



**Paulo Roberto Megna Francisco  
José Hugo Simplício de Sousa  
George do Nascimento Ribeiro  
José Nilton Silva**



# **Variáveis Climáticas e sua Projeção Através de Modelagem Espacial e Simulação por Forçantes de Parte do Território Brasileiro**

***Variáveis Climáticas e sua  
Projeção através de Modelagem  
Espacial e Simulação por  
Forçantes de Parte do  
Território Brasileiro***



Dados Internacionais de Catalogação na Publicação (CIP)

Sa339	Variáveis climáticas e sua projeção através de modelagem espacial e simulação por forçantes de parte do território brasileiro/Francisco et al. — Campina Grande: EPTEC, 2024.
	86 f.: il. color.
	Formato: PDF
	Requisitos de sistema: Adobe Acrobat Reader
	Modo de acesso: World Wide Web
	Inclui bibliografia
	ISBN: 978-65-01-01996-3
	1. Modelos climáticos globais. 2. Cenários futuros. 3. Variabilidade climática. 4. Estatística zonal. 5. Índice de aridez. I. Francisco, Paulo Roberto Megna. II. Sousa, José Hugo Simplicio de. III. Ribeiro, George do Nascimento. IV. Silva, José Nilton. V. Título.
	CDU 62

Os capítulos ou materiais publicados são de inteira responsabilidade de seus autores.  
As opiniões neles emitidas não exprimem, necessariamente, o ponto de vista do Editor responsável.  
Sua reprodução parcial está autorizada desde que cite a fonte.



Todo o conteúdo deste livro está licenciado sob a Licença de Atribuição Creative Commons.  
Atribuição-Não-Comercial-Não Derivativos 4.0 Internacional (CC BY-NC-ND 4.0).

2024 by Eptec  
Copyright © Eptec  
Copyright do texto © 2024 Os autores  
Copyright da edição © 2024 Eptec  
Direitos para esta edição cedidos à Eptec pelos autores.  
Open access publication by Eptec

**Créditos das Imagens da capa**  
Pixabay/Freepick

**Editoração, Revisão e Arte da Capa**  
Paulo Roberto Megna Francisco

**Conselho Editorial**  
Claudiomir Silva Santos (IFSULMINAS)  
Djail Santos (CCA-UFPB)  
Dermeval Araújo Furtado (CTRN-UFCG)  
Flávio Pereira de Oliveira (CCA-UFPB)  
George do Nascimento Ribeiro (CDSA-UFCG)  
Gypson Dutra Junqueira Ayres (CTRN-UFCG)  
João Miguel de Moraes Neto (CTRN-UFCG)  
José Nilton Silva (CTRN-UFCG)  
José Wallace Barbosa do Nascimento (CTRN-UFCG)  
Lúcia Helena Garofalo Chaves (CTRN-UFCG)  
Luciano Marcelo Fallé Saboya (CTRN-UFCG)  
Newton Carlos Santos (UFRN)  
Paulo da Costa Medeiros (CDSA-UFCG)  
Paulo Roberto Megna Francisco (CTRN-UFCG)  
Raimundo Calixto Martins Rodrigues (DEAG-UEMA)  
Soahd Arruda Rached Farias (CTRN-UFCG)  
Virgínia Mirtes de Alcântara Silva (CTRN-UFCG)  
Viviane Farias Silva (CSTR-UFCG)

Paulo Roberto Megna Francisco  
José Hugo Simplicio de Sousa  
George do Nascimento Ribeiro  
José Nilton Silva

***Variáveis Climáticas e sua  
Projeção através de Modelagem  
Espacial e Simulação por  
Forçantes de Parte do  
Território Brasileiro***



1.a Edição  
Campina Grande-PB  
2024

## REALIZAÇÃO



## APOIO



# SUMÁRIO

<i>Apresentação .....</i>	6
<i>Capítulo I.....</i>	7
<i>Variáveis Climáticas Utilizando Modelagem Espacial do WORDCLIM®2 da Região Nordeste e dos Estados de Minas Gerais, Maranhão e Amapá.....</i>	7
<i>Capítulo II.....</i>	31
<i>Projeção Climática da Pluviosidade e Temperatura do Ar da Região Continental Brasileira entre 2021 a 2040 Simulada por Modelos do CMIP6-SSP126/245/370 .....</i>	31
<i>Capítulo III .....</i>	57
<i>Projeção Climática dos Estados da Região Nordeste, Minas Gerais, Maranhão e Amapá Simulada até 2040 por Forçantes SSP126/245/370 do CIMP6.....</i>	57
<i>Curriculum dos Autores.....</i>	85

# APRESENTAÇÃO

A presente obra é dedicada à análise das mudanças climáticas no Brasil, empregando técnicas avançadas de modelagem e simulação. Sob a liderança do pesquisador Paulo Megna, os autores proporcionam uma análise detalhada de como diversas variáveis climáticas, incluindo temperatura e precipitação, poderão evoluir nas próximas décadas sob a influência de várias forçantes climáticas.

Dividido em capítulos claros e informativos, o livro começa explorando as variáveis climáticas usando modelagem espacial da ferramenta WorldClim®2, focando em áreas específicas do Brasil como o Nordeste, Minas Gerais, Maranhão e Amapá. Esta abordagem permite uma visão granular das mudanças regionais e é vital para compreender as complexidades climáticas nestas áreas variadas.

Um dos pontos fortes da obra é a projeção climática para a pluviosidade e a temperatura do ar em todo o território continental brasileiro entre 2021 e 2040, simuladas por modelos do CMIP6-SSP126/245/370. Este capítulo não só fornece projeções futuras valiosas, mas também destaca a importância de entender as variações climáticas para a gestão de recursos naturais e planejamento ambiental.

O livro também se aprofunda na projeção climática específica para estados selecionados, simulada até 2040, oferecendo insights cruciais sobre como as mudanças climáticas poderão afetar áreas geograficamente e ecologicamente distintas. Estas projeções são essenciais para formuladores de políticas, pesquisadores e profissionais envolvidos em agricultura, gestão de recursos hídricos e planejamento urbano.

Além das projeções e análises, a obra é enriquecida com um robusto suporte de dados e metodologias, como o uso de dados do WorldClim® e técnicas de interpolação para criar modelos climáticos de alta resolução. Isto não apenas assegura a precisão das informações, mas também fornece uma ferramenta valiosa para estudos futuros e aplicações práticas.

Em resumo, esta obra é uma contribuição significativa para a literatura climática, essencial para todos os envolvidos com as ciências ambientais e climáticas, desenvolvimento sustentável e políticas de adaptação climática no Brasil.

**José Nilton Silva**

*Prof. Dr. Eng. Químico*

# CAPÍTULO I

# VARIÁVEIS CLIMÁTICAS UTILIZANDO MODELAGEM ESPECIAL DO WORDCLIM®2 DA REGIÃO NORDESTE E DOS ESTADOS DE MINAS GERAIS, MARANHÃO E AMAPÁ

## INTRODUÇÃO

O clima é formado por vários elementos, como radiação solar, precipitação pluviométrica, temperatura do ar, umidade do ar, vento, pressão atmosférica, evaporação entre outros, onde é importante analisar a ação desses no ambiente. A variabilidade é um dos elementos mais conhecidos da dinâmica climática, e o impacto produzido por essa variabilidade, mesmo dentro do esperado pode ter reflexos significativos nas atividades humanas (OLIVEIRA et al., 2014).

A temperatura apresenta uma variabilidade temporal e espacial ao longo do dia, mês ou ano, sendo, portanto, um elemento climático muito complexo. Em geral as maiores médias térmicas de temperatura do ar na superfície ocorrem durante o verão, e as menores durante o inverno, mesmo em localidades com baixas latitudes. Esse aspecto latitudinal é fundamental para alterar a média térmica à medida que se distancia do Equador e se aproxima dos Polos. Fatores geográficos como os grandes corpos hídricos, os oceanos, por exemplo, atuam como um regulador térmico da temperatura do ar, tendendo a suavizar as flutuações e reduzir a amplitude anual (VAREJÃO-SILVA, 2006).

Outro fator fundamental para a variação da temperatura é a altitude, à medida que aumenta a altitude na troposfera diminui a temperatura. Nas regiões tropicais esse efeito é muito significativo para a melhoria do conforto ambiental. A temperatura do ar se destaca entre as variáveis atmosféricas mais utilizadas no desenvolvimento de estudos de impactos ambientais com mudanças nos processos meteorológicos e hidrológicos de acordo com Nogueira et al. (2012) e Correia et al. (2011).

A produção agrícola depende essencialmente do balanço de umidade do solo, que é dependente, da precipitação, temperatura, evaporação, etc. (FRANCISCO et al., 2015). A agricultura é uma das atividades econômicas que apresenta uma dependência do tempo e do clima. As condições atmosféricas afetam todas as etapas das atividades agrícolas, desde o preparo do solo para o plantio até o armazenamento dos produtos e seu transporte. As condições meteorológicas adversas levam constantemente a graves impactos sociais sem precedentes (SOUZA et al., 2004).

Conforme Viana (2010), nos dias atuais é perceptível a importância das pesquisas que envolvem o estudo do clima na busca da construção de novos parâmetros de conhecimento e consequente aplicação nas diversas atividades humanas que dependem dos dados e informações cada vez mais concisos sobre chuvas, secas, temporais e eventos extremos, com informações de médio e longo prazo geradas com um alto grau. As informações das condições climáticas de uma determinada região são necessárias para que se possam instituir estratégias, que visem o manejo mais adequado dos recursos naturais, planejando dessa forma, a busca por um desenvolvimento sustentável e implementação das práticas agrícolas viáveis e seguras para o meio ambiente e a produtividade agropecuária (FRANCISCO et al., 2016).

Uma possível solução para obter alguma informação à escala local a partir dos resultados do modelo climático são os procedimentos de *downscaling*, que utilizam modelos dinâmicos ou estatísticos para relacionar informação em grande escala dos GCM (Global Climatic Model), considerados modelados de forma fiável, com informações regionais ou locais. Cada abordagem dinâmica ou estatística tem suas próprias desvantagens e vantagens. É difícil encontrar um método universal de redução de escala válido para todas as variáveis e todas as regiões (von STORCH, 1995). Embora os modelos climáticos globais (GCMs) sejam úteis para simular respostas climáticas a perturbações no sistema climático da Terra, há muitos casos em que são necessárias informações de maior resolução espacial (MOSIER et al., 2018). De acordo com Marengo et al. (2012), nas últimas décadas, tanto os modelos climáticos globais (MCGs), quanto os modelos climáticos regionais (MCRs), têm tido grandes avanços na

representação dos componentes do sistema climático, principalmente devido à melhor representação dos processos físicos e fenômenos a eles associados e as suas interações.

WorldClim® é um conjunto de camadas climáticas globais, dados climáticos em grade no formato *geotiff*, que podem ser usados para mapeamento e modelagem espacial. A versão 1 do WorldClim® é um conjunto de dados em grade climática global de alta resolução cobrindo 1961-1990 (MARCHI et al., 2019). O método de interpolação, a resolução espacial e a cobertura são as três principais características que os pesquisadores utilizam para selecionar os conjuntos de dados mais adequados para suas pesquisas (ATTORRE et al. 2007; MARCHI et al., 2007; AZUPURA et al., 2010; MBOGGA et al., 2009). A primeira versão do conjunto de dados WorldClim® (HIJMANS et al., 2005) é provavelmente o mais importante conjunto de dados climáticos em grade, amplamente utilizado. Graças à sua alta resolução (30 segundos de arco no sistema de referência WGS84 e aproximadamente 1 km no equador), de cobertura global e disponibilidade. Um dos principais produtos desta base de dados é a representativa do período normal climático de 1961-1990 para todo o globo. Este conjunto de dados foi gerado interpolando dados de estações meteorológicas utilizando latitude, longitude e elevação como variáveis independentes (MARCHI et al., 2019).

A versão 1.4 do WordlClim® contém dados em grade para as mesmas variáveis para o período 1960-1990, bem como projeções de temperatura e precipitação do Quinto Relatório de Avaliação do IPCC usando vários modelos de circulação geral (GCMs) para quatro caminhos de concentração representativos (RCPs) e simulações de temperatura e precipitação baseadas em GCM para o Holoceno Médio,(cerca de 6.000 anos atrás, o Último Máximo Glacial, cerca de 22.000 anos atrás, e o Último Interglacial entre 120.000 - 140.000 anos atrás.

A versão 2 do WordlClim® contém dados climáticos médios mensais em grade para o período 1970-2000 com diferentes resoluções espaciais, de 30 segundos ( $\sim 1 \text{ km}^2$ ) a 10 minutos ( $\sim 340 \text{ km}^2$ ). O conjunto de dados inclui as principais variáveis climáticas (temperatura mínima, média e máxima mensal, precipitação, radiação solar, velocidade do vento e pressão de vapor de água), bem como 19 variáveis bioclimáticas derivadas. As correlações globais de validação cruzada foram  $\geq 0,99$  para temperatura e umidade, 0,86 para precipitação e 0,76 para velocidade do vento (FICK & HIJMANS, 2017).

O Índice Global de Aridez e o Banco de Dados de Evapotranspiração Potencial - Versão 3 (Global-AI\_PET\_v3) fornece dados hidroclimáticos globais de alta resolução (30 segundos de arco) com média mensal e anual entre 1970 a 2000, com base na equação de Evapotranspiração de Referência (ET0) da FAO Penman-Monteith, onde os resultados foram comparados para

validação técnica com dados da estação meteorológica da FAO CLIMWAT 2.0 for CROPWAT (ET0:  $r^2 = 0,85$ ; AI:  $r^2 = 0,90$ ) e com a Unidade de Pesquisa Climática: Série Temporal v 4.04 do Reino Unido (ET0:  $r^2 = 0,89$ ; AI:  $r^2 = 0,83$ ), demonstrando diferenças significativas em relação a versão anterior do banco de dados. Desenvolvido utilizando a metodologia padrão aceita para estimativa da referência ET0, o banco de dados e o código-fonte, fornecem uma ferramenta robusta para uma variedade de pesquisas científicas e aplicações em uma era de condições climáticas em rápida mudança (ZOMER et al., 2022).

Num ambiente e clima globais em rápida mudança, estas métricas e os seus derivados índices, tornam-se uma medida direta e crítica, e uma ferramenta preditiva, da tendência, direção e magnitude de mudanças climáticas e seus impactos na biosfera terrestre, com implicações para o crescimento das plantas, sustentabilidade desenvolvimento e, eventualmente, considerando as conclusões recentemente divulgadas dos últimos relatórios do IPCC para a civilização humana (ALLAN et al., 1998; JENSEN & ALLEN, 2016; ZOTARELLI et al., 2018; PANDEY et al., 2017; VALIPOUR et al., 2020; ANWAR, 2021; IPCC, 2019; 2021).

O WorldClim® também já foi utilizado em outras aplicações como eco-hidrologia (IMBACH et al., 2010), em climatologia (MORENO & HASENAUER, 2016), na avaliação de estoques de carbono e suas mudanças (YIGINI & PANAGOS, 2016; LUGATO et al., 2016) e para modelagem de erosão (PANAGOS et al., 2017; BALLABIO et al., 2017).

Portanto, o objetivo deste trabalho é mapear as variáveis climáticas dos Estados da região Nordeste, Sudeste e Norte do Brasil utilizando modelagem espacial e geotecnologias.

## **MATERIAL E MÉTODOS**

A área de estudo compreende a região Nordeste e os Estados de Minas Gerais, Maranhão e Amapá com diversidade de ambientes (Figura 1a), solos, vegetação e clima (Figura 1b). De acordo com Alvares et al. (2013), o clima Af é identificado no Estado da Bahia, ao longo do litoral em uma faixa estreita nas Planícies Marinhas e Planaltos Costeiros; o clima Am apresenta-se na faixa litorânea do Nordeste; o clima Aw ocorre em uma ampla faixa de forte gradiente de umidade de oeste para leste, vindo do oeste dos Estados do Piauí e Bahia; o clima tropical, com chuvas de inverno (As) ocorre principalmente no Nordeste entre os climas Aw e BSh, na faixa que define o Agreste, região do Semiárido, entre os Estados do Rio Grande do Norte e da Bahia; o clima semiárido BSh é notadamente o clima típico do Nordeste, ocorrendo basicamente em paisagens onde a precipitação anual cai em média para menos de 800mm, é um clima sertanejo, na Paraíba se estende por todo o Planalto da Borborema, onde no vale do rio Paraíba a

precipitação anual oscila em torno de 400mm, considerado um dos locais mais secos do Brasil; o Cwa é um clima típico do sudeste e observado no Estado de Minas Gerais; o Cwb ocorre no centro-sul de Minas Gerais e na Bahia, na região centro-sul onde as altitudes são superiores a 1.000 m como no Planalto de Diamantina em que a precipitação anual é inferior a 700mm, sendo, portanto, o local Cwb mais seco do Brasil, e em algumas paisagens de altitude do Planalto da Borborema (Pernambuco e Paraíba), nas encostas de altitude acima de 1.000 m, ocorre o clima mais setentrional do tipo Cwb no Brasil.

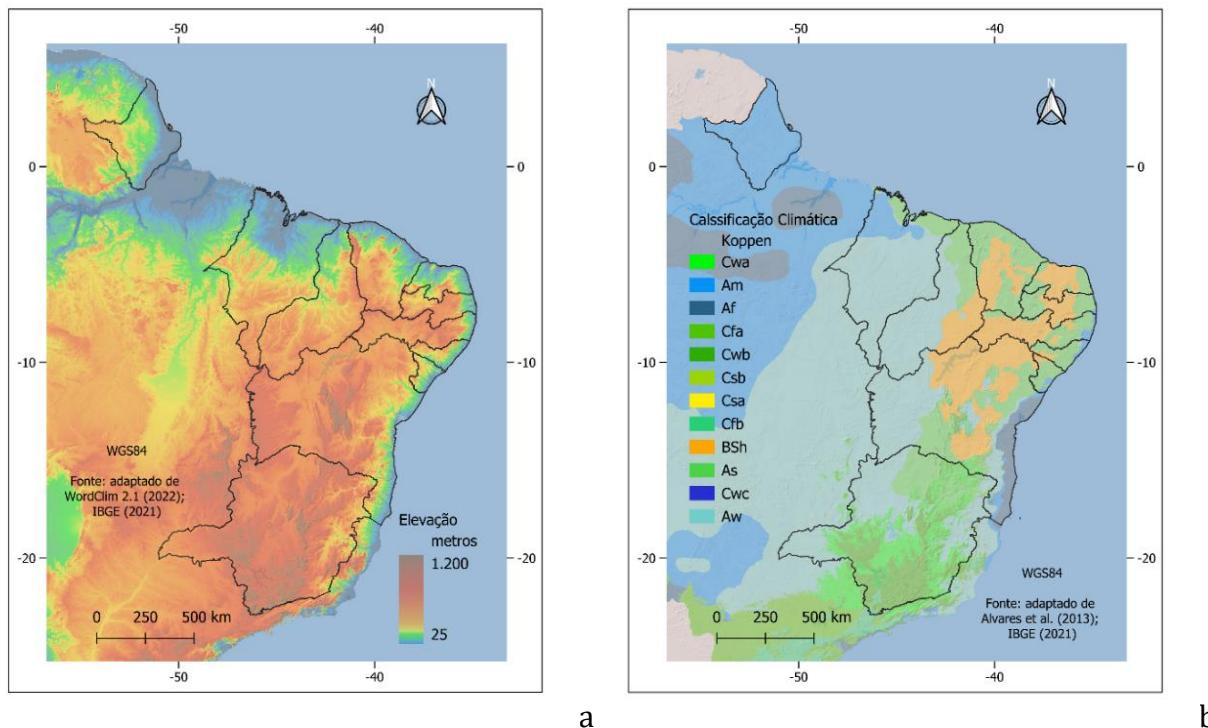


Figura 1. Elevação da área de estudo (a); Classificação climática de Köppen (b).

Fonte: adaptado de WorldClim 2.1 (2022); Alvares et al. (2013); IBGE (2021).

Na realização deste trabalho foi utilizado a base digital da WordClim® v2.1 de dados entre 1970 a 2000 (ZOMER et al., 2022) de alta resolução espacial de 30s de arco ~1 km<sup>2</sup> do Índice Global de Aridez e Banco de Dados de Evapotranspiração Potencial v.3. As variáveis climáticas avaliadas foram temperatura mínima média mensal (°C), temperatura máxima média mensal (°C), precipitação total mensal (mm), radiação solar (kJ m<sup>-2</sup> day<sup>-1</sup>), pressão de vapor de água (kPa), evapotranspiração de referência (ET0), índice de aridez mensal e anual, todas adquiridas em formato *tif*.

Utilizando o QGIS® 3.36.1 foram importados os arquivos, recortados e classificados. Após, utilizando a calculadora *raster* foi gerado o mapa de temperatura média anual utilizando

a temperatura mensal média. Após foi realizada a estatística zonal através do SAGA® 9.2.0 desenvolvido por Conrad et al. (2015).

Utilizando o RStudio® 2023 foram elaborados os testes de normalidade de Shapiro-Wilk (1965), o teste de aderência de Kolmogorov-Smirnov (1933; 1948), o teste de Lilliefors (1967) e o teste de Anderson-Darling (1954). 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 principais.

## **RESULTADOS E DISCUSSÃO**

Pelos resultados obtidos, pode-se observar pela Figura 2 que, os maiores valores médios e máximos de radiação solar ( $\text{kJ m}^{-2} \text{ day}^{-1}$ ) se localizam no Estado de Alagoas, já os valores mínimos, maior variabilidade e maior desvio padrão localizam-se em Minas Gerais, isto devido, a localização geográfica ocorrer mais ao sul, próximo ao Trópico de Capricórnio, com menor inclinação em relação ao Sol. Observa-se também que o Estado do Piauí apresenta o menor desvio padrão entre os demais. De maneira geral, a avaliação quantitativa e a variabilidade espacial da radiação solar incidente na superfície utiliza o conhecimento da dinâmica de localização do Sol, das características topográficas e dos processos de atenuação atmosférica (BUFFO et al., 1972). Os ambientes tropicais caracterizam-se pela elevada incidência de radiação solar, insolação e temperatura. Quanto mais próximo do equador, mais crítica é a incidência, como é o caso das regiões norte, nordeste e centro-oeste do Brasil (BAYER, 2004; BLEY JR., 1999).

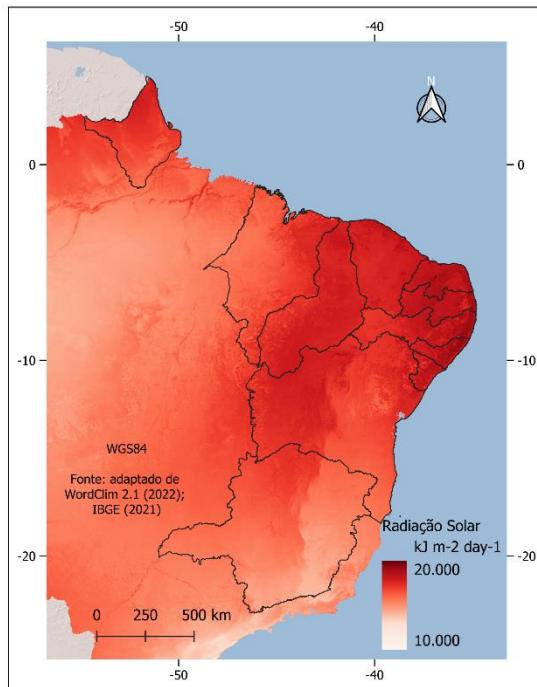


Figura 2. Radiação solar ( $\text{kJ m}^{-2} \text{ day}^{-1}$ ).

Fonte: adaptado de WordClim® 2.1 (2022); IBGE (2021).

Tabela 1. Estatística descritiva da radiação solar

Estado	Radiação solar ( $\text{kJ m}^{-2} \text{ day}^{-1}$ )					
	Mediana	Média	Desv. P.	Mínimo	Máximo	Variabilidade
AL	18.476,3	18.510,4	535,8	16.938,6	20.117,5	287.078,3
BA	17.142,5	17.247,6	578,7	15.522,7	19.309,7	334.949,6
CE	17.797,8	17.743,8	279,5	15.704,8	19.810,3	78.107,1
MA	16.574,4	16.468,3	622,8	15.171,8	18.277,8	387.890,6
PB	18.373,6	18.364,8	323,7	17.205,9	19.623,6	104.780,1
PE	17.931,0	17.879,5	613,0	16.969,2	20.084,8	375.714,2
PI	17.693,9	17.750,6	265,9	16.098,0	19.255,8	70.715,7
RN	18.462,1	18.442,1	344,1	17.474,2	19.977,7	118.375,8
SE	18.102,0	18.176,0	422,2	16.604,8	19.086,2	178.227,6
AP	16.993,1	17.064,3	530,9	15.553,4	18.663,7	281.818,4
MG	15.717,6	15.717,3	778,6	13.916,1	17.587,9	606.182,4

Quanto a variável temperatura mínima, observa-se pela Figura 3a e Tabela 2 que, os maiores valores se apresentam no Estado de Pernambuco e valores mínimos em Minas Gerais. Os maiores e menores valores médios, desvio padrão e variabilidade apresentam-se no Amapá e Minas Gerais, respectivamente. Comportamento este esperado, devido a localização geográfica do continente brasileiro ser de clima tropical a sub tropical conforme a latitude.

A temperatura máxima (Figura 3b) pode-se verificar que, os valores máximos apresentam-se no Piauí e valores mínimos em Minas Gerais, com maiores desvio padrão e

variabilidade na Bahia e menores valores em Minas Gerais. O Estado da Bahia apresenta maior variabilidade devido sua extensão territorial ser maior em relação aos demais Estados, tanto em latitude como na longitude. Para a Paraíba, Francisco et al. (2017) e Medeiros et al. (2015), obtiveram média anual de 21,7°C, resultado similar a este estudo. Para o Ceará, Medeiros et al. (2011) observaram para Sobral, que a variabilidade da temperatura mínima entre as séries estudadas apresentou reduções em todos os meses do ano, com oscilações de -0,1 a -0,8°C. Para Minas Gerais, Reboita et al. (2015) observaram que, no Estado a temperatura é influenciada tanto pela latitude quanto pela topografia, com a região sul apresentando médias anuais de cerca de 20°C, e o norte de 26°C.

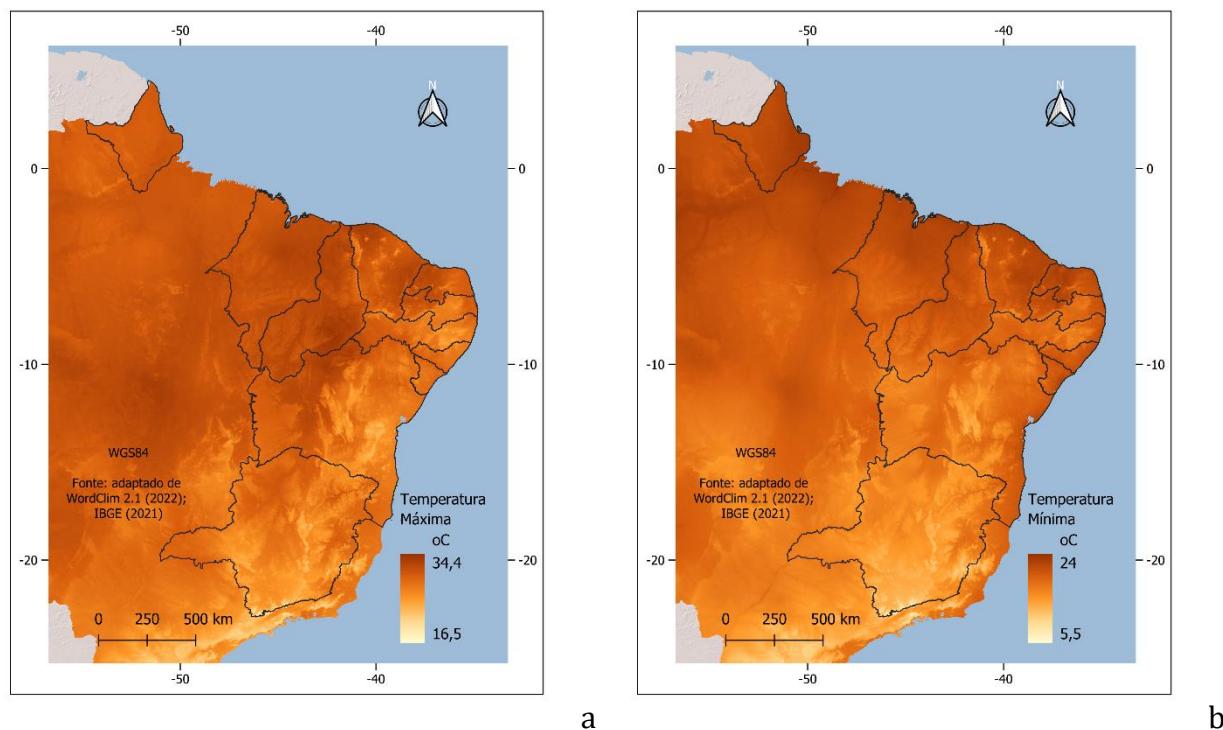


Figura 3. Temperatura mínima (°C) (a); Temperatura máxima (°C) (b).

Fonte: adaptado de WordClim® 2.1 (2022); IBGE (2021).

Tabela 2. Estatística descritiva da temperatura mínima e máxima

Estado	Temperatura mínima (°C)						Temperatura máxima (°C)					
	Mediana	Média	Desv. P.	Mínimo	Máximo	Variabilidade	Mediana	Média	Desv. P.	Mínimo	Máximo	Variabilidade
AL	19,93	20,01	0,86	16,23	21,86	0,74	28,41	28,40	0,98	23,49	30,82	0,96
BA	17,67	17,75	1,51	10,26	22,25	2,28	29,08	29,07	2,10	21,23	33,85	4,42
CE	20,67	20,93	1,48	15,36	23,07	2,19	30,78	30,89	1,46	24,48	33,72	2,12
MA	20,54	20,64	1,37	15,88	23,29	1,87	31,46	31,45	0,66	28,95	33,67	0,44
PB	19,46	19,33	1,45	14,48	22,33	2,10	29,03	28,88	1,66	23,60	32,34	2,76
PE	18,41	18,44	1,04	14,53	24,19	1,08	28,48	28,42	1,74	23,02	32,16	3,04
PI	19,68	19,81	1,25	15,30	23,23	1,57	31,90	31,98	0,96	26,99	34,48	0,92
RN	21,28	21,49	1,01	17,43	23,11	1,02	30,73	30,82	1,19	26,37	33,03	1,43
SE	20,20	20,10	0,94	16,96	22,57	0,88	28,73	28,76	0,66	25,44	30,73	0,44
AP	21,69	21,63	0,79	19,11	23,98	0,62	30,30	30,24	0,45	28,11	31,67	0,20
MG	15,29	15,40	1,62	3,40	20,10	2,61	27,52	27,64	1,84	14,98	31,19	3,39

No mapa da precipitação total (Figura 4a), pode-se observar que, as menores precipitações ocorrem na região semiárida do Nordeste brasileiro. Na Tabela 3 verifica-se que, no Estado de Alagoas ocorre o maior desvio padrão e maior variabilidade dos resultados. Os maiores valores máximos e médios ocorrem no Amapá, e mínimos na Bahia. A menor variabilidade apresenta-se no Ceará. Medeiros et al. (2015) observaram tendências de reduções dos índices pluviométricos para a Paraíba, com oscilações das precipitações ao longo da série amostral com evidências a recorrência de valores máximos de precipitação anual dentro de um intervalo de 15, 12 e 7 anos.

Quanto a precipitação média (Figura 4b), verifica-se que, na Bahia ocorre os menores valores mínimos. No Estado do Amapá ocorre a maior média e os valores máximos. O maior desvio padrão e variabilidade ocorrem em Alagoas, e os menores valores no Ceará. A região do semiárido é influenciada por sistemas atmosféricos de frentes frias vindas do sudeste brasileiro, variações sazonais da Zona de Convergência Intertropical (MUTTI et al., 2020).

De acordo com Alvares et al. (2013), onde observaram em seu estudo que, a variabilidade espacial se apresenta semelhante ao mapa normal climatológico apresentado pelo INMET em que, a precipitação anual varia de 387 a 4.003mm, muito semelhante ao encontrado por este trabalho e em outros estudos (GOLFARÍ et al., 1978; NIMER, 1989; GRIMM, 2009; MARENGO & NOBRE, 2009; ALVES, 2009; NUNES et al., 2009). Os autores também identificaram precipitações anuais inferiores a 700mm que ocorrem no Planalto da Borborema, Agreste da Paraíba, Vale do Rio São Francisco e norte da Bahia, regiões mais secas do país denominadas como Sertão, resultado similar a este estudo.

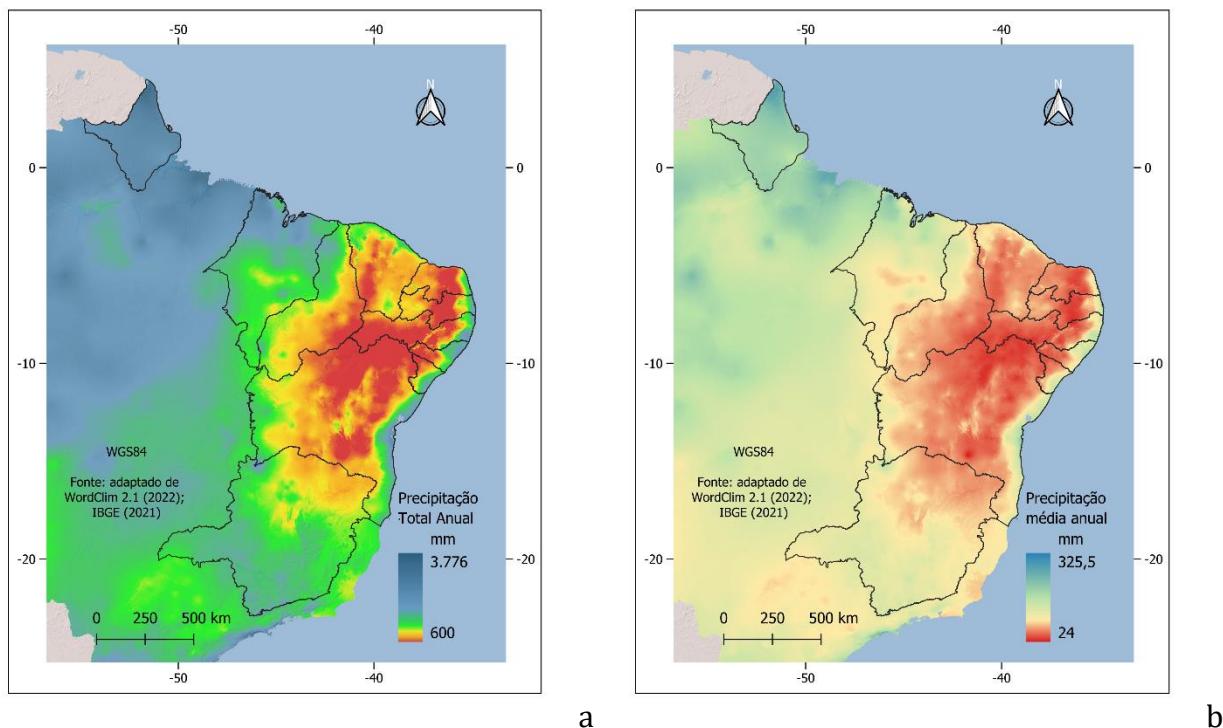


Figura 4. Precipitação Total (mm) (a); Precipitação média (mm) (b).

Fonte: adaptado de WordClim® 2.1 (2022); IBGE (2021).

Tabela 3. Estatística descritiva da precipitação total e média

Estado	Precipitação Total (mm)						Precipitação média (mm)					
	Mediana	Média	Desv. P.	Mínimo	Máximo	Variabilidade	Mediana	Média	Desv. P.	Mínimo	Máximo	Variabilidade
AL	1.099,7	1.059,0	450,1	454,0	2.077,0	202.567,6	91,6	88,3	37,5	37,8	173,1	1.406,7
BA	877,0	812,0	317,1	289,0	2.444,0	100.558,9	73,1	67,7	26,4	24,1	203,7	698,3
CE	887,3	844,0	184,1	567,0	1.752,0	33.911,0	73,9	70,3	15,3	47,3	146,0	235,5
MA	1.511,3	1.450,0	328,8	952,0	2.993,0	108.137,9	125,9	120,8	27,4	79,3	249,4	751,0
PB	802,2	796,0	288,8	377,0	2.007,0	83.394,0	66,8	66,3	24,1	31,4	167,3	579,1
PE	745,3	646,0	322,5	366,0	2.142,0	104.027,9	62,1	53,8	26,9	30,5	178,5	722,4
PI	1.006,4	983,0	263,8	467,0	1.797,0	69.613,8	83,9	81,9	22,0	38,9	149,8	483,4
RN	762,3	745,0	212,4	433,0	1.606,0	45.102,2	63,5	62,1	17,7	36,1	133,8	313,2
SE	1.041,3	981,0	358,0	462,0	1.826,0	128.193,3	86,8	81,8	29,8	38,5	152,2	890,2
AP	2.467,1	2.404,0	245,3	1.940,0	3.535,0	60.192,8	205,6	200,3	20,4	161,7	294,6	418,0
MG	1.272,4	1.301,0	245,1	687,0	2.365,0	60.051,6	106,0	108,4	20,4	57,3	197,1	417,0

Oliveira et al. (2019), avaliando os dados de precipitação do Worldclim® para o Estado de Pernambuco concluíram que, apresentaram boa correspondência com as informações provenientes de estações pluviométricas em que a precipitação anual média obteve bons resultados para todos os critérios de análise aplicados. Em relação aos valores médios anuais, a base Worldclim® possibilitou a representação da distribuição espacial da precipitação estando de acordo com o Plano Estadual de Recursos Hídricos (PERNAMBUCO, 1998).

No que se refere à precipitação, comparando com outras bases correlatas como TRMM, CHIRPS e GPCC, a principal vantagem da base de dados WorldClim® está na resolução espacial

das informações, cujos pixels possuem aproximadamente 1km<sup>2</sup>. Além disso, para trabalhos que precisam realizar a caracterização de precipitações médias de longo termo (normais climatológicas), o formato matricial dos dados permite uma representação das informações de forma distribuída, para qualquer lugar do planeta, fornecendo vantagens em relação aos dados pontuais de estações pluviométricas (OLIVEIRA et al., 2019).

No Brasil, as análises dos padrões temporais e espaciais de precipitação, são muitas vezes limitadas pela baixa densidade da rede de monitoramento meteorológico, além de serem influenciadas pela escala reduzida de observação dos fenômenos climáticos através do monitoramento *in situ*; estações meteorológicas em solo apresentam características pontuais, que expressam maior correlação com os fenômenos microclimáticos, uma vez que coletam informações da precipitação e temperatura somente para a área localizada no entorno do dispositivo (DE ANGELIS, 2005).

Sobreiro et al. (2017), comparando os dados de precipitação na região montanhosa de Minas Gerais, divisa com a Bahia, observaram que, o WorldClim® apresentou forte correlação com os dados de 112 estações com coeficiente de determinação de regressão simples de  $r^2 = 0,95$ .

Pela Figura 5a e pela Tabela 4, verifica-se o comportamento da evapotranspiração na área de estudo, onde pode-se verificar que, em toda a região litorânea seus valores apresentam-se maiores e também na área central e região Amazônica, no caso o Estado do Amapá com as maiores médias e valores máximos, e apresentando a menor variabilidade entre os demais. O Estado do Ceará apresenta a maior variabilidade e o maior desvio padrão. Em Minas Gerais ocorrem os menores valores mínimos, menor média e mediana entre as demais.

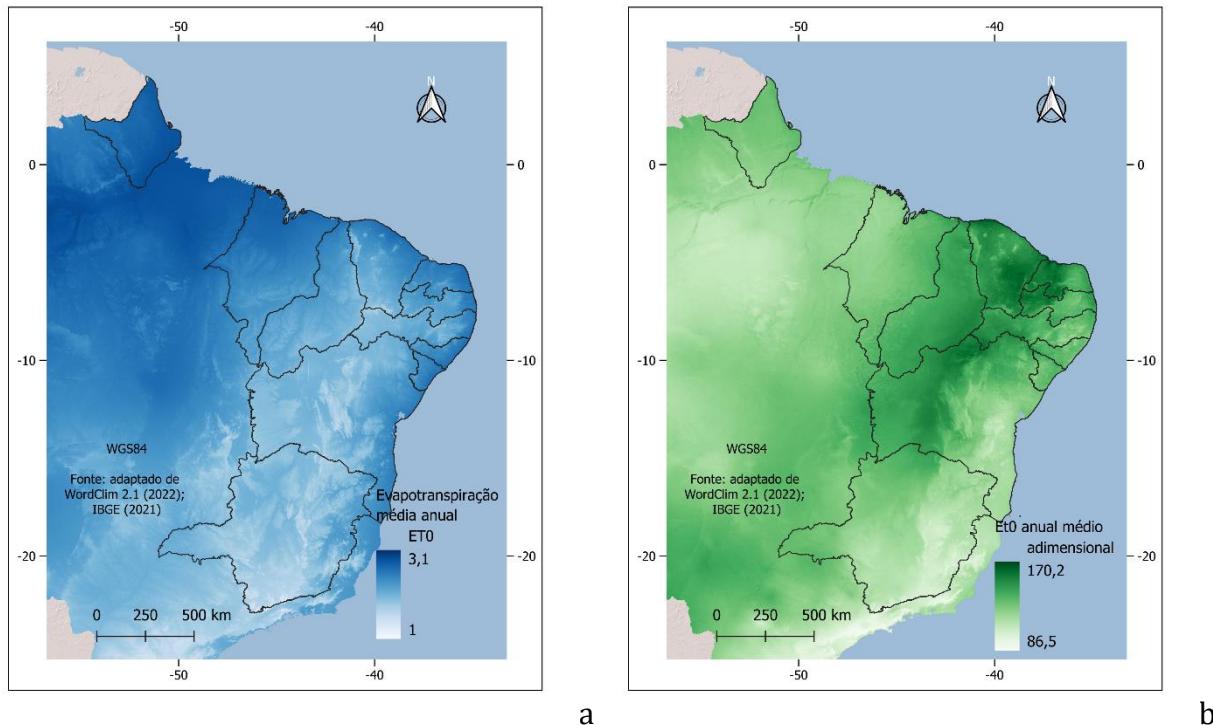


Figura 5. Evapotranspiração anual (a); Eto anual (b).

Fonte: adaptado de WordClim® 2.1 (2022); IBGE (2021).

Tabela 4. Estatística descritiva da evapotranspiração e Eto

Estado	Evapotranspiração						Eto					
	Mediana	Média	Desv. P.	Mínimo	Máximo	Variabilidade	Mediana	Média	Desv. P.	Mínimo	Máximo	Variabilidade
AL	2,46	2,45	0,13	2,01	2,68	0,02	134,36	134,42	4,88	115,50	151,92	23,78
BA	2,06	2,02	0,20	1,35	2,63	0,04	136,23	139,17	12,77	103,25	165,92	163,00
CE	2,27	2,27	0,22	1,73	2,71	0,05	151,26	151,17	7,03	119,83	173,83	49,45
MA	2,51	2,51	0,17	1,99	2,82	0,03	128,99	128,67	6,08	117,08	153,67	36,99
PB	2,26	2,23	0,15	1,77	2,65	0,02	144,08	141,75	9,71	122,50	162,75	94,25
PE	2,11	2,08	0,18	1,73	2,76	0,03	140,45	140,08	8,93	115,08	162,08	79,76
PI	2,17	2,15	0,15	1,76	2,66	0,02	144,10	144,00	4,76	128,08	159,67	22,62
RN	2,47	2,48	0,13	2,03	2,70	0,02	151,05	154,33	8,80	129,17	174,25	77,40
SE	2,48	2,47	0,10	2,11	2,68	0,01	133,92	133,67	4,26	118,25	149,17	18,18
AP	2,76	2,77	0,09	2,40	2,91	0,01	128,87	129,58	3,55	116,58	140,42	12,61
MG	1,91	1,91	0,16	0,93	2,47	0,03	120,42	119,50	10,02	88,50	148,92	100,39

A evapotranspiração potencial (ETP) é o fenômeno associado à perda simultânea de água do solo pela evaporação e da planta pela transpiração. A estimativa da ETP mostra a máxima perda de água possível ocorrer em uma comunidade vegetada. Ela significa a demanda máxima de água pela cultura e vem a tornar-se o referencial de máxima reposição de água à cultura, seja pela irrigação ou pela precipitação pluviométrica de acordo com Barros et al. (2012). Para o Estado da Paraíba, Francisco et al. (2015) concluíram que, os índices evaporativos apresentam dependência da localização geográfica, sobretudo, da topografia local.

Pelos dados descritivos estatísticos da ETo (Tabela 4) e pela Figura 5b, verifica-se o comportamento inverso, apresentando valores máximos no Rio Grande do Norte e mínimos em Minas Gerais, onde a maior variabilidade ocorre na Bahia e menor variabilidade no Amapá. Para o ETo do Estado da Paraíba, Francisco et al. (2017) observaram que os resultavam estavam de acordo com vários estudos realizados para a região semiárida do Nordeste Brasileiro.

Osejo et al. (2019), obtendo a estimativa de evapotranspiração da distribuição espacial da precipitação e evapotranspiração utilizando o WordClim® para a Colômbia concluíram que, os dados climáticos em grade espacial de alta resolução, como temperatura, energia solar radiação, velocidade do vento e pressão de vapor permitiram a obtenção de métodos mais reais.

Na Figura 6, representativa do índice de aridez pode-se observar que, os menores valores mínimos situam-se na Bahia e maiores valores máximo no Amapá. Na região semiárida ocorre valores do índice entre 0,19 a 0,31. Nos Estados de Alagoas e Ceará ocorrem os menores e o maiores desvio padrão e variabilidade, respectivamente. A aridez é um forte indicador do grau de secura dos ambientes (ZARCH et al., 2017). Para Minas Gerais, Reboita et al. (2015) encontraram resultados similares a este trabalho, comprovando eficácia do índice de aridez gerado pelo WordClim® para a região. Xavier et al. (2022) relatam que, as áreas com índices inferiores a 0,5 (semiárido), localizam-se no interior da região Nordeste (exceto Maranhão) e no norte de Minas Gerais. Todavia, os mapas destacam áreas no interior da região com índices superiores a 0,5 como é o caso da Chapada Diamantina e o Cariri. Resultados similares a este trabalho.

Beck et al. (2018) utilizaram um conjunto de dados climáticos para temperatura do ar e para precipitação do WorldClim® v1 e v2 para mapear a classificação global futura de Köppen-Geiger, onde obtiveram resultados excelentes de acurácia.

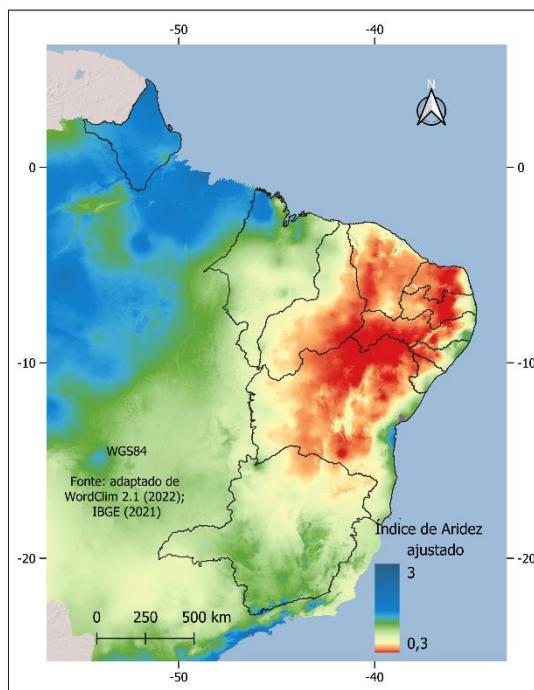


Figura 6. Índice de aridez. Fonte: adaptado de WordClim 2.1 (2022); IBGE (2021).

Tabela 5. Estatística descritiva do índice de aridez

Estado	Índice de Aridez					
	Mediana	Média	Desv. P.	Mínimo	Máximo	Variabilidade
AL	0,69	0,66	0,30	0,25	1,33	0,09
BA	0,55	0,49	0,22	0,19	1,62	0,05
CE	0,49	0,46	0,11	0,31	1,19	0,01
MA	0,98	0,93	0,24	0,59	2,02	0,06
PB	0,46	0,45	0,16	0,23	1,15	0,03
PE	0,45	0,38	0,21	0,20	1,39	0,04
PI	0,58	0,57	0,16	0,25	1,08	0,03
RN	0,42	0,39	0,12	0,25	0,96	0,02
SE	0,65	0,62	0,22	0,26	1,16	0,05
AP	1,59	1,56	0,14	1,26	2,26	0,02
MG	0,89	0,90	0,21	0,42	2,20	0,04

Através dos boxplots das variáveis, pode-se observar o comportamento das mesmas em que, quanto a radiação solar (Figura 7a), verifica-se que o Estado do Amapá por estar localizado próximo a linha do Equador não ultrapassa  $18.663,7 \text{ kJ m}^{-2} \text{ day}^{-1}$ , isto devido a maior precipitação total de 3.535mm e ocorrendo possivelmente a maior cobertura de nuvens e consequentemente a menor insolação e menor radiação solar.

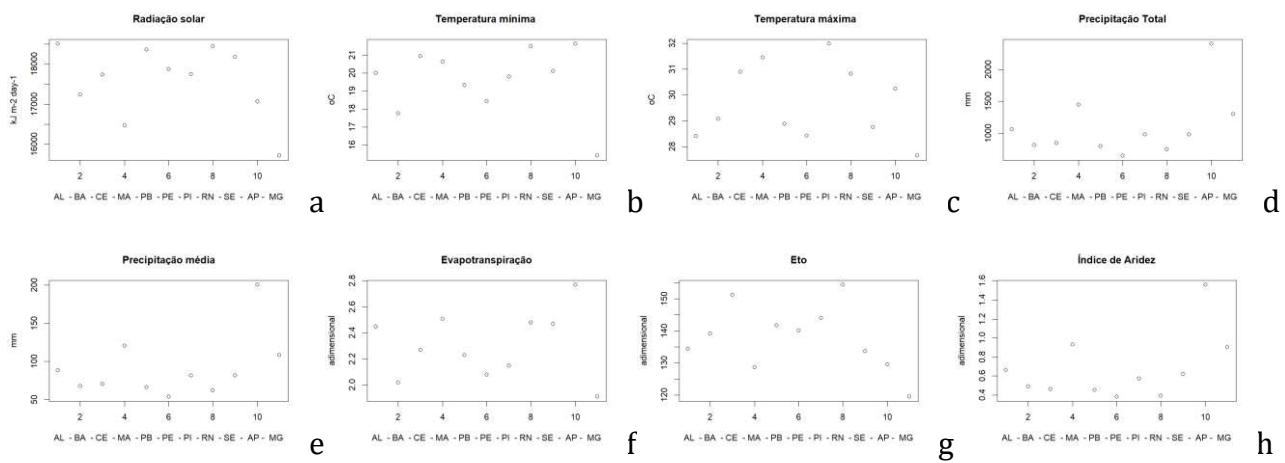


Figura 7. Boxplot do comportamento das variáveis.

Quanto a temperatura mínima (Figura 7b), Minas Gerais se diferencia dos demais Estados com maiores valores entre 16 e 22°C. A temperatura máxima (Figura 7c) segue o mesmo comportamento, com valores entre 27 a 32°C. No comportamento da precipitação total (Figura 7d) ocorrem maiores valores de chuvas em Minas Gerais, Maranhão e Amapá, respectivamente. Quanto a evapotranspiração (Figura 7f), no Amapá devido a maior precipitação ocorre a maior evaporação do solo e pelo maior porte da vegetação, a maior transpiração, resultando nos maiores valores, e menores em Minas Gerais devido a menor insolação. Na Figura 7h do comportamento do índice de aridez, os Estados do Maranhão, Amapá e Minas Gerais apresentam os melhores valores devido a ocorrência de maior precipitação nestas áreas.

A variação dos parâmetros estudados é devido aos principais sistemas responsáveis de influência climática na região Nordeste, a Zona de Convergência Intertropical - ZCIT (SERRA, 1941; HASTENRATH & HELLER, 1977), as Frentes Frias (ARAGÃO, 1976; KOUSKY, 1979), os Distúrbios de Leste ou Ondas de Leste (YAMAZAKI & RAO, 1977) e os Vórtices Ciclônicos de Altos Níveis (VCAN) (ARAGÃO, 1976; KOUSKY & GAN, 1981).

Pela Tabela 6, dos testes de normalidade, tendência e aderência, verifica-se que o teste de Shapiro-Wilk demonstra que os dados são normalmente distribuídos. Para a pluviosidade o teste não apresenta normalmente distribuído. No teste de Kolmogorov-Smirnov com *p-valor* em sua maioria  $<2,2\text{e}^{-16}$  indica uma probabilidade extremamente pequena de se observar os dados, portanto, rejeita-se a hipótese nula. No entanto, para a variável índice de aridez o teste resultou *p-valor* de  $4,89\text{e}^{-02}$  aceitando a hipótese nula. Já para o teste de Lilliefors que é baseado no teste de Kolmogorov-Smirnov, apresenta hipótese nula de que os dados provêm de uma população distribuída exponencialmente. No teste de Anderson-Darling verifica-se que a distribuição se ajusta e segue de uma população distribuída. Quanto ao teste Pearson os

resultados demonstram uma correlação moderada nas variáveis radiação solar, temperatura mínima e Eto, seguida de correlação fraca nas demais variáveis. Quanto ao teste Mann-Kendall, verifica-se que o *p-valor* apresenta tendência significativa em todas as variáveis.

Tabela 6. Testes de normalidade, tendência e correlação

Variável/Teste	Shapiro-Wilk		Kolmogorov-Smirnov		Lilliefors		Anderson-Darling		Pearson		Mann-Kendall	
	W	p-valor	D	p-valor	D	p-valor	A	p-valor	P	p-valor	tau	p-valor
Radiação solar	0,902	0,200	1	< 2,2e-16	0,210	0,188	0,420	0,265	1,545	0,671	-0,345	0,161
Temp. mínima	0,903	0,202	1	< 2,2e-16	0,210	0,188	0,420	0,265	1,545	0,671	0,090	0,755
Temp. máxima	0,928	0,400	1	< 2,2e-16	0,210	0,188	0,420	0,265	3,727	0,292	-0,090	0,755
Pluvios. total	0,769	0,003	1	< 2,2e-16	0,210	0,188	0,420	0,265	9,181	0,026	0,127	0,640
Pluvios. média	0,769	0,003	1	< 2,2e-16	0,210	0,188	0,420	0,265	9,181	0,026	0,127	0,640
Evapotransp.	0,965	0,835	0,971	< 2,2e-16	0,210	0,188	0,420	0,265	4,818	0,185	0,054	0,876
Eto	0,982	0,979	1	< 2,2e-16	0,210	0,188	0,420	0,265	1,545	0,671	-0,164	0,533
Índice de Aridez	0,790	0,007	0,648	4,89e-02	0,210	0,188	0,420	0,265	10,273	0,016	0,127	0,640

Pelos dados estatísticos, observa-se pela Figura 8 que, as menores variações de amplitude se apresentam na precipitação total e média, como também no índice de aridez. A maior amplitude ocorre na variável temperatura máxima.

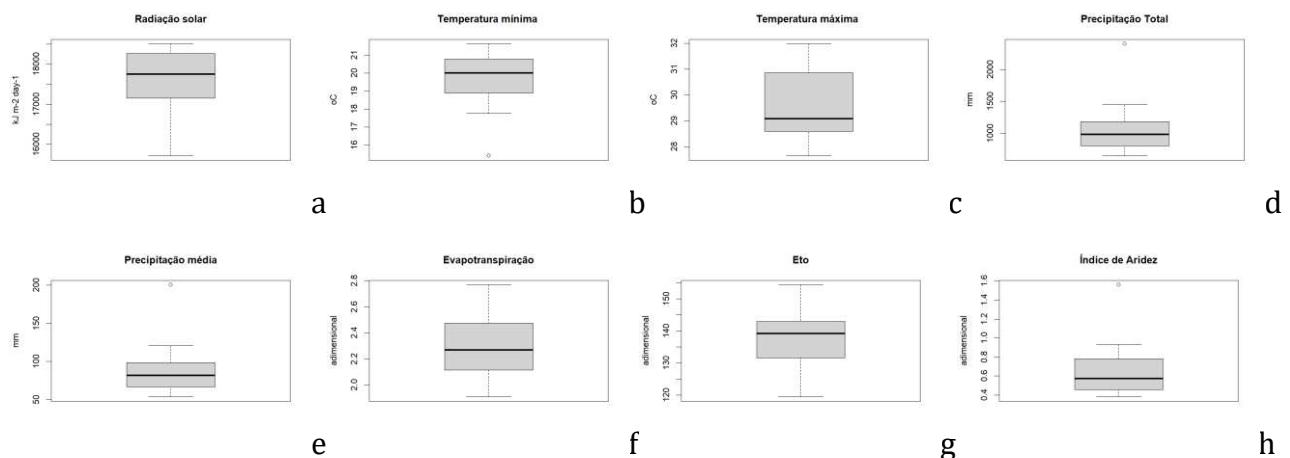


Figura 8. Boxplot das variáveis.

Observa-se que a distribuição (Figura 9) apresenta irregularidades nas variáveis precipitação total e média, e o índice de aridez que apresentam relação entre si. Nas demais variáveis os quantis teórico e acumulado se apresentam de forma regular.

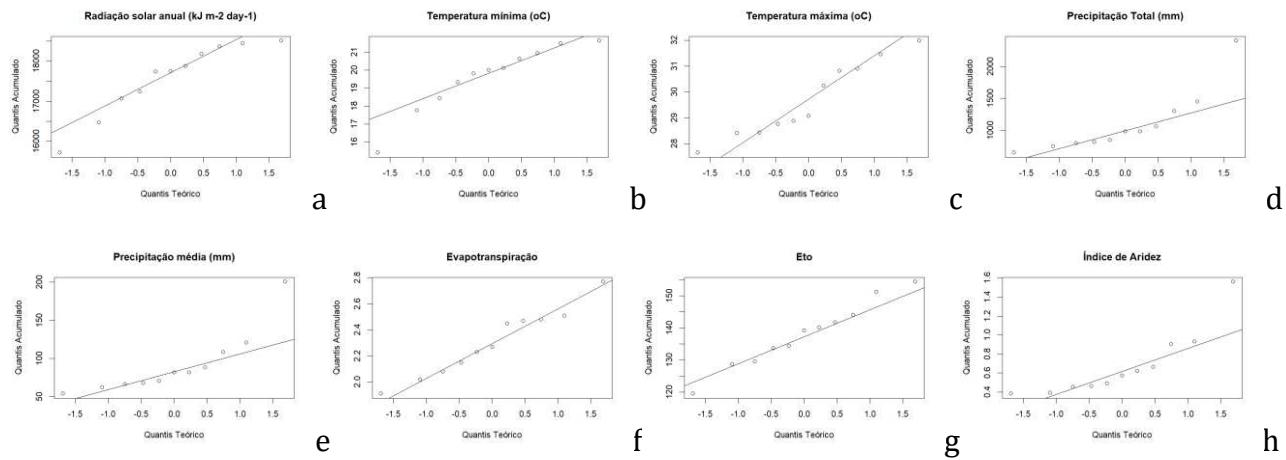


Figura 9. QQplot dos quantis das variáveis.

Quanto a correlação entre as principais variáveis, pode-se verificar que a variável precipitação e o índice de aridez apresenta valores de  $R=0,99$ , seguida das correlações entre precipitação e evapotranspiração e Eto, as demais variáveis seguem com correlação menor.

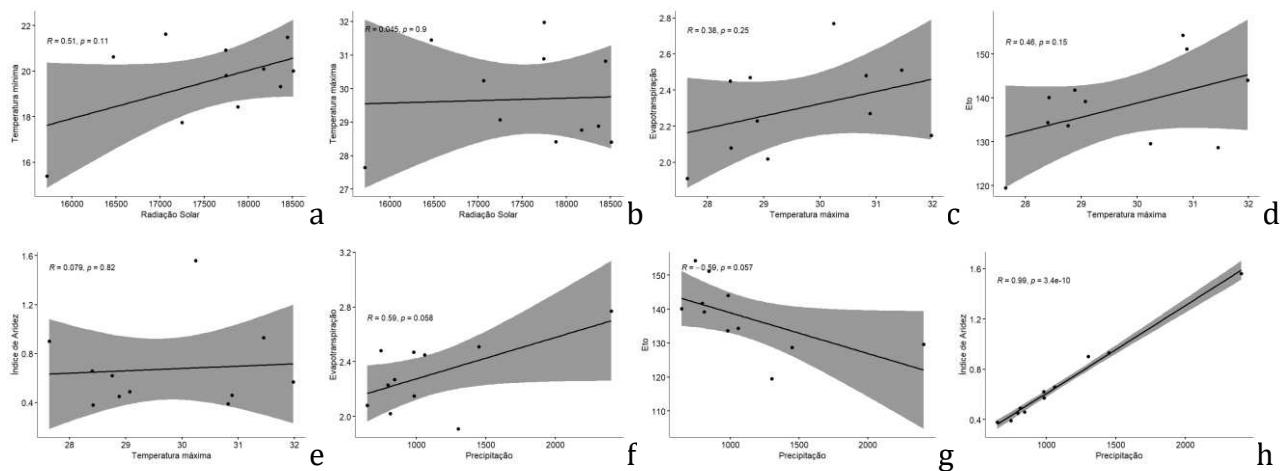


Figura 10. Correlação entre as principais variáveis.

Para o Estado de Pernambuco o coeficiente de correlação de Pearson calculado por Oliveira et al. (2019) para a precipitação mensal e anual apresentou valores acima de 0,90. Para os Estados da Bahia e Pernambuco, Lopes et al. (2018) obtiveram correlação entre a precipitação e o índice de aridez de 0,83.

Cabral Júnior e Bezerra (2018), analisando a evapotranspiração de referência e do índice de aridez para o Nordeste do Brasil identificaram que o índice de aridez depende predominantemente da precipitação, corroborando com a correlação deste trabalho.

Lopes et al. (2018), concluíram que a elevação das temperaturas pode ser explicada pela série histórica, sendo o principal fator climático responsável pela redução do índice de aridez

na região central do Semiárido brasileiro. Para o sertão pernambucano as altas temperaturas e baixos índices pluviométricos exerceram maiores relações com o índice de aridez. Em avaliação conjunta, a variação da temperatura explica o aumento das condições de aridez.

## **CONCLUSÃO**

Pelos resultados obtidos neste trabalho observou-se que os dados do WordClim® v2.1 se apresentaram como uma ferramenta robusta na análise das variáveis climáticas.

Os maiores valores de radiação solar foram observados no Estado de Alagoas com maior variabilidade e maior desvio padrão em Minas Gerais.

A temperatura máxima apresentou maiores valores no Piauí e mínimos em Minas Gerais.

A menor precipitação total ocorreu na região semiárida e maior precipitação no Amapá.

A evapotranspiração apresentou maiores valores na região litorânea e na Amazônica, e menores valores em Minas Gerais. Quanto a Eto verificou-se comportamento inverso.

Os menores valores do índice de aridez ocorreram na região semiárida entre 0,19 a 0,31.

Os testes de normalidade das variáveis demonstraram que os dados são normalmente distribuídos.

Na correlação entre as principais variáveis, verificou-se que a precipitação e o índice de aridez apresentaram valores de  $R=0,99$ , seguida das correlações entre precipitação e evapotranspiração e Eto.

## **REFERÊNCIAS BIBLIOGRÁFICAS**

- ALLAN, R.; PEREIRA, L.; SMITH, M. Crop evapotranspiration-guidelines for computing crop water requirements. FAO Irrigation and Drainage paper 56. Food and Agriculture Organization, Rome, 1998.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. Meteorologische Zeitschrift, v.22, n.6, p.711-728, 2013.
- ALVES, L. M. Clima da Região Centro-oeste do Brasil. In: CAVALCANTI, I. F. A.; FERREIRA, N. J.; SILVA, M. G. A. J.; DIAS M. A. F. S. (Eds.). Tempo e Clima no Brasil. Oficina de Textos, São Paulo, p.235–241, 2009.
- ANDERSON, T. W.; DARLING, D. A. A test of goodness of t. Journal of American Statistical Association, v.49, p.765-769, 1954.

ANWAR, S. A.; MAMADOU, O.; DIALLO, I.; SYLLA, M. B. On the influence of vegetation cover changes and vegetation-runoff systems on the simulated summer Potential Evapotranspiration of Tropical Africa using RegCM4. *Earth Syst. Environ.*, v.5, p.883–897, 2021.

ATTORRE, F.; ALFO, M.; DE SANCTIS, M.; BRUNO, F. Comparison of interpolation methods for mapping climatic and bioclimatic variables at regional scale. *International Journal Climatology*, v.1843, 1825-1843, 2007.

AZUPURA, M.; DOS RAMOS, K. A comparison of spatial interpolation methods for estimation of average electromagnetic field magnitude. *Prog. Electromagn. Res.*, v.14, p.135-145, 2010.

BALLABIO C.; BORRELLI, P.; SPINONI, J.; MEUSBURGER, K.; MICHAELIDES, S.; BEGUERÍA, S.; KLIK, A.; PETAN, S.; JANEČEK, M.; OLSEN, P.; AALTO, J.; LAKATOS, M.; RYMSZEWICZ, A.; DUMITRESCU, A.; TADIĆ, M. P.; DIODATO, N.; KOSTALOVA, J.; ROUSSEVA, S.; BANASIK, K.; ALEWELL, C.; PANAGOS, P. Mapping monthly rainfall erosivity in Europe. *Science of the Total Environment*, v.579, p.1298-1315, 2017.

BARROS, A. H. C.; ARAÚJO FILHO, J. C. DE; SILVA, A. B. DA; SANTIAGO. G. A. C. F. Climatologia do Estado de Alagoas. Boletim de Pesquisa e Desenvolvimento, n.211. Recife: Embrapa Solos, 2012. 32p.

BAYER, C. Manejando os solos agrícolas para alta qualidade em ambientes tropicais e subtropicais. In: FERTBIO, 26, 2004, Lages. Anais...Lages, 2004.

BECK, H. E.; ZIMMERMANN, N. E.; MCVICAR, T. R.; VERGOPOLAN, N.; BERG, A.; WOOD, E. F. Data Descriptor: Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Scientific Data*, v.5, e180214, 2018.

BLEY JR., C. Erosão Solar: riscos para a agricultura nos trópicos. *Ciência Hoje*, v.25, n.148, p.24-29, 1999.

BUFFO, J.; FRITSCHEN, L. J.; MURPHY, J. L. Direct solar radiation on various slopes from 0 to 60 degrees north latitude. Portland: Pacific Northwest Forest and Range Experiment Station, 1972. 74p.

CABRAL JÚNIOR, J. B.; BEZERRA, B. G. Análises da evapotranspiração de referência e do índice de aridez para o Nordeste do Brasil. *REGNE*, v.4, n.1, p.71-89, 2018.

CORREIA, M. F.; SILVA, F. S.; ARAGÃO, M. R. S.; SANTOS, E. P.; MOURA, M. S. B. Impacto da expansão agrícola na amplitude térmica diária em ambiente semiárido. *Ciência e Natura*, n. supl., p.311-314, 2011.

- DE ANGELIS, C. F. Análise dos sistemas precipitantes no Brasil a partir de dados processados em um integrador de informações adquiridas por pluviômetros, satélites, rede de relâmpagos e radares meteorológicos - PRECIBRA. Projeto de Pesquisa CPTEC-INPE, 2005.
- FICK, S. E.; HIJMANS, R. J. Worldclim 2: New 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*, v.37, n.12, p.4302-4315, 2017.
- FRANCISCO, P. R. M.; MEDEIROS, R. M. DE; MATOS, R. M. DE; BANDEIRA, M. M.; SANTOS, D. Análise e mapeamento dos Índices de Umidade, Hídrico e Aridez através do BHC para o Estado da Paraíba. *Revista Brasileira de Geografia Física*, v.8, n.4, p.1093-1108, 2015.
- FRANCISCO, P. R. M.; MEDEIROS, R. M. DE; MATOS, R. M. DE; SANTOS, D.; SOUSA, T. P. DE. Análise e mapeamento da evaporação para o Estado da Paraíba. *Agropecuária Científica no Semi-Árido*, v.11, n.2, p.111-121, 2015.
- FRANCISCO, P. R. M.; MEDEIROS, R. M.; MATOS, R. M.; BANDEIRA, M. M.; SANTOS, D. Análise e mapeamento dos Índices de Umidade, Hídrico e Aridez através do BHC para o Estado da Paraíba. *Revista Brasileira de Geografia Física*, v.8, n.4, p.1093-1108, 2016.
- GAIPE. Global Aridity Index and Potential Evapotranspiration (ET0) Climate Database. Disponível em: [https://figshare.com/articles/dataset/Global\\_Aridity\\_Index\\_and\\_Potential\\_Evapotranspiration\\_ET0\\_Climate\\_Database\\_v2/7504448/4](https://figshare.com/articles/dataset/Global_Aridity_Index_and_Potential_Evapotranspiration_ET0_Climate_Database_v2/7504448/4). Acesso em: 5 de abril de 2024.
- GOLFARI, L.; CASER, R. L.; MOURA, V. P. G. Zoneamento ecológico esquemático para reflorestamento no Brasil. PRODEPEF 11. 1978. 66p.
- GRIMM, A. M. Clima do Sul do Brasil. In: CAVALCANTI, I. F. A.; N. J. FERREIRA, N. J.; SILVA, M. G. A. J.; DIAS M. A. F. S. (Eds.). *Tempo e Clima no Brasil*. Oficina de Textos, São Paulo, p.259–275, 2009.
- HIJMANS, R. J.; CAMERON, S. E.; PARRA, J. L.; JONES P. G.; JARVIS, A. Very high resolution interpolated climate surfaces for global land areas. *International Journal of Climatology*, v.25, p.1965-1978, 2005.
- IMBACH, P.; MOLINA, L.; LOCATELLI, B.; ROUPSARD, O.; CIAIS, P.; CORRALES, L.; MAHÉ, G. Climatology-based regional modelling of potential vegetation and average annual long-term runoff for Mesoamerica. *Hydrology and Earth System Sciences*, v.14, n.10, p.1801–1817, 2010.
- IPCC. Summary for Policymakers. In: *Climate Change 2021: The Physical Science Basis*. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. 2021.

IPCC. Summary for Policymakers. In: Climate Change and Land: an IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems. 2019.

JENSEN, M. E.; ALLEN, R. G. (eds.). Evaporation, Evapotranspiration, and Irrigation Water Requirements: Task Committee on Revision of Manual 70. American Society of Civil Engineers (ASCE), 2016.

LILLIEFORS, H. W. On the Kolmogorov-Smirnov test for normality with mean and variance unknown. Journal of the American Statistical Association, v.62, n.318, p.399-402, 1967.

LOPES, I.; MELO, J. M. M. DE; CARVALHO, A. A. DE; MOURA, G. B. DE A.; LEAL, B. G. Análise multivariada no estudo da variação do Índice de Aridez da Bahia e Pernambuco. Agrometeoros, v.26, n.1, p.93-102, 2018.

LUGATO, E.; PAUSTIAN, K.; PANAGOS, P.; JONES, A.; BORRELLI, P. Quantifying the erosion effect on current carbon budget of European agricultural soils at high spatial resolution. Global Change Biology, v.22, n.5, p.1976-1984, 2016.

MARCHI, M.; CHIAVETTA, U.; CASTALDI, C.; DUCCI, F. Does complex always mean powerful? A comparison of eight methods for interpolation of climatic data in Mediterranean area. Italian Journal Agrometeorology, v.1, p.59-72, 2017.

MARCHI, M.; SINJUR, I.; BOZZANO, M.; WESTERGREN, M. Evaluating WorldClim Version 1 (1961–1990) as the Baseline for Sustainable Use of Forest and Environmental Resources in a Changing Climate. Sustainability, v.11, n.11, e3043, 2019.

MARENGO, J. A.; CHOU, S. C.; KAY, G.; ALVES, L. M.; PESQUERO, J. F.; SOARES, W. R.; SANTOS, D. C.; LYRA, A. A.; SUEIRO, G.; BETTS, R.; CHAGAS, D. J.; GOMES, J. L.; BUSTAMANTE, J. F.; TAVARES, P. Development of regional future climate change scenarios in South America using the Eta Cptec/HadCM3 climate change projections: climatology and regional analyses for the Amazon, São Francisco and the Paraná River basins. Climate Dynamics, v.38, p.1829-1848, 2012.

MARENGO, J. A.; NOBRE, C. A. Clima da Região Amazônica. In: CAVALCANTI, I. F. A.; FERREIRA, N. J.; SILVA, M. G. A. J.; DIAS M. A. F. S. (Eds.). Tempo e Clima no Brasil. Oficina de Textos, São Paulo, p.197–212, 2009.

MBOGGA, M. S.; HAMANN, A.; WANG, T. Historical and projected climate data for natural resource management in western Canada. Agric. For. Meteorol., v.149, p.881-890, 2009.

MEDEIROS, R. M. DE; FRANCISCO, P. R. M.; MATOS, R. M. DE; SANTOS, D.; SABOYA, L. M. F. Diagnósticos das flutuações pluviométricas no Estado da Paraíba. Revista Brasileira de Geografia Física, v.8, n.4, p.1017-1027, 2015.

- MEDEIROS, R. M. DE; FRANCISCO, P. R. M.; SANTOS, D.; SILVA, L. L. DA; BANDEIRA, M. M. Variabilidade da Temperatura Média do Ar no Estado da Paraíba-Brasil. Revista Brasileira de Geografia Física, v.8, n.1, p.128-135, 2015.
- MEDEIROS, R. M. DE; FRANCISCO, P. R. M.; TAVARES, A. L. Classificação e análises das indicações de mudanças climáticas no município de Sobral – Ceará. Revista Brasileira de Geografia Física, n.5, p.1056-1067, 2011.
- MORENO, A.; HASENAUER, H. Spatial downscaling of European climate data. International Journal of Climatology, v.36, n.3, p.444-1458, 2016.
- MOSIER, T. M.; HILL, D. F.; SHARP, K. V. Update to the Global Climate Data package: analysis of empirical bias correction methods in the context of producing very high resolution climate projections. International Journal of Climatology, v.38, n.2, p.825-840, 2018.
- MUTTI, P. R.; ABREU, L. P.; ANDRADE, L. M. B.; SPYRIDES, M. H. C.; LIMA, K. C.; OLIVEIRA, C. P. DE; BEZERRA, B. G. A detailed framework for the characterization of rainfall climatology in semi-arid watersheds. Theoretical and Applied Climatology, v.139, n.1-2, p.109-125, 2020.
- NIMER, E. Climatologia do Brasil. Fundação Instituto Brasileiro de Geografia e Estatística. Rio de Janeiro, 1989. 421p.
- NOGUEIRA, V. F. B.; CORREIA, M. F.; NOGUEIRA, V. S. Impacto do plantio de soja e do Oceano Pacífico Equatorial na precipitação e temperatura na cidade de Chapadinha-MA. Revista Brasileira de Geografia Física, v.5, p.708-724, 2012.
- NUNES, L. H.; VICENTE, A. K.; CANDIDO, D. H. Clima da Região Sudeste do Brasil. In: CAVALCANTI, I. F. A.; N. J. FERREIRA, N. J.; SILVA, M. G. A. J.; DIAS, M. A. F. S. (Eds.). Tempo e Clima no Brasil. Oficina de Textos, São Paulo, p.197–212, 2009.
- OLIVEIRA, G. A. DE; BATISTA, L. F. D. R.; CIRILO, J. A.; RIBEIRO NETO, A.; MONTENEGRO, S. M. G. L. Validação de dados matriciais do projeto WORLDCLIM para caracterização de precipitações no Estado de Pernambuco, Brasil. In: Simpósio Brasileiro de Recursos Hídricos, 23, 2019, Foz do Iguaçu. Anais...Foz do Iguaçu, 2019.
- OLIVEIRA, R. C. S.; MEDEIROS, R. M. DE; COSTA NETO, F. DE A.; GOMES FILHO, M. F. Estudo das oscilações da temperatura máxima do ar e precipitação em Lagoa Seca-PB visando mudanças climáticas. In: Workshop de Mudanças Climáticas e Recursos Hídricos do Estado de Pernambuco e Workshop Internacional sobre Mudanças Climáticas e Biodiversidade, 6, 2014, Recife. Anais...Recife, 2014.
- OSEJO, B. B.; VARGAS, T. B.; MARTINEZ, J. A. Spatial distribution of precipitation and evapotranspiration estimates from Worldclim and Chelsa datasets: improving long-term water

balance at the watershed-scale in the Urabá region of Colombia. Int. J. Sus. Dev. Plann., v.14, n.2, p.105–117, 2019.

PANAGOS, P.; BALLABIO, C.; MEUSBURGER, K.; SPINON, J.; ALEWELL, C.; BORRELLI, P. Towards estimates of future rainfall erosivity in Europe based on {REDES} and WorldClim datasets. Journal of Hydrology, v.548, p.251-262, 2017.

PANDEY, P. K.; NYORI, T.; PANDEY, V. Estimation of reference evapotranspiration using data driven techniques under limited data conditions. Model Earth Syst. Environ., v.3, p.1449–1461, 2017.

PERNAMBUCO. Plano Estadual de Recursos Hídricos – PERH/PE. Secretaria de Ciência, Tecnologia e Meio Ambiente. Governo do Estado de Pernambuco. Recife, 1998.

REBOITA, M. S.; RODRIGUES, M.; SILVA, L. F.; ALVES, M. A. Aspectos climáticos do Estado de Minas Gerais. Revista Brasileira de Climatologia, v.11, v.17, p.206-226, 2015.

SOBREIRO, J. F. F.; STREHER, A. S.; SILVA, T. S. F. Análise comparativa de produtos geoespaciais para monitoramento de precipitação em uma região montanhosa tropical. In: Congresso Nacional de Geografia Física, 1, 2017, Campinas. Anais...Campinas, 2017.

SOUZA, W. G. DE; RIBEIRO, A.; AMORIM, R. C. F.; SOUZA, M. J. H. DE; RIBEIRO, C. A. A. S.; FACCO, A. G. Geoespecialização da evapotranspiração potencial e real para a bacia do rio Doce – Minas Gerais. In: Congresso Brasileiro de Meteorologia, 13, 2004, Fortaleza. Anais...Fortaleza, 2004.

TRABUCCO, A.; ZOMER, R. J. Global Aridity Index and Potential Evapo-Transpiration (ET0) Climate Database v2. Disponível em:

[https://classes.engr.oregonstate.edu/cce/spring2019/ce202/Data/global-ai\\_et0/ai\\_et0/Global%20AI\\_PET%20v2%20-%20Readme.pdf](https://classes.engr.oregonstate.edu/cce/spring2019/ce202/Data/global-ai_et0/ai_et0/Global%20AI_PET%20v2%20-%20Readme.pdf). Acesso em: 5 de abril de 2024.

VALIPOUR, M.; BATENI, S. M.; SEFIDKOUHI, M. A. G.; RAEINI-SARJAZ, M.; SINGH, V. P. Complexity of forces driving trend of reference evapotranspiration and signals of climate change. Atmosphere-Basel, v.11, p.1081, 2020.

VAREJÃO-SILVA, M. A. Meteorologia e Climatologia. Recife: INMET, 2006.

VIANA, P. C. Estimativa e espacialização das temperaturas do ar mínimas, médias e máximas com base em um modelo digital de elevação para o Estado do Ceará. Trabalho de Conclusão de Curso. Curso de Graduação em Tecnologia em Irrigação e Drenagem. Instituto Federal de Educação e Ciência Tecnologia. Campus Iguatu, 2010.

VON STORCH, H. Inconsistencies at the interface of climate impact studies and global climate research. Meteorologische Zeitschrift, v.4, p.72–80, 1995.

WORDCLIM. Historical climate data. Disponível em:  
<https://worldclim.org/data/worldclim21.html>. Acesso em: 5 de abril de 2024.

- XAVIER, A. C.; SCANLON, B. R.; KING, C. W.; ALVES, A. I. New improved Brazilian daily weather gridded data (1961–2020). *International Journal of Climatology*, p.1–15, 2022.
- YIGINI, Y.; PANAGOS, P. Assessment of soil organic carbon stocks under future climate and land cover changes in Europe. *Science of The Total Environment*, v.557–558, p.838-850, 2016.
- ZARCH, M. A. A.; SIVAKUMAR, B.; MALEKINEZHAD, H.; SHARMA, A. Future aridity under conditions of global climate change. *Journal of Hydrology*, v.554, p 451-469, 2017.
- ZOMER, R. J.; XU, J.; TRABUCCO, A. Version 3 of the Global Aridity Index and Potential Evapotranspiration Database. *Scientific Data*, v.9, e409, 2022.
- ZOTARELLI, L.; DUKES, M. D.; ROMERO, C. C.; MIGLIACCIO, K. W.; MORGAN, K. T. Step by Step Calculation of the Penman-Monteith Evapotranspiration (FAO-56 Method)1. University of Florida. IFAS Extension, 2018.

## CAPÍTULO II

# PROJEÇÃO CLIMÁTICA DA PLUVIOSIDADE E TEMPERATURA DO AR DA REGIÃO CONTINENTAL BRASILEIRA ENTRE 2021 A 2040 SIMULADA POR MODELOS DO CMIP6-SSP126/245/370

## INTRODUÇÃO

A precipitação é uma das variáveis mais importantes para a caracterização do clima e para o estudo de impactos hidrológicos face às mudanças climáticas (MONTEIRO et al., 2021). A América do Sul, como tem grande parte do seu território em área tropical, recebe anualmente volumes elevados de precipitação. Além disso, há grande variabilidade temporal e espacial da precipitação (REBOITA et al., 2010; MONTEIRO et al., 2021; REBOITA & AMBRIZZI, 2022).

Para o Brasil, vários estudos têm observado pela modelagem por projeções climáticas, o aumento da frequência de extremos climáticos em diversas regiões do país (MARENGO et al., 2013; SOUSA, 2017; NATIVIDADE et al., 2017; BRITO et al., 2019). Problemas com a falta de chuva também fazem parte da história recente, como os eventos que ocorreram na Amazônia entre 2005 a 2016 e em grande parte do território brasileiro em 2014 e 2015 (MARENGO, 2009; MARENGO et al., 2011; 2017; COELHO et al., 2015; RIBEIRO NETO et al., 2021). A região Nordeste tem um histórico de secas (MARENGO et al., 2020, MARENGO & BERNASCONI, 2015), dentre essas, destaca-se a seca plurianual na região entre 2011-2018 (CUNHA et al., 2018; MARENGO et al., 2017).

Em decorrência de processos naturais, tais como a dinâmica das massas de ar, correntes marinhas, erupções vulcânicas, entre outros, o clima da Terra está sempre mudando ao longo do tempo, sendo a modelagem numérica essencial para aprimorar o conhecimento a respeito dos componentes do sistema climático, bem como para elencar os possíveis impactos da mudança do clima em diversos setores importantes de um país, como por exemplo, os de recursos hídricos, energético, agricultura, etc. (SANTOS et al., 2020).

De acordo com Allen et al. (2018), o resultado dessa modelagem é um dos principais componentes nos estudos de vulnerabilidade climática e de elaboração de medidas e estratégias de adaptação às mudanças climáticas atuais e porvir, servindo como base para análises de risco e vulnerabilidade, e para, assim, propor políticas de Estado para mitigação.

O Painel Intergovernamental de Mudança do Clima (IPCC, Intergovernmental Panel on Climate Change), uma das mais importantes organizações que avaliam as alterações do clima e seus impactos no mundo, também analisam projeções oriundas de modelos climáticos acoplados atmosfera-oceano (FERREIRA & VALVERDE, 2022). Os modelos climáticos acoplados atmosfera-oceano são utilizados para realizar projeções com cenários de emissões de CO<sub>2</sub>, os quais têm evoluído consideravelmente. Atualmente, no seu 6.o relatório (AR6-IPCC) utiliza os cenários de emissões Shared Socioeconomic Pathways (SSP) que fazem parte de uma nova estrutura de cenários, a fim de facilitar a análise integrada de futuros impactos climáticos, vulnerabilidades, adaptação e mitigação (RIAHI et al., 2017).

O recente relatório do IPCC (AR6) afirma que, as mudanças projetadas para os extremos de clima serão maiores em frequência, com cada incremento adicional de aquecimento. Isto é, um evento extremo que ocorria a cada 10 anos, para um cenário de aquecimento com anomalia de 1,5°C poderia ocorrer com uma frequência de até quatro vezes a mais a cada 10 anos, como seria o caso das ondas de calor (IPCC, 2021).

De acordo com Marengo et al. (2012), nas últimas décadas, tanto os modelos climáticos globais (MCGs), quanto os modelos climáticos regionais (MCRs), têm tido grandes avanços na representação dos componentes do sistema climático, principalmente devido à melhor representação dos processos físicos e fenômenos a eles associados e as suas interações. A melhoria na resolução e nas parametrizações físicas dos modelos tem permitido uma representação mais detalhada das características da paisagem, como cordilheiras, lagos, tipos de vegetação e características do solo, levando a uma melhor caracterização do ciclo hidrológico e dos eventos extremos associados, bem como a uma representação mais realista do clima regional/local em comparação aos modelos com resoluções mais baixas (100-200 km) (AMBRIZZI et al., 2019; CHOU et al., 2014; FLATO et al., 2013; NAUMANN et al., 2018).

Dias e Reboita (2021) afirmam que, uma forma de identificar as melhores projeções futuras para uma região, é obtendo a classificação dos melhores modelos no período histórico. Assim, é possível filtrar apenas os modelos que melhor descrevem o comportamento de determinada região. Os autores ainda observam que, a área de estudos do clima futuro é custosa financeiramente, uma vez que, necessita de computadores potentes para executar os modelos numéricos e de espaço físico para guardar as simulações. Além disso, demanda de uma equipe de profissionais com experiência na área. Não obstante, os usuários desses dados também necessitam de espaço em disco para armazenarem os dados para seus estudos. Diante disso, para a redução de custos por parte dos usuários de simulações e projeções numéricas, uma estratégia é avaliar os modelos que melhor representam o clima presente no local de interesse e selecioná-los para gerar as avaliações do clima futuro, sem necessitar de todos os modelos disponíveis.

As primeiras projeções de mudanças climáticas sobre a América do Sul foram realizadas a partir de modelos climáticos regionais (AMBRIZZI et al., 2007; MARENGO & AMBRIZZI, 2006; MARENGO et al., 2009). Experiências em regionalização das projeções de clima dos modelos globais usando modelos regionais (*downscaling* dinâmico), de acordo com Correa et al. (2022), têm sido reportadas na literatura (CHOU et al., 2012, 2014, 2020; IPCC, 2014, 2021; PBMC, 2013, SOLMAN et al., 2013). Chou et al. (2014) avaliaram as simulações da temperatura e precipitação para o Brasil a partir do modelo regional Eta conduzidas por três modelos globais, o Hadley Centre Global Environmental (HadGEM2-ES), o Brazilian Earth System Model (BESM) e o Model for Interdisciplinary Research on Climate (MIROC5).

Diversas pesquisas foram realizadas com simulados por modelos climáticos do CMIP6 para diversas regiões brasileira, como de Bosco e Valverde (2022), Correa et al. (2022), Ferreira e Valverde (2022), Naitzel (2021), Santos et al. (2020), Avila-Diaz et al. (2020), Natividade et al. (2017), Lyra et al. (2017), Menezes et al. (2016) e Jones e Carvalho (2013). Dias e Reboita (2021), avaliaram a performance de 46 modelos do CMIP6 sobre a bacia do Rio São Francisco e sobre o Brasil tropical, encontrando o EC-Earth3-Veg, MPI-ESM1-2-LR e outros como modelos de melhor performance em simular a precipitação sazonal.

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 da região continental brasileira utilizando geotecnologias.

## MATERIAL E MÉTODOS

A área de estudo compreende a área do território brasileiro 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/m<sup>2</sup>, respectivamente). A Representative Concentration Pathways (RCP) (Forçante Radiativa) é expressa na unidade W/m<sup>2</sup> 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 VUREN 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.

## RESULTADOS E DISCUSSÃO

Na Figura 1 observa-se o comportamento mensal anual da distribuição sazonal da projeção da temperatura média mínima para o ssp126 de 21,14°C, para o ssp245 de 19,46°C e ssp370 de 19,55°C, demonstrando uma tendência de resfriamento de 1,59°C, de acordo com a Figura 2 da distribuição sazonal da temperatura mínima. Resultado similar ao de Santos et al. (2020), levando em consideração as décadas de 2020 a 2040 totalizando 1,5°C, em que observaram uma tendência de resfriamento de até 0,5°C por década, porém de forma pontual em algumas áreas do País principalmente para a estação de outono. Resultado este, obtido do Climate Prediction Center/National Oceanic and Atmospheric Administration (CPC/NOAA) do RX5day e CDD, e do Rainfall Estimates from Rain Gauge and Satellite Observations – Chirps2 (FUNK et al., 2015).

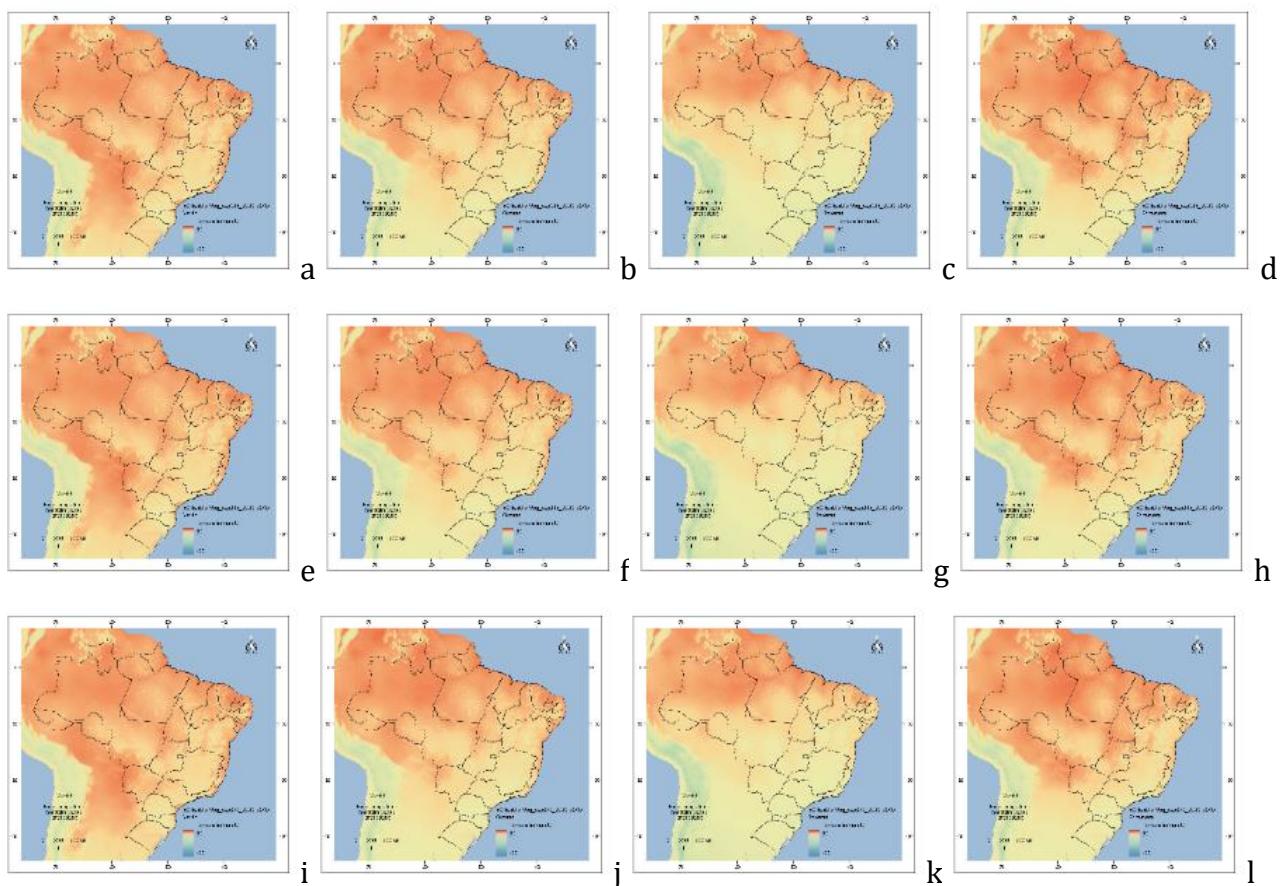


Figura 1. Distribuição sazonal da temperatura média mínima ( $^{\circ}\text{C}$ ) do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

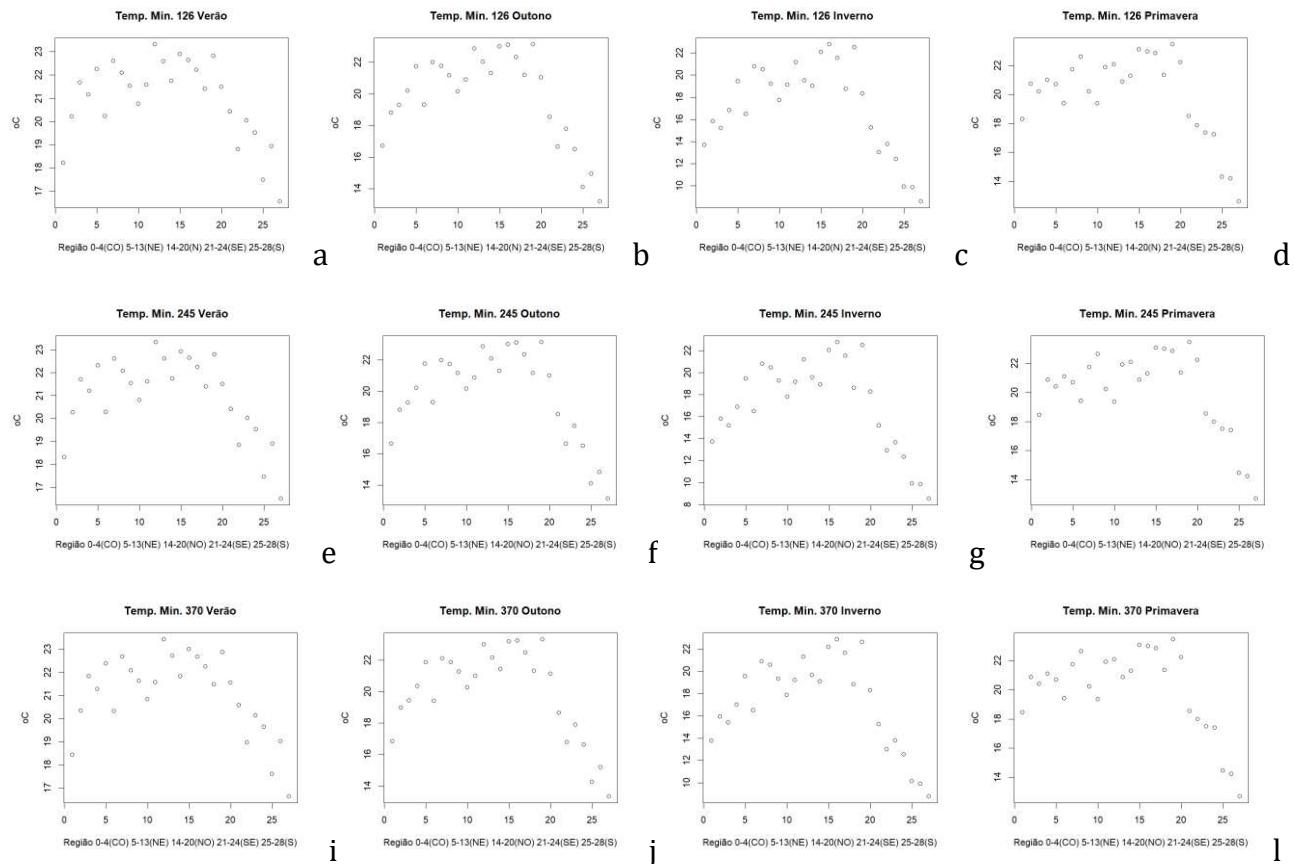


Figura 2. Distribuição da temperatura média mínima ( $^{\circ}\text{C}$ ) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

Na Figura 3, do comportamento da distribuição sazonal da projeção da temperatura média máxima para o ssp126/ssp245/ssp370, observa-se que demonstra uma tendência de manter a temperatura máxima em  $30^{\circ}\text{C}$  sem incrementos significativos, como pode-se verificar na Figura 4, nos gráficos de distribuição.

De acordo com Fan et al. (2020), os modelos do CMIP6 tendem a subestimar as temperaturas de maio a agosto para o Brasil e América do Sul, pois os dados observados, estão mais próximos à mediana nas demais estações do ano. Ortega et al. (2021) destacam que, tanto as simulações do CMIP6 quanto as do CMIP5 representam melhor os padrões de temperatura do que os de precipitação.

Almazroui et al. (2021) afirmam que, as projeções das temperaturas dos modelos do CMIP6, para aumentos da temperatura na América do Sul são robustos em termos de magnitude, mesmo sob o SSP1 2.6 que é um cenário menos extremo.

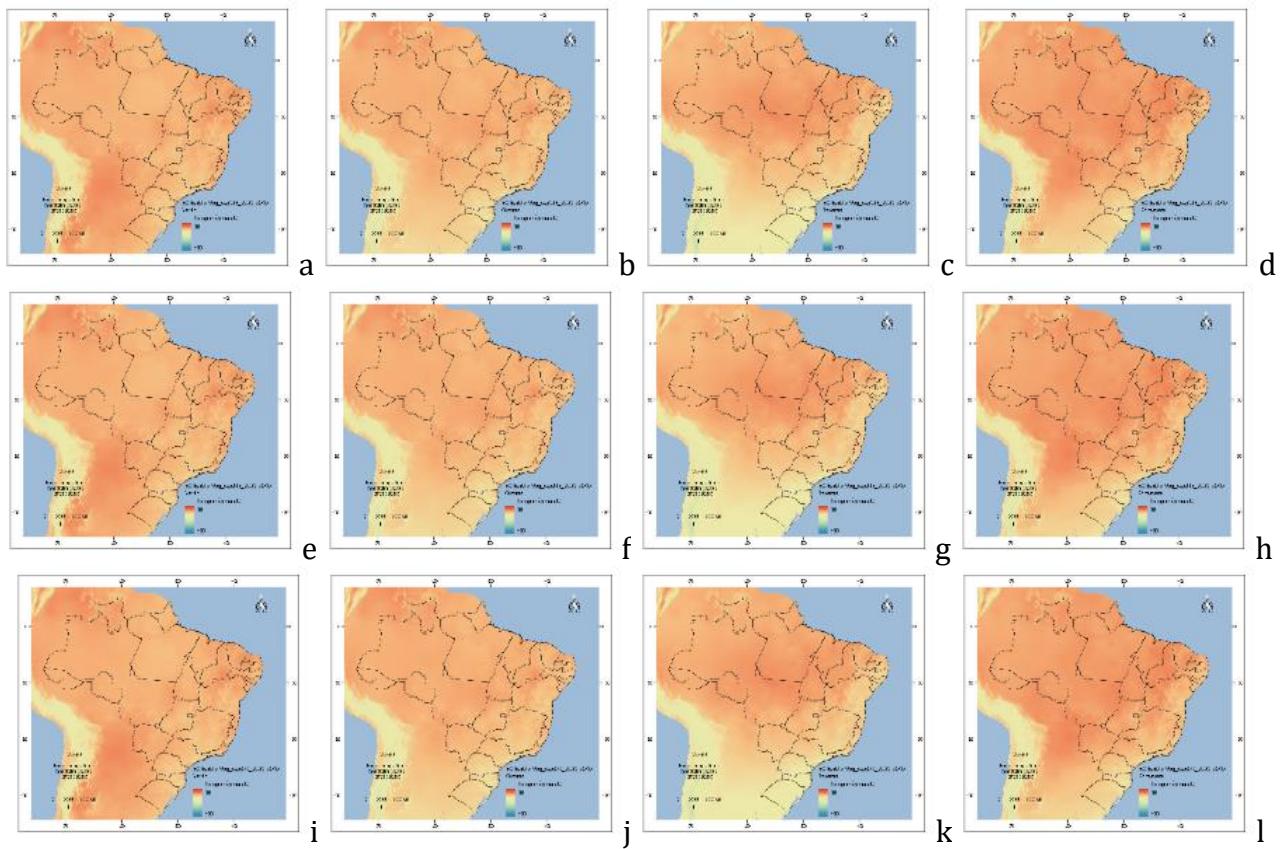


Figura 3. Distribuição sazonal da temperatura média máxima ( $^{\circ}\text{C}$ ) do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

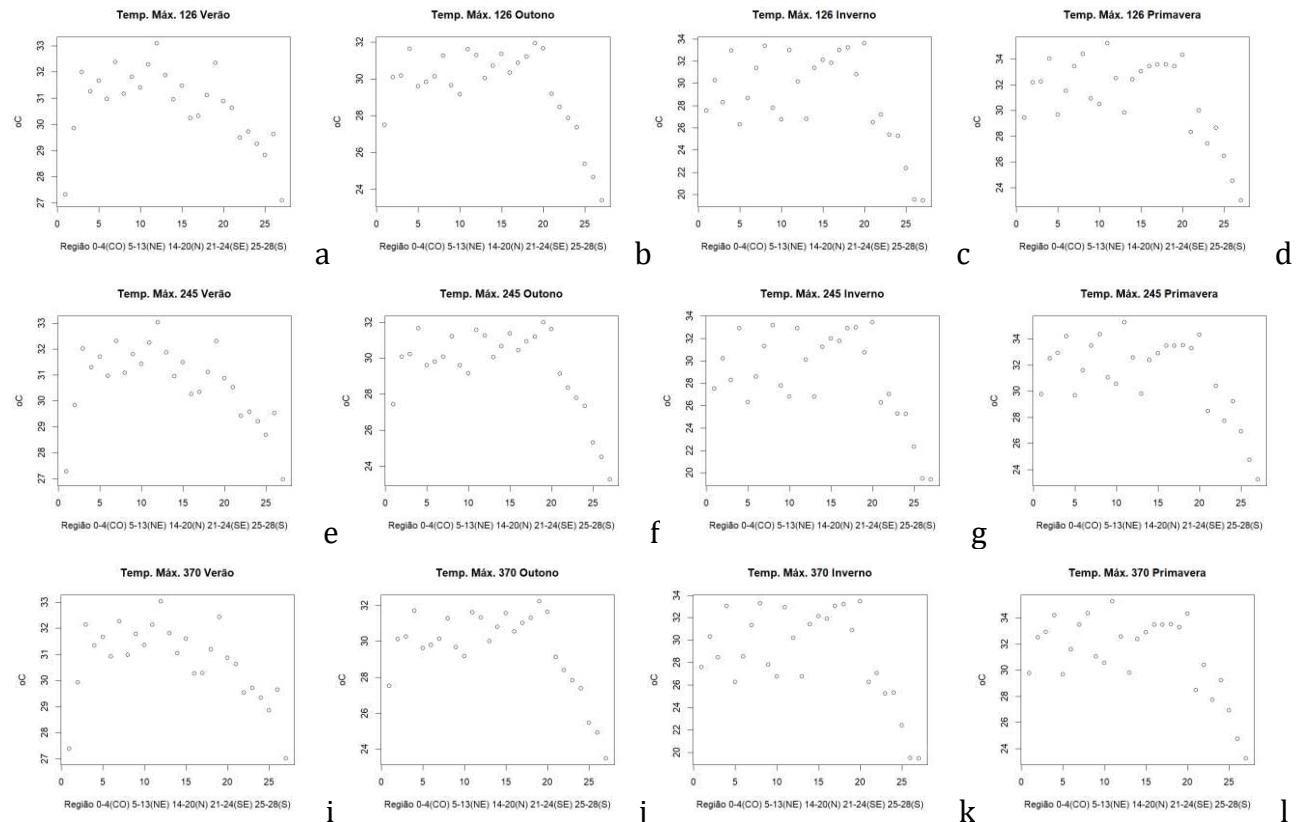


Figura 4. Distribuição da temperatura média máxima ( $^{\circ}\text{C}$ ) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

No comportamento da distribuição sazonal da projeção da precipitação média (Figura 5), esta distribuição reflete a variabilidade espaço-temporal do clima do Brasil, estando de acordo com Correa et al. (2022). Observa-se para o ssp126, o valor de 126,4mm, para o ssp245 de 120,69mm e para o ssp370 o valor de 121,44mm, onde demonstra uma tendência de diminuição de 5mm na precipitação futura distribuída para todo o Brasil. Valor pouco significativo estimado na projeção elaborada pelo CMIP6, como pode-se verificar na distribuição apresentado na Figura 6.

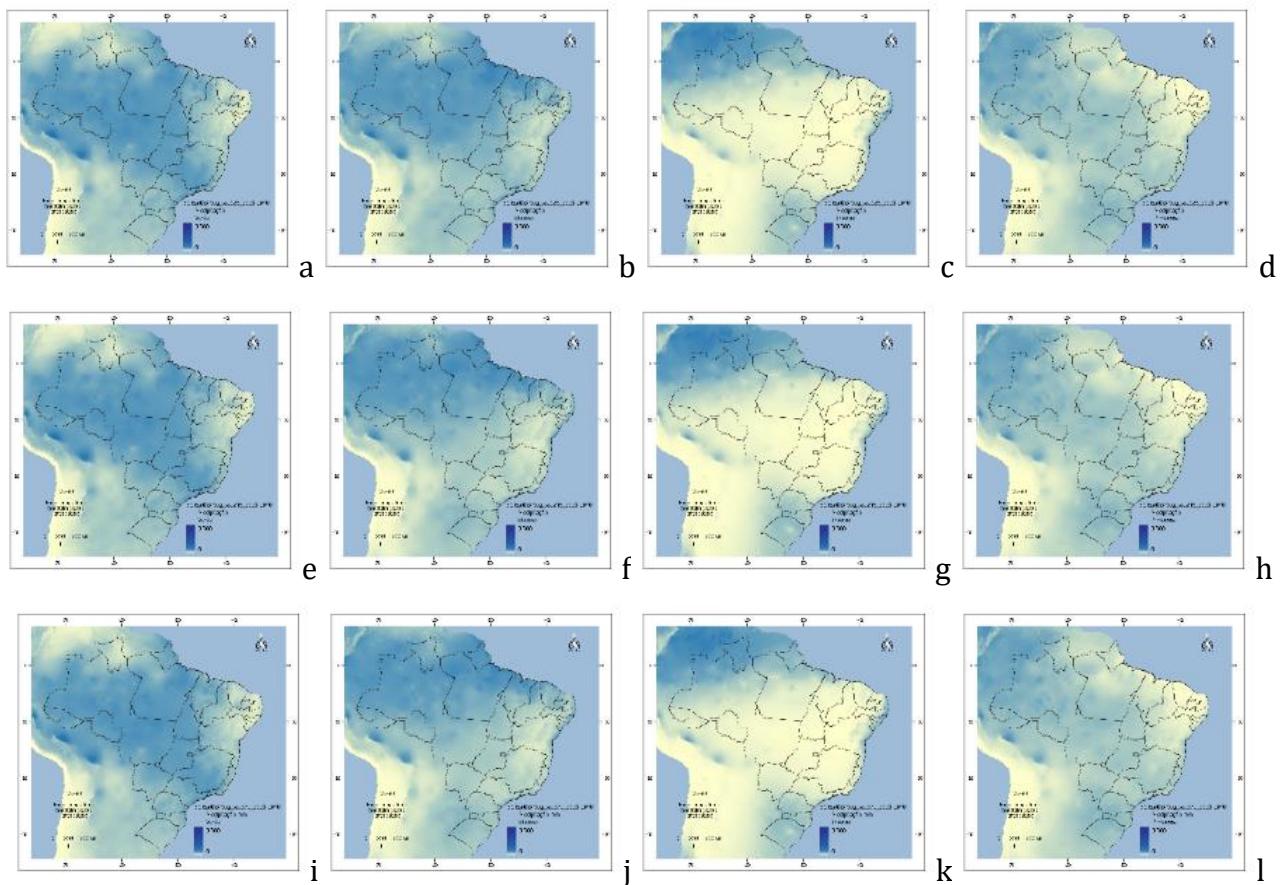


Figura 5. Distribuição sazonal da precipitação média (mm) do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

De acordo com Bosco e Valverde (2022), as projeções climáticas de precipitação em cenários futuros nas escalas global, regional e sub-regional, continuam não tendo consenso, o que ainda denota altas incertezas, este foi um assunto levantado no último relatório (AR6), as Bases Físicas do IPCC (IPCC, 2021).

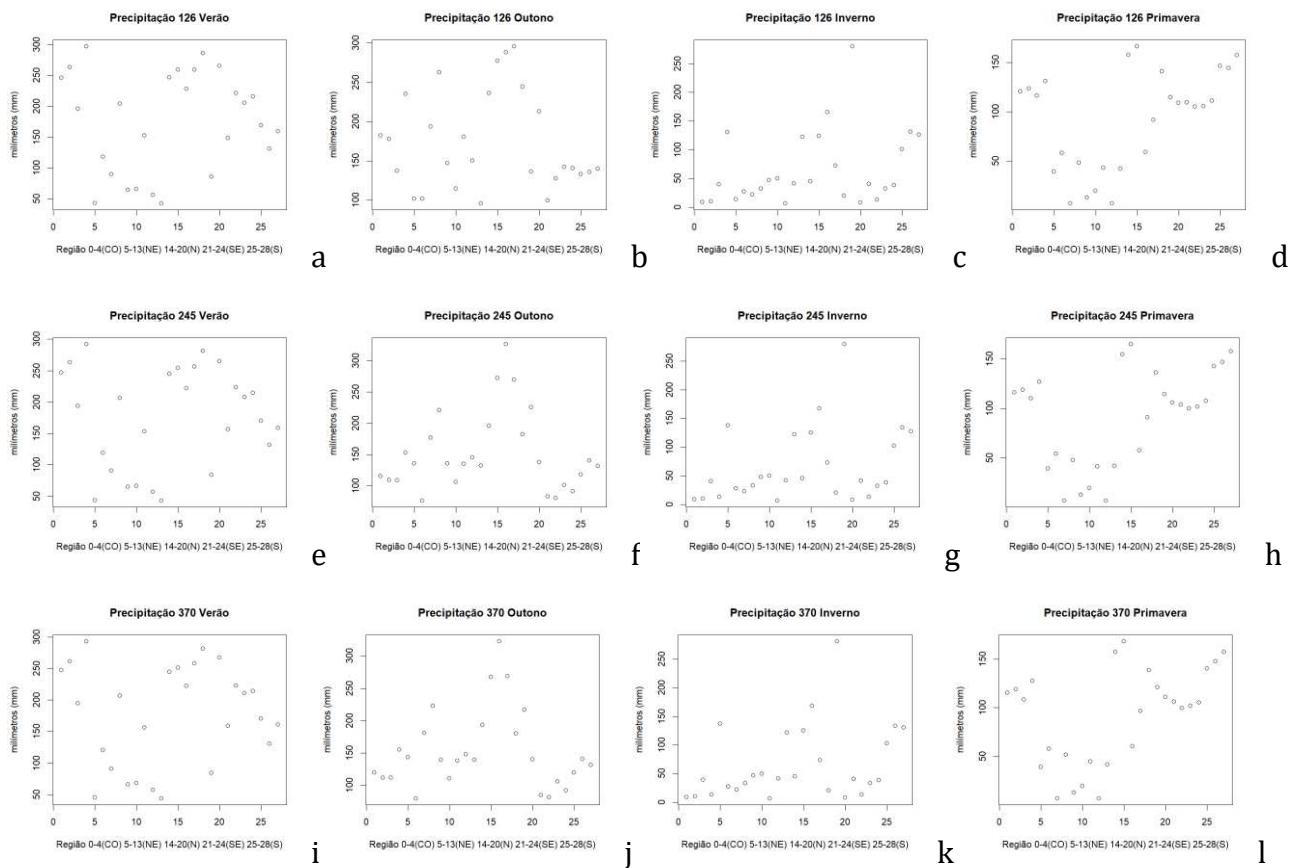


Figura 6. Distribuição da precipitação média (mm) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

Na Figura 7, observa-se a distribuição anual da temperatura máxima e mínima e da precipitação para o Brasil, onde verifica-se sua mínima variabilidade entre o ssp126/245/370. Destaca-se que, o conjunto CMIP6 consegue simular o ciclo anual das variáveis climáticas para toda a região de estudo, porém, no geral, a variação desta reflete a variabilidade do clima do Brasil em suas diversas regiões. Resultado similar observado por Correa et al. (2022).

Bosco e Valverde (2022) afirmam que, as projeções das temperaturas dos modelos do CMIP6, para aumentos da temperatura na América do Sul são robustos em termos de magnitude, mesmo sob o SSP1 2.6 que é um cenário menos extremo.

Correa et al. (2022) afirmam que, a má representação de alguns componentes do ciclo hidrológico (umidade do solo, fluxos superficiais e tipos de vegetação) ou a dificuldade de parametrização convectiva pelos modelos globais podem levar a superestimação ou subestimação dos dados (MARENGO et al., 2009, 2012; SOARES & MARENGO, 2009; MARTIN et al., 2011; CHOU et al., 2014; DERECZYNSKI et al., 2020).

Almazroui et al. (2021) avaliou o desempenho dos 38 modelos globais acoplados do CMIP6 para a América do Sul, e examinou as projeções de precipitação e temperatura até o

século XXI, considerando quatro caminhos socioeconômicos (SSP1 2.6, SSP2 4.5, SSP3 7.0 e SSP5 8.5). Os resultados mostraram que os modelos do CMIP6 capturam com sucesso as principais características climáticas da América do Sul.

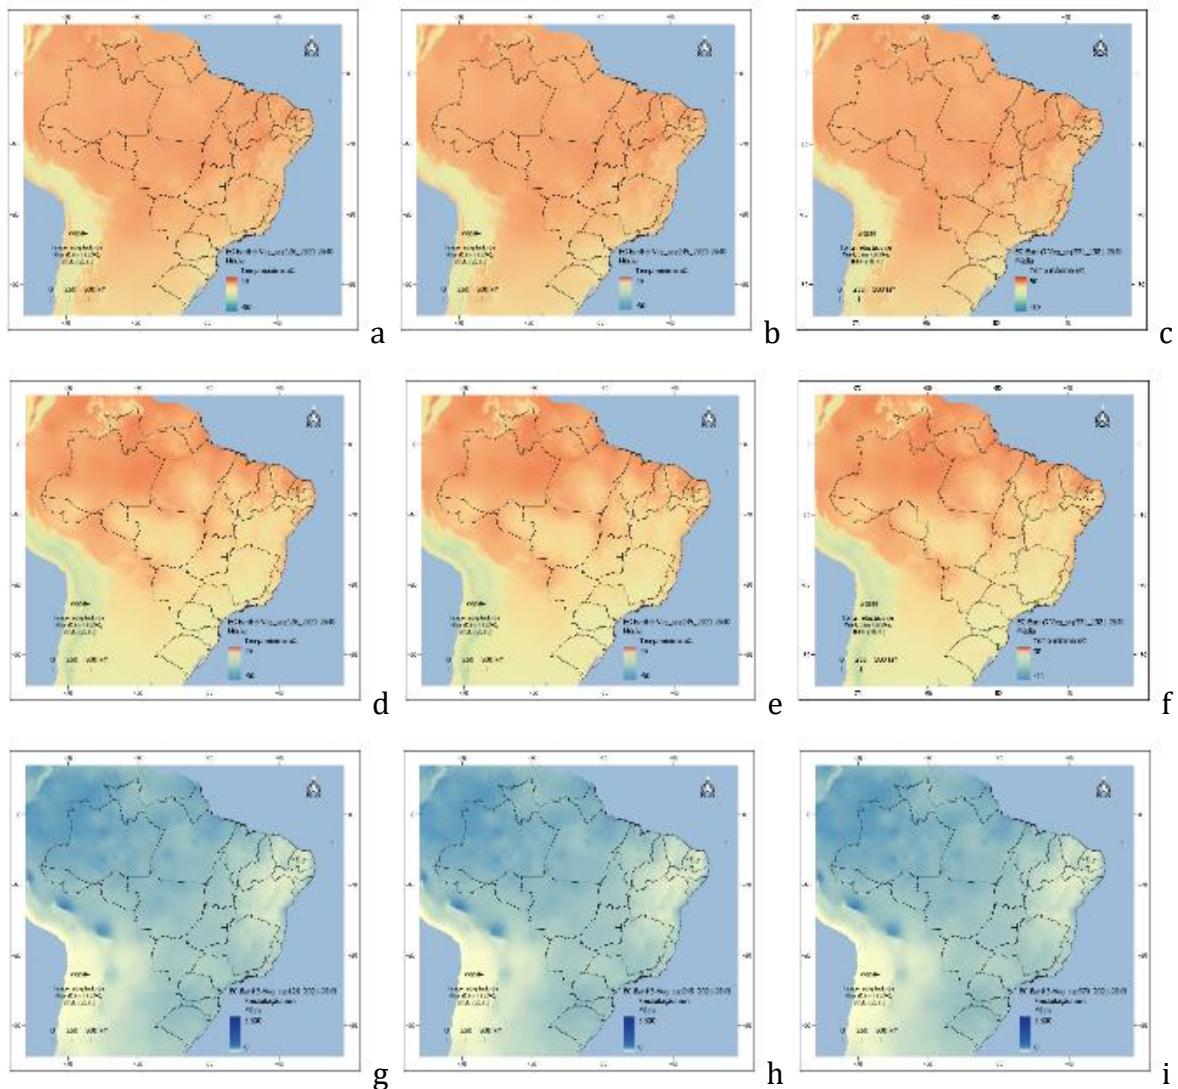


Figura 7. Distribuição anual média (a, b, c) da temperatura máxima ( $^{\circ}\text{C}$ ), (d, e, f) temperatura mínima ( $^{\circ}\text{C}$ ), (g, h, i) precipitação (mm) do ssp126/ssp245/ssp370.

Nos testes de normalidade, tendência e aderência (Tabela 1) pode-se observar que o teste de Shapiro-Wilk evidencia que os dados testados não são normalmente distribuídos, ou seja, é uma distribuição diferente da normal, isto devido a área de estudo ser continental e com diversidade na distribuição da precipitação e da temperatura.

No teste de Kolmogorov-Smirnov com o valor  $p < 2,2 \times 10^{-16}$  indica uma probabilidade extremamente pequena de observar os dados, portanto rejeita-se a hipótese nula. O *p*-valor do

teste Mann-Kendall nas estações sazonais do inverno e primavera da precipitação ssp245 e ssp370 apresentam tendência significativa na série da projeção da mudança climática.

Tabela 1. 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	0,931	0,071	1	< 2,2e-16	64,82	0,262	0,009	0,967
P126O	0,904	0,016	1	< 2,2e-16	14,19	0,014	-0,071	0,617
P126I	0,800	0,000	1	< 2,2e-16	18,33	0,003	0,271	0,050
P126P	0,921	0,042	1	< 2,2e-16	70,74	0,215	0,259	0,061
P245V	0,926	0,056	1	< 2,2e-16	76,67	0,176	0,020	0,900
P245O	0,880	0,005	1	< 2,2e-16	15,37	0,009	-0,003	1,000
P245I	0,805	0,000	1	< 2,2e-16	18,33	0,003	0,276	0,045
P245P	0,930	0,068	1	< 2,2e-16	82,59	0,143	0,276	0,045
P370V	0,927	0,059	1	< 2,2e-16	58,89	0,317	0,020	0,900
P370O	0,885	0,006	1	< 2,2e-16	88,52	0,115	-0,009	0,967
P370I	0,803	0,000	1	< 2,2e-16	18,33	0,003	0,282	0,041
P370P	0,933	0,083	1	< 2,2e-16	76,67	0,176	0,276	0,045
TM126V	0,941	0,129	1	< 2,2e-16	58,89	0,317	-0,368	0,008
TM126O	0,859	0,002	1	< 2,2e-16	15,96	0,007	-0,214	0,123
TM126I	0,912	0,026	1	< 2,2e-16	82,59	0,143	-0,231	0,095
TM126P	0,917	0,033	1	< 2,2e-16	11,82	0,037	-0,231	0,095
TM245V	0,937	0,104	1	< 2,2e-16	82,59	0,143	-0,359	0,009
TM245O	0,858	0,002	1	< 2,2e-16	14,19	0,014	-0,231	0,095
TM245I	0,909	0,021	1	< 2,2e-16	11,22	0,047	-0,251	0,070
TM245P	0,912	0,025	1	< 2,2e-16	11,22	0,047	-0,268	0,052
TM370V	0,938	0,112	1	< 2,2e-16	41,11	0,534	-0,348	0,012
TM370O	0,875	0,004	1	< 2,2e-16	10,04	0,074	-0,219	0,113
TM370I	0,908	0,021	1	< 2,2e-16	13,00	0,023	-0,231	0,095
TM370P	0,912	0,025	1	< 2,2e-16	11,22	0,047	-0,268	0,052
TN126V	0,927	0,058	1	< 2,2e-16	94,44	0,093	-0,214	0,123
TN126O	0,909	0,021	1	< 2,2e-16	70,74	0,215	-0,151	0,278
TN126I	0,943	0,147	1	< 2,2e-16	35,19	0,621	-0,191	0,169
TN126P	0,897	0,012	1	< 2,2e-16	70,74	0,215	-0,171	0,219
TN245V	0,924	0,049	1	< 2,2e-16	94,44	0,093	-0,208	0,133
TN245O	0,909	0,021	1	< 2,2e-16	7,07	0,215	-0,151	0,278
TN245I	0,943	0,146	1	< 2,2e-16	35,19	0,621	-0,200	0,150
TN245P	0,894	0,010	1	< 2,2e-16	76,67	0,176	-0,185	0,182
TN370V	0,928	0,063	1	< 2,2e-16	88,52	0,115	-0,231	0,095
TN370O	0,913	0,026	1	< 2,2e-16	70,74	0,215	-0,162	0,243
TN370I	0,944	0,155	1	< 2,2e-16	35,19	0,621	-0,197	0,156
TN370P	0,894	0,010	1	< 2,2e-16	76,67	0,176	-0,185	0,182

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

Regoto et al. (2021), analisaram tendências sazonais e anuais de índices extremos de temperatura do ar e precipitação sobre o Brasil durante o período 1961-2018, utilizando o teste

de Mann-Kendall, onde identificaram tendências extremas de precipitação positiva e negativa, sem significância estatística, na Região Sudeste. Resultado similar a este trabalho.

Pelas Figuras 8, 9 e 10 pode-se verificar o comportamento das variáveis em que apresentam mínima variabilidade entre as forçantes ssp126, ssp245 e a ssp370.

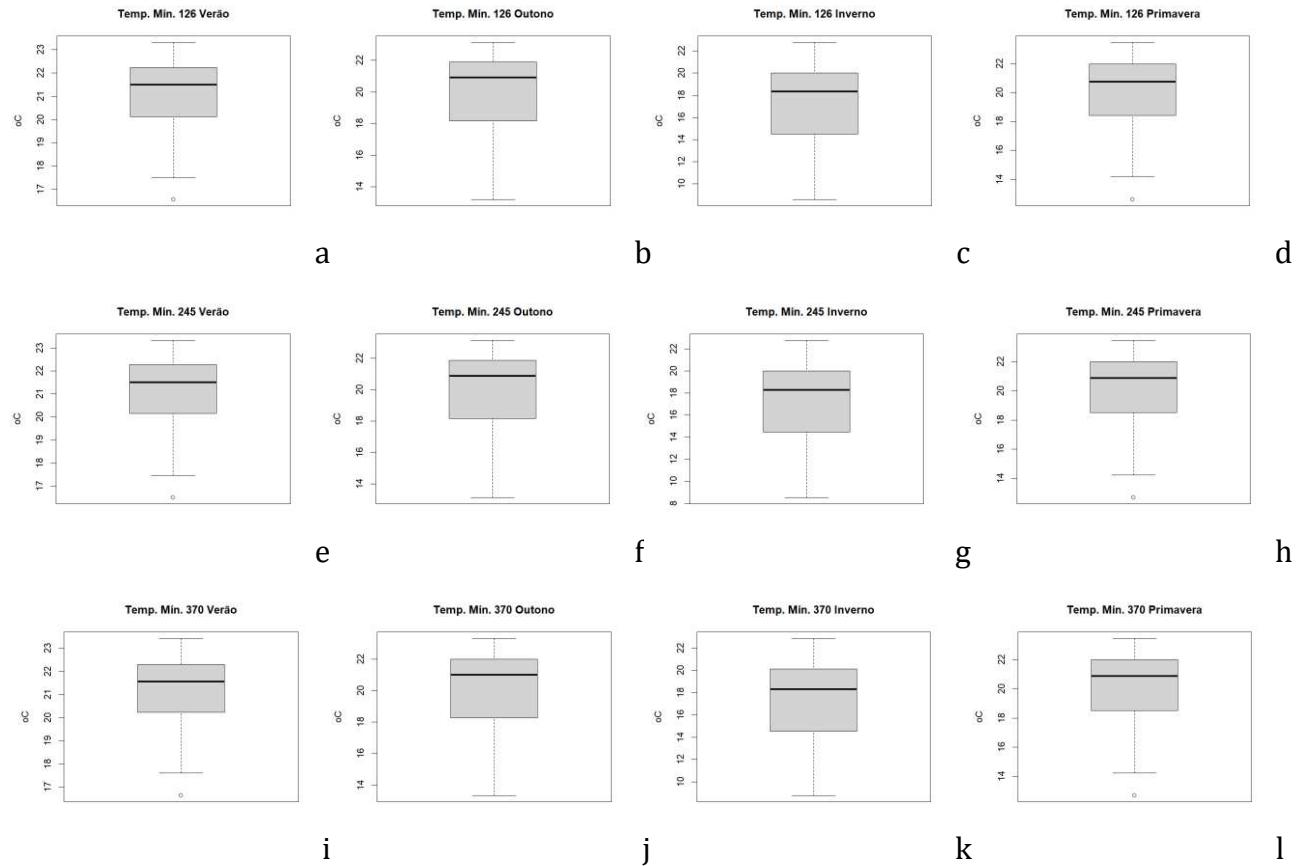


Figura 8. Boxplot da temperatura média mínima ( $^{\circ}\text{C}$ ) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

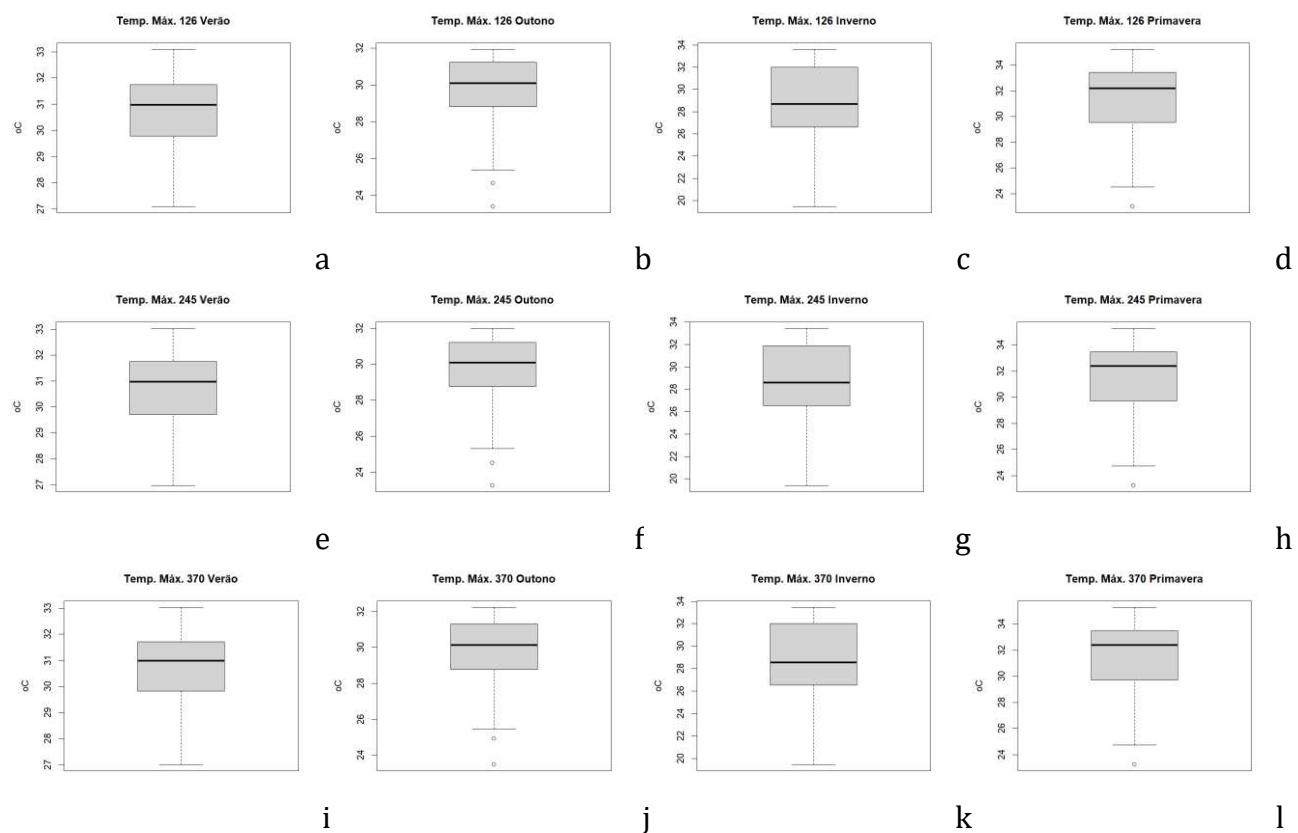


Figura 9. Boxplot da temperatura média máxima ( $^{\circ}\text{C}$ ) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

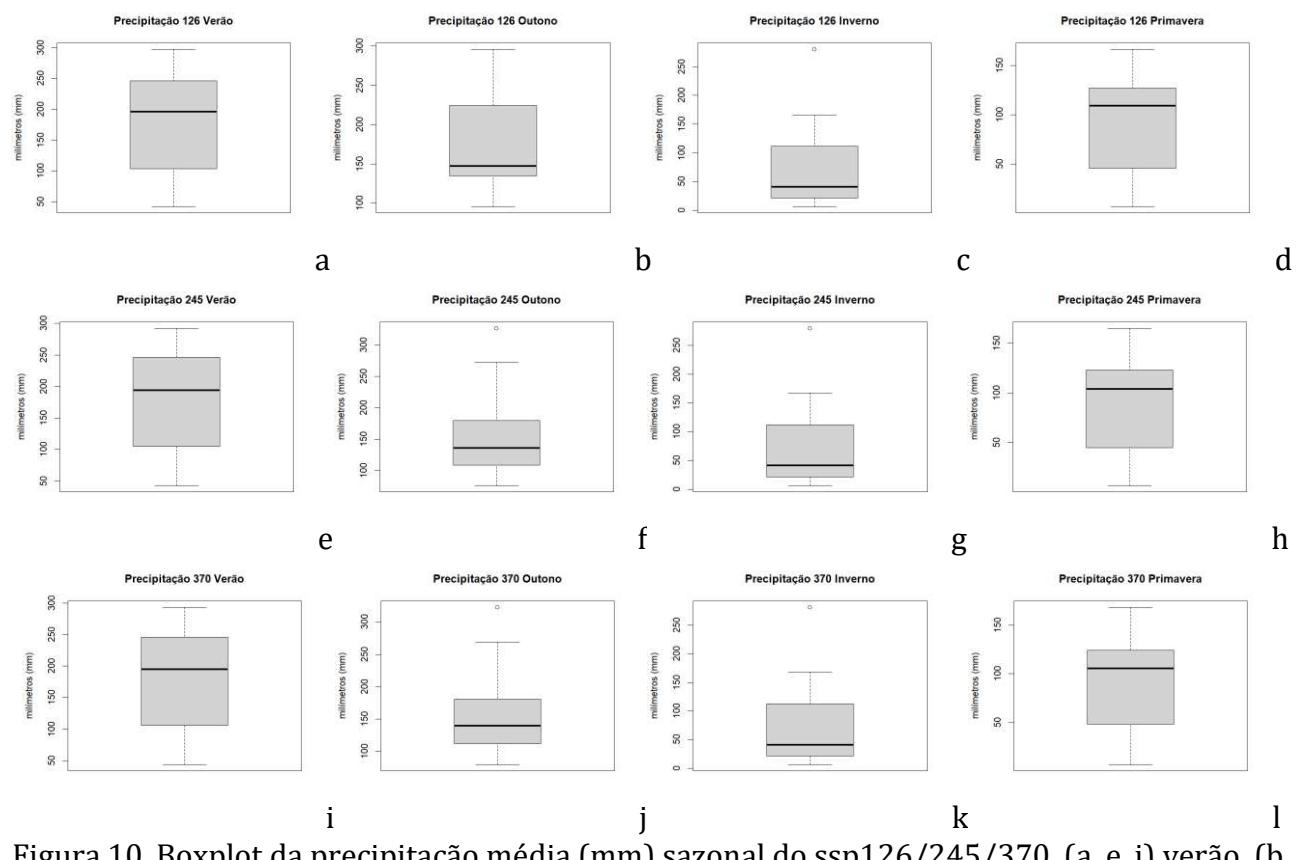


Figura 10. Boxplot da precipitação média (mm) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

No teste de normalidade da temperatura mínima sazonal (Figura 11), observa-se que a distribuição apresenta irregularidade na estação do outono do ssp245 e ssp370, nas demais segue a regularidade. Quanto ao teste de normalidade da temperatura máxima sazonal (Figura 12), observa-se que a distribuição se apresenta com regularidade nas projeções futuras. Na Figura 13, da precipitação sazonal, pode-se verificar a irregularidade na estação do outono do ssp245 e ssp370, seguindo o comportamento da temperatura mínima.

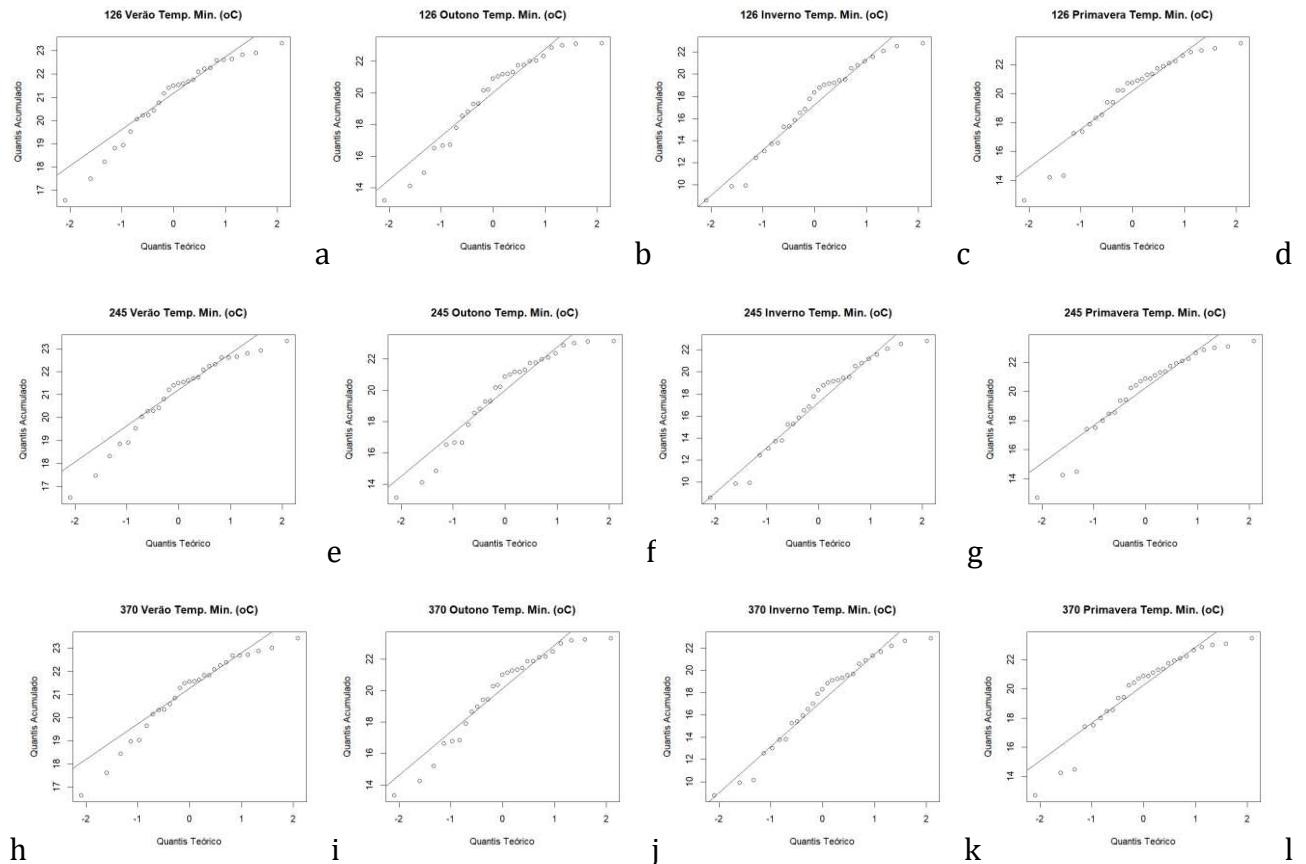


Figura 11. Quantis da temperatura mínima média sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

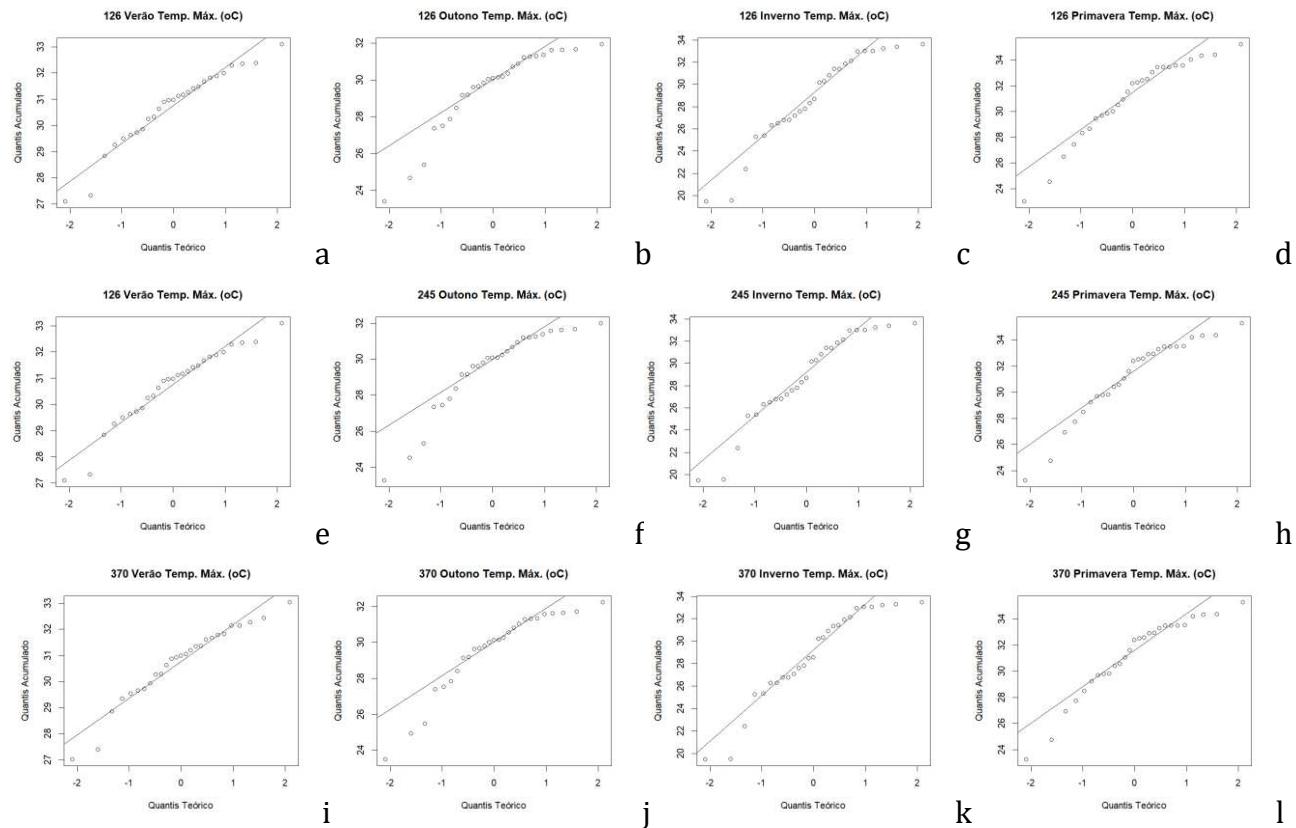


Figura 12. Quantis da temperatura máxima média sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

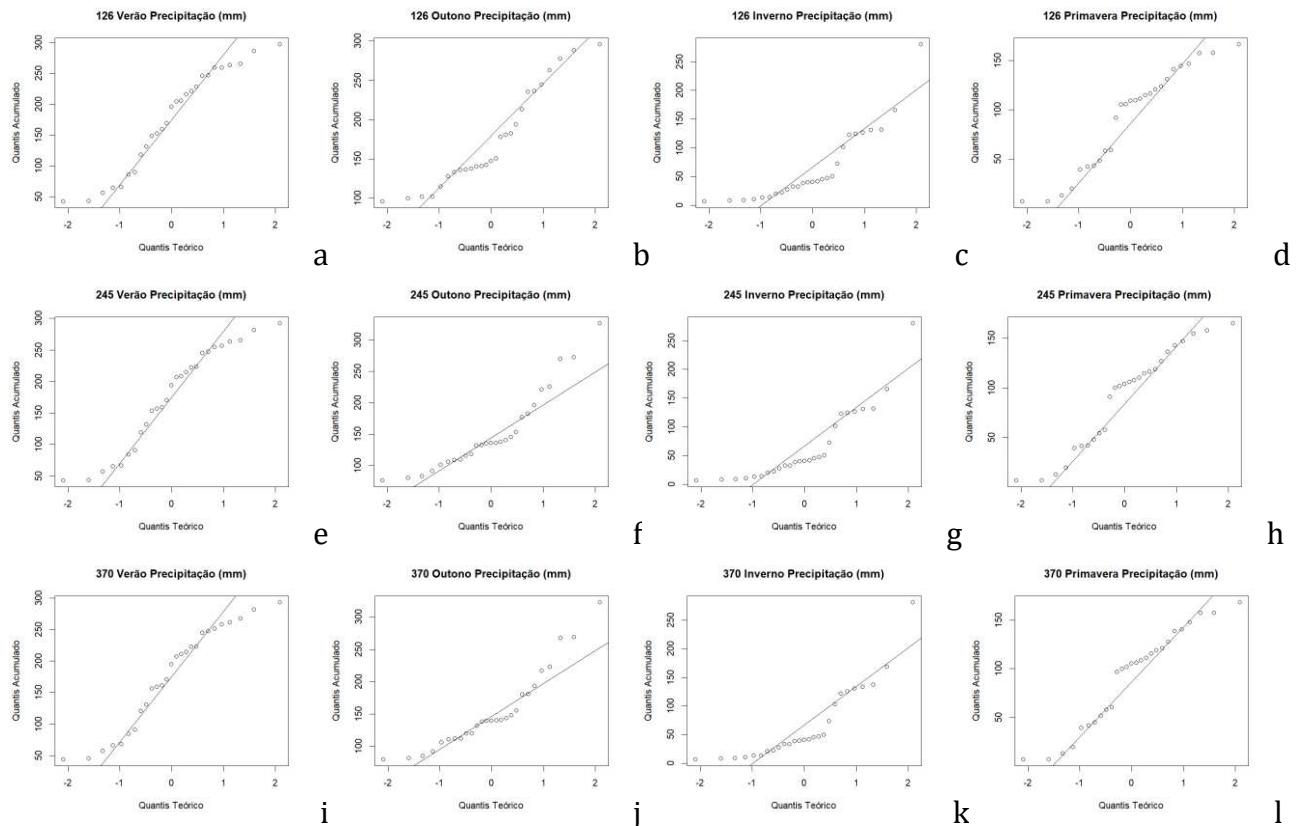


Figura 13. Quantis da precipitação média sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

De acordo com a Figura 14 e a Tabela 2 a correlação entre a precipitação e a temperatura máxima apresenta-se em sua maioria muito forte, e no sazonal outono a correlação ssp126 é forte e na ssp245 e ssp370 apresenta-se desprezível, o que se pode verificar pela Figura 14 entre a precipitação e temperatura máxima sazonal onde a estação outono diverge das demais no sentido positivo da correlação.

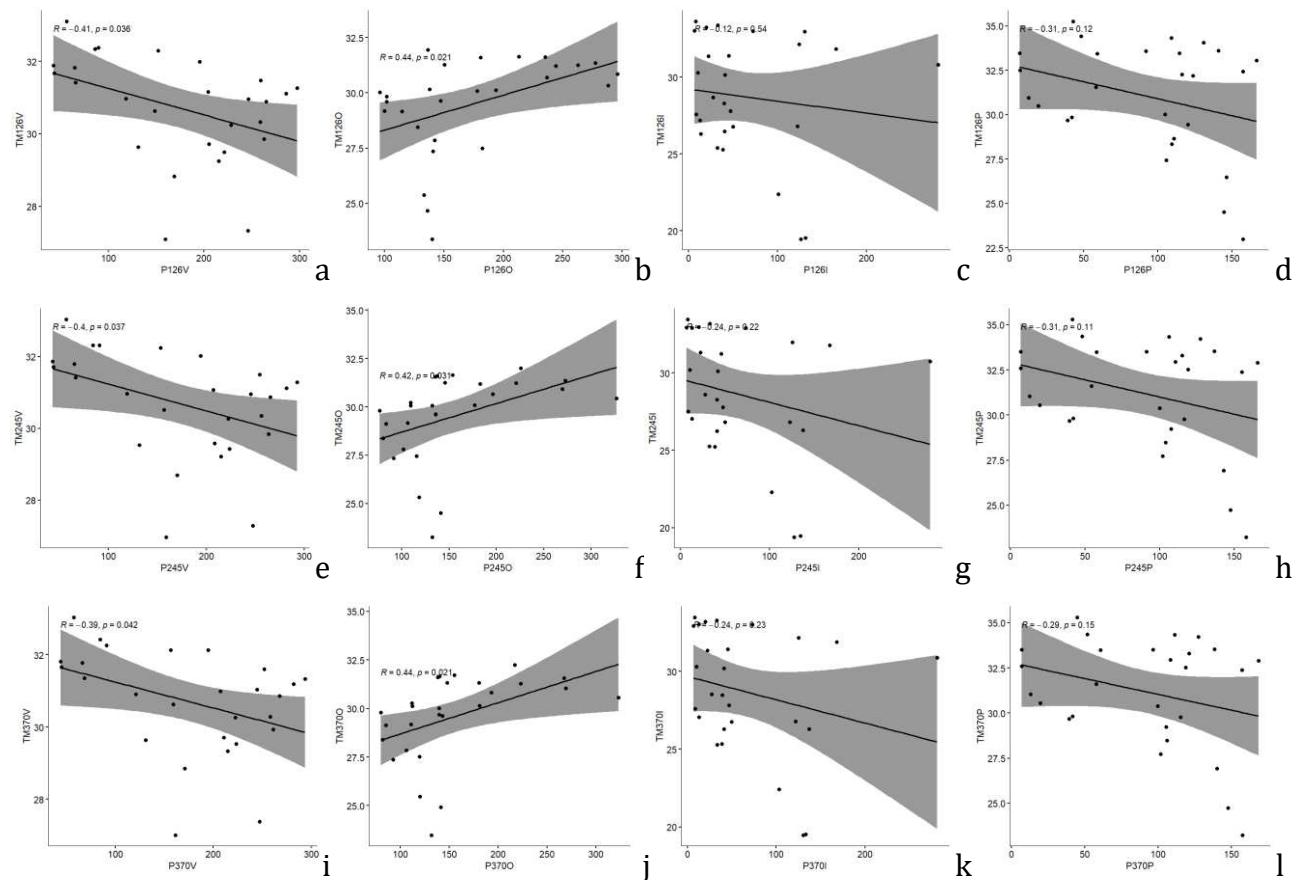


Figura 14. Correlação de Pearson entre a precipitação e temperatura máxima sazonal do ssp126 (a, b, c, d), ssp245 (e, f, g, h), ssp370 (i, j, k, l).

Riahi et al. (2017) afirmam que, é importante destacar que os novos cenários de emissões (SSP) elaborados para o CMIP6 são baseados em 5 narrativas (SSP1, SSP2, SSP3, SSP4 e SSP5) que descrevem desenvolvimentos socioeconômicos alternativos, incluindo desenvolvimento sustentável, rivalidade regional, desigualdade, desenvolvimento movido a combustíveis fósseis e desenvolvimento intermediário, sendo traduzidos em crescimento econômico, mudança populacional e urbanização, para consequentemente representar diferentes desafios de mitigação e adaptação. O cenário SSP2 descreve um caminho nas quais as tendências sociais, econômicas e tecnológicas não mudam acentuadamente dos padrões

históricos, porém o desenvolvimento e o crescimento da renda prosseguem de maneira desigual, e deve enfrentar desafios médios à mitigação e adaptação.

Tabela 2. Correlação entre as variáveis precipitação e temperatura máxima

1.o Parâmetro	2.o Parâmetro	<i>rho</i>	95% CI	S	<i>p</i>
P126V	TM126V	-0,45	[-0,71, -0,07]	4.752	>0,999
P126O	TM126O	0,55	[0,20, 0,77]	1.472	0,875
P126I	TM126I	-0,20	[-0,55, 0,20]	3.936	>0,999
P126P	TM126P	-0,21	[-0,56, 0,19]	3.968	>0,999
P245V	TM245V	-0,47	[-0,72, -0,09]	4.805	>0,999
P245O	TM245O	0,64	[0,33, 0,82]	1.188	0,128
P245I	TM245I	-0,39	[-0,68, 0,00]	4.553	>0,999
P245P	TM245P	-0,22	[-0,56, 0,19]	4.000	>0,999
P370V	TM370V	-0,46	[-0,72, -0,08]	4.768	>0,999
P370O	TM370O	0,62	[0,30, 0,81]	1.260	0,218
P370I	TM370I	-0,39	[-0,68, 0,00]	4.552	>0,999
P370P	TM370P	-0,19	[-0,54, 0,22]	3.884	>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).

Almazroui et al. (2021) afirmam que, as mudanças futuras, em sua maioria, progridem monotonicamente do cenário de forçamento mais fraco para o mais forte, e do período de projeção de meados do século ao final do século.

## CONCLUSÃO

Pelos resultados obtidos neste trabalho observou-se que demonstrou uma tendência de resfriamento de 1,59°C.

A projeção da temperatura máxima demonstrou tendência de se manter a temperatura máxima em 30°C.

A precipitação futura demonstrou uma tendência de diminuição de 5mm distribuída para todo o Brasil.

A distribuição anual da temperatura máxima e mínima e da precipitação apresentou mínima variabilidade entre as forçantes.

Os testes de normalidade da temperatura mínima sazonal e da precipitação apresentou irregularidade na estação do outono para as forçantes ssp245 e ssp370. Na temperatura máxima apresentou regularidade nas projeções futuras.

A correlação entre a precipitação e a temperatura máxima apresentou em sua maioria muito forte divergindo na estação sazonal do outono.

Os cenários de forçamento não apresentaram resultados significativos não havendo progressão.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALMAZROUI, M.; ASHFAQ, M.; ISLAM, M. N. Assessment of CMIP6 performance and projected temperature and precipitation changes over South America. *Earth Syst Environ*, v.5, p.155–183, 2021.
- REGOTO, P.; DERECHYNSKI, C.; CHOU, S. C.; BAZZANELA, A. C. Observed changes in air temperature and precipitation extremes over Brazil. *International Journal of Climatology*, v.41, n.11, p.5125–5142, 2021.
- ALLEN, M. R.; DUBE, O. P.; SOLECKI, W.; ARAGÓN-DURAND, F.; CRAMER, W.; HUMPHREYS, S.; KAINUMA, M.; KALA, J.; MAHOWALD, N.; MULUGETTA, Y.; PEREZ, R.; WAIRIU, M.; ZICKFELD, K. Framing and Context. In: Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty. MASSON-DELMOTTE, V.; ZHAI, P.; PÖRTNER, H.O.; ROBERTS, D.; SKEA, J.; SHUKLA, P.R.; PIRANI, A.; MOUFOUMA-OKIA, W.; PÉAN, C.; PIDCOCK, R.; CONNORS, S.; MATTHEWS, J.B.R.; CHEN, Y.; ZHOU, X.; GOMIS, M. I.; LONNOY, E.; MAYCOCK, T.; TIGNOR, M.; WATERFIELD, T. (eds.). Cambridge University Press, Cambridge, UK and New York, NY, USA, 2018. p.49-92. Disponível em: [https://www.ipcc.ch/site/assets/uploads/sites/2/2022/06/SR15\\_Chapter\\_1\\_HR.pdf](https://www.ipcc.ch/site/assets/uploads/sites/2/2022/06/SR15_Chapter_1_HR.pdf). Acesso em: 12 de março de 2024.
- AMBRIZZI, T.; REBOITA, M. S.; ROCHA, R. P. DA; LLOPART, M. The state of the art and fundamental aspects of regional climate modeling in South America. *Annals of the New York Academy of Sciences*, v.1436, n.1, p.98-120, 2019.
- ANDERSON, T. W.; DARLING, D. A. A test of goodness of t. *Journal of American Statistical Association*, v.49, p.765-769, 1954.
- AVILA-DIAZ, A.; ABRAHÃO, G.; JUSTINO, F.; TORRES, F.; WILSON, A. Extreme climate indices in Brazil: evaluation of downscaled earth system models at high horizontal resolution. *Climate Dynamics*, v.54, p.5065–5088, 2020.

- BARBOSA, C. C.; CÂMARA, G.; MEDEIROS, J. S. DE; CREPANI, E.; NOVO, E.; CORDEIRO, J. P. C. Operadores zonais em álgebra de mapas e sua aplicação no Zoneamento Ecológico Econômico. In: Simpósio Brasileiro de Sensoriamento Remoto, 9, 1998, Santos. Anais...Santos, 1998.
- BERTRAND, G. Paisagem e Geografia Física Global: Esboço Metodológico. Caderno de Ciências da Terra, 13. Inst. de Geografia-USP. São Paulo. 1981.
- BOSCO, R. B.; VALVERDE, M. C. Projeções climáticas de precipitação e temperatura na Região Metropolitana do Vale do Paraíba-SP simulados por modelos climáticos do CMIP6. Revista Brasileira de Geografia Física, v.15, n.3, p.1621-1638, 2022.
- BRITO, A. L.; VEIGA, J. A. P.; CORREIA, F. W.; CAPISTRANO, V. B. Avaliação do desempenho dos modelos HadGEM2-ES e Eta a partir de indicadores de extremos climáticos de precipitação para a Bacia Amazônica. Revista Brasileira de Meteorologia, v.34, n.2, p.165-177, 2019.
- CHOU, S. C.; LYRA, A.; MOURÃO, C. Assessment of climate change over South America under RCP 4.5 and 8.5 downscaling scenarios. American Journal of Climate Change, v.3, n.5, p.512-525, 2014.
- CHOU, S. C.; DE ARRUDA LYRA, A.; GOMES, J. L.; RODRIGUEZ, D. A.; MARTINS, M.; RESENDE, N.; TAVARES, P.; DERECZYNSKI, C. P.; PILOTTO, I.; MARTINS, A. M.; CARVALHO, L. F. A.; ONOFRE, J. L. L.; MAJOR, I.; PENHOR, M.; SANTANA, A. Downscaling projections of climate change in São Tome and Principe Islands, Africa. Climate Dynamics, v.54, p.4021-4042, 2020.
- CHOU, S. C.; LYRA, A.; MOURÃO, C.; DERECZYNSKI, C.; PILOTTO, I.; GOMES, J.; BUSTAMANTE, J.; TAVARES, P.; SILVA, A.; RODRIGUES, D.; CAMPOS, D.; CHAGAS, D.; SUEIRO, G.; SIQUEIRA, G.; NOBRE, P.; MARENKO, J. Evaluation of the Eta Simulations Nested in Three Global Climate Models. American Journal of Climate Change, v.3, n.5, p.438-454, 2014.
- CHOU, S. C.; MARENKO, J. A.; LYRA, A.; SUEIRO, G.; PESQUERO, J.; ALVES, L. M.; KAY, G.; BETTS, R.; CHAGAS, D.; GOMES, J. L.; BUSTAMANTE, J.; TAVARES, P. Downscaling of South America present climate driven by 4-member HadCM3 runs. Climate Dynamics, v.38, n.3-4, p.635-653, 2012.
- COELHO, C. A. S.; CARDOSO, D. H. F.; FIRPO, M. A. F. Precipitation diagnostics of an exceptionally dry event in São Paulo, Brazil. Theoretical and Applied Climatology, v.125, n.3-4, p.769-784, 2015.
- CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WEHBERG, J.; WICHMANN, V.; BÖHNER, J. System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. Geosci. Model Dev., v.8, p.1991-2007, 2015.

- CORREA, W. de S. C.; SOARES, W. R.; AYLAS, G. Y. R.; REIS JUNIOR, N. C.; MARENKO, J. A.; CHOU, S. C.; NOBRE, C. Avaliação das simulações de temperatura e precipitação de um subconjunto de modelos do CMIP6 para o Brasil. Derbyana, v.43, e774, 2022.
- CUNHA, A. P. M. A.; TOMASELLA, J.; RIBEIRO NETO, G. G.; BROWN, M.; GARCIA; S. R.; BRITO, S. B.; CARVALHO, M. A. Changes in the spatial–temporal patterns of droughts in the Brazilian Northeast. Atmospheric Science Letters, v.19, n.10, p.1-8, 2018.
- DERECZYNSKI, C.; CHOU, S. C.; LYRA, A.; SONDERMANN, M.; REGOTO, P.; TAVARES, P.; CHAGAS, D.; GOMES, J. L.; RODRIGUES, D. C.; SKANSI, M. L. M. Downscaling of climate extremes over South America - Part I: Model evaluation in the reference climate. Weather and Climate Extremes, v.29, e100273, 2020.
- DIAS, C. G.; REBOITA, M. S. Assessment of CMIP6 simulations over Tropical South America. Revista Brasileira de Geografia Física, v.14, n.3, p.1282-1295, 2021.
- EC-EARTH CONSORTIUM. ECEarth-Consortium EC-Earth3-Veg model output prepared for CMIP6 ScenarioMIP. Earth System Grid Federation. 2019.
- FAN, X.; MIAO, C.; DUAN, Q.; SHEN, C.; WU, Y. The Performance of CMIP6 versus CMIP5 in simulating temperature extremes over the global land surface. Journal of Geophysical Research: Atmospheres, v.125, n.18, p.1-16, 2020.
- FERREIRA, B. C. C.; VALVERDE, M. C. Análise dos índices de extremos de precipitação em cenários futuros na bacia do Rio Ribeira de Iguape - São Paulo. Revista Brasileira de Meteorologia, v.37, n.1, p.41-55, 2022.
- FLATO, G.; MAROTZKE, J.; ABIODUN, B.; BRACONNOT, P.; CHOU, S. C.; COLLINS, W.; COX, P.; DRIOUECH, F.; EMORI, S.; EYRING, V.; FOREST, C.; GLECKLER, P.; GUILYARDI, E.; JAKOB, C.; KATTSOV, V.; REASON, C.; RUMMUKAINEN, M. Evaluation of climate models. In: Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. STOCKER, T. F.; QIN, D.; PLATTNER, G. K.; TIGNOR, M.; ALLEN, S. K.; BOSCHUNG, J.; NAUELS, A.; XIA, Y.; BEX, V.; MIDGLEY, P. M. (eds.). Cambridge University Press, 2014. p.741-866. Disponível em: [https://www.ipcc.ch/site/assets/uploads/2018/02/WG1AR5\\_Chapter09\\_FINAL.pdf](https://www.ipcc.ch/site/assets/uploads/2018/02/WG1AR5_Chapter09_FINAL.pdf). Acesso em: 30 de março de 2024.
- FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J. HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations – a new environmental record for monitoring extremes. Scientific Data, v.2, n.150066, 2015.

GROOPPO, J. D.; BEDUSCHI, C. E.; MENUZZO, R.; MORAES, J. M.; MARTINELLI, L. A. Análise de séries temporais de vazão e precipitação em algumas bacias do estado de São Paulo com diferentes graus de intervenções antrópicas. *Revista Brasileira de Geociências*, v.24, p.181-192, 2005.

HARTSHORNE, R. Propósitos e Natureza da Geografia. São Paulo. HUCITEC/EDUSP, 1978.

HYNDMAN, R. J.; FAN, Y. Sample Quantiles in Statistical Packages. *The American Statistician*, v.50, n.4, p.361-365, 1996.

IBGE. Instituto Brasileiro de Geografia e Estatística. 2021. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/15774-malhas.html>. Acesso em: 10 de abril de 2022.

IPCC. Climate Change 2014 Part A: Global and Sectoral Aspects. In: Field, C.; Barros, V. R. (ed.). Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part A: Global and Sectoral Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change (1a). Cambridge University Press. 2014. Disponível em: <https://www.ipcc.ch/report/ar5/wg2/>. Acesso em: 13 de março de 2024.

IPCC. Climate Change 2021: The Physical Science Basis Summary for Policymakers Working Group I Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. In: ONU. 2021. Disponível em: <https://www.ipcc.ch/report/sixth-assessment-report-working-group-ii/>. Acesso em: 13 de março de 2024.

IPCC. Intergovernmental Panel on Climate Change. Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. MASSON-DELMOTTE, V.; ZHAI, P.; PIRANI, A. et al. 2021. 280p. Disponível em: [https://www.ipcc.ch/report/ar6/wg1/downloads/report/IPCC\\_AR6\\_WGI\\_SummaryVolume.pdf](https://www.ipcc.ch/report/ar6/wg1/downloads/report/IPCC_AR6_WGI_SummaryVolume.pdf). Acesso em: 12 de março de 2024.

JARQUE, C. M.; BERA, A. K. A test for normality of observations and regression residuals. *International Statistical Review*, v.55, p.163-172, 1987.

JONES, C.; CARVALHO, L. M. V. Climate change in the South American monsoon system: present climate and CMIP5 projections. *Journal of Climate*, v.26, n.17, p.6660-6678, 2013.

KARMESHU, N. Trend Detection in Annual Temperature & Precipitation using the Mann Kendall Test - A Case Study to Assess Climate Change on Select States in the Northeastern United States. Master of Environmental Studies Capstone Projects. University of Pennsylvania. Department of Earth and Environmental Science, 2012.

KENDALL, M. A.; STUART, A. The advanced theory of statistics. 2.a ed. Londres: Charles Griffin, 1967.

KOLMOGOROV, A. Sulla determinazione empirica di una legge di distribuzione. Giornale dell'Istituto Italiano Degli Attuari, v.4, p.83-91, 1933.

KVAM, P. H.; VIDAKOVIC, B. Nonparametric statistics with applications to science and engineering. New York: Wiley, 2007.

LILLIEFORS, H. W. On the Kolmogorov-Smirnov test for normality with mean and variance unknown. Journal of the American Statistical Association, v.62, n.318, p.399-402, 1967.

LYRA, A.; TAVARES, P.; CHOU, S. C.; SUEIRO, G.; DERECZYNSKI, C. et al. Climate change projections over three metropolitan regions in Southeast Brazil using the nonhydrostatic Eta regional climate model at 5-km resolution. Theoretical and Applied Climatology, v.132, n1-2, p. 683-683, 2017.

MANN, H. B. Non-parametric tests against trend. Econometrica, v.13, n.3, p. 245-259, 1945.

MARENGO, J. A.; CHOU, S. C.; KAY, G.; ALVES, L. M.; PESQUERO, J. F.; SOARES, W. R.; SANTOS, D. C.; LYRA, A. A.; SUEIRO, G.; BETTS, R.; CHAGAS, D. J.; GOMES, J. L.; BUSTAMANTE, J. F.; TAVARES, P. Development of regional future climate change scenarios in South America using the Eta Cptec/HadCM3 climate change projections: climatology and regional analyses for the Amazon, São Francisco and the Paraná River basins. Climate Dynamics, v.38, p.1829-1848, 2012.

MARENGO, J. A. Impactos de Extremos Relacionados com o Tempo e o Clima - Impactos Sociais e Econômicos. 8. ed. São Paulo: GPMC, 2009. 5p. Disponível em: [http://mudancasclimaticas.cptec.inpe.br/~rmclima/pdfs/newsletters/Boletim\\_No8\\_Port.pdf](http://mudancasclimaticas.cptec.inpe.br/~rmclima/pdfs/newsletters/Boletim_No8_Port.pdf). Acesso em: 12 de março de 2024.

MARENGO, J. A.; BERNASCONI, M. Regional differences in aridity/drought conditions over Northeast Brazil: present state and future projections. Climatic Change, v.129, n.1-2, p.103-115, 2015.

MARENGO, J. A.; CUNHA, A. P. M. A.; 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.; ÁLVALA, R. C. S. Assessing drought in the drylands of northeast Brazil under regional warming exceeding 4°C. Natural Hazards, v.103, n.2, p.2589-2611, 2020.

MARENGO, J. A.; JONES, R.; ALVES, L. M.; VALVERDE, M. C. Future change of temperature and precipitation extremes in South America as derived from the PRECIS regional climate modeling system. International Journal of Climatology, v.29, n.15, p. 2241-2255, 2009.

- MARENGO, J. A.; TOMASELLA, J.; ALVES, L. M.; SOARES, W. R.; RODRIGUEZ, D. A. The drought of 2010 in the context of historical droughts in the Amazon region. *Geophysical Research Letters*, v.38, n.12, p.1-5, 2011.
- MARENGO, J. A.; TORRES, R. R.; ALVES, L. M. Drought in northeast Brazil-past, present, and future. *Theoretical and Applied Climatology*, v.129, n.3-4, p.1189-1200, 2017.
- MARENGO, J. A.; VALVERDE. R.; OBREGON, G. O. Observed and projected changes in rainfall extremes in the Metropolitan Area of São Paulo. *Climate Research*, v.57, n.1, p.61-72, 2013.
- MARTIN, G. M.; BELLOUIN, N.; COLLINS, W. J.; CULVERWELL, I. D.; HALLORAN, P. R.; HARDIMAN, S. C.; HINTON, T. J.; JONES, C. D.; MCDONALD, R. E.; MCLAREN, A. J.; O'CONNOR, F. M.; ROBERTS, M. J.; RODRIGUEZ, J. M.; WOODWARD, S.; BEST, M. J.; BROOKS, M. E.; BROWN, A. R.; BUTCHART, N.; DEARDEN, C.; WILTSHERE, A. The HadGEM2 family of Met Office Unified Model climate configurations. *Geoscientific Model Development*, v.4, p.723-757, 2011.
- MENEZES, L. S.; CHOU, S. C.; ALMEIDA, J. M. V. de; SOUZA, S. A.; BEZERRA, W. de A.; RODRIGUES, L. N.; ROCHA, C. H. E. D'A. Mudanças climáticas no DF e Ride: detecção e projeções das mudanças climáticas para o Distrito Federal e região integrada de desenvolvimento do DF e entorno. Brasília, Secretaria do Meio Ambiente. 2016. 192p. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/159656/1/mudancas-climaticas-DF.pdf>. Acesso em: 30 de março de 2024.
- MONTEIRO, A. F. M.; YAMAMOTO, A. L. C.; SILVA, P. N.; REBOITA, M. S. Conhecer a complexidade do sistema climático para entender as mudanças climáticas. *Terrae Didatica*, v.17, p.1-12, 2021.
- NAITZEL, L. T. Validação de modelos climáticos globais e análise de projeções futuras para o Rio Grande do Sul. 151f. Trabalho de Conclusão de Curso (Engenharia Ambiental). Universidade Federal do Rio Grande do Sul. Porto Alegre, 2021.
- NATIVIDADE, U. A.; GARCIA, S. R.; TORRES, R. R. Tendência dos índices de extremos climáticos observados e projetados no Estado de Minas Gerais. *Revista Brasileira de Meteorologia*, v.32, n.4, p.600-614, 2017.
- NAUMANN, G.; ALFIERI, L.; WYSER, K.; MENTASCHI, L.; BETTS, R. A.; CARRAO, H.; SPINONI, J.; VOGT, J.; FEYEN, L. Global changes in drought conditions under different levels of warming. *Geophysical Research Letters*, v.45, n.7, p.3285-3296, 2018.
- OLIVEIRA, D. M. DE; RIBEIRO, J. G. M.; FARIA, L. F. DE; REBOITA, M. S. Performance dos modelos climáticos do CMIP6 em simular a precipitação em subdomínios da América do Sul no período histórico. *Revista Brasileira de Geografia Física*, v.16, n.1, p.116-133, 2023.

ORTEGA, G.; ARIAS, P. A.; VILLEGAS, J. C.; MARQUET, P. A.; NOBRE, P. Present-day and future climate over central and South America according to CMIP5/ CMIP6 models. International Journal of Climatology, v.41, n.15, p.6713-6735, 2021.

PBMC. Base Científica das Mudanças Climáticas. Contribuição do Grupo de Trabalho 1 do Painel Brasileiro de Mudanças Climáticas ao Primeiro Relatório da Avaliação Nacional sobre Mudanças Climáticas. AMBRIZZI, T.; ARAUJO, M. (Ed.). Coppe. Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2013. 464p.

PBMC. Painel Brasileiro de Mudanças Climáticas. Contribuição do Grupo de Trabalho 1 ao Primeiro Relatório de Avaliação Nacional do Painel Brasileiro de Mudanças Climáticas. Sumário Executivo GT1. Base Científica das Mudanças Climáticas. Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2014. 464p. Disponível em: [http://www.pbmccoppe.ufrj.br/documentos/RAN1\\_completo\\_vol1.pdf](http://www.pbmccoppe.ufrj.br/documentos/RAN1_completo_vol1.pdf). Acesso em: 13 de março de 2024.

PEARSON, K. The grammar of science. London, J. M. Dent and Company, 1892.

QGIS. Development Team. 2022. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Disponível em: <http://qgis.osgeo.org>.

REBOITA, M. S.; AMBRIZZI, T. Climate system in a nutshell: An overview for understanding Climate change. International Journal of Development Research, v.12, e53365-53378, 2022.

REBOITA, M. S.; GAN, M. A.; ROCHA, R. P. DA; AMBRIZZI, T. Regimes de precipitação na América do Sul: uma revisão bibliográfica. Revista Brasileira de Meteorologia, v.25, p.185-204, 2010.

RIAHI, K.; VAN VUUREN, D. P.; KRIEGLER, E.; EDMONDS, J.; O'NEIL, B. C. et al. The shared socioeconomic pathways and their energy, land use, and greenhouse gas emissions implications: an overview. Global Environmental Change, v.42, p.153-168, 2017.

RIBEIRO NETO, G. G.; ANDERSON, L. O.; BARRETOS, N. J. C.; ABREU, R.; ALVES, L. et al. Attributing the 2015/2016 Amazon basin drought to anthropogenic influence. Climate Resilience and Sustainability, p.1-10, 2021.

RStudio. Posit Software. Disponível em: <https://posit.co/download/rstudio-desktop/>.

SANTOS, D. J. DOS; PEDRA, G. U.; SILVA, M. G. B. DA; GUIMARÃES JÚNIOR, C. A.; ALVES, L. M.; SAMPAIO, G.; MARENGO, J. A. Mudanças futuras de precipitação e temperatura no Brasil a partir dos níveis de aquecimento global de 1,5°C, 2°C e 4°C. Sustainability in Debate, v.11, n.3, p 74-90, 2020.

SANTOS, D. J. DOS; PEDRA, G. U.; SILVA, M. G. B. DA; GUIMARÃES JÚNIOR, C. A.; ALVES, L. M.; SAMPAIO, G.; MARENGO, J. A. Mudanças futuras de precipitação e temperatura no Brasil a partir

dos níveis de aquecimento global de 1,5°C, 2°C e 4°C. Sustainability in Debate, v.11, n.3, p.74-90, 2020.

SHAPIRO, A. S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). Biometrika, v.52, n.3/4, p.591–611, 1965.

SMIRNOV, N. Table for Estimating the Goodness of Fit of Empirical Distributions. The Annals of Mathematical Statistics v.19, n.2, p.279–281, 1948.

SOARES, W. R.; MARENKO, J. A. Assessments of moisture fluxes east of the Andes in South America in a global warming scenario. International Journal of Climatology, v.2, n.9/10, p.1395-1414, 2009.

SOLMAN, S. A.; SANCHEZ, E.; SAMUELSSON, P.; ROCHA, R. P.; LI, L.; MARENKO, J.; PESSACG, N. L.; REMEDIO, A. R. C.; CHOU, S. C.; BERBERY, H.; LE TREUT, H.; CASTRO, M.; JACOB, D. Evaluation of an ensemble of regional climate model simulations over South America driven by the ERA-Interim reanalysis: Model performance and uncertainties. Climate Dynamics, v.41, n.5-6, p.1139-1157, 2013.

SOUSA, R. M. Mudanças climáticas futuras simuladas pelos modelos regionais Eta-HadGEM2-Es e Eta-MIROC5 para o Estado do Tocantins. 96f. Dissertação (Mestrado) Curso de Ciências Florestais e Ambientais. Universidade Federal do Tocantins. Palmas, 2017.

TRICART, J. Ecodinâmica. Rio de Janeiro. IBGE-SUPREN, 1977.

TRICART, J.; KIEWIETDEJONGE, C. Ecogeography and Rural Management: A Contribution to the International Geosphere-Biosphere Programme. Essex. Longman Scientific & Technical, 1992.

VAN VUUREN, D. P.; EDMONDS, J.; KAINUMA, M.; RIAHI, K.; THOMSON, A. et al. The representative concentration pathways: an overview. Climatic Change, v.5, p.109, 2011.

VOLODIN, E.; MORTIKOV, E.; GRITSUN, A.; LYKOSOV, V.; GALIN, V.; DIANSKY, N.; GUSEV, A.; KOSTRYKIN, S.; IAKOVLEV, N.; SHESTAKOVA, A.; EMELINA, S. INM INM-CM4-8 model output prepared for CMIP6 CMIP piControl. Earth System Grid Federation. 2019.

VON STORCH, J. S.; PUTRASAHAN, D.; LOHmann, K.; GUTJAHR, O.; JUNGCLAUS, J.; BITTNER, M.; HAAK, H.; WIENERS, K. H.; GIORGETTA, M.; REICK, C.; ESCH, M.; GAYLER, V.; VRESE, P.; RADDATZ, T.; MAURITSEN, T.; BEHRENS, J.; BROVKIN, V.; CLAUSSEN, M.; CRUEGER, T.; FAST, I.; FIEDLER, S.; HAGEMANN, S.; HOHENEGGER, C.; JAHNS, T.; KLOSTER, S.; KINNE, S.; LASSLOP, G.; KORNBLUEH, L.; MAROTZKE, J.; MATEI, D.; MERANER, K.; MIKOLAJEWICZ, U.; MODALI, K.; MÜLLER, W.; NABEL, J.; NOTZ, D.; GEHLEN, K.P.; PINCUS, R.; POHLMANN, H.; PONGRATZ, J.; RAST, S.; SCHMIDT, H.; SCHNUR, R.; SCHULZWEIDA, U. S. K.; STEVENS, B.; VOIGT, A.;

*Variáveis climáticas e sua projeção através de modelagem espacial e simulação por forçantes de parte do território brasileiro*

ROECKNER, E. MPI-M MPIESM1.2-HR model output prepared for CMIP6 HighResMIP. Earth System Grid Federation. 2017.

## CAPÍTULO III

# PROJEÇÃO CLIMÁTICA DOS ESTADOS DA REGIÃO NORDESTE, MINAS GERAIS, MARANHÃO E AMAPÁ SIMULADA ATÉ 2040 POR FORÇANTES SSP126/245/370 DO CIMP6

## 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 & SEDLÁCEK 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, fenômenos 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; BABAOUSMAIL 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.

## 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/m<sup>2</sup>, respectivamente). A Representative Concentration Pathways (RCP) (Forçante Radiativa) é expressa na unidade W/m<sup>2</sup> 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 ( $^{\circ}\text{C}$ ), temperatura máxima média mensal ( $^{\circ}\text{C}$ ), 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.

$$S_s = \sqrt{\frac{\sum_{i=1}^n (S_i - \bar{S})^2}{n-1}} \quad (\text{Eq.1}) \quad S_o = \sqrt{\frac{\sum_{i=1}^n (O_i - \bar{O})^2}{n-1}} \quad (\text{Eq.2})$$

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 Teste 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).

$$Dn = \sqrt{n} \sup_x |Fn(x) - F0(x)| \text{ (Eq.3)}$$

Em que:  $Fn(x)$  denota a distribuição teórica e  $F0(x)$  a distribuição ajustada.

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

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

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.

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

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: tp 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.

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

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.

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

## 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.

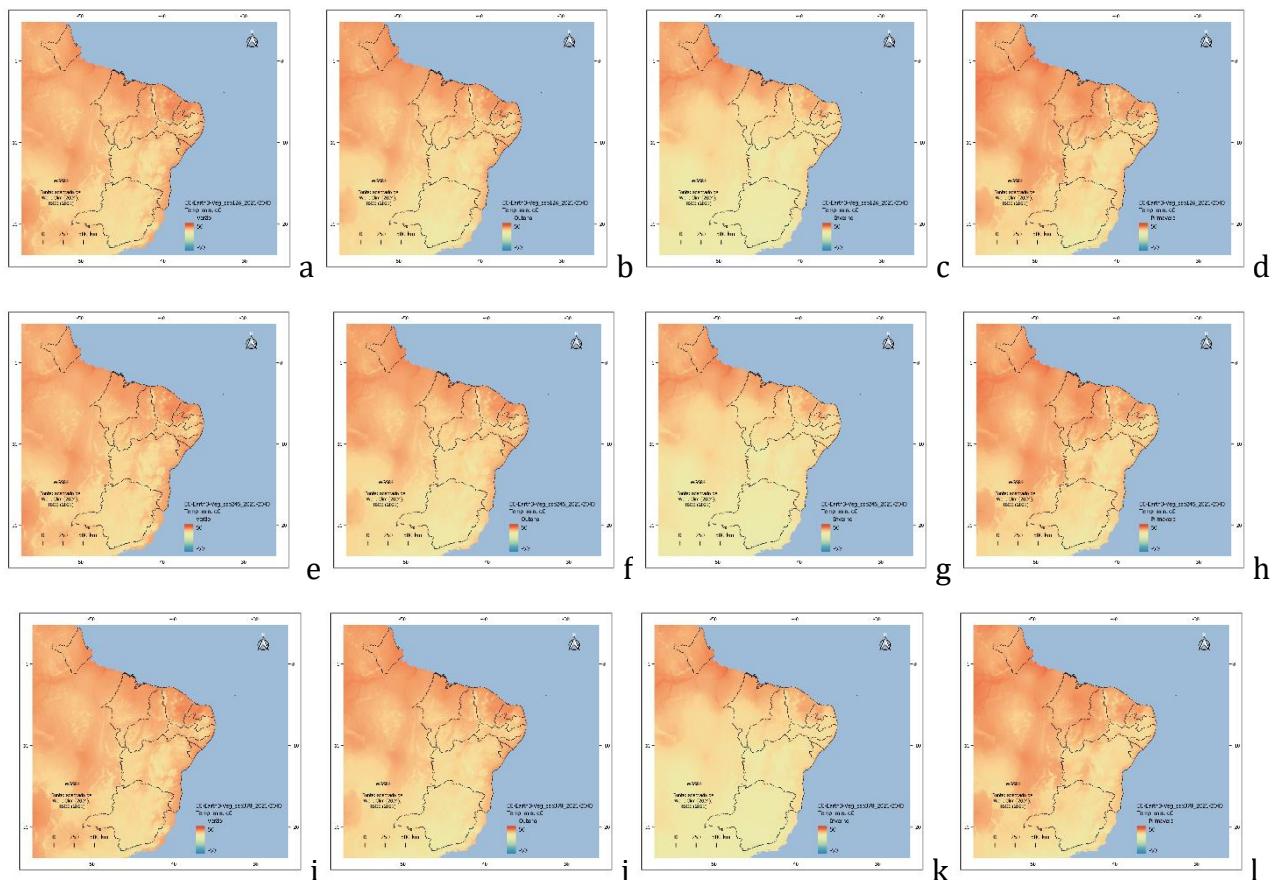


Figura 1. Distribuição sazonal da temperatura média mínima (°C) do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

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.

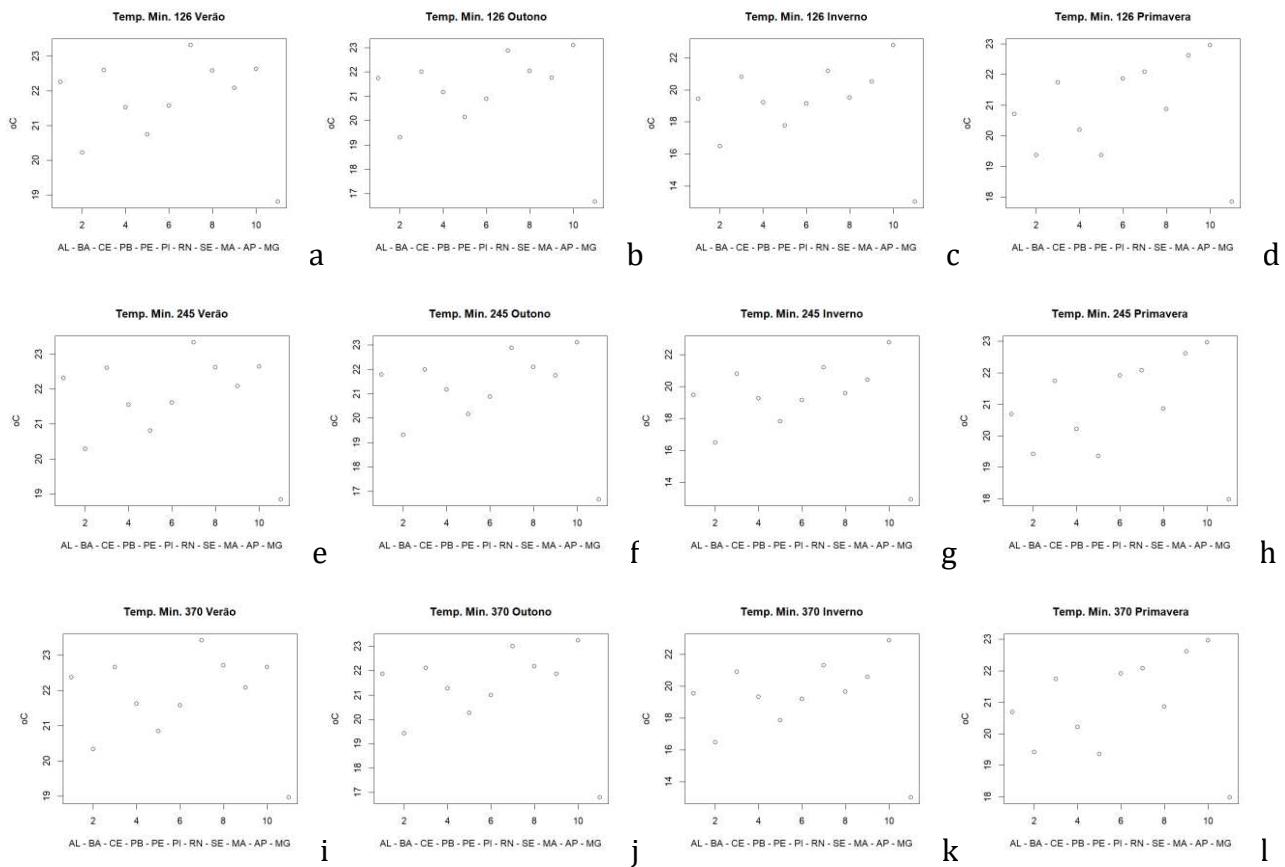


Figura 2. Distribuição da temperatura média mínima ( $^{\circ}\text{C}$ ) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

De acordo com a Tabela 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 ( $^{\circ}\text{C}$ ) 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.

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  $30,7^{\circ}\text{C}$  em praticamente toda a área de estudo sem incrementos significativos futuros.

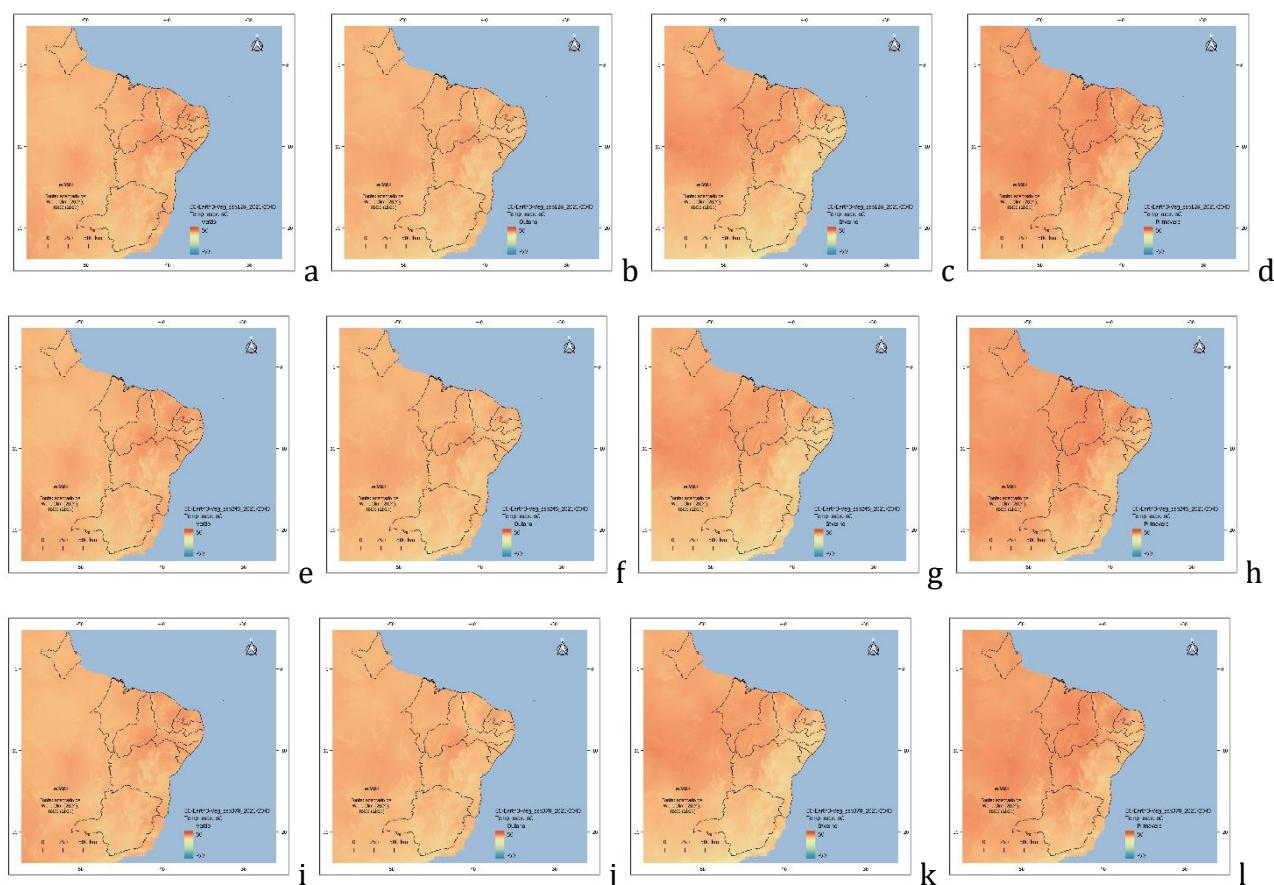


Figura 3. Distribuição sazonal da temperatura média máxima ( $^{\circ}\text{C}$ ) do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

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

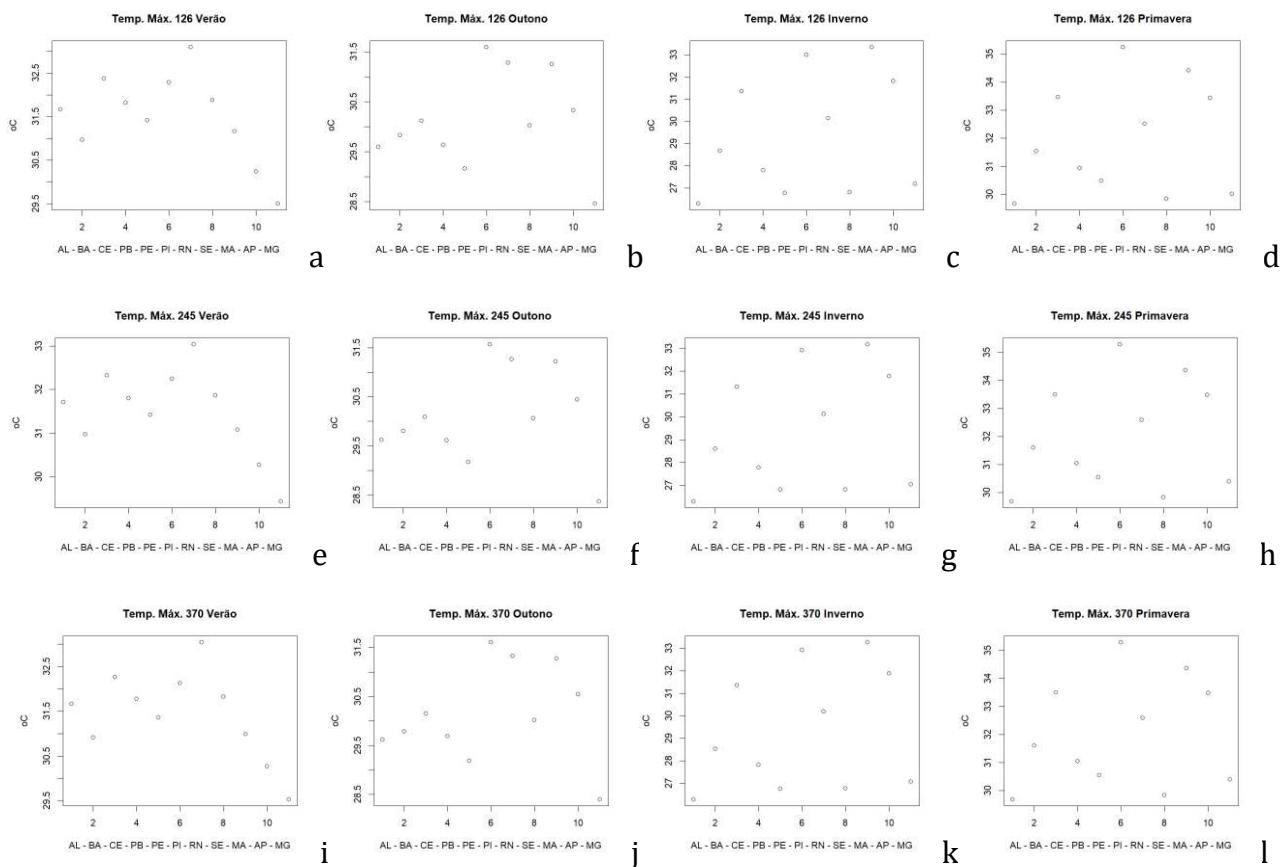


Figura 4. Distribuição da temperatura média máxima ( $^{\circ}\text{C}$ ) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

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.

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.

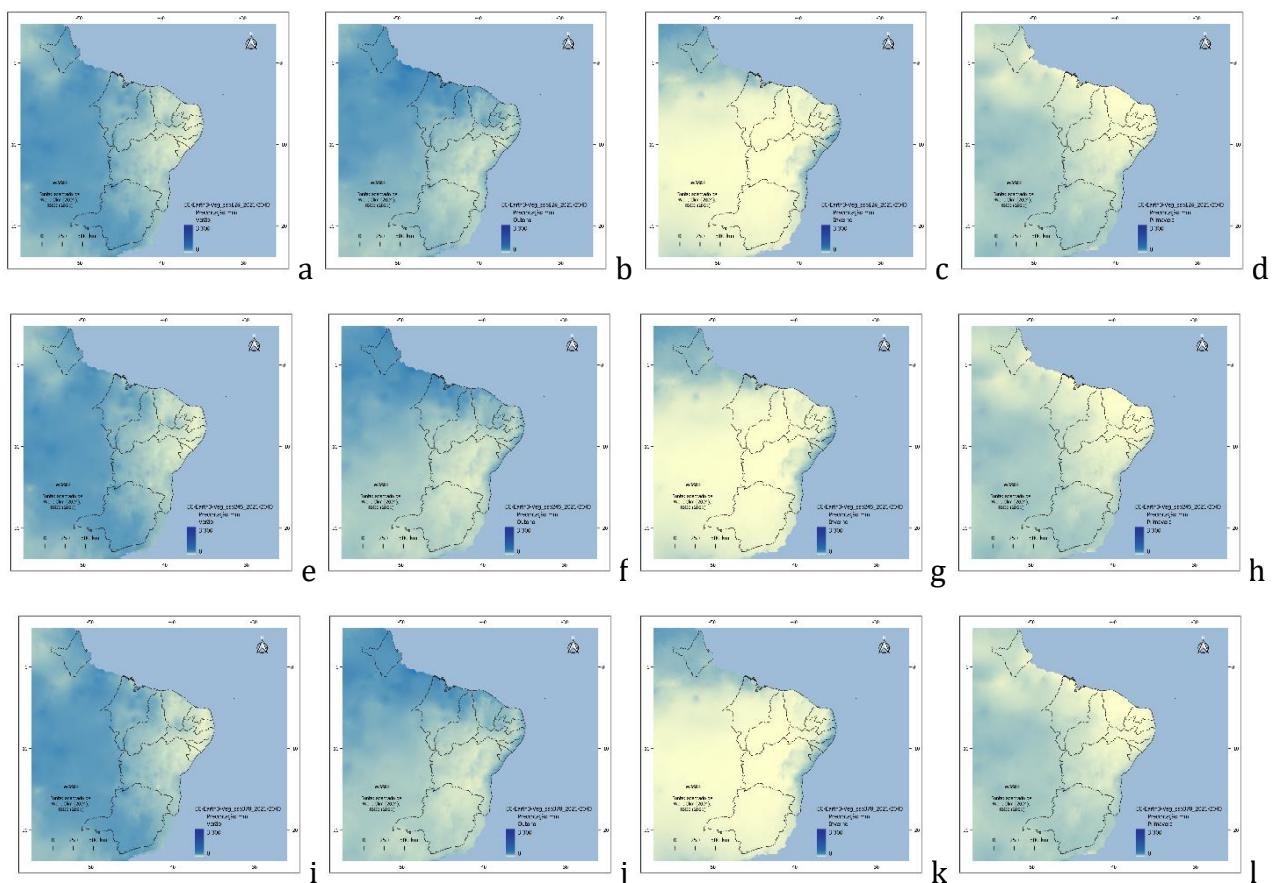


Figura 5. Distribuição sazonal da precipitação média (mm) do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

Pela Figura 6 pode-se verificar o comportamento sazonal das estações, em que as forçantes ssp 245 e ssp370 da estação do outono se diferencia da ssp126, com pequena variação negativa no Estado do Piauí.

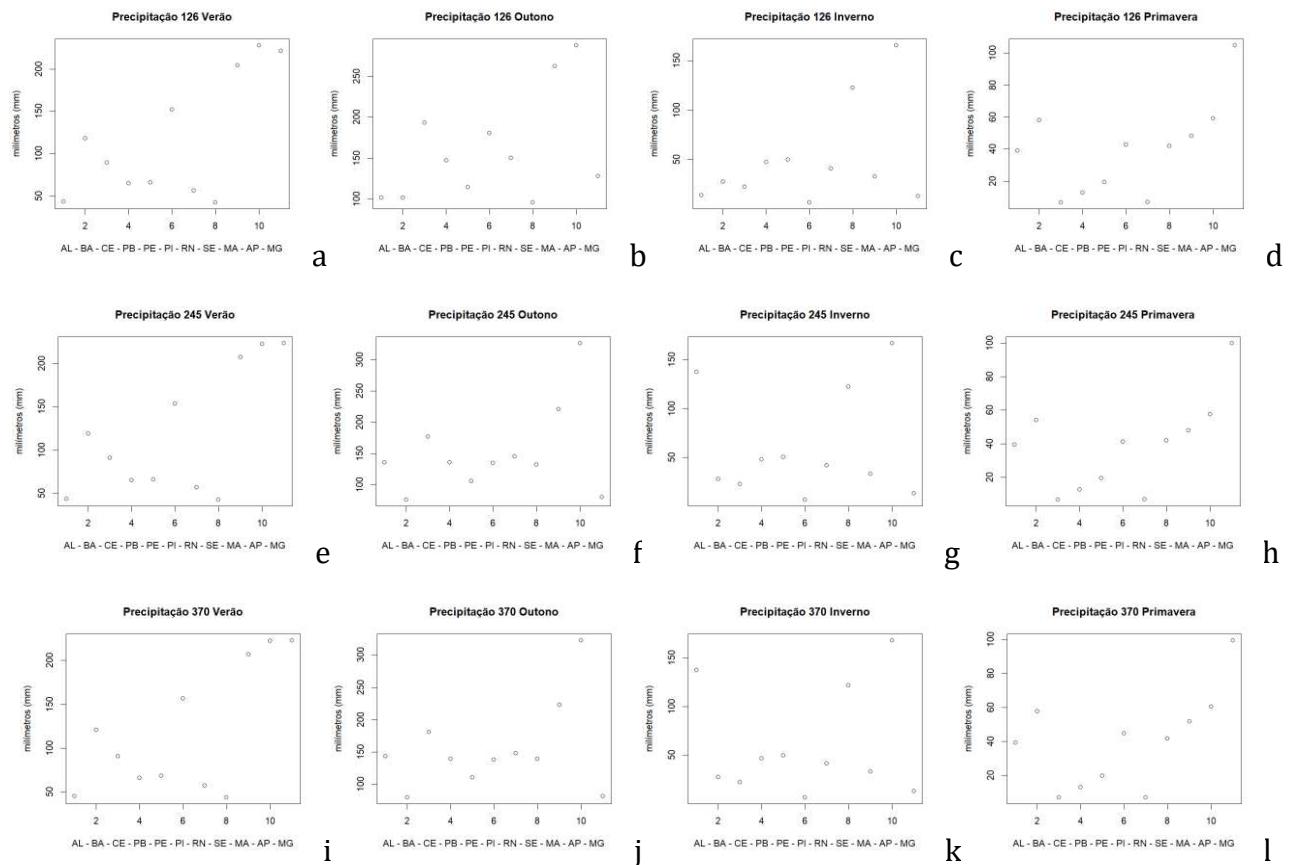


Figura 6. Distribuição da precipitação média (mm) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

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 mantém 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 mantém com valores mínimos no Ceará e maiores em Minas Gerais.

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	221,32	127,92	13,02	104,97	223,41	80,47	13,24	100,04	223,15	81,74	13,03	99,62

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

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.

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.

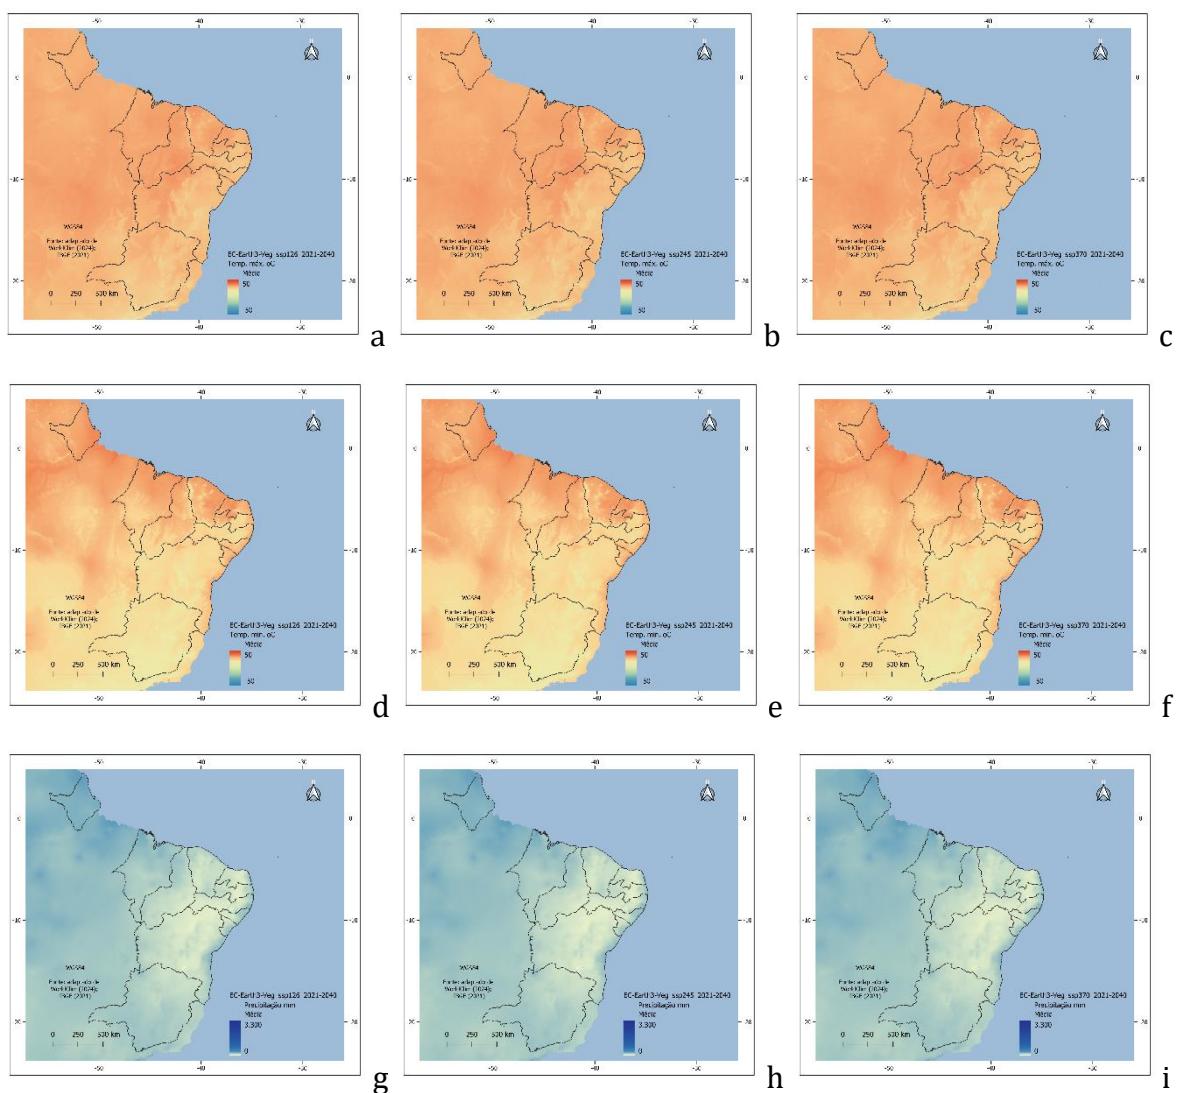


Figura 7. Distribuição anual média (a, b, c) da temperatura máxima ( $^{\circ}\text{C}$ ), (d, e, f) temperatura mínima ( $^{\circ}\text{C}$ ), (g, h, i) precipitação (mm) do ssp126/ssp245/ssp370.

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.

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.

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.

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.

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.

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.

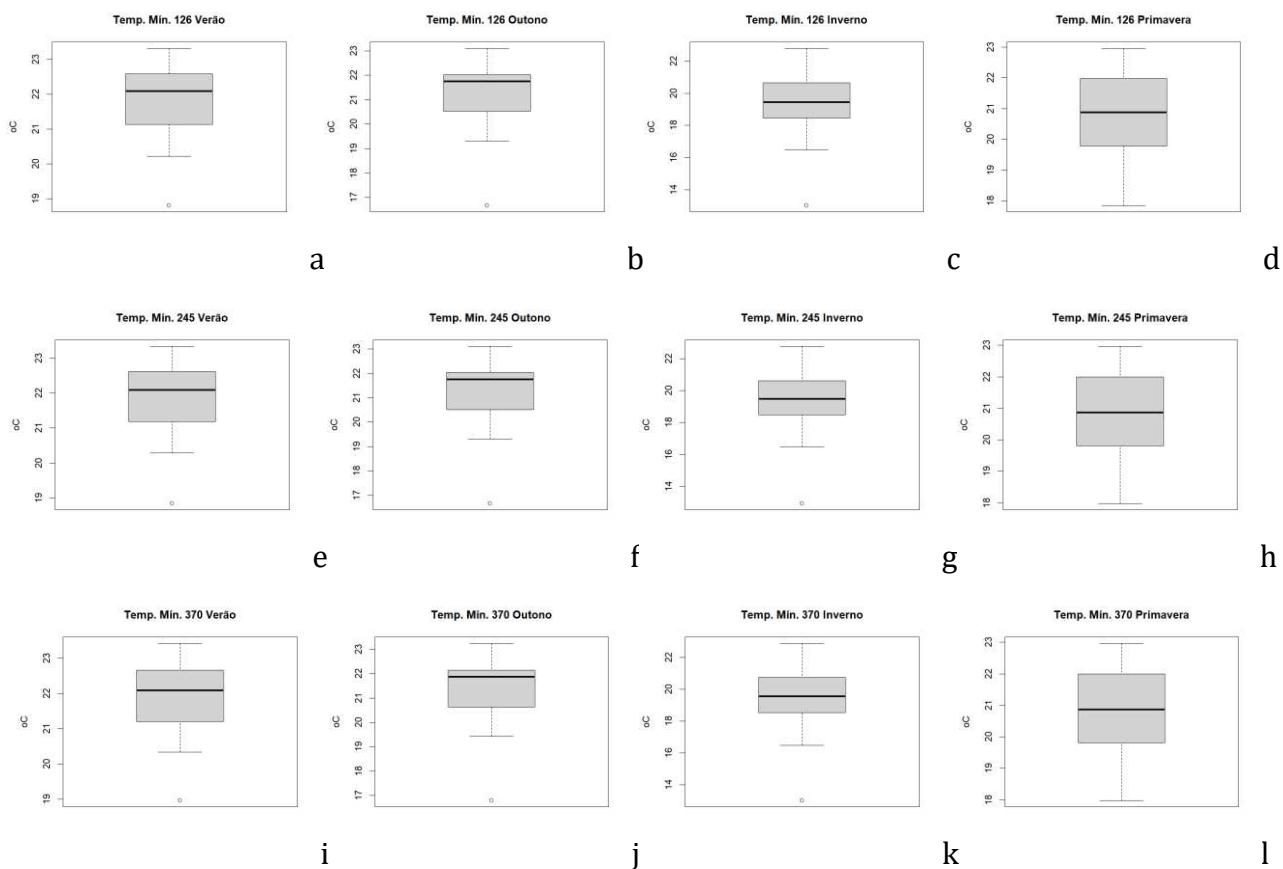


Figura 8. Boxplot da temperatura mínima ( $^{\circ}\text{C}$ ) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

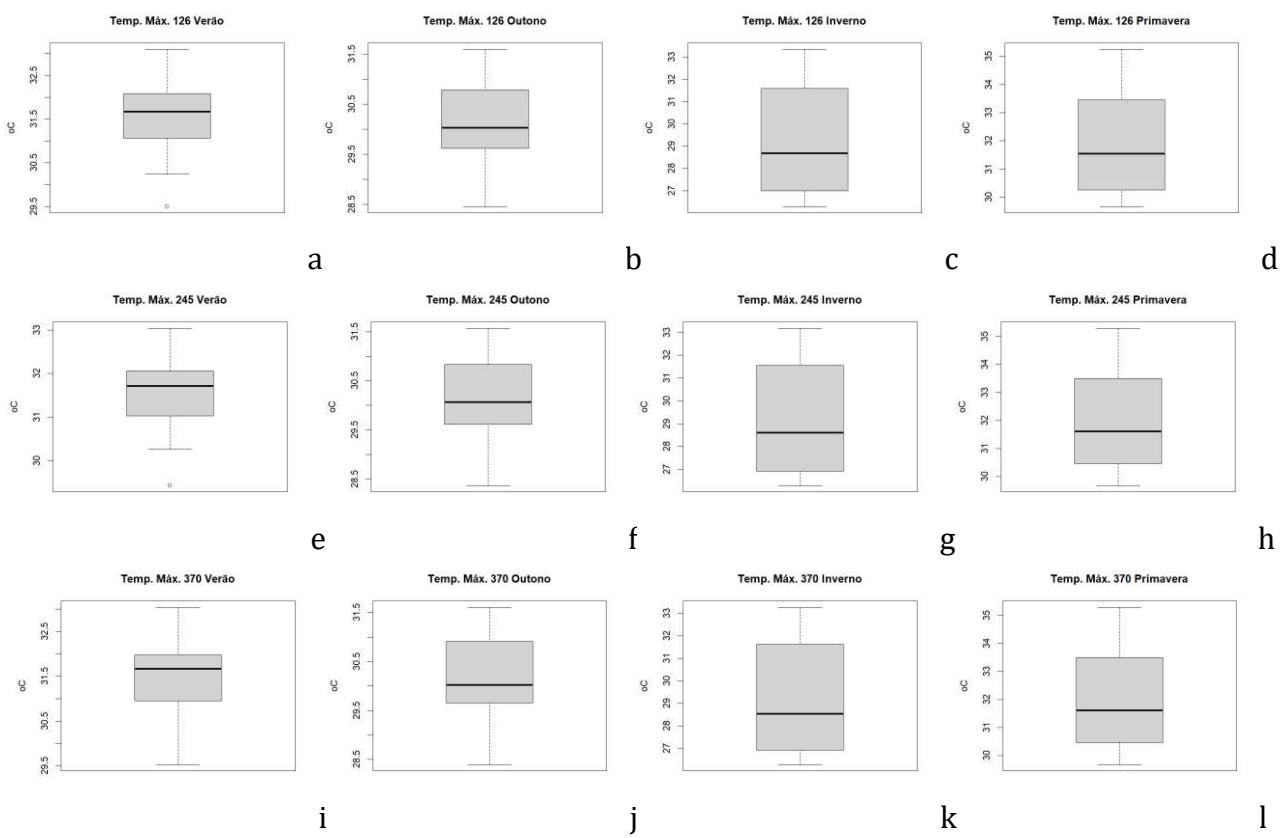


Figura 9. Boxplot da temperatura máxima ( $^{\circ}\text{C}$ ) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

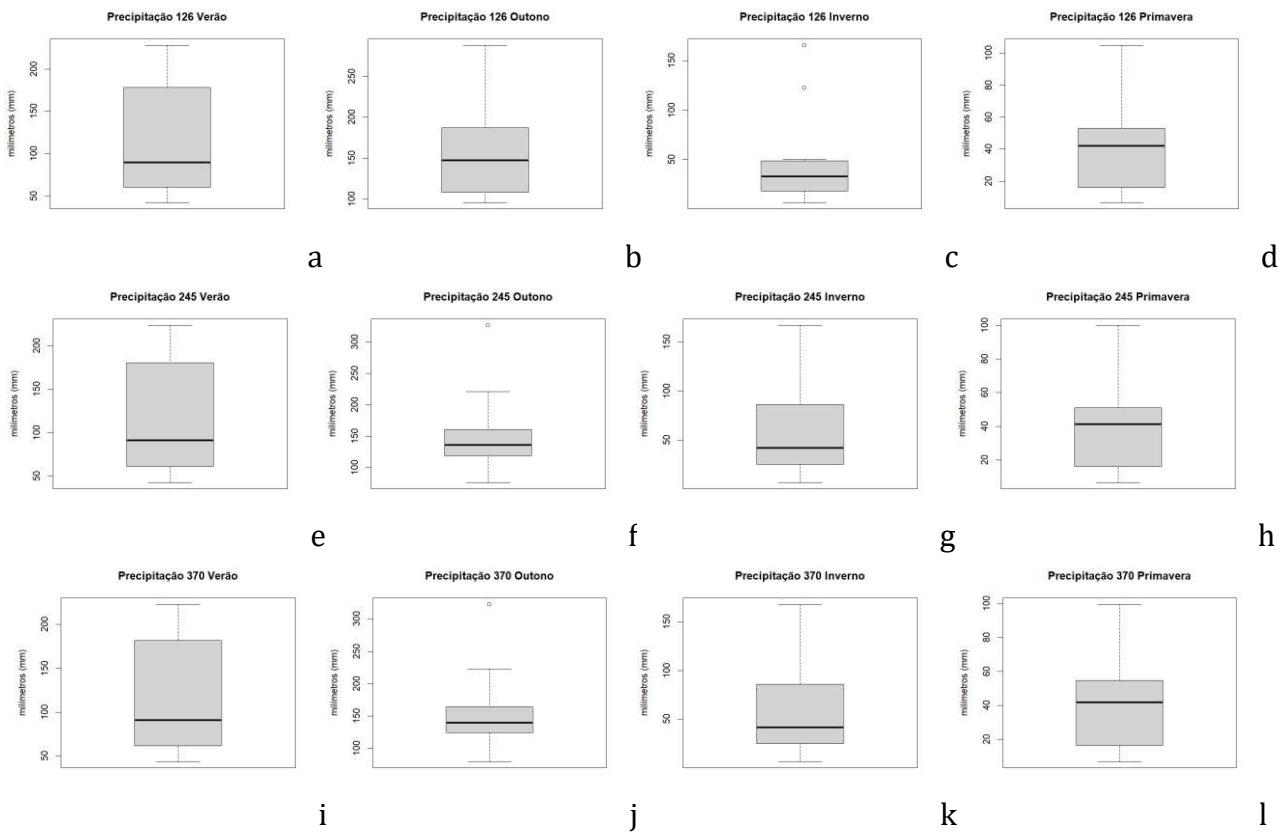


Figura 10. Boxplot da precipitação (mm) sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

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.

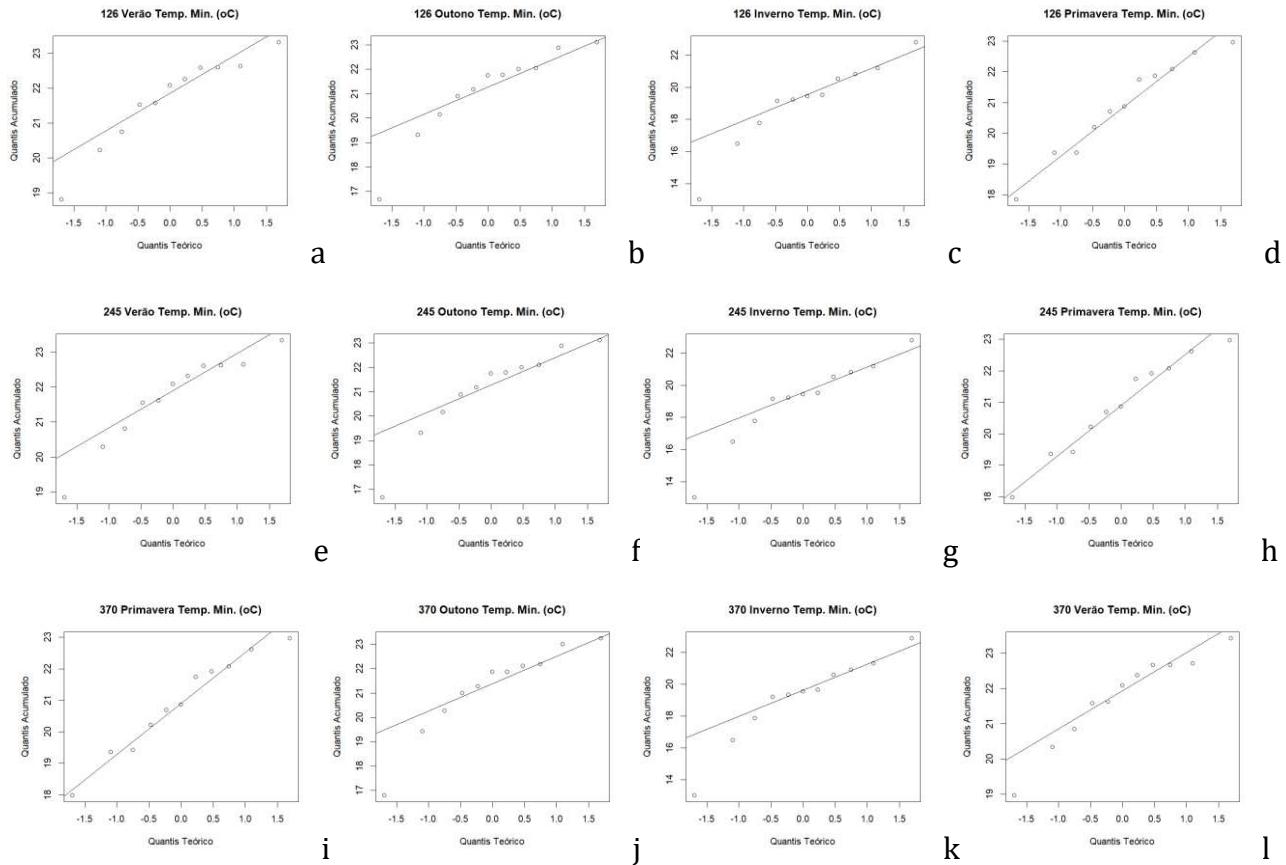


Figura 11. Quantis da temperatura mínima média sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

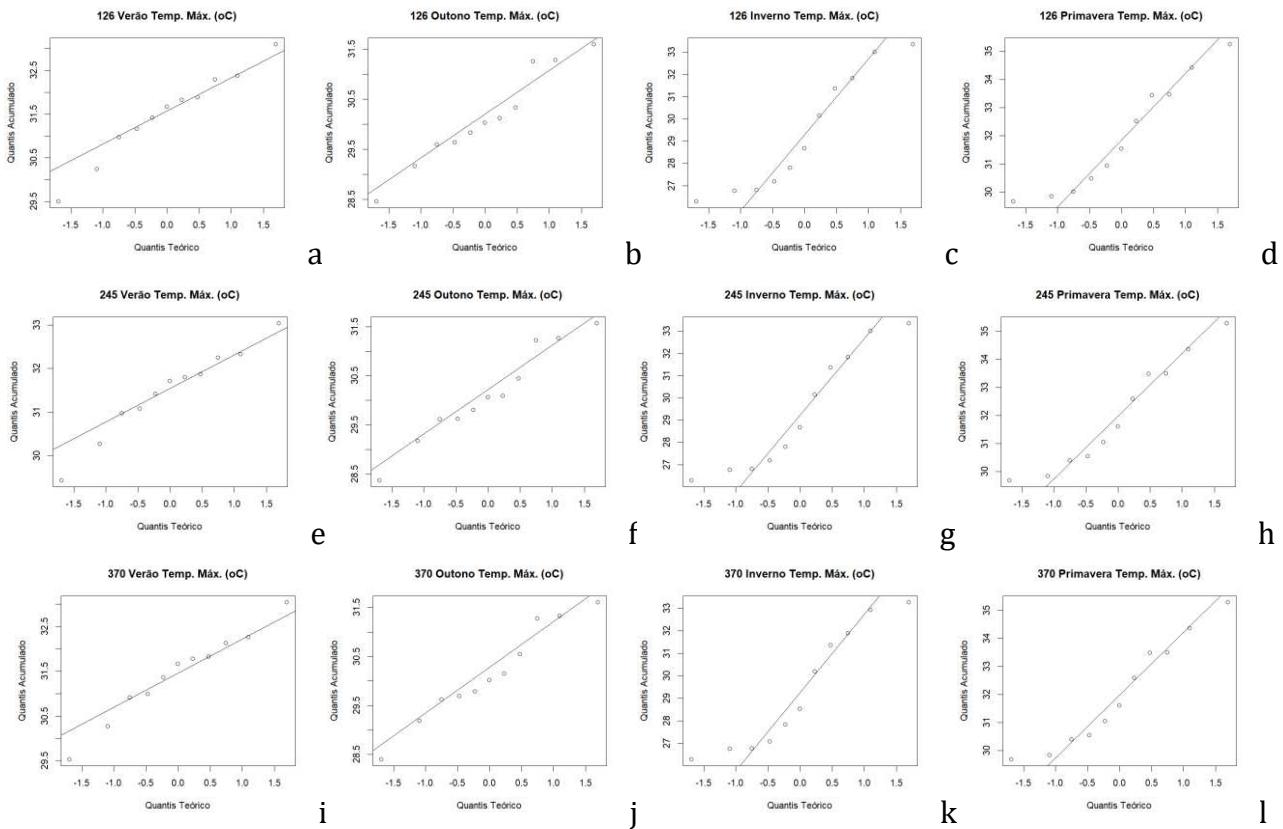


Figura 12. Quantis da temperatura máxima média sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

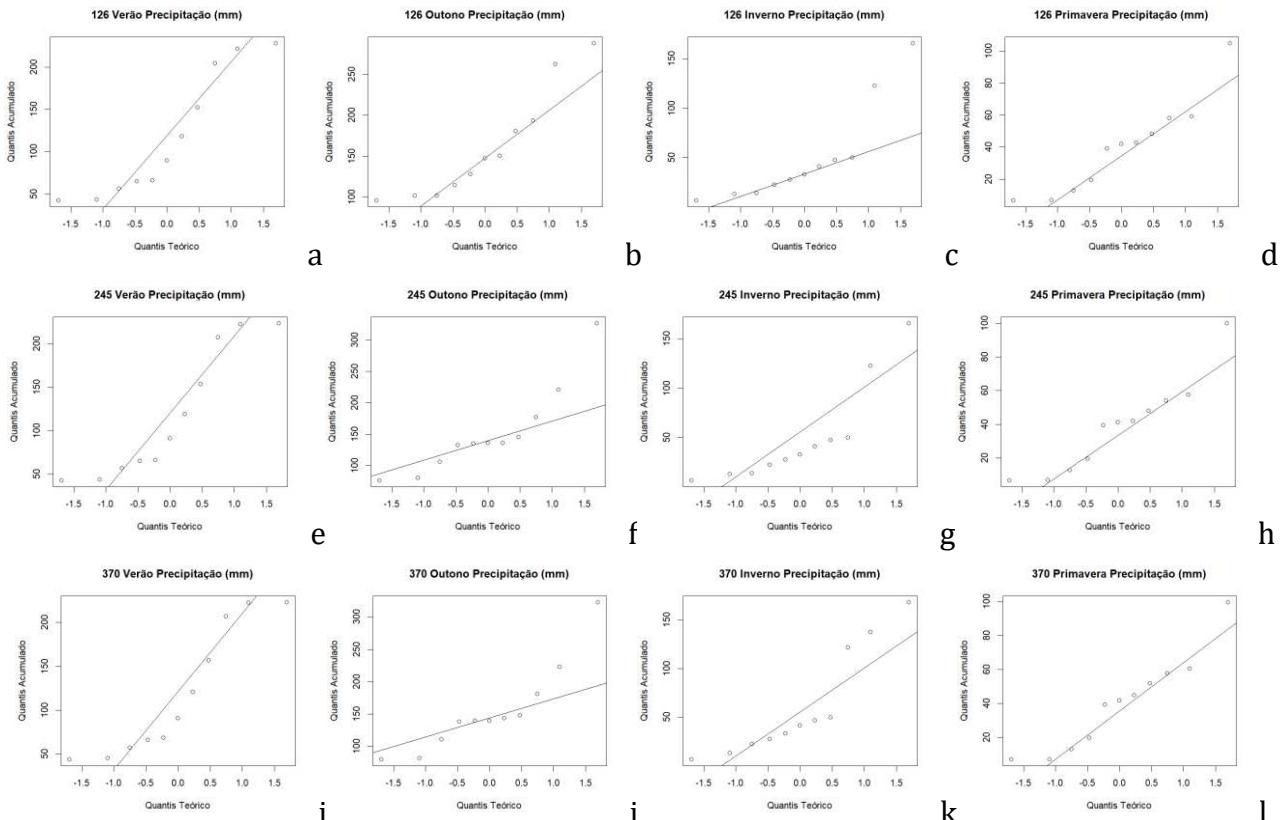


Figura 13. Quantis da precipitação média sazonal do ssp126/245/370, (a, e, i) verão, (b, f, j) outono, (c, g, k) inverno, (d, h, l) primavera.

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.

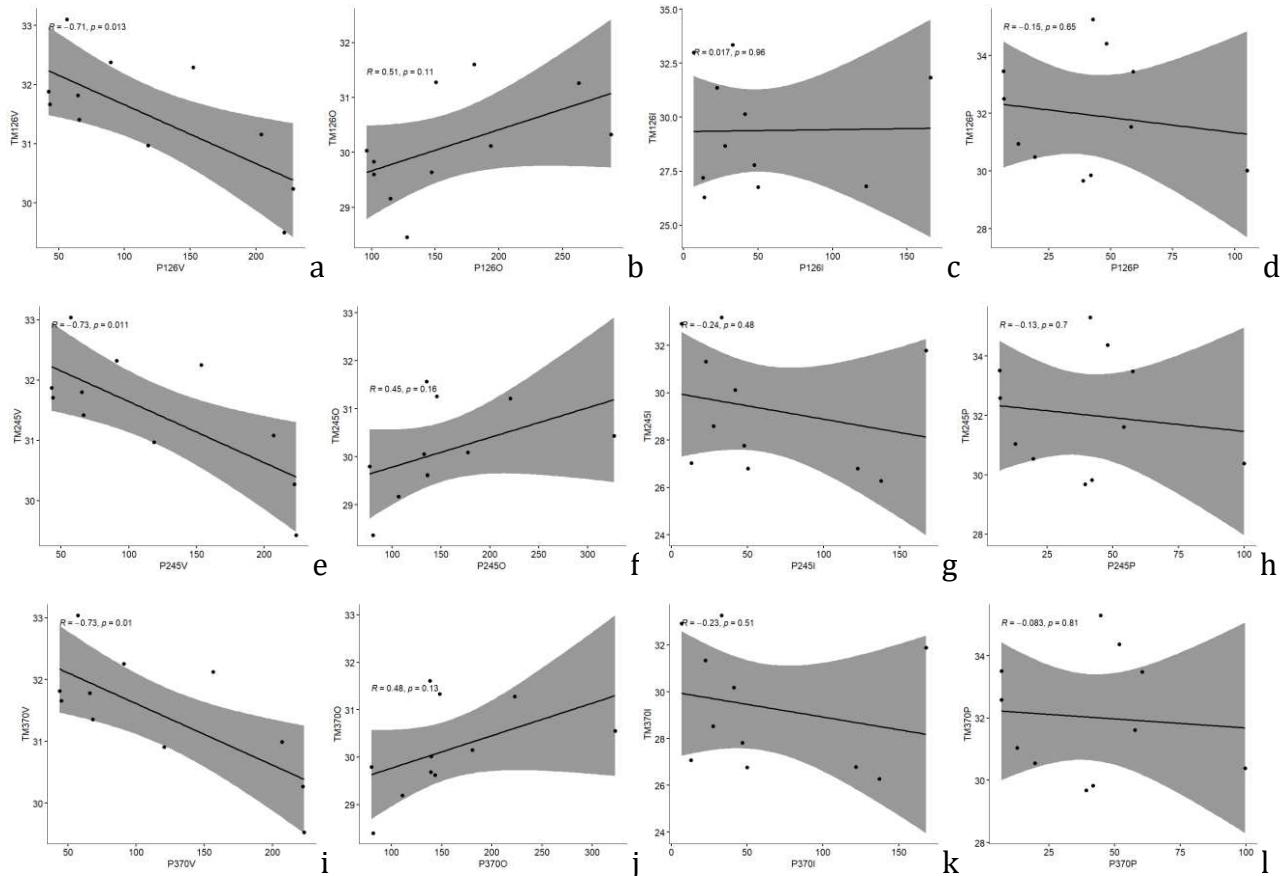


Figura 14. Correlação de Pearson entre a precipitação e temperatura máxima sazonal do ssp126 (a, b, c, d), ssp245 (e, f, g, h), ssp370 (i, j, k, l).

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 melhoraram, 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.

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).

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 BIBLIOGRÁFICAS**

ALMAZROUI, M.; ASHFAQ, M.; ISLAM, M. N. Assessment of CMIP6 performance and projected temperature and precipitation changes over South America. *Earth Syst Environ*, v.5, p.155–183, 2021.

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.; TIPPETT, M. K.; SAEED, S.; HAARSMA, R.; DOBLAS-REYS, F. J.; SAEED, F.; KUCHARSKI, F.; NADEEM, I.; SILVAVIDAL, Y.; RIVERA, J. A.; EHSAN, M. A.; MARTÍNEZ-CASTRO, D.; MUÑOZ, A. G.; ALI, M. A.; COPPOLA, E.; SYLLA, M. B. Assessment of CMIP6 performance and projected temperature and precipitation changes over South America. *Earth Systems and Environment*, v.5, n.2, p.155-183, 2021.

- ALVES, L. M.; CHADWICK, R.; MOISE, A.; BROWN, J.; MARENGO, J. A. Assessment of rainfall variability and future change in Brazil across multiple timescales. *International Journal of Climatology*, v.41, e1875-1888, 2021.
- BABAOUSMAIL, H.; HOU, R.; AYUGI, B.; OJARA, M.; NGOMA, H.; KARIM, R.; RAJASEKAR, A.; ONGOMA, V. Evaluation of the performance of CMIP6 models in reproducing rainfall patterns over North Africa. *Atmosphere*, v.12, n.4, p.475, 2021.
- BARBOSA, C. C.; CÂMARA, G.; MEDEIROS, J. S. DE; CREPANI, E.; NOVO, E.; CORDEIRO, J. P. C. Operadores zonais em álgebra de mapas e sua aplicação no Zoneamento Ecológico Econômico. In: Simpósio Brasileiro de Sensoriamento Remoto, 9, 1998, Santos. Anais...Santos, 1998.
- BERTRAND, G. Paisagem e Geografia Física Global: Esboço Metodológico. Caderno de Ciências da Terra, 13. Inst. de Geografia-USP. São Paulo. 1981.
- BLÁZQUEZ, J.; NUNEZ, M. N. Analysis of uncertainties in future climate projections for South America: comparison of WCRP-CMIP3 and WCRP-CMIP5 models. *Climate Dynamics*, v.41, n.3, p.1039-1056, 2013.
- BOCK, L.; LAUER, A.; SCHLUND, M.; BARREIRO, M.; BELLOUIN, N.; JONES, C.; MEEHL, G. A.; PREDOI, V.; ROBERTS, M. J.; EYRING, V. Quantifying progress across different CMIP phases with the ESMValTool. *Journal of Geophysical Research: Atmospheres*, v.125, n.21, e2019JD032321, 2020.
- BUSTOS USTA, D. F.; TEYMOURI, M.; CHATTERJEE, U. Projections of temperature changes over South America during the twenty-first century using CMIP6 models. *GeoJournal*, v.87, p.1-25, 2021.
- CHEN, C. A.; HSU, H. H.; LIANG, H. C. 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*, v.31, e100303, 2021.
- CHEN, H.; SUN, J.; LIN, W.; XU, H. Comparison of CMIP6 and CMIP5 models in simulating climate extremes. *Science Bulletin*, v.65, n.17, p.1415-1418, 2020.
- CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WEHBERG, J.; WICHMANN, V.; BÖHNER, J. System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. *Geosci. Model Dev.*, v.8, p.1991-2007, 2015.
- CUNHA, A. P. M. A.; TOMASELLA, J.; RIBEIRO NETO, G. G.; BROWN, M.; GARCIA; S. R.; BRITO, S. B.; CARVALHO, M. A. Changes in the spatial-temporal patterns of droughts in the Brazilian Northeast. *Atmospheric Science Letters*, v.19, n.10, p.1-8, 2018.

DANTAS, L. G.; SANTOS, C. A.; SANTOS, C. A.; MARTINS, E. S.; ALVES, L. M. Future changes in temperature and precipitation over northeastern Brazil by CMIP6 model. *Water*, v.14, n.24, e4118, 2022.

EC-EARTH CONSORTIUM. ECEarth-Consortium EC-Earth3-Veg model output prepared for CMIP6 ScenarioMIP. Earth System Grid Federation. 2019.

EYRING, V.; BONY, S.; MEEHL, G. A.; SENIOR, C. A.; STEVENS, B.; STOUFFER, R. J.; TAYLOR, K. E. Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geoscientific Model Development*, v.9, n.5, p.1937-1958, 2016.

FAN, X.; DUAN, Q.; SHEN, C.; WU, Y.; XING, C. Global surface air temperatures in CMIP6: Historical performance and future changes. *Environmental Research Letters*, v.15, n.10, e104056, 2020.

FAN, X.; MIAO, C.; DUAN, Q.; SHEN, C.; WU, Y. The Performance of CMIP6 versus CMIP5 in simulating temperature extremes over the global land surface. *Journal of Geophysical Research: Atmospheres*, v.125, n.18, p.1-16, 2020.

FEDOROVA, N.; LEVIT, V.; CRUZ, C. D. On frontal zone analysis in the tropical region of the Northeast Brazil. *Pure and Applied Geophysics*, v.173, p.1403-1421, 2016.

FIRPO, M. A. F.; GUIMARASIM, B. S.; DANTAS, L. G.; SILVA, M. G. B.; ALVES, L. M.; CHADWICK, R.; LLOPART, M. P.; OLIVEIRA, G. S. Avaliação do desempenho dos modelos CMIP6 na simulação do clima atual no Brasil. *Frente. Clim.*, v.4, e948499, 2022.

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. Climatology of easterly wave disturbances over the tropical South Atlantic. *Climate Dynamics*, v.53, p.1393-1411, 2019.

GOMES, H. B.; SILVA, M. C. L.; BARBOSA, H. D. M. J.; AMBRIZZI, T.; BALTAZI, H.; GOMES, H. B.; SILVA, F. D. S.; COSTA, R. L.; FIGUEROA, S. N.; HERDIES, D. L.; PAULIQUEVIS JÚNIOR, T. M. WRF Sensitivity for Seasonal Climate Simulations of Precipitation Fields on the CORDEX South America Domain. *Atmosphere*, v.13, n.1, e107, 2022.

GULIZIA, C.; CAMILLONI, I. 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*, v.35, n.4, p.583-595, 2015.

GUSAIN, A.; GHOSH, S.; KARMAKAR, S. Added value of CMIP6 over CMIP5 models in simulating Indian summer monsoon rainfall. *Atmospheric Research*, v.232, e104680, 2020.

HANSEN, J.; FUNG, I.; LACIS, A.; RIND, D.; LEBEDEFF, S.; RUEDY, R.; RUSSELL, G.; STONE, P. Global climate changes as forecast by Goddard Institute for Space Studies 3-dimensional model. *Journal Geophys. Res.*, v.93, p.9341-9364, 1988.

HARTSHORNE, R. Propósitos e Natureza da Geografia. São Paulo. HUCITEC/EDUSP, 1978.

HYNDMAN, R. J.; FAN, Y. Sample Quantiles in Statistical Packages. *The American Statistician*, v.50, n.4, p.361-365, 1996.

KENDALL, M. A.; STUART, A. The advanced theory of statistics. 2.a ed. Londres: Charles Griffin, 1967.

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. A Review of Uncertainties in Global Temperature Projections over the Twenty-First Century. *Journal of Climate*, v.21, n.11, p.2651–2663, 2008.

KNUTTI, R.; SEDLÁČEK, J. Robustness and uncertainties in the new CMIP5 climate model projections. *Nature Climate Change*, v.3, p.369–373, 2013.

KNUTTI, R.; STOCKER, T. F.; JOOS, F.; PLATTNER, G. K. Constraints on radiative forcing and future climate change from observations and climate model ensembles. *Nature*, v.416, p.719-723, 2002.

KODAMA, Y. 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*, v.70, n.4, p.813-836, 1992.

KOLMOGOROV, A. Sulla determinazione empirica di una legge di distribuzione. *Giornale dell'Istituto Italiano Degli Attuari*, v.4, p.83-91, 1933.

KOUSKY, V. E. Frontal influences on northeast Brazil. *Monthly Weather Review*, v.107, n.9, p.1140-1153, 1979.

KOUSKY, V. E.; ALONSO GAN, M. Upper tropospheric cyclonic vortices in the tropical South Atlantic. *Tellus*, v.33, n.6, p.538-551, 1981.

KVAM, P. H.; VIDAKOVIC, B. Nonparametric statistics with applications to science and engineering. New York: Wiley, 2007.

LILLIEFORS, H. W. On the Kolmogorov-Smirnov test for normality with mean and variance unknown. *Journal of the American Statistical Association*, v.62, n.318, p.399-402, 1967.

LOVINO, M. A.; MÜLLER, O. V.; BERBERY, E. H.; MÜLLER, G. V. Evaluation of CMIP5 retrospective simulations of temperature and precipitation in northeastern Argentina. *International Journal of Climatology*, v.38, p.1158-1175, 2018.

LUIZ-SILVA, W.; OSCAR-JÚNIOR, A. C.; CAVALCANTI, I. F. A.; TREISTMAN, F. An overview of precipitation climatology in Brazil: space-time variability of frequency and intensity associated with atmospheric systems. *Hydrological Sciences Journal*, v.66, n.2, p.289-308, 2021.

- LUO, N.; GUO, Y.; CHOU, J.; GAO, Z. Added value of CMIP6 models over CMIP5 models in simulating the climatological precipitation extremes in China. *International Journal of Climatology*, v.42, n.2, p.1148-1164, 2022.
- MANN, H. B. Non-parametric tests against trend. *Econometrica*, v.13, n.3, p. 245-259, 1945.
- 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. Assessing drought in the drylands of northeast Brazil under regional warming exceeding 4 °C. *Natural Hazards*, v.103, p.2589-2611, 2020.
- MARENGO, J. A.; TORRES, R. R.; ALVES, L. M. Drought in northeast Brazil-past, present, and future. *Theoretical and Applied Climatology*, v.129, n.3-4, p.1189-1200, 2017.
- MEDEIROS, F. J.; GOMES, R. D. S.; COUTINHO, M. D. L.; LIMA, K. C. Meteorological droughts and water resources: Historical and future perspectives for Rio Grande do Norte state, Northeast Brazil. *International Journal of Climatology*, v.42, n.13, p.6976-6995, 2022.
- MEDEIROS, F. J.; OLIVEIRA, C. P.; TORRES, R. R. Climatic aspects and vertical structure circulation associated with the severe drought in Northeast Brazil (2012–2016). *Climate Dynamics*, v.55, p.2327-2341, 2020.
- MEEHL, G. A.; COVEY, C.; DELWORTH, T.; LATIF, M.; McAVANEY, B.; MITCHELL, J. F.; STOUFFER, R. J.; TAYLOR, K. E. The WCRP CMIP3 multimodel dataset: A new era in climate change research. *Bulletin of the American Meteorological Society*, v.88, n.9, p.1383-1394, 2007.
- MORAIS, M. D. C.; GAN, M. A.; YOSHIDA, M. C. Features of the upper tropospheric cyclonic vortices of Northeast Brazil in life cycle stages. *International Journal of Climatology*, v.41, e39-58, 2021.
- MUTTI, P. R.; DUBREUIL, V.; BEZERRA, B. G.; ARVOR, D.; OLIVEIRA, C. P.; SANTOS e SILVA, C. M. Assessment of gridded CRU TS data for long-term climatic water balance monitoring over the São Francisco Watershed, Brazil. *Atmosphere*, v.11, n.11, e1207, 2020.
- OLIVEIRA, D. H. M. C.; LIMA, K. C. What is the return period of intense rainfall events in the capital cities of the northeast region of Brazil? *Atmospheric Science Letters*, v.20, n.10, e934, 2019.
- OLIVEIRA, P. D.; SANTOS e SILVA, C. M.; LIMA, K. C. Climatology and trend analysis of extreme precipitation in subregions of Northeast Brazil. *Theoretical and Applied Climatology*, v.130, p.77-90, 2017.
- ORTEGA, G.; ARIAS, P. A.; VILLEGAS, J. C.; MARQUET, P. A.; NOBRE, P. Present-day and future climate over central and South America according to CMIP5/ CMIP6 models. *International Journal of Climatology*, v.41, n.15, p.6713-6735, 2021.

- PEARSON, K. The grammar of science. London, J. M. Dent and Company, 1892.
- 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.; FICHEFET, 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.; WEAVER, A. J. Long-Term Climate Commitments Projected with Climate–Carbon Cycle Models. *Journal of Climate*, v.21, n.12, p.2721-2751, 2008.
- QGIS. Development Team. 2022. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Disponível em: <http://qgis.osgeo.org>.
- RIVERA, J. A.; ARNOULD, G. Evaluation of the ability of CMIP6 models to simulate precipitation over Southwestern South America: Climatic features and long-term trends (1901–2014). *Atmospheric Research*, v.241, e104953, 2020.
- RODRIGUES, D. T.; GONÇALVES, W. A.; SPYRIDES, M. H.; SANTOS e SILVA, C. M.; SOUZA, D. O. Spatial distribution of the level of return of extreme precipitation events in Northeast Brazil. *International Journal of Climatology*, v.40, n.12, p.5098-5113, 2020.
- RStudio. Posit Software. Disponível em: <https://posit.co/download/rstudio-desktop/>.
- S. B.; CARVALHO, M. A. Changes in the spatial-temporal patterns of droughts in the Brazilian Northeast. *Atmospheric Science Letters*, v.19, n.10, p.1-8, 2018.
- SANTOS, A. L. S.; SILVA, H. S. D.; SILVA, J. R. S.; STOSIC, T. Propriedades multifractais da temperatura do ar diária no Nordeste do Brasil. *Revista Brasileira de Meteorologia*, v. 34, p. 23-31, 2019.
- SHAPIRO, A. S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). *Biometrika*, v.52, n.3/4, p.591–611, 1965.
- SMIRNOV, N. Table for Estimating the Goodness of Fit of Empirical Distributions. *The Annals of Mathematical Statistics* v.19, n.2, p.279–281, 1948.
- SRIVASTAVA, A.; GROTJAHN, R.; ULLRICH, P. A. Evaluation of historical CMIP6 model simulations of extreme precipitation over contiguous US regions. *Weather and Climate Extremes*, v.29, e100268, 2020.
- STOTT, P. A.; KETTLEBOROUGH, J. A. Origins and estimates of uncertainty in predictions of twenty-first century temperature rise. *Nature*, v.416, p.723-726, 2002.
- STOTT, P. A.; MITCHELL, J. F. B.; ALLEN, M. R.; DELWORTH, T. L.; GREGORY, J. M.; MEEHL, G. A.; SANTER, B. D. Observational constraints on past attributable warming and predictions of future global warming. *Journal Climate*, v.19, p.3055-3069, 2006.
- TAYLOR, K. E.; STOUFFER, R. J.; MEEHL, G. A. An overview of CMIP5 and the experiment design. *Bulletin of the American meteorological Society*, v.93, n.4, p.485-498, 2012.

TRICART, J. Ecodinâmica. Rio de Janeiro. IBGE-SUPREN, 1977.

TRICART, J.; KIEWIETDEJONGE, C. Ecogeography and Rural Management: A Contribution to the International Geosphere-Biosphere Programme. Essex. Longman Scientific & Technical, 1992.

UKKOLA, A. M.; KAUWE, M. G.; RODERICK, M. L.; ABRAMOWITZ, G.; PITMAN, A. J. Robust future changes in meteorological drought in CMIP6 projections despite uncertainty in precipitation. *Geophysical Research Letters*, v.47, n.11, e2020GL087820, 2020.

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. Tropical South Atlantic influence on Northeastern Brazil precipitation and ITCZ displacement during the past 2300 years. *Scientific Reports*, v.9, n.1, e1698, 2019.

UVÖ, C. B.; REPELLI, C. A.; ZEBIAK, S. E.; KUSHNIR, Y. The relationships between tropical Pacific and Atlantic SST and northeast Brazil monthly precipitation. *Journal of Climate*, v.11, n4, p. 551-562, 1998.

VAN VUUREN, D. P.; EDMONDS, J.; KAINUMA, M.; RIAHI, K.; THOMSON, A. et al. The representative concentration pathways: an overview. *Climatic Change*, v.5, p.109, 2011.

WIGLEY, T. M. L. 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. 2004.

WIGLEY, T. M. L.; RICHELS, R.; EDMONDS, J. A. Economic and environmental choices in the stabilization of atmospheric CO<sub>2</sub> concentrations. *Nature*, v.379, p.240-243, 1996.

ZAMANI, Y.; MONFARED, S. A. H.; MOGHADDAM, M. A.; HAMIDIANPOUR, M. A comparison of CMIP6 and CMIP5 projections for precipitation to observational data: the case of Northeastern Iran. *Theoretical and Applied Climatology*, v.142, p.1613-1623, 2020.

ZHU, H.; JIANG, Z.; LI, J.; LI, W.; SUN, C.; LI, L. Does CMIP6 inspire more confidence in simulating climate extremes over China? *Advances in Atmospheric Sciences*, v.37, p.1119-1132, 2020.

ZILLI, M. T.; CARVALHO, L. M.; LINTNER, B. R. The poleward shift of South Atlantic Convergence Zone in recent decades. *Climate Dynamics*, v.52, p.2545-2563, 2019.

## CURRICULUM DOS AUTORES

**Paulo Roberto Megna Francisco:** Atuou como Pesquisador de Desenvolvimento Científico Regional de Interiorização na Universidade Federal da Paraíba-UFPB-CCA/Areia. Graduado como Engenharia Agrícola pela UFCG. Doutorado em Recursos Naturais (Concentração em Engenharia de Recursos Naturais). Possui Doutorado em Engenharia Agrícola (Concentração em Irrigação e Drenagem) pela Universidade Federal de Campina Grande - UFCG (2013), Mestrado em Agronomia - Manejo de Solo e Água (Concentração - Agricultura Sustentável e Planejamento Ambiental) pela Universidade Federal da Paraíba - UFPB - Areia (2010), Graduado como Tecnólogo Agrícola (Mecanização) pela Universidade Estadual Paulista Júlio de Mesquita Filho - UNESP - Bauru (1990). Tem experiência na Docência na área de Agronomia, com ênfase em Mecanização Agrícola, Máquinas e Implementos Agrícolas e Máquinas Agrozootécnicas. Atua como pesquisador, colaborador e orientador em projetos junto à UFPB Campus de Areia, UFCG - Campus de Campina Grande e Campus de Sumé. Tem experiência em classificação técnica e mapeamento de solos, aptidão agrícola e pedoclimática, capacidade de uso do solo, geoprocessamento, cartografia, sensoriamento remoto, geoestatística, geração de balanço hídrico e índices climáticos. Prestou consultoria para o INCRA/PB na realização de PDAs. Foi Consultor Ad hoc do CONFEA como organizador do CONTECC. Editor Chefe da Editora Portal Tecnológico-EPTEC. Atualmente colabora como organizador e na comissão científica do CNMA-Poços de Caldas.

**paulomegna@gmail.com**

 <https://orcid.org/0000-0002-5062-5434>

**José Hugo Simplicio de Sousa:** Engenheiro de Biossistemas pela Universidade Federal de Campina Grande, CDSA/Campus Sumé com ênfase em Sensoriamento Remoto e geoprocessamento. Atuou como bolsista do Programa Institucional de Iniciação Científica-PIBIC, em projetos na área de Sensoriamento Remoto e Geoprocessamento, entre 2021 a 2023 e atuou em projeto na área de secagem de alimentos entre 2020 e 2021. Ex-Membro Associado Consultor Júnior da SistemBIO Jr, Empresa Júnior do curso de Engenharia de Biossistemas da UFCG/CDSA.

**hugosimplicio123@gmail.com**

 <https://orcid.org/0000-0001-5068-0663>

**George do Nascimento Ribeiro:** Possui graduação em Agronomia (2003) e mestrado em Manejo e Conservação de Solo e Água (2006) pela Universidade Federal da Paraíba, doutorado em Engenharia Agrícola pela Universidade Federal de Campina Grande (2014) e Pós-doutorado em Fontes Alternativas de Energias pelo Programa de Pós-graduação em Engenharia Química da UFCG (LABFREN/UFCG). Atualmente é professor da Universidade Federal de Campina Grande/CDSA/Campus Sumé. Tem experiência nas áreas de Geociências, com ênfase em Sensoriamento Remoto (recursos naturais, geotecnologias e mapeamento temático) e em Energias Renováveis (produção de hidrogênio como fonte de combustível para fuel cell e energia solar - placas fotovoltaicas).

**george.nascimento@professor.ufcg.edu.br**

 <https://orcid.org/0000-0003-4225-0967>

**José Nilton Silva:** Bacharel em Engenharia Química pela Universidade Federal de Campina Grande (2009), Mestre e Doutor em Engenharia Química pela Universidade Federal de Campina Grande (2013), Licenciado em Química pela Universidade Estadual da Paraíba (2006). É Professor Adjunto na Universidade Federal de Campina Grande, lotado no Departamento de Engenharia Química, do Centro de Ciências e Tecnologias. Tem experiência na área de Engenharia Química, Sistemas Computacionais, com ênfase em processos e processamento de dados, atuando principalmente nos temas: modelagem, simulação de processos, projeto de processos industriais e energias renováveis. Na área de Gestão em Ciência, Tecnologia e Inovação é ativo em Sistemas de Inovação, Empreendedorismo Inovador, Proteção do Conhecimento, Transferência de Tecnologia, Interação Universidade-Empresa e Incubadoras de Empresas/Parques Tecnológicos. É orientador do quadro dos PPGs em Engenharia Química-UFCG e do PROFNIT- ponto focal Paraíba. Coordenou o Núcleo de Inovação e Transferência de Tecnologia NITT/UFCG (2017-2018), e atual assessor de PI do NITT-UFCG, e em 2018, Diretor Geral da Fundação Parque Tecnológico da Paraíba - PaqTcPB. [nilton@eq.ufcg.edu.br](mailto:nilton@eq.ufcg.edu.br)

 <https://orcid.org/0000-0001-7128-8396>



978-65-00-90539-7