.F.; Matthews, H.D.; Mouchet, A.; Müller, S.A.; Nawrath, S.; Price, A.; Sokolov, A.; Strassmann, K.M.; Weave, A.J. 2008. Long-Term Climate Commitments Projected with Climate–Carbon Cycle Models. *Journal of Climate* 21(12) 2721-2751.
- QGIS. Development Team. 2022. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Disponível em: <http://qgis.osgeo.org>.
- Rivera, J.A.; Arnould, G. 2020. Evaluation of the ability of CMIP6 models to simulate precipitation over Southwestern South America: Climatic features and long-term trends (1901–2014). *Atmospheric Research* 241 e104953.
- Rodrigues, D.T.; Gonçalves, W.A.; Spyrides, M.H.; Santos e Silva, C.M.; Souza, D.O. 2020. Spatial distribution of the level of return of extreme precipitation events in Northeast Brazil. *International Journal of Climatology* 40(12) 5098-5113.
- RStudio. Posit Software. Disponível em: <https://posit.co/download/rstudio-desktop/>.
- Cunha, A.P.M.A.; Tomasella, J.; Ribeiro-NETO, G.G.; Brown, M.; Garcia, S.R.; Brito, S.B.; Carvalho, M. A. 2018. Changes in the spatial–temporal patterns of droughts in the Brazilian Northeast. *Atmospheric Science Letters* 19(10) 1-8.
- Santos, A.L.S.; Silva, H.S.D.; Silva, J.R.S.; Stosic, T. 2019. Propriedades multifractais da temperatura do ar diária no Nordeste do Brasil. *Revista Brasileira de Meteorologia* 34 23-31.
- Shapiro, A.S.S.; Wilk, M.B. 1965. An analysis of variance test for normality (complete samples). *Biometrika* 52(3/4) 591–611.
- Smirnov, N. 1948. Table for Estimating the Goodness of Fit of Empirical Distributions. *The Annals of Mathematical Statistics* 19(2) 279–281.
- Srivastava, A.; Grotjahn, R.; Ullrich, P.A. 2020. Evaluation of historical CMIP6 model simulations of extreme precipitation over contiguous US regions. *Weather and Climate Extremes* 29 e100268.
- Stott, P.A.; Kettleborough, J.A. 2002. Origins and estimates of uncertainty in predictions of twenty-first century temperature rise. *Nature* 416 723-726.
- Stott, P.A.; Mitchell, J.F.B.; Allen, M.R.; Delworth, T.L.; Gregory, J.M.; Meehl, G.A.; Santer, B.D. 2006. Observational constraints on past attributable warming and predictions of future global warming. *Journal Climate* 19 3055-3069.
- Taylor, K.E.; Stouffer, R.J.; Meehl, G.A. 2012. An overview of CMIP5 and the experiment design. *Bulletin of the American meteorological Society* 93(4) 485-498.
- Tricart, J. 1977. *Ecodinâmica*. Rio de Janeiro. IBGE-SUPREN.
- Tricart, J.; Kiewietdejonge, C. 1992. *Ecogeography and Rural Management: A Contribution to the International Geosphere-Biosphere Programme*. Essex. Longman Scientific & Technical.
- Ukkola, A.M.; Kauwe, M.G.; Roderick, M.L.; Abramowitz, G.; Pitman, A.J. 2020. Robust future changes in meteorological drought in CMIP6 projections despite uncertainty in precipitation. *Geophysical Research Letters* 47(11) e2020GL087820.
- Utida, G.; Cruz, F.W.; Etourneau, J.; Bouloubassi, I.; Schefuß, E.; Vuille, M.; Novello, V.F.; Prado, L. F.; Sifeddine, A.; Klein, V.; Zular, A.; Viana, J.C.C.; Turcq, B. 2019. Tropical South Atlantic influence on Northeastern Brazil precipitation and ITCZ displacement during the past 2300 years. *Scientific Reports* 9(1) e1698.
- Uvo, C.B.; Repelli, C.A.; Zebiak, S.E.; Kushnir, Y. 1998. The relationships between tropical Pacific and Atlantic SST and northeast Brazil monthly precipitation. *Journal of Climate* 11(4) 551-562.
- Van Vuuren, D.P.; Edmonds, J.; Kainuma, M.; Riahi, K.; Thomson, A. 2011. The representative concentration pathways: an overview. *Climatic Change* 5 109.
- Wigley, T.M.L. 2004. Modeling climate change under no-policy and policy emissions pathways. *The Benefits of Climate Change Policies: Analytical and Framework Issues*. Morlot, J.C.; Agrawala, S. (Ed.). OECD Publications, p.221–248.
- Wigley, T.M.L.; Richels, R.; Edmonds, J.A. 1996. *Economic and environmental choices in the*

- stabilization of atmospheric CO₂ concentrations. *Nature* 379 240-243.
- Zamani, Y.; Monfared, S.A.H.; Moghaddam, M.A.; Hamidianpour, M. 2020. A comparison of CMIP6 and CMIP5 projections for precipitation to observational data: the case of Northeastern Iran. *Theoretical and Applied Climatology* 142 1613-1623.
- Zhu, H.; Jiang, Z.; Li, J.; Li, W.; Sun, C.; Li, L. 2020. Does CMIP6 inspire more confidence in simulating climate extremes over China? *Advances in Atmospheric Sciences* 37 1119-1132.
- Zilli, M.T.; Carvalho, L.M.; Lintner, B.R. 2019. The poleward shift of South Atlantic Convergence Zone in recent decades. *Climate Dynamics* 52 2545-2563.