

AVALIAÇÃO DAS SIMULAÇÕES DE TEMPERATURA E PRECIPITAÇÃO DE UM SUBCONJUNTO DE MODELOS DO CMIP6 PARA O BRASIL

Wesley de Souza Campos CORREA

Wagner Rodrigues SOARES

Georgynio Y. Rosales AYLAS

Neyval Costa REIS JUNIOR

José A. MARENGO

Sin Chan CHOU

Carlos NOBRE

RESUMO

Este artigo examina a capacidade do conjunto de 40 modelos climáticos do Coupled Model Intercomparison Projects Generation 6 - CMIP6, conjunto MOD, para simular a temperatura do ar e a precipitação médias do período de janeiro de 1985 a dezembro de 2014 em cada estado do Brasil. Apesar dos vieses nas simulações, o subconjunto do CMIP6 conseguiu simular satisfatoriamente o ciclo anual e sazonal da temperatura e precipitação, bem como captar a tendência das variáveis analisadas no Brasil. Em relação a temperatura do ar à superfície, o subconjunto do CMIP6 apresentou o melhor desempenho para as Regiões Sul e Sudeste do Brasil, com destaque para os estados do Paraná, Santa Catarina e São Paulo. O melhor desempenho para a precipitação, com o subconjunto do CMIP6 foi verificado sobre a Região Centro-Oeste. Em relação às tendências de aquecimento no período de 30 anos do estudo, 1985-2014, todos estados do Brasil apresentaram tendência de aquecimento, tanto para os dados do subconjunto do CMIP6, quanto para os dados observados. A precipitação na região Norte e Sudeste, não exibiu tendências claras para o período analisado, alguns estados apresentaram aumento e outros redução da precipitação. Nas Regiões Centro-Oeste e Nordeste todos estados apresentam tendência de redução da chuva. Na Região Sul, os três estados mostram tendência de aumento na chuva tanto no observado quanto no simulado. No entanto, além das incertezas inerentes a modelagem climática e vieses detectados, este estudo é relevante para indicar o comportamento dos modelos em simular o clima presente. A avaliação apresentada neste trabalho estabeleceu níveis de confiança no uso deste subconjunto de simulações de modelos para estudos do clima futuro, conforme detalhado no texto.

Palavras-chave: Modelagem; Modelos Climáticos Globais; IPCC; Mudanças climáticas.

ABSTRACT

EVALUATION OF TEMPERATURE AND PRECIPITATION SIMULATIONS OF A SUBSET OF CMIP6 MODELS FOR BRAZIL. This article examines the ability of 40 CMIP6 climate models to simulate the mean temperature and mean precipitation observed in each state in Brazil from January 1985 to December 2014. Despite the simulation biases, the CMIP6 was able to simulate the annual and seasonal behavior and capture the trend of the analyzed variables. For surface temperature, the subset of the CMIP6 showed the best performance for the South and Southeast Brazil regions,

highlighted in Paraná, Santa Catarina, and São Paulo states. Midwest Region has the best performance for precipitation. In relation to temperature trends over the 30-year study period, 1985–2014, all states in Brazil showed an increasing trend, both for the subset of the CMIP6 and observed data. However, precipitation in the North and Southeast regions did not show a clear trend for the analyzed period, since some states showed an increase whereas some showed a reduction. However, the states in the Central-West and Northeast regions show a trend toward a reduced precipitation. On the other hand, in the South Region, all states have increasing precipitation, as supported by observed and simulated data. Even with the inherent uncertainties in climate modeling and detected biases, this study is relevant to show the behavior of the present models nowadays climate simulations. The evaluation presented in this work established confidence levels to use the subset CMIP6 model in future climate studies, as detailed in this paper.

Keywords: Modeling; Global Climate Model; IPCC; Climate change.

INTRODUÇÃO

As mudanças climáticas globais são um tema amplamente debatido, principalmente durante as duas últimas décadas, foco de diversos estudos científicos e relatórios direcionados para a comunidade científica e tomadores de decisão. Entre eles, há relatórios elaborados pelo Painel Intergovernamental de Mudanças Climáticas (IPCC) desde a década de 1990, os quais vêm sinalizando o aquecimento global, e também realizando análises de impactos e vulnerabilidade para estratégias de adaptação e mitigação. Propostas de mitigação para reduzir o aquecimento global para menos de 2 °C, metas estabelecidas no Acordo de Paris de 2015 (DELBEKE *et al.* 2019), foram reforçadas na Conferência das Partes das Nações Unidas sobre Mudanças Climáticas – COP26 em Glasgow de 2021 na *United Nations Framework Convention on Climate Change* (UNFCCC 2021). O aquecimento global de 1,5 °C e 2 °C será excedido durante o século 21, a menos que reduções profundas no desmatamento e nas emissões de CO₂ e outros gases de efeito estufa ocorram nas próximas décadas.

O Relatório do IPCC AR6 (IPCC 2021) indica que a temperatura média global aumentou em 1,1 °C em relação a era pré-industrial, de 1850 até 2020. Segundo o Atlas do IPCC (IPCC 2021), a temperatura do ar no Brasil aumentou 0,15 °C por década desde 1961 até 2015. As projeções do clima para o final do século XXI apontam aumento de temperatura e variações na precipitação.

As consequências do aquecimento global têm sido experimentadas em todo mundo, incluindo extremos do tempo e do clima no Brasil.

A Região Nordeste tem um histórico de secas (MARENGO *et al.* 2020a, MARENGO & BER-

NASCONI 2015), dentre essas, destaca-se a seca plurianual na Região entre 2011-2018 (CUNHA *et al.* 2018, MARENGO *et al.* 2017).

O Sudeste do Brasil foi afetado entre 2013 e 2015 por uma seca que gerou uma das piores crises hídricas na história do país (COELHO *et al.* 2016a, b).

Na Amazônia, as secas estão mais cada vez mais recorrentes (GARCIA *et al.* 2018, LIBONATI *et al.* 2021). Sobre o Pantanal, a seca e o calor entre 2019-2021 causaram grandes impactos sobre a fauna e a flora (LIBONATI *et al.* 2022, MARENGO *et al.* 2021).

Por outro lado, eventos de precipitação ao longo do país têm deflagrado enxurradas, enchentes e deslizamentos de terra em áreas urbanas e rurais deixando centenas de mortos (MARENGO *et al.* 2020b, VASCONCELLOS & CAVALCANTI 2010). Ante a esta situação e a fim de compreender as mudanças climáticas no presente e as projeções do clima futuro na América do Sul e no Brasil, foram realizados diversos estudos com a aplicação de Modelos Climáticos Globais e Regionais (MCG e MCR). Por exemplo, JOETZJER *et al.* (2013) avaliaram e compararam a precipitação histórica e futura da Amazônia por meio das fases 3 e 5 do *Coupled Model Intercomparison Project* (CMIP3 e CMIP5) usados nos relatórios do IPCC - *Fifth Assessment Report* (AR5) (IPCC 2014) e anteriores. ALVES *et al.* (2021) avaliaram a variabilidade da precipitação e as mudanças futuras no Brasil em várias escalas de tempo utilizando o CMIP5. DOS SANTOS *et al.* (2020) analisaram os impactos do aquecimento global de 1,5°C a 4°C acima dos níveis pré-industriais sobre o território brasileiro. Mais recentemente, ALMAZROUI *et al.* (2021)

avaliaram o desempenho de um grande conjunto do CMIP6 sobre a América do Sul para um período de referência e examinaram projeções de mudanças de precipitação e temperatura para o século XXI, enquanto DIAS & REBOITA (2021) avaliaram o desempenho do CMIP6 para a América do Sul tropical.

Experiências em regionalização das projeções de clima dos modelos globais usando modelos regionais (*downscaling* dinâmico) 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).

Fica evidente que para se obter alguma confiança nas projeções do clima futuro, derivadas de modelos globais ou regionais, o primeiro passo é avaliar se os modelos representam bem o clima atual, assim como a sua variabilidade espacial e temporal. Todos estes estudos acima listados mostram incertezas nas simulações do clima atual e nas projeções de clima futuro. Tal constatação, reflete-se na relativa dificuldade em representar adequadamente alguns processos do sistema climático. Entretanto, os modelos estão evoluindo, melhorando as parametrizações de processos físicos antes pouco estudados (ex. vegetação dinâmica, química da atmosfera e aerossóis), bem como a sua resolução espacial (IPCC 2021). Esta incerteza é inerente às simulações do clima presente, quanto às projeções do clima futuro. Portanto, estudos de validação das simulações do clima atual a partir dos modelos são uma etapa relevante para estimar a confiabilidade das projeções climáticas futuras e auxiliar os gestores locais no uso destas informações e na tomada de decisões relativa ao clima.

Poucos estudos analisaram o desempenho de modelos para a América do Sul ou para regiões do Brasil, utilizando o conjunto de modelos globais do CMIP6. Por exemplo, DIAS & REBOITA (2021) utilizaram um subconjunto com vários modelos do CMIP6 para avaliar o desempenho regional das simulações para setores da América do Sul e Brasil, porém, não foi elaborada uma análise por estado brasileiro.

Do exposto, faz-se necessário estudos de avaliação de simulações climáticas de temperatura e precipitação, considerando um conjunto (*ensem-*

ble) de simulações do CMIP6, no total de 40 modelos (ver tabela 1, próxima seção), para avaliar a sua performance em representar o clima atual no Brasil. Tal processo é feito comparando as simulações dos modelos com os dados observados regionalizados para cada estado do Brasil.

Informações regionais detalhadas sobre os climas e extremos e com medidas de incerteza são essenciais para alertar os tomadores e gestores de decisão sobre as questões do clima. Tais conhecimentos sobre a tendências de extremos, cada vez mais frequentes e intensos são úteis para preparar medidas de contingência e planos de adaptação, assim como dar suporte às medidas de mitigação, para reduzir o aquecimento global e os seus impactos da mudança do clima.

Assim, uma análise por estado é interessante, pois permite que gestores em nível estadual possam incorporar esses resultados em seus planos de adaptação em relação às mudanças climáticas. A identificação das alterações por território pode auxiliar os gestores dos governos estadual e regional no planejamento urbano, dos recursos hídricos, defesa civil, agricultura e outros. Devemos lembrar da importância estratégica das bacias hidrográficas para a questão de segurança hídrica, as quais se estendem por vários estados (bacias do Paraná, Amazônia, São Francisco, Tocantins), sendo que, nos últimos anos, várias vêm sofrendo com o problema da seca. Desta forma, a análise por estado pode ser útil para a integração de estudos mais elaboradas em nível de bacias ou biomas.

2 METODOLOGIA

2.1 Dados utilizados

2.1.1 Modelos Climáticos Globais (MCG)

O conjunto de modelos climáticos globais utilizados no presente trabalho são provenientes do projeto *Coupled Model Intercomparison Program* Versão 6 - CMIP6 (EYRING *et al.* 2016). O conjunto (*ensemble*) é composto por 40 modelos listados na tabela 1. Os dados do *ensemble* do CMIP6 são fornecidos individualmente e nesse estudo optou-se pela média dos modelos. O conjunto de dados foram obtidos junto a plataforma *Climate Explore* do Instituto de Meteorologia da Holanda, KNMI (https://climexp.knmi.nl/selectfield_cmip6.cgi?id=someone@somewhere). Para a realização

deste estudo foram obtidas as saídas mensais da precipitação e da temperatura do ar, do período histórico de janeiro de 1985 a dezembro de 2014. Esse subconjunto de dados do CMIP6 foi escolhido por

ter o maior número de modelos (40), comparado a outros disponíveis. Doravante, o conjunto MOD, será referido como subconjunto do CMIP6 ou somente CMIP6.

TABELA 1 – Lista dos 40 modelos do CMIP6 usados neste estudo.

TABLE 1 – 40 CMIP6 models list used for this study.

Nº	Nome do modelo do CMIP6	País	Resolução espacial	Referência
1	ACCESS-CM2	Austrália	1,9° × 1,3°	DIX <i>et al.</i> 2019
2	ACCESS-ESM1-5	Austrália	1,9° × 1,2°	ZIEHN <i>et al.</i> 2019
3	AWI-CM-1-1-MR	Alemanha	0,9° × 0,9°	SEMMLER <i>et al.</i> 2022
4	BCC-CSM2-MR	China	1,1° × 1,1°	WU <i>et al.</i> 2018
5	CAMS-CSM1-0	China	1,1° × 1,1°	RONG 2019
6	CanESM5 p1	Canadá	2,8° × 2,8°	SWART <i>et al.</i> 2019a
7	CanESM5 p2	Canadá	2,8° × 2,8°	SWART <i>et al.</i> 2019b
8	CanESM5-CanOE p2	Canadá	2,8° × 2,8°	SWART <i>et al.</i> 2019c
9	CESM2	EUA	1,3° × 0,9°	DANABASOGLU 2019a
10	CESM2-WACCM	EUA	1,3° × 0,9°	DANABASOGLU 2019b
11	CIESM	China	1,0° × 1,0°	HUANG 2019
12	CMCC-CM2-SR5	Itália	1,0° × 1,0°	FOGLI <i>et al.</i> 2020
13	CNRM-CM6-1 f2	França	1,4° × 1,4°	VOLDOIRE 2018
14	CNRM-CM6-1-HR f2	França	0,5° × 0,5°	VOLDOIRE 2019
15	CNRM-ESM2-1 f2	França	1,4° × 1,4°	SEFERIAN 2018
16	EC-Earth3	Europa	0,7° × 0,7°	EC-EARTH 2019a
17	EC-Earth3-Veg	Europa	0,7° × 0,7°	EC-EARTH 2019b
18	FGOALS-f3-L	China	1,3° × 1,0°	YU 2019
19	FGOALS-g3	China	2,0° × 2,3°	LI 2019
20	FIO-ESM-2-0	China	1,3° × 0,9°	SONG <i>et al.</i> 2019
21	GFDL-CM4	EUA	1,0° × 1,0°	GUO <i>et al.</i> 2018
22	GFDL-ESM4	EUA	1,3° × 1,0°	KRASTING <i>et al.</i> 2018
23	GISS-E2-1-G p1	EUA	2,0° × 2,5°	KELLEY <i>et al.</i> 2020
24	GISS-E2-1-G p3	EUA	2,0° × 2,5°	MILLER <i>et al.</i> 2021
25	HadGEM3-GC31-LL f3	Reino Unido	1,3° × 1,9°	ROBERTS 2017a
26	HadGEM3-GC31-MM f3	Reino Unido	0,6° × 0,8°	ROBERTS 2017b
27	INM-CM4-8	Rússia	2,0° × 1,5°	VOLODIN <i>et al.</i> 2019a
28	INM-CM5-0	Rússia	2,0° × 1,5°	VOLODIN <i>et al.</i> 2019b
29	IPSL-CM6A-LR	França	2,5° × 1,3°	BOUCHER <i>et al.</i> 2018
30	KACE-1-0-G	Coreia do Sul	1,7° × 1,3°	BYUN <i>et al.</i> 2019
31	MCM-UA-1-0	EUA	3,8° × 2,3°	STOUFFER, 2019
32	MIROC6	Japão	1,4° × 1,4°	SHIOGAMA <i>et al.</i> 2019
33	MIROC-ES2L f2	Japão	2,8° × 2,8°	TACHIIRI <i>et al.</i> 2019
34	MPI-ESM1-2-HR	Alemanha	0,9° × 0,9°	VON STORCH <i>et al.</i> 2017
35	MPI-ESM1-2-LR	Alemanha	1,9° × 1,9°	WIENERS <i>et al.</i> 2019
36	MRI-ESM2-0	Japão	1,1° × 1,1°	YUKIMOTO <i>et al.</i> 2019
37	NESM3	China	1,9° × 1,9°	CAO & WANG 2019
38	NorESM2-LM	Noruega	2,5° × 1,9°	SELAND <i>et al.</i> 2019
39	NorESM2-MM	Noruega	0,9° × 1,3°	BENTSEN <i>et al.</i> 2019
40	UKESM1-0-LL f2	Reino Unido	1,9° × 1,3°	TANG <i>et al.</i> 2019

2.1.2 Observações

Os dados do CMIP6 foram comparados com duas bases de dados observacionais para temperatura e precipitação, todos para período histórico de janeiro de 1985 a dezembro de 2014.

A primeira base de dados é a versão 4 do conjunto CRU TS (*Climatic Research Unit Gridded Time Series*) da University of East Anglia do Reino Unido (HARRIS *et al.* 2020). Estes dados possuem a resolução espacial de 0,5° de latitude por 0,5° de longitude sobre a superfície continental, exceto para Antártida. Os dados do CRU vêm sendo utilizados em centenas de publicações científicas, principalmente na validação de simulações e tendências do clima no presente e para avaliar projeções do clima futuro (MARENGO 2007; MARENGO *et al.* 2009, 2010; SILVEIRA *et al.* 2013; CHOU *et al.* 2014; TORRES 2014; HARRIS *et al.* 2014; FUNK *et al.* 2015; MARENGO & BERNASCONI 2015; DOHLER *et al.* 2016; XAVIER *et al.* 2016; SILVA *et al.* 2019; FAN *et al.* 2020, entre outros).

A segunda base de dados é a *Daily Gridded Meteorological Variables in Brazil* - Grade de Dados Meteorológicos Diários para o Brasil (BR-DWGD) (XAVIER *et al.* 2016). A BR-DWGD foi criada a partir dos dados de 3.625 pluviômetros e 735 estações meteorológicas para o período de 1961-2020 do Instituto Nacional de Meteorologia (INMET) e da Agência Nacional das Águas (ANA), respectivamente, com resolução espacial de 0,1° de latitude por 0,1° de longitude para todo o território do Brasil.

Esse conjunto de dados, BR-DWGD, tem sido utilizado em várias publicações de estudos climáticos sobre o Brasil. COSTA *et al.* (2020) analisaram os índices de extremos climáticos no Nordeste do Brasil de 1961 a 2014. GADELHA *et al.* (2019) examinaram o desempenho do produto *Integrated Multi-Satellite Retrievals for GPM* (IMERG) para o Brasil por meio de análises multitemporais e espaciais. PAREDES-TREJO *et al.* (2017) averiguaram as estimativas de precipitação por satélite baseadas em CHIRPS no Nordeste do Brasil.

Posteriormente, para analisarmos o viés das simulações do clima presente, reajustamos a resolução horizontal dos dois conjuntos de dados observacionais para uma grade de 1° × 1°, a mesma resolução do CMIP6, com o auxílio do *Grid Analysis and Display System* (GrADS).

2.2 Desempenho das simulações

O desempenho das simulações foi verificado e obtido a partir de métricas estatísticas, comparando os dados do subconjunto de modelos do CMIP6 com os dados observacionais para o período histórico de janeiro de 1985 a dezembro de 2014. As métricas utilizadas são apresentadas a seguir.

O desvio padrão (S) é expresso pelas equações 1 e 2:

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

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

onde S e O são, respectivamente os dados simulados e observados no período estabelecido, a barra indica a média temporal e n é o número de meses do período que totaliza 360 meses.

São apresentadas abaixo o erro médio (EM), o erro médio quadrático (EMQ), a raiz do erro médio quadrático ($REMQ$) e a raiz do erro médio quadrático após a remoção de um desvio médio ($REMQUB$). Sendo assim, estas métricas são expressas por:

$$EM = \frac{1}{n} \sum_{i=1}^n (S_i - O_i) \quad \text{Eq.3}$$

$$EMQ = \frac{\sum_{i=1}^n (S_i - O_i)^2}{n} \quad \text{Eq.4}$$

$$REMQ = \sqrt{\frac{\sum_{i=1}^n (S_i - O_i)^2}{n}} \quad \text{Eq.5}$$

$$REMQUB = \sqrt{\frac{1}{n} \sum_{i=1}^n [(S_i - \bar{S}) - (O_i - \bar{O})]^2} \quad \text{Eq.6}$$

O coeficiente de correlação Pearson, R , foi calculado de acordo com a equação abaixo:

$$R = \frac{\sum_{i=1}^n (S_i - \bar{S})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (S_i - \bar{S})^2} \sqrt{\sum_{i=1}^n (O_i - \bar{O})^2}} \quad \text{Eq.7}$$

O índice de Willmott (WILLMOTT & MATSUURA 1995), d , estabelece a concordância entre o dado simulado e observado e foi calculado pela equação:

$$d = 1 - \frac{\sum_{i=1}^n (S_i - O_i)^2}{\sum_{i=1}^n (|S_i - O_i| + |O_i - O_i|)^2} \quad \text{Eq.8}$$

PIELKE (2013) propõe uma metodologia complementar para a determinação da qualidade das simulações com modelos meteorológicos, visando que três critérios sejam cumpridos:

- 1) $S_i \cong S_o$ ou, equivalente, $\frac{S_i}{S_o} \cong 1$;
- 2) $REMQ < S_o$
- 3) $REMQ_{BIAS} < S_o$

Assim, para se chegar ao índice de destreza (PIELKE 2013), a equação é expressa por:

$$D_{PIELKE} = ABS \left(1 - \frac{S_i}{S_o} \right) + \frac{REMQ}{S_o} + \frac{REMQ_{BIAS}}{S_o} \quad \text{Eq.9}$$

De acordo com o a proposta de PIELKE (2013):

- 1) Se $D_{PIELKE} < 2$, a destreza do modelo pode ser comprovada;
- 2) A melhor simulação é a que apresenta o menor D_{PIELKE} ; e
- 3) Simulações perfeitas apresentam $D_{PIELKE} = 0$

Para melhor compreensão dos dados, foi calculada a média entre os cenários de emissões impulsionados por diferentes premissas socioeconômicas ou *Shared Socio-Economic Pathways* – Caminhos Socioeconômicos Compartilhados (SSP), cenários do conjunto CMIP6 MOD (SSP1-2.6, SSP2-4.5, SSP3-7.0, e SSP5-8.5) (RIAHI *et al.* 2017).

3 RESULTADOS

As variáveis temperatura e precipitação foram analisadas para o Brasil. Inicialmente, avaliou-se o padrão espacial, ciclo anual e tendência e, posteriormente, a acurácia estatística da simulação.

3.1 Temperatura

3.1.1 Padrão espacial

Iniciamos a análise comparando os padrões espaciais da temperatura média para o período climatológico estabelecido (janeiro de 1985 a dezembro de 2014) e seu viés médio, ou seja, a diferença entre as simulações do clima presente do CMIP6 e as observações (Figura 1).

As avaliações das simulações mostram que do subconjunto do CMIP6 consegue capturar a variabilidade do ciclo anual da temperatura, porém, existem algumas diferenças entre os dados observados e simulados, conforme pode ser verificado na figura 1.

A climatologia simulada da temperatura do ar à superfície apresentou viés positivo no norte do estado do Pará (Amazônia) (Figura 1d, e). No Sul do Brasil, a temperatura foi subestimada, porém, no Paraná e leste de Santa Catarina foi superestimada exceto em partes dos estados do Paraná e Santa Catarina. No Nordeste do Brasil, o viés médio é negativo, exceto em alguns locais do sertão nordestino. Sobre o Sudeste e o Centro-oeste o viés é negativo na maior parte destas regiões, exceto no Mato Grosso do Sul. Resultados semelhantes a este estudo foram observados por ALMAZROUI *et al.* (2021) e DIAS & REBOITA (2021) com os modelos do CMIP6.

No litoral brasileiro, do Rio de Janeiro até o Maranhão, o conjunto do CMIP6 apresenta viés negativo em relação à média da temperatura, quando comparado com os dados observacionais (Figura 1d, e). Destaca-se que sobre a Serra do Mar (RJ e SP) e Serra da Mantiqueira (ES e MG) o viés

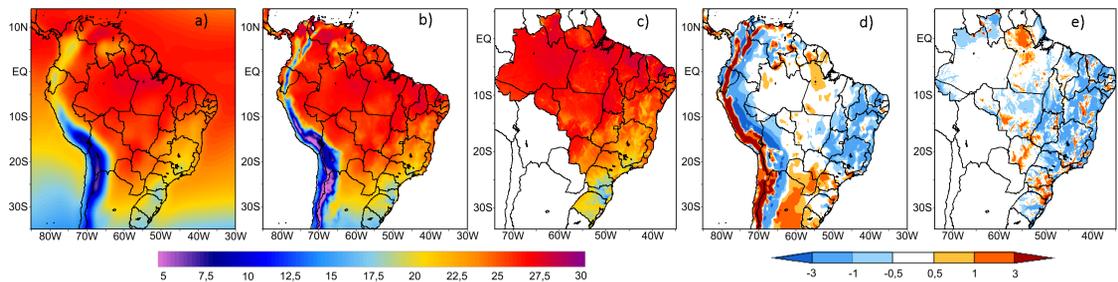


FIGURA 1 – Temperatura média anual (°C) para o período 1985-2014 e Viés de temperatura média anual (°C). a) CMIP6; b) Dados CRU; c) Dados BR-DWGD; d) Viés médio (°C) CMIP6 menos CRU; e) Viés médio (°C) CMIP6 menos BR-DWGD.

FIGURE 1 – Average annual temperature (°C) from 1985 to 2014: a) CMIP6; b) CRU; c) BR-DWGD; d) Mean bias (°C) from CMIP6 and CRU; e) Mean bias (°C) from CMIP6 and BR-DWGD.

é positivo, tanto comparando com a base do CRU (Figura 1d), quanto a BR-DWGD (Figura 1e). Esta condição pode estar relacionada à escala das simulações dos modelos do CMIP6, normalmente com grade de 100 a 200 km. Com isso, o modelo não consegue representar os pontos mais altos das serras. A diferença entre o simulado e o observado é um problema comum aos modelos climáticos, que necessitam aplicar simplificações para resolver numericamente as equações.

A figura 2 apresenta o viés da temperatura simulada pelo CMIP6, para cada estação do ano em relação aos dados do CRU e BR-DWGD, per-

mitindo inferir que o subconjunto do CMIP6 consegue capturar bem a sazonalidade da temperatura à superfície, mostrando o avanço de temperaturas mais baixas no sul do país no inverno austral e com pouca variação na parte tropical do país

No verão (DJF) (Figura 2a-e) e no outono (MAM) (Figura 2f-j) o viés é positivo em parte da Amazônia, especialmente ao norte (Amapá, Pará e Roraima), e nos estados do sul, Paraná e Santa Catarina. Resultados semelhantes a este estudo foram observados por DIAS & REBOITA (2021) com CMIP6. O viés da temperatura simulada pelo CMIP6 para o inverno (JJA) (Figura 2k-o) foi ne-

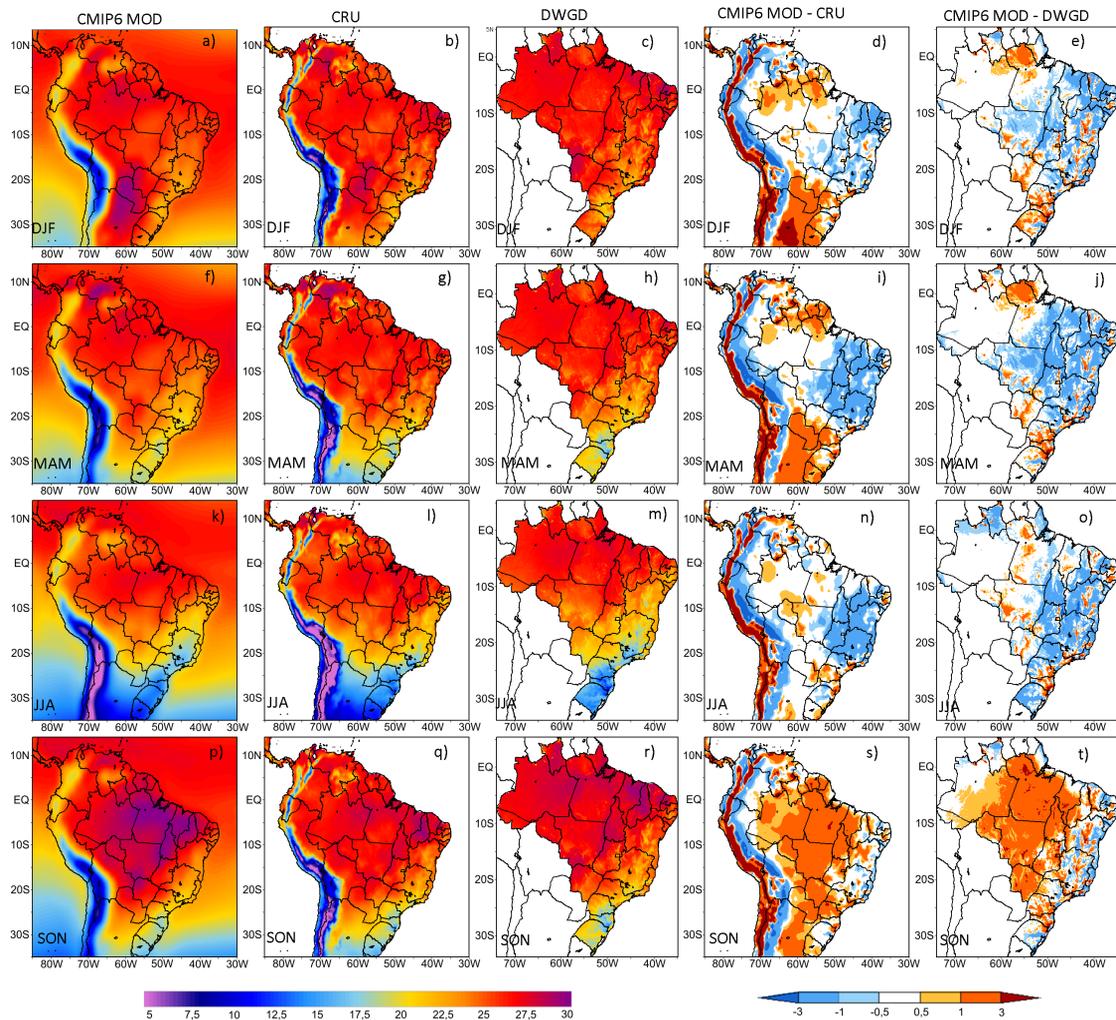


FIGURA 2 – Viés sazonal da temperatura do ar (°C) para o período 1985 – 2014 em relação à base de dados do CRU e BR-DWGD. Sendo o verão: dezembro, janeiro e fevereiro (DJF) (a-e); outono: março, abril e maio (MAM) (f-j); inverno: junho, julho e agosto (JJA) (k-o); primavera: setembro, outubro, novembro (SON) (p-t).

FIGURE 2 – Air temperature seasonal bias (°C) from 1985 to 2014 for CRU and BR-DWGD database. (a-e) Summer (DJF); (f-j) Autumn (MAM); (k-o) Winter (JJA); (p-t) Spring (SON).

gativo ou nulo para quase todas as regiões do Brasil, exceto para o Paraná, Santa Catarina e parte do Mato Grosso e Pará. Na primavera (SON) (Figura 2p-t), o viés médio das simulações de temperatura do conjunto do CMIP6 é positivo sobre quase todo o Brasil, exceto nas localidades próximas ao litoral, onde geralmente foram subestimadas. Este resultado é semelhante àquele obtido por CHOU *et al.* (2014), utilizando as simulações do modelo regional Eta acoplado a modelos globais do CMIP5, HadGEM2-ES, BESM e MIROC5.

Segundo 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, como os da base CRU, 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. Entretanto, destaca-se que os últimos autores utilizaram a base de dados do ERA5 como observações, diferentemente do nosso estudo e dos estudos de FAN *et al.* (2020).

3.1.2 Ciclo anual

A figura 3 mostra o ciclo anual da temperatura média (1985-2014) para os estados do Brasil. Destaca-se que o conjunto CMIP6 conseguiu simular o ciclo anual da temperatura para os estados brasileiros, porém, com alguns vieses. No geral, a variação desta reflete a grande variabilidade espaço-temporal do clima do Brasil.

O CMIP6 superestimou a temperatura do ar nos meses de setembro a dezembro para os estados do Norte do Brasil (Figura 3a-g), exceto no Acre e Roraima. Em contrapartida, o CMIP6 subestimou a temperatura em todos os estados da Região Norte no período no inverno.

Sobre a região Nordeste (Figura 3h-p), verifica-se que o CMIP6 apresenta relativa dificuldade em simular (subestima) a variação mensal da temperatura do ar. Segundo DIAS & REBOITA (2021), o CMIP6 tende a deslocar a área mais úmida da Amazônia para leste entre as Regiões Norte e Nordeste do Brasil, condição que pode favorecer o resfriamento da Região Nordeste e o aquecimento da Região Norte do Brasil. A superestimativa ou subestimativa da temperatura nas Regiões Norte e Nordeste do Brasil podem estar também relacionadas ao pequeno conjunto de dados das estações meteorológicas, sobretudo no Norte do Brasil, que fazem parte das duas bases de dados observacionais

(FAN *et al.* 2020), bem como a má representação de alguns componentes do ciclo hidrológico (umidade do solo, fluxos superficiais e tipos de vegetação) ou à dificuldade de parametrização convectiva pelos modelos globais (ALVES & MARENGO 2010). Além disso, os modelos globais tendem a superestimar precipitação sobre o Nordeste do Brasil, condição que pode estar corroborando para subestimar as temperaturas (ALVES *et al.* 2016, COSTA *et al.* 2021).

O CMIP6 também conseguiu simular o ciclo anual da temperatura para os estados localizados no semiárido nordestino, apesar dos vieses, que subestimam a variável na maioria dos meses, como no Maranhão (Figura 3k), Piauí (Figura 3n), Bahia (Figura 3i), Rio Grande do Norte (Figura 3o) e Sergipe (Figura 3p).

O CMIP6 superestimou as temperaturas nos meses de setembro a dezembro para a Região Centro-Oeste do Brasil (Figura 3q-t). Tal comportamento também pode ser verificado na figura 2 (s, t). Nos demais meses, o CMIP6 subestimou a temperatura, exceto para Mato Grosso (Figura 3s). Resultados semelhantes foram observados por DIAS & REBOITA (2021) e ALMAZROUI *et al.* (2021).

A dificuldade do CMIP6 em simular a temperatura na primavera (SON) sobre a região Centro-Oeste do Brasil é apontada por MARENGO *et al.* (2009). Os autores destacaram que os modelos globais apresentam menor habilidade em simular a temperatura nesta região, ao se comparar com as regiões Norte e Nordeste do Brasil, indicando que a variabilidade sazonal é menos influenciada pelas temperaturas da superfície do mar (TSM) e mais pela variabilidade atmosférica na região Central do Brasil.

A análise do ciclo anual da temperatura permite-nos inferir que o CMIP6 simulou a variação das temperaturas sobre a região Sudeste do Brasil (Figura 3u-x), porém, com vieses, subestimando o padrão climatológico da temperatura. Segundo LYRA *et al.* (2018), a temperatura do ar nesta região é melhor simulada com modelos de resolução maior, como por exemplo o Eta 5km, por representarem melhor a fisiografia e o desenho da linha costeira, assim como os processos físicos relacionados às brisas.

Destaca-se que o CMIP6 subestimou a temperatura no estado de Minas Gerais (Figura 3v) para todo o ciclo anual e para o Espírito Santo apresenta um atraso de cerca de 1 mês no ciclo da temperatura (Figura 3u).

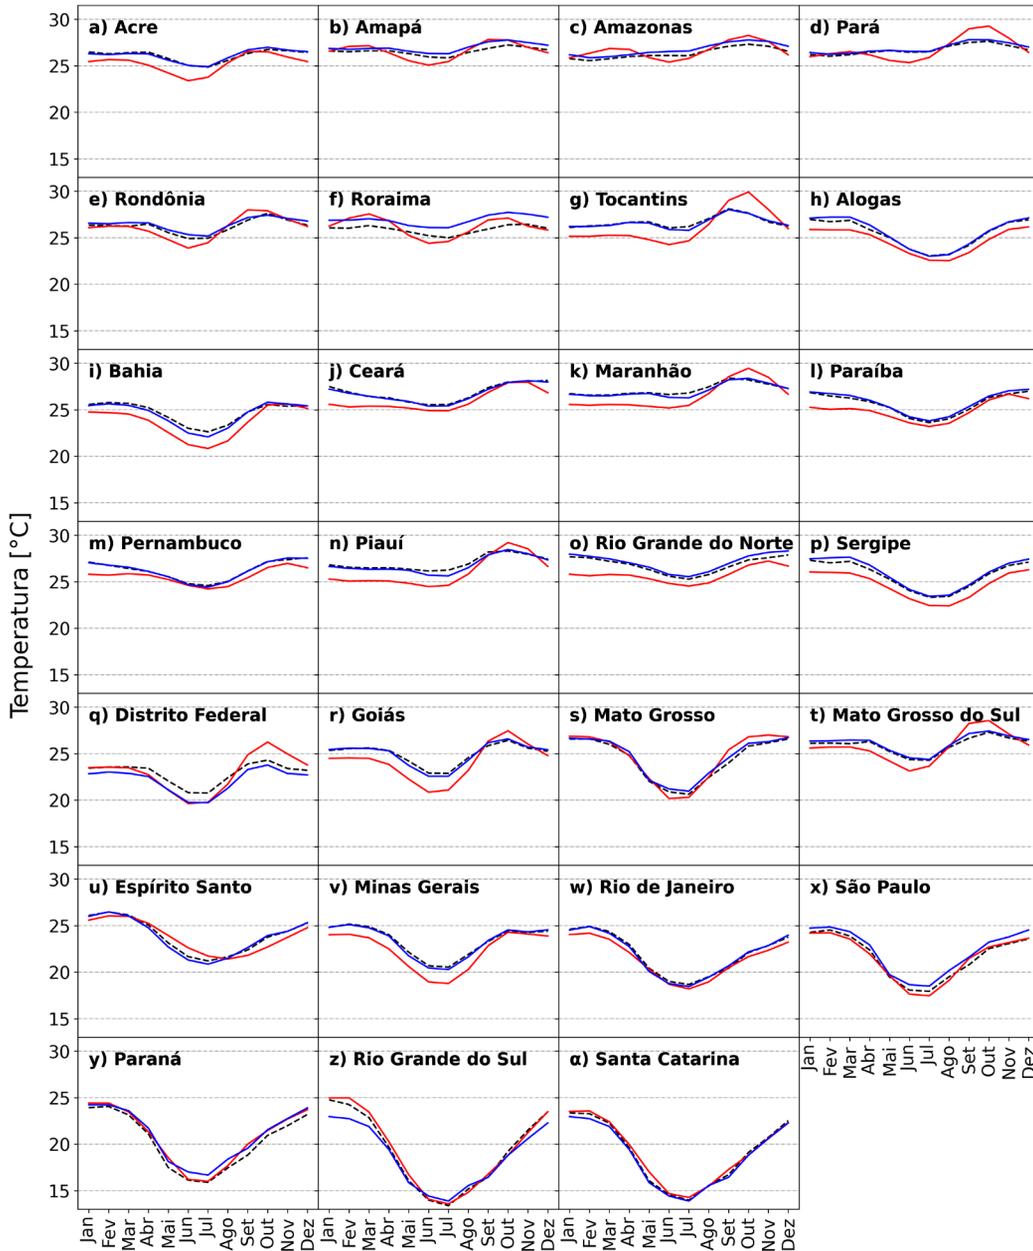


FIGURA 3 – Ciclo anual da temperatura do ar ($^{\circ}\text{C}$) para os estados do Brasil no período 1985-2014. A linha vermelha corresponde ao MOD, a linha preta representa as observações CRU e a linha azul cinza representa as observações BR-DWGD.

FIGURE 3 – Air temperature annual cycle ($^{\circ}\text{C}$) for the Brazil states between 1985 and 2014. The red line corresponds to the MOD, the black line represents the CRU observations and the blue line represents the BR-DWGD observations.

O subconjunto do CMIP6 conseguiu simular com relativa eficiência o ciclo anual da temperatura do ar da Região Sul do Brasil (Figura 3y- α), acompanhando o padrão sazonal das temperaturas mais elevadas e mais baixas quando comparados com os dados observacionais. Entretanto, o CMIP6

tende, levemente, a subestimar a temperatura para os seis primeiros meses do ano para todos os estados da Região Sul.

De modo geral, a figura 3 mostra que o CMIP6 reproduz o ciclo anual corretamente com o máximo no verão e o mínimo, no inverno. Os

vieses nas temperaturas da Região Norte devem ser considerados com cautela, visto que é uma região de baixa densidade observacional. Segundo ALVES & MARENGO (2010), o número de estações com dados de temperatura é menor do que o número de estações pluviométricas, e a interpolação tem sido utilizada para preencher as muitas lacunas nessa região pelas bases de dados. Outrossim, a má representação de alguns componentes do ciclo hidrológico (umidade do solo, fluxos superficiais e tipos de vegetação) ou a dificuldade de parame-trização 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; DEREZYSKI *et al.* 2020).

3.1.3 Tendência

As séries temporais da anomalia da temperatura entre janeiro de 1985 a dezembro de 2014 do conjunto de modelos do CMIP6 usados neste estudo foram comparado aos dados observados e são apresentados na figura 4 para todos os estados do Brasil. Na tabela 2 foram calculados a taxa linear de variação da temperatura do ($^{\circ}\text{C}$), o valor de P , bem como o a tendência de aquecimento entre 1985 a 2014. Destaca-se que a taxa de variação da temperatura foi estimada a partir da inclinação da reta de tendência, Sen's Slope. A significância dessas tendências estimadas é avaliada em termos do método de Mann-Kendall.

A análise dos dados indica tendência de aquecimento para todos os estados do Brasil, tanto para os observados, quanto para as simulações do CMIP6. A taxa de variação para cada estado e para cada conjunto de dados é resumida na tabela 2. De modo geral o CMIP6 consegue captar o aumento de tendência da temperatura, assim como os dados do CRU e BR-DWGD. Estes dados são significantes estatisticamente para as regiões Norte, Nordeste e Centro-Oeste (Tabela 2).

As taxas de variação das temperaturas apresentam pequenas diferenças entre as regiões (Tabela 2). As tendências de aumento nas regiões Norte, Nordeste e Centro-Oeste são maiores do que nas regiões Sudeste e Sul. Comportamento semelhante em relação à tendência de aquecimento por região foi observado por DEREZYSKI *et al.* (2020), mesmo que com base de dados diferentes (Eta-CanESM2, Eta-MIROC5, Eta-HadGEM2-ES). Tais constatações podem ser verificadas em nosso estudo, tanto pelos dados do CMIP6, quanto pelos dados observados.

Na Região Norte houve tendência de aquecimento entre 1985 a 2014. Entretanto, observa-se que os dados do BR-DWGD ($1,12\text{ }^{\circ}\text{C}$) apresentam maiores tendências do que os dados do subconjunto do CMIP6 ($0,96\text{ }^{\circ}\text{C}$) e do CRU ($0,66\text{ }^{\circ}\text{C}$). De acordo com os dados do BR-DWGD, para o período analisado, o estado do Amazonas apresentou um aumento de temperatura de $1,3\text{ }^{\circ}\text{C}$, enquanto para o CMIP6 foi de $0,96\text{ }^{\circ}\text{C}$ e para o CRU, $0,71\text{ }^{\circ}\text{C}$. Porém, para o estado de Rondônia, os dados do BR-DWGD e CMIP6 apresentaram aumento de temperatura de pouco mais de um $1\text{ }^{\circ}\text{C}$, enquanto a base de dados do CRU apresentou um incremento de $0,06\text{ }^{\circ}\text{C}$ (Tabela 2).

Para a Região Norte (Figure 3a-g), a tendência de aquecimento tem sido relacionada a variações no clima regional, tais como uma estação seca mais longa e quente, particularmente no leste do estado do Pará e na região do MATOPIBA (Maranhão – Tocantins – Piauí – Bahia) (MARENGO *et al.* 2022). Tais condições, também podem estar associadas às mudanças na circulação atmosférica, associadas as mudanças no uso e cobertura da terra, como o desmatamento, avanço da agricultura, queimadas e garimpo (NOBRE *et al.* 2016, MARENGO *et al.* 2018b, DA SILVA CRUZ *et al.* 2022). Isso parece ser mais intenso na região leste na área do arco de desmatamento (GATTI *et al.* 2021, MARENGO *et al.* 2022).

Os padrões verificados nas tendências para a região Norte do Brasil podem resultar dos efeitos combinados da mudança de uso da terra, aumento da concentração de Gases do Efeito Estufa, anomalias na temperatura da superfície do mar (TSM), o El Niño-Oscilação Sul (ENSO), a Oscilação Multidecadal do Atlântico (AMO) e o gradiente de TSM entre o Atlântico Tropical Norte e Sul, como sugerido por alguns estudos de cunho observacional e modelagem (FEARNSIDE 2009, GRIMM 2011, NOBRE *et al.* 2013, DUFFY *et al.* 2015, ALMEIDA *et al.* 2017, LIBONATI *et al.* 2021, MARENGO *et al.* 2022, entre outros). No período 1985-2014 houve *El Niño* em 1986-87, 1997-98, e 2010 e *La Niña* em 1988-89 e 1998-99, assim como um aquecimento intenso no Atlântico tropical Norte em 2005 durante a grande seca na Amazônia deste ano.

Na Região Nordeste, para o período de 1985 a 2014 (Figura 4h-p), o conjunto BR-DWGD apresentou tendência de aumento superior aos demais (Tabela 2). Enquanto o primeiro indicou um incremento de $0,99\text{ }^{\circ}\text{C}$ para a região, o subconjunto do CMIP6 apresentou $0,74\text{ }^{\circ}\text{C}$ e o CRU, $0,51\text{ }^{\circ}\text{C}$. Os

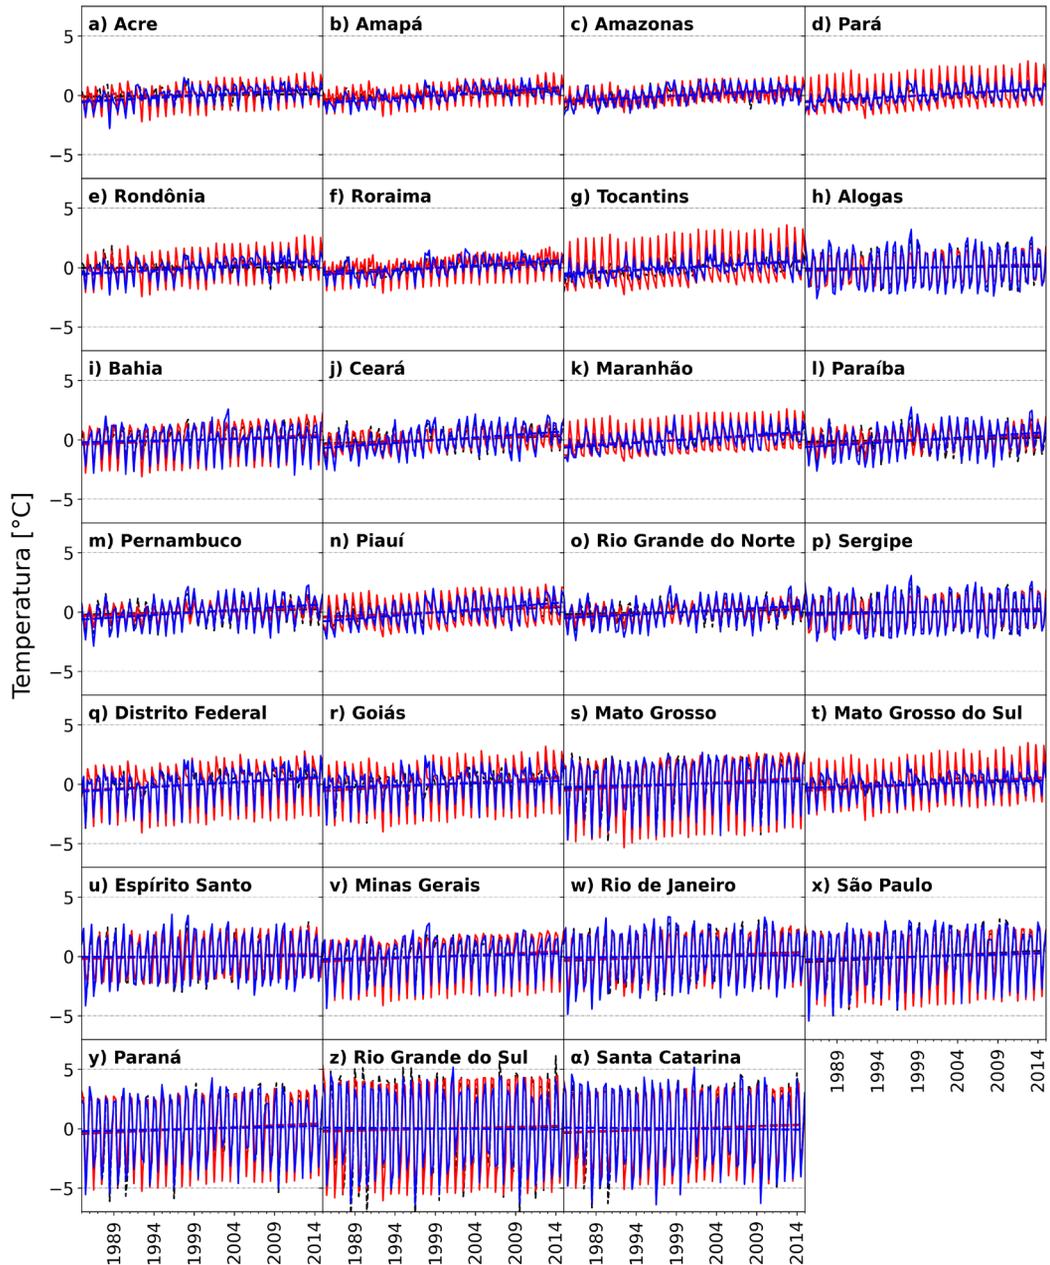


FIGURA 4 – Série temporal da anomalia da temperatura para os estados do Brasil entre janeiro de 1985 e dezembro de 2014. As linhas vermelhas correspondem ao conjunto (MOD) CMIP6, as linhas pretas representam as observações CRU, as linhas azuis representam as observações BR-DWGD. As linhas tracejadas de mesma cor indicam a tendência dos respectivos dados.

FIGURE 4 – Temperature anomaly time series for the Brazil states between January 1985 and December 2014. The red line corresponds to the MOD, the black line represents the CRU observations and the blue line represents the BR-DWGD observations. The dashed lines of the same color to each indicate the trend of the respective data.

estados do Piauí e Ceará aqueceram $1,53\text{ }^{\circ}\text{C}$ e $1,34\text{ }^{\circ}\text{C}$, respectivamente, de acordo com a base de dados BR-DWGD, enquanto os estados do Maranhão e Piauí, $0,87\text{ }^{\circ}\text{C}$ e $0,85\text{ }^{\circ}\text{C}$, respectivamente, para o mesmo período, de acordo com o subconjunto do

CMIP6. Por fim, de acordo com os dados do CRU, os estados que mais aqueceram, também foram Maranhão ($0,99\text{ }^{\circ}\text{C}$) e Piauí ($0,79\text{ }^{\circ}\text{C}$) (Tabela 2).

Na Região Nordeste, o aquecimento está relacionado as mudanças do uso e cobertura, como

TABELA 2 – Tendência da Temperatura anual entre 1985 a 2014 para os dados do CMIP6, CRU e BR-DWGD.

TABLE 2 – Annual temperature trend from 1985 to 2014 to the CMIP6, CRU and BR-DWGD data.

Estado	Taxa de Variação (°C)			Valor-P			Tendência (1985-2014) (°C)		
	CMIP6	CRU	BR-DWGD	CMIP6	CRU	BR-DWGD	CMIP6	CRU	BR-DWGD
AC	0,03	0,01	0,01	1,77E-11	0,232086	6,9E-06	0,94	0,24	1,12
AM	0,03	0,02	0,02	8,41E-12	1,71E-05	3,48E-07	0,96	0,71	1,30
AP	0,03	0,03	0,03	3,6E-11	6,66E-05	3,43E-05	0,84	0,75	1,03
PA	0,03	0,03	0,03	1,55E-11	1,09E-06	1,23E-05	0,94	0,96	1,10
RO	0,04	0,00	0,00	1,06E-11	0,649517	9,24E-07	1,06	0,06	1,09
RR	0,03	0,02	0,02	1,17E-11	0,00075	7,68E-06	0,97	0,73	1,23
TO	0,03	0,04	0,04	6,04E-12	1,3E-05	4,27E-05	0,99	1,16	0,99
AL	0,02	0,01	0,01	4,55E-11	0,259395	0,064503	0,64	0,25	0,40
BA	0,03	0,02	0,02	4,89E-11	0,004912	0,188824	0,79	0,54	0,43
CE	0,03	0,02	0,02	3,1E-11	0,006891	0,000109	0,76	0,59	1,34
MA	0,03	0,03	0,03	1,69E-11	5,62E-05	3,22E-06	0,87	0,99	1,28
PB	0,02	0,01	0,01	4,2E-11	0,082173	0,000229	0,72	0,37	1,25
PE	0,02	0,02	0,02	2,11E-11	0,028622	5,23E-05	0,70	0,46	1,25
PI	0,03	0,03	0,03	4,52E-11	0,000651	9,2E-07	0,85	0,79	1,53
RN	0,02	0,01	0,01	2,37E-11	0,047041	0,001055	0,71	0,42	1,05
SE	0,02	0,01	0,01	5,67E-11	0,374103	0,033307	0,63	0,21	0,42
DF	0,03	0,04	0,04	5,6E-11	6,15E-06	2,59E-06	0,96	1,07	1,24
GO	0,03	0,04	0,04	3,65E-11	9,52E-08	0,01137	1,01	1,16	0,56
MS	0,04	0,03	0,03	5,8E-11	0,000279	0,010179	1,07	0,83	0,49
MT	0,04	0,02	0,02	1,2E-11	0,000185	0,000309	1,06	0,58	0,67
ES	0,02	0,02	0,02	1,18E-10	0,015301	0,717286	0,52	0,49	0,17
MG	0,03	0,03	0,03	6,75E-11	2,26E-05	0,047868	0,88	0,86	0,49
RJ	0,02	0,03	0,03	1,56E-10	0,000203	0,492104	0,69	0,82	0,28
SP	0,02	0,03	0,03	3,36E-08	1,86E-05	0,054705	0,67	1,02	0,54
PR	0,03	0,03	0,03	1,54E-10	0,000151	0,15208	0,88	0,96	0,50
RS	0,02	0,01	0,01	1,81E-09	0,022596	0,872456	0,65	0,45	0,08
SC	0,02	0,03	0,03	5,64E-10	0,000805	0,872456	0,73	0,80	-0,08

a agricultura rudimentar, desertificação e a urbanização (MARENGO *et al.* 2017). Entretanto, as tendências verificadas na região podem estar associadas, além das alterações no uso do solo, a flutuações naturais do clima, que por vez estão associadas a padrões de variabilidade nos oceanos Pacífico e Atlântico (FERREIRA & MELLO 2005), como o fenômeno El Niño Oscilação Sul (ENSO) na escala de tempo interanual. Os estudos de MARENGO *et al.* (2020a) indicam que as áreas áridas e secas do nordeste devem se intensificar, caso o aquecimento global atinja 4 °C. Em um clima mais quente e seco, como mostra a tendência de

aquecimento, a Região Nordeste, pode sofrer ainda mais com a escassez de água (ALVES *et al.* 2016, MARENGO *et al.* 2020a, COSTA *et al.* 2021), impactando diretamente a população local.

Os dados analisados na tabela 2 e figura 4 (q-t) mostram tendência de aumento da temperatura para a Região Centro-Oeste no período em questão. O conjunto CMIP6 apresentou tendência de aumento superior para os estados de Mato Grosso (1,07 °C) e Mato Grosso do Sul (1,06 °C), para a base CRU foi para Goiás (1,16 °C), e para a base BR-DWGD foi para o Distrito Federal (1,24 °C). De fato, nossos resultados destacam que a tendên-

cia atual da temperatura sobre a região, corroboram com os resultados de outros estudos que apontam o aumento da temperatura para o Centro-Oeste do Brasil (AVILA-DIAZ *et al.* 2020, LIBONATI *et al.* 2022).

A tendência de aumento na temperatura em todos os estados da Região Centro-Oeste do Brasil é consistente com a pressão que os biomas locais, Cerrado e Pantanal, têm sofrido com a expansão da agricultura intensiva, causando a supressão da vegetação nativa e incêndios florestais e consequentemente impactos sobre o clima (SIQUEIRA & PETERSON 2003, BUSTAMANTE *et al.* 2012, HOFMANN *et al.* 2021). A pecuária bovina, sobretudo na Região Centro-Oeste, é um dos principais segmentos brasileiros na produção de gases do efeito estufa (BERGIER *et al.* 2019), além do mais, essa região, recentemente, tem sido afetada por incêndios florestais e secas (MARENGO *et al.* 2010, 2021; LIBONATI *et al.* 2022).

A Região Sudeste do Brasil é a área mais urbanizada e industrializada do país. Tal processo leva a uma série de impactos sobre o clima. A região mostra uma tendência de aumento da temperatura em todos os estados (Tabela 2 e Figura 4 u-x). DE ABREU *et al.* (2019), analisaram a temperatura da Região Sudeste do Brasil, com os modelos do CMIP5, e indicaram que todos os Estados apresentam tendência de aquecimento e que fatores como a urbanização, a ilha de calor, as mudanças no uso e cobertura da terra para a agricultura e os gases do efeito estufa, contribuíram com um aumento de 0,95 °C a 1,5 °C da temperatura entre 1955 e 2004. Condição semelhante ao estudo de DE ABREU *et al.* (2019) foi verificada em nosso estudo.

Entre 1985 e 2014, os estados de São Paulo, Minas Gerais e Rio de Janeiro apresentam os maiores incrementos de temperatura (Tabela 2), em relação ao estado do Espírito Santo. Porém, o conjunto CMIP6 (SP = 0,7 °C, MG = 0,9 °C, RJ = 0,7 °C, ES = 0,5 °C – estatisticamente significativo) e CRU (SP = 1,0 °C, MG = 0,9 °C, RJ = 0,8 °C, ES = 0,5 °C) apresentaram valores superiores de tendência no período analisado em relação à base BR-DWGD (SP = 0,5 °C, MG = 0,5 °C, RJ = 0,3 °C, ES = 0,2 °C).

A Região Sul é uma das mais desenvolvidas dos Brasil. A tabela 2 e figura 4 (y-α) mostram tendência de aquecimento para todos os estados da Região Sul, embora menor que nas demais regiões, sendo os maiores incrementos nos estados do Paraná e Santa Catarina. Os estudos observacionais (VINCENT *et al.* 2005, SKANSI *et al.* 2013) ou a partir de

simulações globais e/ou regionais (MÜLLER *et al.* 2018, DEREZYNSKI *et al.* 2020) também apontam para a tendência de aquecimento na Região Sul. Tal processo ocorre em função dos gases do efeito estufa, mudança no uso e cobertura da terra, bem como, a ilha de calor e processo de urbanização (MARENGO & CAMARGO 2008, ROESCH *et al.* 2009, SOARES & MARENGO 2009).

A tendência de aquecimento para os estados do Brasil, a partir dos dados observados e do CMIP6, já era um resultado esperado. Segundo o IPCC (2014) o aquecimento global tem aumentado a uma taxa de 0,10 a 0,25 °C por década em relação aos níveis pré-industriais. Diante deste cenário, pode-se afirmar que várias regiões do planeta, inclusive o Brasil, já estão sofrendo com mudanças significativas do clima e extremos climáticos, como secas e inundações, ondas de calor ou de frio (LYRA *et al.* 2018, MARENGO *et al.* 2020b, DÍAZ *et al.* 2021, ORTEGA *et al.* 2021, LORENÇONE *et al.* 2022).

3.1.4 Índices de desempenho temporal do subconjunto do CMIP6

Nessa seção analisaremos o desempenho do subconjunto do CMIP6 em relação aos dados observacionais, para todos os estados do Brasil entre 1985-2014 e para a variável temperatura. Sendo assim, além das métricas que serão utilizadas nessa seção, atribuímos o termo satisfatório ao desempenho do CMIP6 quando, concomitantemente, o índice de Willmott (d) e o índice de destreza Pielke (D_{PIELKE}) estiveram acima de 0,6 e abaixo de 2.

Na tabela 3, verifica-se a relativa dificuldade do conjunto em simular a temperatura sobre o Norte do Brasil. Em relação aos estados do Pará e do Tocantins, o subconjunto do CMIP6 apresentou o desempenho estatístico não satisfatório quando comparamos com as duas bases de dados observados para Região Norte.

Em análise mais detalhada, verificou-se que em nenhum estado do Norte, o desempenho do subconjunto do CMIP6 foi satisfatório, de acordo com os índices Willmott e D_{PIELKE} , exceto para o estado do Amapá ao comparamos com a base do CRU. Tal constatação também pode ser corroborada pelas figuras 1 e 2. Um dos motivos para esse baixo índice pode ser a parametrização de chuvas convectivas pelos modelos globais (ALVES & MARENGO 2010, YIN *et al.* 2013). Para os estados do Acre, Amapá e Rondônia, o CMIP6 obteve um desempenho pouco melhor que os demais, ao comparar com as duas bases de dados.

TABELA 3 – Índices de desempenho do CMIP6 para temperatura do ar de cada estado do Brasil entre janeiro de 1985 a dezembro de 2014, comparado com as bases de dados CRU e BR-DWGD. Onde os índices são: coeficiente de correlação (r), o erro médio (EM), o erro médio quadrático (EMQ), a raiz do erro médio quadrático ($REMQ$) e a raiz do erro médio quadrático após a remoção de um desvio médio ($REMQU_B$), desvio padrão simulado (S_s) e desvio padrão observado (S_o), índice de Willmott (d), índice de destreza Pielke (D_{PIELKE}).

TABLE 3 – Air temperature CMIP6 performance indices to each Brazil states between January 1985 and December 2014, for CRU and BR-DWGD databases. Where the indices are: correlation coefficient (r), the mean error (EM), the mean squared error (MSE), the root mean squared error ($RMSE$) and the root mean squared error after removing a mean deviation ($RMSE_{UB}$), simulated standard deviation (S_s) and observed standard deviation (S_o), Willmott index (d), Pielke dexterity index (D_{PIELKE}).

Estado	Base de Dados	r	EM	$REMQU$	$REMQU_B$	S_s	S_o	d	D_{PIELKE}
AC	CRU	0,67	-0,85	1,13	0,75	1,01	0,75	0,61	2,86
	BR-DWGD	0,74	-0,88	1,12	0,69	1,01	0,88	0,67	2,22
AM	CRU	0,67	0,04	0,67	0,67	0,90	0,57	0,75	2,96
	BR-DWGD	0,66	-0,37	0,78	0,68	0,90	0,73	0,74	2,24
AP	CRU	0,69	0,30	0,72	0,65	0,90	0,68	0,76	2,32
	BR-DWGD	0,62	-0,11	0,75	0,75	0,90	0,81	0,76	1,97
PA	CRU	0,75	0,12	0,92	0,91	1,29	0,66	0,75	3,74
	BR-DWGD	0,74	-0,05	0,90	0,90	1,29	0,74	0,78	3,16
RO	CRU	0,52	-0,68	1,30	1,11	1,25	0,95	0,59	2,86
	BR-DWGD	0,76	-0,33	0,88	0,82	1,25	0,90	0,81	2,28
RR	CRU	0,67	0,29	0,82	0,77	1,03	0,63	0,72	3,15
	BR-DWGD	0,59	-0,73	1,13	0,86	1,03	0,81	0,61	2,72
TO	CRU	0,68	-0,48	1,45	1,37	1,80	0,85	0,66	4,41
	BR-DWGD	0,75	-0,54	1,41	1,30	1,80	0,84	0,70	4,36
AL	CRU	0,96	-0,73	0,86	0,44	1,34	1,50	0,91	0,97
	BR-DWGD	0,93	-0,89	1,10	0,65	1,34	1,68	0,87	1,25
BA	CRU	0,90	-1,00	1,27	0,77	1,64	1,17	0,81	2,15
	BR-DWGD	0,89	-0,91	1,18	0,75	1,64	1,44	0,86	1,49
CE	CRU	0,80	-0,81	1,05	0,68	1,10	1,03	0,76	1,76
	BR-DWGD	0,76	-0,72	1,07	0,79	1,10	1,17	0,77	1,65
MA	CRU	0,80	-0,63	1,15	0,96	1,48	0,80	0,74	3,46
	BR-DWGD	0,82	-0,51	1,03	0,89	1,48	0,90	0,81	2,76
PB	CRU	0,86	-0,72	0,95	0,62	1,07	1,21	0,83	1,41
	BR-DWGD	0,83	-0,91	1,17	0,74	1,07	1,35	0,78	1,63
PE	CRU	0,88	-0,61	0,80	0,52	0,84	1,07	0,83	1,45
	BR-DWGD	0,86	-0,60	0,89	0,67	0,84	1,23	0,82	1,58
PI	CRU	0,87	-0,91	1,31	0,94	1,59	0,88	0,74	3,39
	BR-DWGD	0,83	-0,71	1,16	0,92	1,59	1,11	0,81	2,32
RN	CRU	0,76	-1,04	1,21	0,62	0,82	0,95	0,61	2,08
	BR-DWGD	0,77	-1,35	1,52	0,71	0,82	1,12	0,55	2,26
SE	CRU	0,96	-1,00	1,08	0,42	1,44	1,50	0,88	1,04
	BR-DWGD	0,93	-1,25	1,40	0,62	1,44	1,67	0,82	1,35
DF	CRU	0,83	0,09	1,16	1,16	1,99	1,29	0,86	2,34
	BR-DWGD	0,87	0,84	1,33	1,03	1,99	1,48	0,85	1,94
GO	CRU	0,86	-0,95	1,44	1,09	1,96	1,27	0,80	2,55
	BR-DWGD	0,88	-0,75	1,24	0,99	1,96	1,40	0,86	1,99
MT	CRU	0,91	0,35	1,09	1,03	2,55	2,38	0,95	0,96
	BR-DWGD	0,92	0,09	1,02	1,01	2,55	2,30	0,95	0,99
MS	CRU	0,81	-0,14	1,00	0,99	1,62	1,00	0,84	2,60
	BR-DWGD	0,82	-0,36	1,03	0,96	1,62	1,06	0,84	2,40
ES	CRU	0,91	-0,13	0,81	0,80	1,67	1,91	0,95	0,97
	BR-DWGD	0,85	-0,02	1,08	1,08	1,67	2,04	0,91	1,24
MG	CRU	0,92	-1,01	1,29	0,81	2,03	1,70	0,88	1,44
	BR-DWGD	0,92	-0,93	1,21	0,78	2,03	1,70	0,90	1,21
RJ	CRU	0,95	-0,47	0,85	0,71	2,04	2,29	0,96	0,79
	BR-DWGD	0,93	-0,40	0,95	0,87	2,04	2,37	0,95	0,93
SP	CRU	0,94	0,07	0,85	0,84	2,40	2,43	0,97	0,71
	BR-DWGD	0,93	-0,54	1,05	0,90	2,40	2,47	0,95	0,82
PR	CRU	0,95	0,51	1,09	0,96	2,98	3,07	0,97	0,70
	BR-DWGD	0,93	-0,12	1,08	1,07	2,98	2,94	0,97	0,74
RS	CRU	0,96	0,20	1,10	1,08	4,07	4,10	0,98	0,54
	BR-DWGD	0,94	0,70	1,59	1,43	4,07	4,10	0,95	1,07
SC	CRU	0,96	0,20	1,01	0,99	3,27	3,49	0,98	0,63
	BR-DWGD	0,94	0,44	1,25	1,17	3,27	3,43	0,96	0,75

Para todos os estados da Região Nordeste o CMIP6 tende a subestimar as temperaturas, ao compararmos com as duas bases de dados, ou seja, o CMIP6 simula temperaturas mais baixas que o padrão climatológico (Figura 3h-p e Tabela 3). Os valores negativos do erro médio (EM) na tabela 3 revelam quantitativamente esta subestimativa da temperatura no Nordeste.

Considerando somente a correlação e o índice Willmot, poderíamos dizer que o conjunto simulou satisfatoriamente o ciclo anual da temperatura do ar à superfície para os estados, uma vez que em todos os estados do Nordeste foi registrada correlação acima de 0,7 e índice Willmot acima de 0,5. Entretanto, quando avaliado com maior detalhe, os demais índices estatísticos, sobretudo o D_{PIELKE} , verificou-se que o desempenho do CMIP6 para alguns estados não foi tão satisfatório.

Nos estados do Maranhão, Piauí, e Rio Grande do Norte, conforme supracitado, o conjunto do CMIP6 não conseguiu simular satisfatoriamente a variação anual e espacial (Figuras 1, 2) da temperatura (máxima e mínima do ciclo anual) (Figura 3h-p) e tal discrepância pode ser verificada nos índices estatísticos (Tabela 3). O índice D_{PIELKE} para os estados do Maranhão e Piauí foram superiores a 2,0, indicando que o CMIP6 possui menor habilidade para simular a variabilidade temporal da temperatura. No estado da Bahia o desempenho não foi satisfatório.

Nos demais estados da Região Nordeste, o subconjunto do CMIP6 conseguiu simular satisfatoriamente o ciclo anual da temperatura (Tabela 3), sendo os melhores desempenhos observados para os estados de Alagoas e Sergipe. Para os estados dos estados de Alagoas (Figura 3h), do Ceará (Figura 3j), da Paraíba (Figura 3l), de Pernambuco (Figura 3m), o subconjunto do CMIP6 conseguiu reproduzir melhor a variabilidade do ciclo anual. Tal condição pode estar relacionada à área relativamente pequena desses estados, se comparadas com a de outros estados do Brasil e por estarem próximos ao litoral. Esses resultados corroboram com a análise espacial (Figuras 1 e 2).

A tabela 3 mostra que o conjunto do CMIP6 apresenta boa destreza em simular a temperatura para os estados da Região Centro-Oeste do Brasil, com correlação acima de 0,8 e índice de Willmot acima de 0,6. Para o estado de Mato Grosso, o desempenho do conjunto foi considerado satisfatório, pois apresentou índice de Willmot acima de 0,80 e índice D_{PIELKE} abaixo de 1,10. Tal constatação cor-

roborava com o baixo viés médio (Figura 1) para a região.

O subconjunto do CMIP6 permite simular com relativa eficiência a temperatura sobre a Região Sudeste do Brasil (Tabela 3). Tal condição é corroborada pelos índices Willmot e D_{PIELKE} , superior a 0,87 e inferior a 2, respectivamente, ou seja, indicando desempenho satisfatório. Entretanto, observa-se que os resultados para os estados de Minas Gerais e Espírito Santo tiveram desempenho levemente inferior aos demais estados. Porém, comparado aos demais estados da região, pode-se depreender que Minas Gerais teve o desempenho menos satisfatório. Pelo erro médio, verifica-se que o CMIP6 tende a subestimar as temperaturas do ar em todos os estados, exceto em São Paulo, quando comparado com a base de dados do CRU. O simulado e o observado, em São Paulo e Rio de Janeiro, foram muito semelhantes para as duas bases de dados.

Os estados da Região Sul do Brasil, apresentaram os melhores índices Willmot e D_{PIELKE} para a temperatura do ar, em comparação aos demais estados do país. O índice Willmot foi superior a 0,95 e o D_{PIELKE} inferior a 0,78, indicando ótimo desempenho do subconjunto CMIP6 em simular a variabilidade sazonal da temperatura do ar à superfície.

As simulações para os estados da Região Sul, com o CMIP6, tendem levemente a superestimar a temperatura. Tal análise pode ser constatada pelo erro médio na tabela 3. Contudo, a simulação tende a subestimar a temperatura para o estado do Paraná.

3.2 Precipitação

Após investigar o desempenho espacial e temporal em relação à temperatura, analisamos o desempenho do subconjunto dos modelos do CMIP6 para precipitação no período de 1985 a 2014 por estado do Brasil.

3.2.1 Padrão espacial

A figura 5 apresenta a distribuição espacial da precipitação média anual em mm.d^{-1} do subconjunto de dados do CMIP6 e das observações para o Brasil entre janeiro de 1985 e dezembro de 2014. Verificou-se que o CMIP6 consegue capturar a variabilidade do ciclo anual da precipitação, porém existem algumas diferenças entre os dados simulados e observados, conforme podem ser verificados na figura 5.

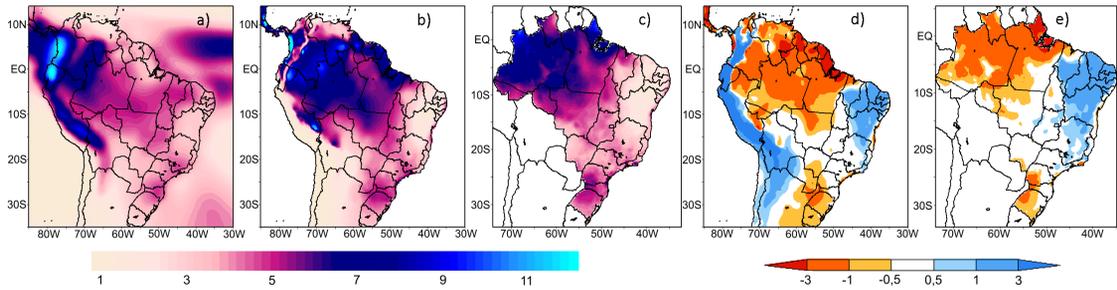


FIGURA 5 – Precipitação (mm d^{-1}) média do período 1985 a 2014: a) CMIP6; b) Dados CRU; c) Dados BR-DWGD; d) Viés (mm d^{-1}) CMIP6 menos CRU; e) Viés (mm d^{-1}) CMIP6 menos BR-DWGD.

FIGURE 5 – Average annual precipitation (mm d^{-1}) from 1985 to 2014: a) CMIP6 subset; b) CRU data; c) BR-DWGD data; d) Mean bias (mm d^{-1}) to CMIP6 and CRU; e) Mean bias (mm d^{-1}) to CMIP6 and BR-DWGD.

Nas regiões Norte e Sul do Brasil, o viés é negativo (Figura 5d-e), o que indica que nessas regiões há uma tendência do subconjunto do CMIP6 em subestimar a precipitação. A precipitação no Norte do Brasil é fortemente controlada pela atividade da Zona de Convergência Intertropical e possivelmente não seja bem representada pelos modelos. Na Região Nordeste e parte das regiões Sudeste e Centro-Oeste, o CMIP6 tende a superestimar a precipitação. O viés positivo da precipitação na parte leste do país também foi verificado por CARVALHO & JONES (2013) nos modelos do CMIP3 e CMIP5.

Destaca-se que tal comportamento, com vieses que incluem precipitação excessiva sobre o Nordeste do Brasil (área continental) e déficit de precipitação sobre a Amazônia e Sul do Brasil, também foram verificados em outros trabalhos, mesmo com bases de dados diferentes, considerando modelos regionais e globais, como os de CHOU *et al.* (2014), GULIZIA & CAMILLONI (2015), ALMAZROUI *et al.* (2021), ORTEGA *et al.* (2021), entre outros.

No verão, o CMIP6 (Figura 6a-e) mostra o padrão da precipitação média sobre a posição climatológica da Zona de Convergência do Atlântico Sul (ZCAS) (QUADRO *et al.* 2013), bem como a subestimativa na Amazônia e superestimativa no Nordeste e Centro-Sudeste do Brasil. A dificuldade dos modelos em simular a precipitação sobre a Amazônia pode estar relacionada à superestimativa da precipitação ao longo da ZCAS, e que poderia estar associada à representação da topografia da América do Sul, o que pode impactar a representação da circulação associada, transporte de umidade e de alguns componentes do ciclo hidrológico ou a parametrização convectiva (ALVES & MARENGO 2010, CHOU *et al.* 2014).

Apesar dessas inconsistências, durante o verão, o subconjunto do CMIP6 subestima a precipitação na Amazônia e superestima no Nordeste. TIAN & DONG (2020) afirmam que as simulações do CMIP6 reduziram a subestimativa da precipitação sobre a Região Norte do Brasil em relação ao CMIP5. Esses vieses no padrão da precipitação, sobretudo no verão, também foram observados nos modelos do CMIP5 e nas simulações climáticas regionais, como em CHOU *et al.* (2014), GULIZIA & CAMILONNI (2015), JOETZJER *et al.* (2013) e CMIP6 por ALMAZROUI *et al.* (2021), ORTEGA *et al.* (2021), entre outros.

No outono, climatologicamente, há redução da convecção na região noroeste da Amazônia (Figura 6f-j), bem como há chuvas abundantes no Norte e Nordeste do Brasil. É possível verificar que o viés é negativo em grande parte da Amazônia e no sul do Brasil alcançando até São Paulo, enquanto no Nordeste do Brasil, Minas Gerais e Espírito Santo observa-se viés positivo. Sobre o Nordeste brasileiro, MARENGO *et al.* (2017) verificaram com o CMIP5 que o fato do viés ser positivo para o outono pode estar relacionado à posição da Zona de Convergência Intertropical (ZCIT). Para ALVES *et al.* (2016) os modelos globais e regionais apresentam certa dificuldade em representar os padrões de variabilidade da temperatura da superfície do mar sobre o Atlântico Tropical, condição que dificulta as simulações da precipitação sobre o Nordeste.

No inverno, verifica-se que o viés da precipitação é negativo na Região Norte, Mato Grosso do Sul e Região Sul do Brasil (Figura 6k-o). Esses vieses podem estar relacionados com as mesmas causas dos vieses do verão. A redução da precipitação no Sul do Brasil, pode estar relacionada ao fato dos modelos globais e regionais superestimarem a intensidade do jato subtropical de oeste, e o posi-

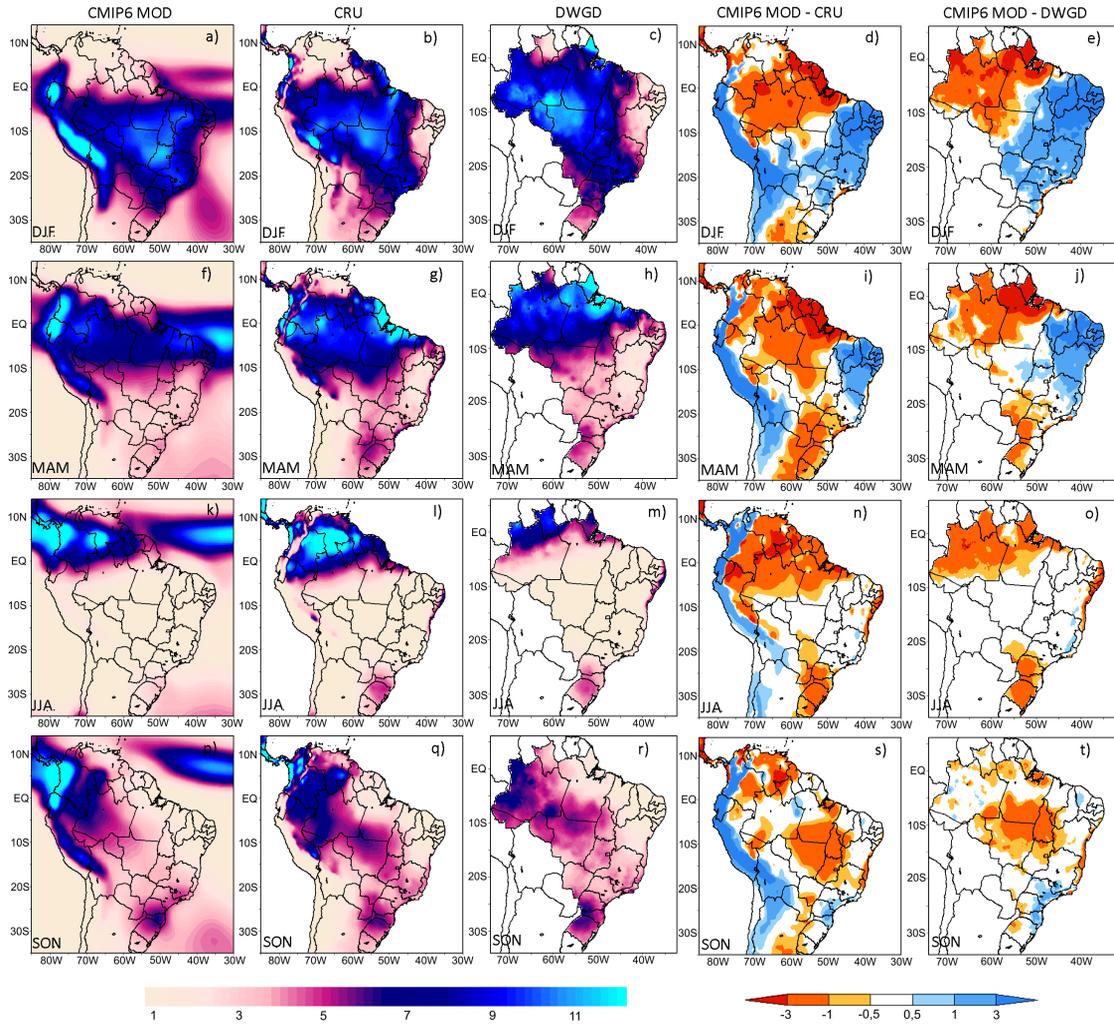


FIGURA 6 – Média sazonal da precipitação (mm d^{-1}) no período 1985–2014: 1ª coluna da esquerda: MOD, 2ª coluna: CRU; 3ª coluna BR-DWGD. Sendo o verão: dezembro, janeiro e fevereiro (DJF) (a-e); outono: março, abril e maio (MAM) (f-j); inverno: junho, julho e agosto (JJA) (k-o); primavera: setembro, outubro, novembro (SON) (p-t).

FIGURE 6 – Precipitation seasonal bias (mm d^{-1}) from 1985 to 2014 related to CRU and BR-DWGD database. (a-e) Summer (DJF); (f-j) Autumn (MAM); (k-o) Winter (JJA); (p-t) Spring (SON).

cionarem mais ao norte nos modelos (ALVES & MARENGO 2010).

A redução da precipitação no inverno (Figura 6k-o) nas regiões Central e Sudeste do Brasil segue o padrão climatológico que é influenciado pela Alta Subtropical do Atlântico Sul (ASAS) (REBOITA *et al.* 2015). O CMIP6 conseguiu capturar essa sazonalidade, apresentando ausência de viés. Tal comportamento ocorre porque a ASAS está mais intensa e próxima ao continente, inibindo a convecção e passagem de sistemas frontais, sobretudo, nas regiões Sudeste e Centro-Oeste. Os modelos glo-

bais e regionais simulam esse padrão climatológico de redução de precipitação no inverno. Tal padrão também foi verificado por ALVES & MARENGO (2010) e REBOITA *et al.* (2019). Também, observou-se viés negativo no litoral leste do Nordeste.

A primavera (Figura 6p-t) é uma estação de transição, quando ocorre o aumento da convecção e temperatura sobre o Brasil. Nesse período, os modelos globais apresentam dificuldades em simular adequadamente várias de suas características climatológicas. De modo geral, o viés da precipitação do Sul do país passa a ser positivo, enquanto

era negativo no inverno. Esse viés estende-se até o Rio de Janeiro e sul de Minas Gerais. Também, verifica-se que o CMIP6 consegue simular a precipitação na orientação noroeste-sudeste, o que caracteriza a ZCAS (QUADRO *et al.* 2013), porém subestima a chuva, estendendo-se para o oeste da Amazônia. No Nordeste do Brasil, o conjunto do CMIP6 consegue capturar a sazonalidade, porém, entre o litoral sul da Bahia até o estado de Pernambuco, a precipitação foi subestimada. Destaca-se também que a relativa dificuldade em simular a precipitação sobre parte do Sul do Brasil, regiões Centro-Oeste e Norte na primavera pode estar relacionada à ocorrência de complexos convectivos de mesoescala que são de desenvolvimento rápido. Estes processos podem não ser bem representados nas dimensões quase subgrade e, consequentemente, podem não ser bem representadas pelos modelos globais (DOSS-GOLLIN *et al.* 2018).

3.2.2 Ciclo anual

A figura 7 mostra que o CMIP6 simula com alguma eficiência o ciclo anual da precipitação sobre o Brasil, mas com alguns erros na intensidade.

Na região Norte, o CMIP6, em geral, subestimou a precipitação, registrando valor abaixo da média climatológica ao longo do ano (Figura 7a-g), exceto em Tocantins (Figura 7g), entre os meses de janeiro e abril, quando foi superestimado a precipitação em relação aos dados observados.

Essas discrepâncias entre os dados simulados e observados do ciclo anual podem estar relacionadas a um conjunto de fatores. Por exemplo, para as estações menos chuvosas, os modelos tendem a produzir menor convergência de umidade, maior divergência do ar, menor evapotranspiração da superfície, superestimando os fluxos sensíveis de calor e da razão de Bowen, reduzindo o calor latente da superfície. Além disso, ocorrem chuvas excessivas da ZICT sobre o Pacífico Leste e Atlântico Tropical o que causa a subestimação da precipitação. Entretanto, na estação chuvosa, os modelos tendem a superestimação dos fluxos sensíveis de calor e razão de Bowen, reduzindo o calor latente da superfície, além da dificuldade em simular a variabilidade do *El Niño* Oscilação Sul (ENOS), impactando na simulação da precipitação (YIN *et al.* 2013, JOETZJER *et al.* 2013).

Na região Nordeste, o subconjunto do CMIP6 conseguiu simular o ciclo anual da precipitação (Figura 7h-p), porém, diverge das observações quan-

to à quantidade de chuva nessa região. Similares vieses também foram constatados por SILVEIRA *et al.* (2013) nos modelos do CMIP5 para o Nordeste. Segundo GUIMARÃES *et al.* (2016), que avaliaram o desempenho do CMIP5 e outros modelos regionais para a precipitação no Nordeste de 1985 a 2005 comparando com os dados do CRU, os modelos apresentam os valores do ciclo anual de precipitação bastante variados em relação às observações, alguns muito chuvosos, superestimando todo o ciclo, e outros com perspectiva contrária, se mostrando mais secos.

As discrepâncias sobre a Região Nordeste se deve principalmente à dependência que a estação chuvosa possui das condições oceânicas e atmosféricas nos oceanos tropical Pacífico e Atlântico (MARENGO *et al.* 2018a). Os estudos de DA SILVA & MENDES (2015) indicam que os modelos globais, como os da geração CMIP, apresentam certa dificuldade em representar a intensidade e a posição média da ZCIT continental e oceânica, deslocando-a mais ao sul em relação à sua média climatológica, dificultando a simulação da precipitação na região. Outrossim, DA SILVA & MENDES (2015) indicam que os modelos não possuem destreza em simular as anomalias da temperatura da superfície do mar (TSM) ao longo do Atlântico Equatorial, condição que resulta em anomalias de precipitação nestas regiões.

No Centro-Oeste (Figura 7q-t), de modo geral, o CMIP6 conseguiu simular as variações do ciclo anual, porém, há divergências em relação à precipitação em cada estado, atrasando o início do período chuvoso (SON) e superestimando a partir da segunda metade desse mesmo período e de dezembro a março.

Sobre o ciclo anual da precipitação para a Região Centro-Oeste, ORTEGA *et al.* (2021) afirmam que simulações do CMIP6 conseguem reproduzir as magnitudes observadas nos dados de precipitação do TRMM e que tal condição também é observada nas simulações do CMIP5, resultados também verificados neste trabalho, mesmo que comparados com base de dados observacionais diferentes (CRU e BR-DWGD). Em relação a subestimação do início do período chuvoso, GULIZIA & CAMILLONI (2015) afirmam que os modelos globais e regionais apresentam certa dificuldade em representar corretamente o transporte de vapor d'água e convergência de umidade sobre a região central do Brasil, condição que repercute sobre a precipitação. A respeito da superestimação no restante do período chuvoso, esta pode estar relacionada à dificuldade do modelo em simular a ZCAS e os sistemas fron-

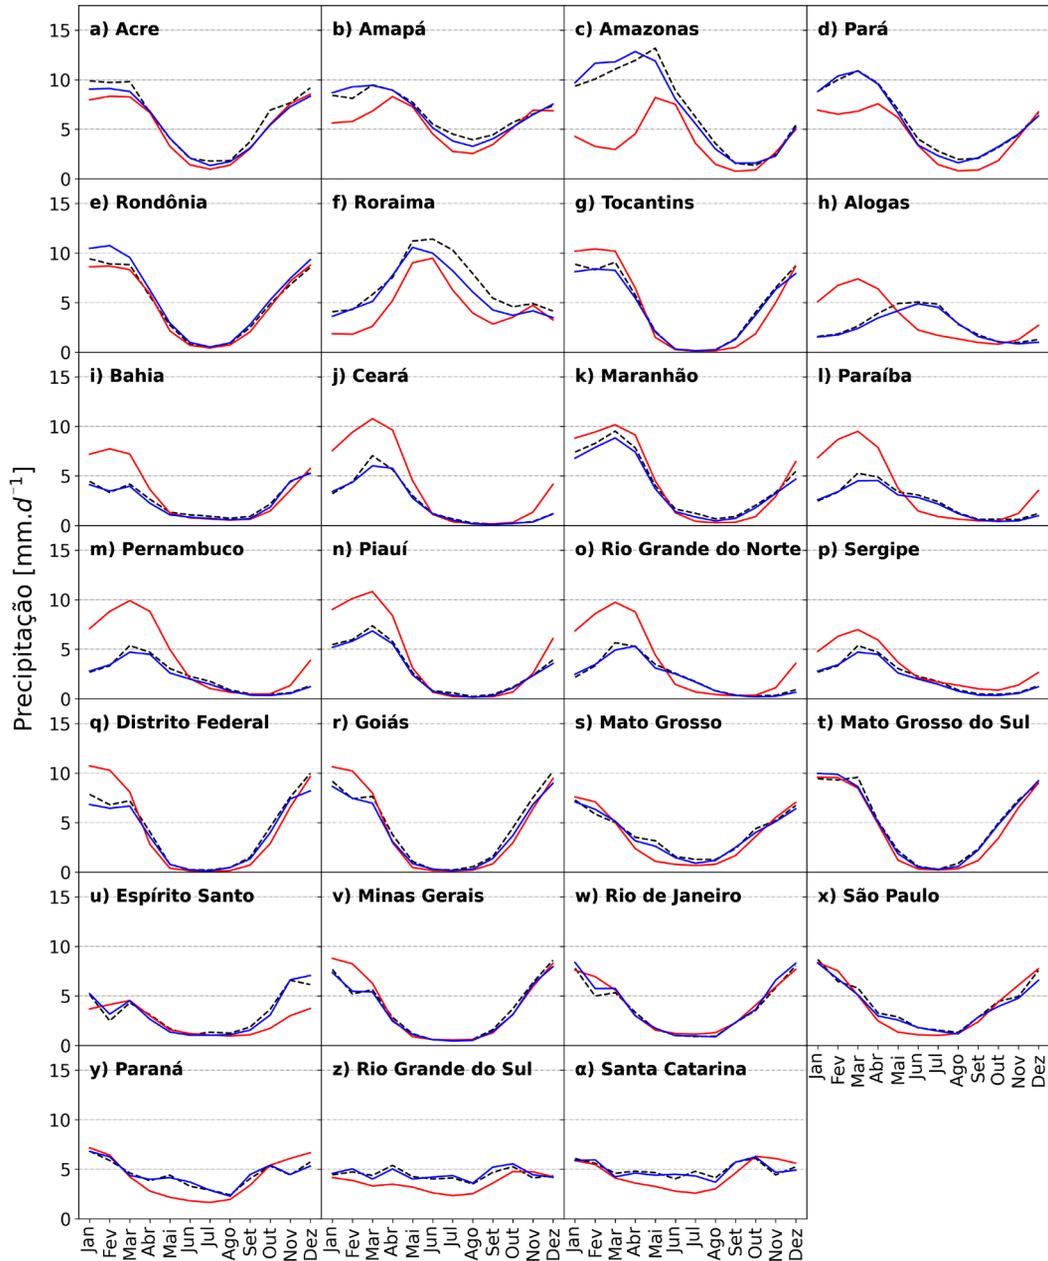


Figura 7: Ciclo anual da precipitação (mm d^{-1}) para os estados do Brasil para o período 1985-2014. As linhas vermelhas correspondem ao subconjunto do CMIP6, as linhas pretas representam as observações CRU, as linhas azuis representam as observações BR-DWGD.

FIGURE 7 – Precipitation annual cycle (mm d^{-1}) for Brazil states from 1985 to 2014. The red line corresponds to the MOD, the black line represents the CRU observations and the blue line represents the BR-DWGD observations.

tais que atuam sobre a região nessa época do ano, conforme destacado por ALVES *et al.* (2021).

O CMIP6 conseguiu reproduzir o ciclo anual da precipitação para os estados do Rio de Janeiro, São Paulo e Minas Gerais (Figura 7u-x); entretanto, no estado do Espírito Santo (Figura 7u) o mode-

lo subestimou a precipitação no início do período chuvoso, entre outubro e dezembro.

O período chuvoso da Região Sudeste é semelhante ao da região Centro-Oeste e os mesmos fatores que corroboram no desempenho das simulações, na região central do país, podem também

influenciar no Sudeste. Além disso, LYRA *et al.* (2018) indicam que modelos com maiores resoluções conseguem melhor simular o ciclo anual da precipitação sobre a Região Sudeste, devido às características da topografia e atmosfera local.

O ciclo anual da precipitação para o Sul do Brasil em relação aos dados simulados e observados é apresentado na figura 7 ($y-\alpha$). De modo geral, o modelo subestimou a precipitação entre os meses de abril e setembro para todos os estados. No período chuvoso, entre outubro e dezembro, o CMIP6, superestimou a precipitação em todos os estados da Região Sul, exceto para o Rio Grande do Sul (Figura 7z), onde o modelo subestimou a precipitação entre janeiro e março. Sobre esse comportamento, o estudo de PEREIRA *et al.* (2022) sugerem que os modelos do CMIP6, não são capazes de reproduzir a transição entre climas tropicais e subtropicais, como é o caso da Região Sul, bem como a passagem de sistemas frontais, condição que impacta diretamente na precipitação observada na região.

3.2.3 Tendência

Na figura 8, são apresentadas e analisadas as séries temporais da anomalia da precipitação entre janeiro de 1985 e dezembro de 2014 do subconjunto do CMIP6 e das bases de dados observacionais para todos os estados do Brasil. Além disso, a taxa linear da precipitação anual entre 1985 a 2014, o valor $-P$ e a tendência da precipitação, comparado ao subconjunto do CMIP6 com os dados observados, são apresentados na tabela 4, para todos os estados do Brasil. De forma geral, nota-se diferentes tendências entre os estados ou regiões.

A Região Norte (Figura 8a-g), apresenta comportamento distinto entre os estados e as bases de dados analisadas. A precipitação exibiu tendência distinta, ao longo prazo, tal comportamento também foi verificado em CARVALHO (2019), JONES & CARVALHO (2018), MARENGO *et al.* (2018b).

O subconjunto do CMIP6, apresenta taxa anual e tendência de redução para todos os estados do Norte do Brasil, sendo significativa estatisticamente para os estados do Amapá, Pará e Rondônia. Porém, os dados do CRU e BR-DWGD (Tabela 4), apresentam o mesmo comportamento para os estados do Amapá, Pará e Tocantins, e para os demais estados, as duas últimas bases, apresentam um leve incremento. O comportamento observado nas bases do CRU e BR-DWGD corrobora com ALVES (2016), que detectou tendência de precipitação negativa para esses três estados, durante a

pré-estação chuvosa e o pico da estação chuvosa durante 1979-2014. A tendência de redução de precipitação no leste da Amazônia e na região MATOPIBA, verificado tanto pelos dados do subconjunto do CMIP6 e pelas bases observacionais utilizadas nesse estudo, foi constatada em estudos anteriores como os de MARENGO *et al.* (2022) e GATTI *et al.* (2014).

A tendência no comportamento da precipitação na Região Norte tem sido relacionada às mudanças no uso e cobertura da terra, como o desmatamento e avanço da agricultura (NOBRE *et al.* 2016; MARENGO *et al.* 2018b, 2022; DA SILVA *et al.* 2022). O impacto antrópico tem causado mudanças no ciclo hidrológico, mudanças no balanço de energia, além de tendência de aumento da temperatura (Tabela 2), afetando a biodiversidade e ecossistemas (NOBRE *et al.* 2009). Além desses fatores, estudos como os de LIEBMANN *et al.* (2004) e ALMEIDA *et al.* (2017) indicam um deslocamento da ZCAS mais ao sul da sua posição, condição que também tem impactado na precipitação da Região Norte. Além disso, padrões de anomalias da TSM e modos acoplados como o El Niño/Oscilação Sul, a Oscilação Decadal do Pacífico e a Oscilação Multidecadal do Atlântico (MARENGO & ESPINOZA 2016, MARENGO *et al.* 2018b) modulam a precipitação na Região Norte, e essas teleconexões são relevantes para avaliar tendências de precipitação usando registros históricos e com os modelos (CARVALHO 2019).

Na Região Nordeste (Figura 8h-p), são verificadas tendências de redução da precipitação para todos os estados entre 1985 e 2014, exceto para o estado do Ceará, tanto para os dados do CMIP6, quanto para os dados observacionais (Tabela 4). Tal comportamento, também é identificado em vários estudos de cunho observacional e de modelagem, como os de TORRES & MARENGO (2014), MARENGO & BERNASCONI (2015), ALVES *et al.* (2016), GUIMARÃES *et al.* (2016), MARENGO *et al.* (2017, 2018a, 2020) e REGOTO *et al.* (2021). Porém, os estudos ressaltam que as mudanças no uso e cobertura da terra, bem como o aquecimento global associado ao aumento na concentração dos gases do efeito estufa, provocam mudanças na precipitação e evapotranspiração do Nordeste, deixando o clima menos úmido. Além dos fatores citados, a redução da precipitação na região pode estar relacionada ao aumento da subsidência sobre a região e o deslocamento para o norte da ZCIT (HAYLOCK *et al.* 2006, DEREZCZYNSKI *et al.* 2020).

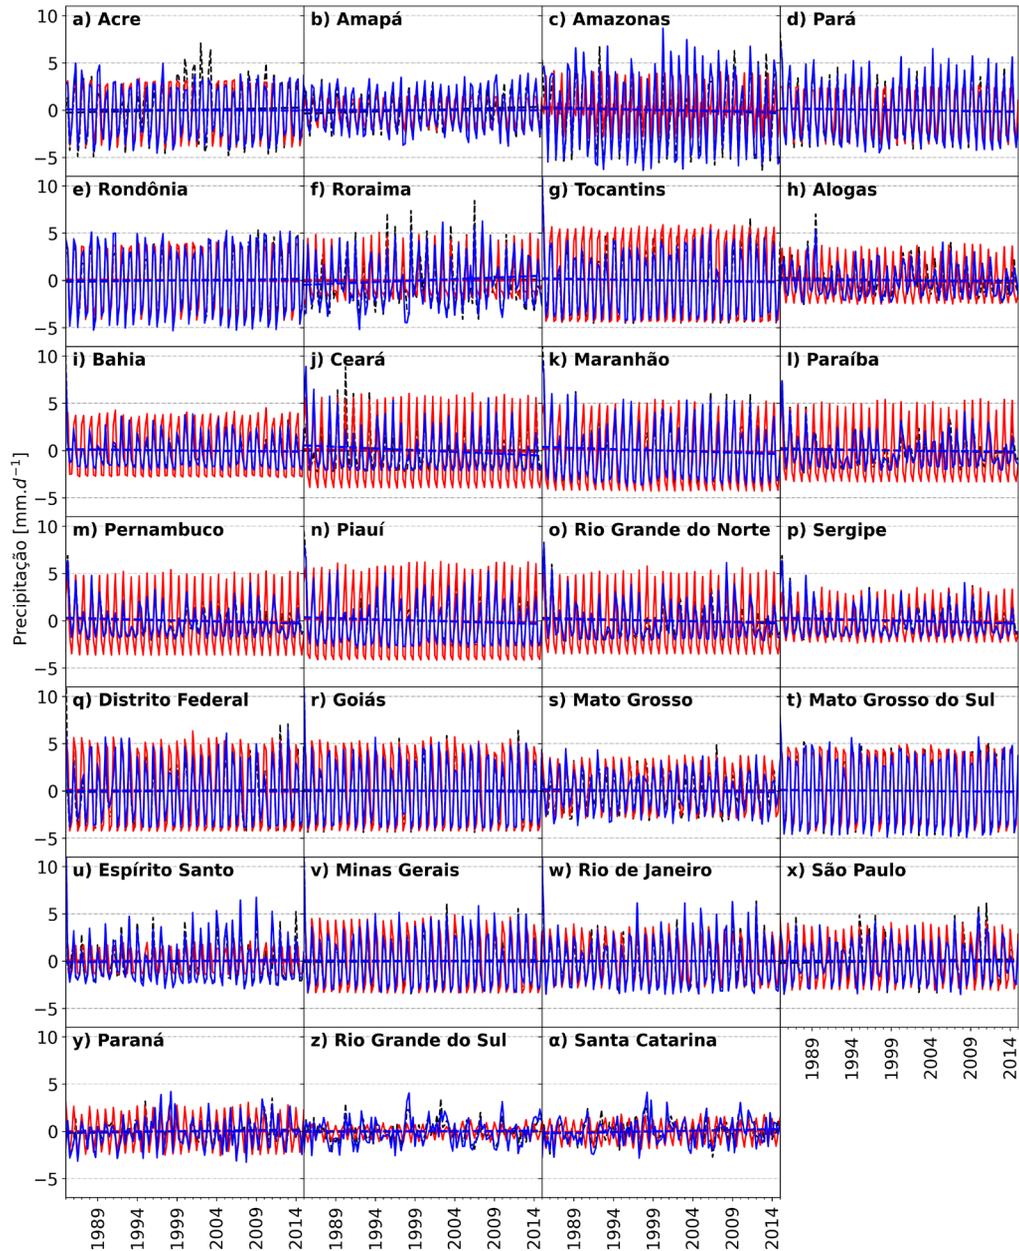


FIGURA 8 – Série temporal da anomalia da precipitação (mm d^{-1}) para os estados do Brasil para o período de janeiro de 1985 a dezembro de 2014. As linhas vermelhas correspondem ao subconjunto do CMIP6, as linhas pretas representam as observações CRU, as linhas azuis representam as observações BR-DWGD. As linhas traçadas de mesma cor indicam a tendência dos respectivos dados.

FIGURE 8 – Precipitation anomaly time series (mm d^{-1}) for Brazilian states between January 1985 and December 2014. Red lines correspond to the CMIP6 subset, black lines represent CRU observations, and blue lines represent BR-DWGD. The dashed lines of the same color indicate the trend of the respective data.

A redução da precipitação, na Região Nordeste vem apresentando ligeiro decréscimo, conforme apontando por MARENGO *et al.* (2013), condição verificada na presente pesquisa, tanto pelos dados observacionais, quanto pelo subconjunto

do CMIP6. Porém, parte desse comportamento foi atribuída às variações da temperatura da superfície do mar (TSM) no Pacífico tropical, manifestadas como os extremos do *El Niño*-Oscilação Sul (ENSO), e ao gradiente meridional de TSM

TABELA 4 – Tendência da Precipitação anual entre 1985 a 2014 para todos os estados do Brasil, de acordo com os dados do CMIP6, CRU e BR-DWGD.

TABLE 4 – Annual precipitation trend from the 1985 to 2014 to the CMIP6, CRU and BR-DWGD data.

Estado	Taxa de Precipitação			Valor-P			Tendência (1985-2014) (mm d ⁻¹)		
	CMIP6	CRU	BR-DWGD	CMIP6	CRU	BR-DWGD	CMIP6	CRU	BR-DWGD
AC	-0,002	0,020	-0,002	0,193172	0,222373	0,93321	-0,07	0,61	-0,05
AM	-0,002	0,018	0,006	0,423607	0,027414	0,40848	-0,06	0,53	0,17
AP	-0,004	-0,010	-0,002	0,015125	0,624744	0,655526	-0,13	-0,29	-0,06
PA	-0,004	-0,002	-0,004	0,018608	0,361889	0,63296	-0,11	-0,06	-0,13
RO	-0,004	0,013	0,009	0,00465	0,023924	0,20458	-0,13	0,39	0,27
RR	-0,003	0,007	0,034	0,245809	0,747225	0,03948	-0,08	0,22	1,01
TO	-0,002	-0,005	-0,010	0,129216	0,383322	0,816248	-0,07	-0,16	-0,29
AL	-0,002	0,000	-0,016	0,263964	0,990828	0,390613	-0,05	0,01	-0,48
BA	-0,003	-0,006	-0,009	0,093989	0,695234	0,904455	-0,08	-0,18	-0,28
CE	0,001	0,007	0,007	0,394374	0,751932	0,342868	0,03	0,21	0,22
MA	-0,002	-0,005	-0,018	0,150046	0,230085	0,867851	-0,06	-0,14	-0,53
PB	0,000	-0,011	-0,004	0,992867	0,866537	0,585714	-0,01	-0,32	-0,12
PE	-0,001	-0,015	-0,016	0,742241	0,885631	0,743383	-0,03	-0,45	-0,49
PI	-0,001	-0,011	-0,019	0,439121	0,582072	0,771219	-0,04	-0,32	-0,56
RN	0,001	-0,014	-0,009	0,598637	0,950166	0,779937	0,02	-0,43	-0,28
SE	-0,002	-0,015	-0,016	0,291784	0,885631	0,743383	-0,05	-0,45	-0,49
DF	-0,004	0,009	0,000	0,08611	0,178796	0,931875	-0,11	0,28	0,01
GO	-0,002	0,003	-0,005	0,170478	0,400001	0,752502	-0,06	0,09	-0,16
MS	-0,003	0,004	-0,009	0,061388	0,880173	0,346265	-0,09	0,11	-0,26
MT	-0,004	-0,003	-0,002	0,001635	0,195815	0,977618	-0,11	-0,09	-0,06
ES	-0,004	0,007	0,006	0,042406	0,169944	0,297464	-0,11	0,21	0,19
MG	-0,003	0,006	-0,003	0,077422	0,173077	0,98628	-0,09	0,19	-0,10
RJ	-0,003	0,003	0,002	0,088508	0,308305	0,552278	-0,09	0,08	0,05
SP	-0,002	-0,015	0,000	0,264075	0,187431	0,510837	-0,06	-0,44	-0,01
PR	-0,001	0,014	0,009	0,834777	0,524866	0,988144	-0,02	0,42	0,27
RS	0,004	-0,001	0,005	0,071349	0,794265	0,896359	0,11	-0,04	0,14
SC	0,003	0,014	0,016	0,099381	0,559571	0,535476	0,10	0,41	0,48

no Atlântico tropical (ACEITUNO 1988; HAYLOCK *et al.* 2006; MARENGO *et al.* 2013, 2017, 2018a; MARENGO & ESPINOZA 2016; WU *et al.* 2020). A variabilidade interanual é controlada principalmente pelo ENSO que está associado a anomalias negativas de precipitação em eventos de El Niño sobre a Região Nordeste (por exemplo, 1982/83, 1997/98, 2005, 2010, 2015) e anomalias positivas em anos de La Niña (por exemplo, 1984/1985, 1999/2000) (MARENGO & BERNASCONI 2015; MARENGO *et al.* 2017, 2018).

Nas regiões Centro-Oeste (Figura 8q-t) e Sudeste (Figura 8u-x), o subconjunto do CMIP6

apresentou redução da precipitação entre 1985 a 2014 (Tabela 4). Enquanto a base de dados CRU apresentou leve tendência de redução para Mato Grosso e São Paulo, a base BR-DWGD apresentou tendência de redução de precipitação em Goiás, Mato Grosso, Mato Grosso do Sul, Minas Gerais e São Paulo, e para os demais estados, uma leve tendência de aumento nas precipitações entre 1985 e 2014. As mudanças na precipitação sobre essas regiões podem estar relacionadas a anomalias da circulação atmosférica que podem ser intensificadas pelas atividades antrópicas.

A expansão da agricultura intensiva sobre o Cerrado, o “arco do desmatamento”, as queimadas, a urbanização e a ilha de calor (SIQUEIRA & PETERSON 2003, DOS SANTOS *et al.* 2020, HOFMANN *et al.* 2021), bem como o aumento da emissão dos gases do efeito estufa (IPCC 2021), têm contribuído para as mudanças na precipitação sobre as regiões Centro-Oeste, Sudeste e leste da Amazônia.

Além desses fatores, a Região Norte, que também apresenta tendência de redução da precipitação, contribui diretamente na precipitação sobre as regiões Centro-Oeste e Sudeste (REBOITA *et al.* 2015); como resposta, essas regiões também apresentam tendência de redução na precipitação em alguns estados; tal relação é apontada nos estudos de LIEBMANN *et al.* (2004), JOETZJER *et al.* (2013), JONES & CARVALHO (2013), YIN *et al.* (2013), DOS SANTOS *et al.* (2020), ALVES *et al.* (2021), e ZILLI & CARVALHO (2021). Segundo CAVALCANTI & SHIMIZU (2012), as mudanças na precipitação estão relacionadas às mudanças no fluxo dos ventos de baixo nível sobre o Atlântico Norte tropical, reduzindo a advecção de umidade para o continente e também ao aumento do fluxo de baixo nível sobre o centro da América do Sul em direção ao sul, o que aumenta a umidade ao sul do país. Outrossim, segundo YIN *et al.* (2013) e JOETZJER *et al.* (2013), a redução do calor latente, evapotranspiração e mudanças no ciclo hidrológico da Amazônia, causadas sobretudo pelo desmatamento e queimadas na floresta, acabam impactando a precipitação sobre as regiões Centro-Oeste e Sudeste do país.

Por fim, destaca-se que nas regiões Centro-Oeste e Sudeste do país, a variabilidade da precipitação é diretamente modulada pelo ENOS, Modo Anular Sul (SAM), Oscilação Decadal do Pacífico (PDO) (ANDREOLI & KAYANO 2005, VASCONCELLOS & CAVALCANTI 2010, GRIMM 2011, OBREGÓN *et al.* 2014, COELHO *et al.* 2016b, JONES & CARVALHO 2018, LYRA *et al.* 2018, SILVA *et al.* 2021), além da Oscilação Madden-Julian (OMJ) (ZHANG 2005).

Na tabela 4 e figura 8 ($y-\alpha$), verifica-se que há tendência de aumento da precipitação nos três estados do Sul do Brasil entre 1985 e 2014, entretanto o subconjunto do CMIP6 captura uma leve tendência de redução da precipitação no Paraná, também apontada pelo CRU no Rio Grande do Sul. Segundo SOARES & MARENGO (2009), a região Sul do Brasil, especialmente o Rio Grande do Sul, recebe umidade transportada na baixa atmosfera

pelo Jato de Baixos Níveis da América do Sul, que é intensificado em um cenário de fortes emissões de gases do efeito estufa. O trabalho de HAYLOCK *et al.* (2006) também indica o deslocamento da ZCAS mais ao sul da sua posição, acarretando em mais chuvas na Região Sul. Alguns trabalhos de cunho observacional e de simulações com modelos globais e regionais também têm evidenciado a tendência de aumento das chuvas da Região Sul, como os de LIEBMANN *et al.* (2004), JONES & CARVALHO (2013), CAVALCANTI & SHIMIZU (2012), DOS SANTOS *et al.* (2020), REGOTO *et al.* (2021), ZILLI & CARVALHO (2021) e PEREIRA *et al.* (2022). Além desse fatores, os padrões de teleconexões, como anomalias da TSM e os modos acoplados como o *El Niño*/Oscilação Sul, a Oscilação Decadal do Pacífico e a Oscilação Multidecadal do Atlântico são eventos preponderantes para o incremento ou não da precipitação (LIEBMANN *et al.* 2005, HAYLOCK *et al.* 2006, MARENGO *et al.* 2009, GRIMM 2011, CARVALHO 2019).

3.2.4 Índices de Desempenho

Os índices de desempenho do CMIP6 para cada estado, comparados com as bases de dados do CRU e BR-DWGD, são apresentados na tabela 5. De modo geral, o CMIP6 apresentou desempenhos diferentes de acordo com a região e com os estados.

Na Região Norte, o subconjunto do CMIP6 teve relativa dificuldade em simular a precipitação, subestimando-a no período 1985-2014. O baixo desempenho do subconjunto do CMIP6 pode estar também relacionado ao pequeno conjunto de dados das estações meteorológicas no Norte do Brasil (FAN *et al.* 2020), bem como a dificuldade de parametrização convectiva pelos modelos globais (ALVES & MARENGO 2010).

O CMIP6 para os estados do Amapá, Roraima e Pará apresentou erro médio -3 mm d^{-1} , $-2,5 \text{ mm d}^{-1}$ e $-1,5 \text{ mm d}^{-1}$, respectivamente. Este resultado reforça as informações obtidas no viés da precipitação (Figuras 5 e 6). Estatisticamente, também se verificou que para estes três estados, o modelo não apresentou desempenho satisfatório, conforme mostrado na tabela 5. O CMIP6, para o estado do Amapá, apresentou valores baixos dos índices de Willmot e de D_{PIELKE} , indicando que o modelo apresenta maior dificuldade em simular a precipitação nesse estado.

O CMIP6 na Região Norte teve um desempenho satisfatório para os estados do Acre, Rondônia

TABELA 5 – Índices de desempenho do CMIP6 para precipitação de cada estado do Brasil entre janeiro de 1985 a dezembro de 2014, comparado com as bases de dados CRU e BR-DWGD. Onde os índices são: coeficiente de correlação (r), o erro médio (EM), o erro médio quadrático (EMQ), a raiz do erro médio quadrático ($REMQ$) e a raiz do erro médio quadrático após a remoção de um desvio médio ($REMQU_B$), desvio padrão simulado (S_S) e desvio padrão observado (S_O), índice de Willmott (d), índice de destreza Pielke (D_{PIELKE}).

TABLE 5 – Precipitation CMIP6 performance indices to each Brazil states between January 1985 and December 2014, for CRU and BR-DWGD databases. Where the indices are: correlation coefficient (r), the mean error (EM), the mean squared error (MSE), the root mean squared error ($RMSE$) and the root mean squared error after removing a mean deviation ($RMSE_{UB}$), simulated standard deviation (S_S) and observed standard deviation (S_O), Willmott index (d), Pielke skill index (D_{PIELKE}).

Estado	Base de Dados	r	EM	EMQ	$REMQU_B$	S_S	S_O	d	D_{PIELKE}
AC	CRU	0,90	-0,87	1,78	1,51	2,95	3,43	0,92	1,10
	BR-DWGD	0,93	-0,35	1,18	1,12	2,95	3,07	0,96	0,79
AM	CRU	0,80	-1,19	1,70	1,22	1,84	2,01	0,80	1,55
	BR-DWGD	0,78	-1,08	1,82	1,46	1,84	2,34	0,80	1,61
AP	CRU	0,67	-3,33	4,70	3,31	2,28	4,37	0,55	2,31
	BR-DWGD	0,56	-3,33	5,05	3,79	2,28	4,58	0,48	2,43
PA	CRU	0,91	-1,49	2,03	1,39	2,59	3,25	0,88	1,26
	BR-DWGD	0,87	-1,35	2,25	1,80	2,59	3,49	0,86	1,42
RO	CRU	0,96	-0,18	1,00	0,98	3,37	3,45	0,98	0,60
	BR-DWGD	0,96	-0,76	1,40	1,18	3,37	3,88	0,96	0,80
RR	CRU	0,78	-2,25	2,98	1,95	2,48	3,12	0,73	1,79
	BR-DWGD	0,75	-1,39	2,45	2,01	2,48	3,00	0,79	1,66
TO	CRU	0,87	0,00	2,07	2,07	4,20	3,92	0,93	1,12
	BR-DWGD	0,88	0,26	2,04	2,03	4,20	3,65	0,93	1,26
AL	CRU	0,09	0,70	3,06	2,98	2,38	2,02	0,15	3,18
	BR-DWGD	0,62	-2,19	3,30	2,47	2,38	3,07	0,62	2,10
BA	CRU	0,66	0,73	2,20	2,08	2,77	2,02	0,75	2,50
	BR-DWGD	0,64	0,92	2,35	2,16	2,77	2,18	0,74	2,34
CE	CRU	0,80	1,88	3,12	2,50	4,07	2,64	0,78	2,67
	BR-DWGD	0,77	2,02	3,33	2,65	4,07	2,69	0,75	2,73
MA	CRU	0,89	0,25	1,79	1,77	3,92	3,43	0,94	1,18
	BR-DWGD	0,88	0,63	1,98	1,88	3,92	3,32	0,92	1,34
PB	CRU	0,58	1,39	3,10	2,78	3,42	2,13	0,64	3,37
	BR-DWGD	0,57	1,60	3,24	2,82	3,42	2,08	0,61	3,55
PE	CRU	0,71	1,93	3,21	2,56	3,57	2,02	0,66	3,63
	BR-DWGD	0,68	2,11	3,38	2,63	3,57	2,05	0,64	3,69
PI	CRU	0,86	1,34	2,63	2,27	4,15	2,82	0,85	2,21
	BR-DWGD	0,84	1,53	2,83	2,37	4,15	2,78	0,83	2,37
RN	CRU	0,67	1,66	3,16	2,69	3,61	2,30	0,69	3,12
	BR-DWGD	0,63	1,76	3,31	2,80	3,61	2,36	0,66	3,12
SE	CRU	0,73	1,00	1,84	1,55	2,17	2,02	0,79	1,75
	BR-DWGD	0,70	1,18	2,02	1,63	2,17	2,04	0,75	1,85
DF	CRU	0,81	0,09	2,49	2,49	4,20	3,91	0,90	1,35
	BR-DWGD	0,81	0,53	2,54	2,48	4,20	3,51	0,88	1,62
GO	CRU	0,91	-0,15	1,70	1,70	4,09	3,80	0,95	0,97
	BR-DWGD	0,90	0,29	1,84	1,82	4,09	3,66	0,94	1,12
MT	CRU	0,98	-0,51	0,94	0,78	3,77	3,62	0,98	0,52
	BR-DWGD	0,96	-0,45	1,20	1,12	3,77	3,84	0,97	0,62
MS	CRU	0,87	-0,39	1,34	1,29	2,62	2,23	0,92	1,35
	BR-DWGD	0,86	-0,34	1,38	1,33	2,62	2,28	0,91	1,35
ES	CRU	0,52	-0,76	2,26	2,13	1,28	2,50	0,57	2,24
	BR-DWGD	0,54	-0,77	2,48	2,35	1,38	2,80	0,57	2,23
MG	CRU	0,88	0,20	1,54	1,53	3,20	3,03	0,93	1,07
	BR-DWGD	0,87	0,40	1,65	1,60	3,20	3,02	0,92	1,14
RJ	CRU	0,85	0,21	1,50	1,49	2,51	2,82	0,91	1,17
	BR-DWGD	0,83	0,00	1,74	1,74	2,51	3,16	0,90	1,31
SP	CRU	0,86	-0,27	1,43	1,41	2,71	2,64	0,92	1,12
	BR-DWGD	0,82	0,00	1,58	1,58	2,71	2,69	0,90	1,26
PR	CRU	0,57	-0,35	1,89	1,85	2,03	1,95	0,72	1,95
	BR-DWGD	0,47	-0,39	2,26	2,23	2,03	2,28	0,63	2,08
RS	CRU	0,17	-0,89	1,82	1,59	0,81	1,51	0,20	2,72
	BR-DWGD	0,15	-0,96	2,23	2,01	0,81	1,97	0,16	2,74
SC	CRU	0,28	-0,58	1,96	1,87	1,35	1,73	0,41	2,43
	BR-DWGD	0,28	-0,49	2,23	2,18	1,35	2,13	0,39	2,43

e Tocantins. O índice de Willmot foi superior 0,90 e o de D_{PIELKE} inferior a 1,5, o que indicam ótimo desempenho do CMIP6 em representar a precipitação para estes três estados (Tabela 5).

O CMIP6 superestimou a precipitação no Nordeste. Tal condição pode ser explicada pela dificuldade dos modelos globais em simular as condições oceânicas e atmosféricas nos oceanos tropical Pacífico e Atlântico (MARENGO *et al.* 2018), em representar a magnitude e a posição média da ZCIT continental e oceânica deslocando-a mais ao sul (DA SILVA & MENDES, 2015), bem como o deslocamento da umidade da Região Norte para o Nordeste (DIAS & REBOITA 2021).

Na Região Nordeste, o CMIP6 conseguiu simular melhor a precipitação para o Estado do Maranhão, diferentemente da temperatura do ar, onde apresentou desempenho não satisfatório.

O subconjunto do CMIP6, sobre a região litorânea do Nordeste, especificamente nos estados do Alagoas, Bahia, Paraíba, Pernambuco, Rio Grande do Norte e Ceará, não apresentou bom desempenho a partir dos índices de Willmot e D_{PIELKE} (Tabela 5). No estado de Alagoas, o índice de Willmot ficou entre 0,15 e 0,62 e o índice D_{PIELKE} foi superior a 2,10, o que indica que para esse estado, o modelo teve relativa dificuldade em simular a precipitação.

Nos estados da Bahia, Paraíba, Pernambuco, Rio Grande do Norte e Ceará, o subconjunto do CMIP6 apresentou índices de Willmot superiores a 0,61 e, sendo considerado somente este índice, poderíamos inferir que o modelo está simulando bem a precipitação. Todavia, ao verificarmos o índice D_{PIELKE} , o CMIP6, para os mesmos estados, apresentou valor superior a 2,34, indicando dificuldade em simular esse parâmetro. Tal constatação é corroborada pelo erro médio, quando se verifica que o subconjunto CMIP6 superestimou a precipitação nesses estados.

Por fim, a maioria dos estados do Nordeste do Brasil apresentou correlação (r) superior a 0,57. Entretanto, SILVEIRA *et al.* (2013) encontraram correlação (r) superior a 0,70 para o período de 1901 a 1999 com os dados do CRU. Tal condição pode indicar uma leve piora dos dados, porém, a análise precisa ser mais acurada.

O melhor desempenho do subconjunto do CMIP6 para precipitação foi na Região Centro-Oeste. Segundo ORTEGA *et al.* (2021), a Região Centro-Oeste é a localidade na América do Sul, com a melhor simulação da precipitação, tanto para o CMIP5, quanto para o CMIP6. O CMIP6, para

estado de Mato Grosso, apresentou os melhores índices de Willmot e D_{PIELKE} , com valores superiores a 0,97 e inferiores a 0,62, respectivamente (Tabela 5).

O subconjunto do CMIP6 apresentou desempenho distinto nos estados da Região Sudeste. Rio de Janeiro, São Paulo e Minas Gerais apresentam os melhores resultados estatísticos, quando comparado ao Espírito Santo. Tal evidência pode estar relacionada ao fato do Sudeste ser uma região de transição climática (REBOITA *et al.* 2010, 2015), o que influencia o desempenho dos modelos, além da dificuldade do modelo em simular a ZCAS e os sistemas frontais (ALVES *et al.* 2021), bem com a resolução do modelo (LYRA *et al.* 2018).

Em Minas Gerais, o subconjunto do CMIP6 apresenta leve superioridade estatística em relação ao Rio de Janeiro e São Paulo. Esses três estados exibem índices de Willmott e D_{PIELKE} , com valores superiores a 0,80 e inferiores a 1,31, respectivamente. Tal constatação mostra a habilidade do CMIP6 em simular a precipitação para esses estados. Concomitantemente, para o estado do Espírito Santo, o modelo apresenta índices estatísticos não satisfatório, com Willmott inferior a 0,54 e de D_{PIELKE} superior a 2,23, indicando a dificuldade em simular a precipitação.

Na Região Sul, o CMIP6 subestimou a precipitação. PEREIRA *et al.* (2022) sugerem que o CMIP6 não é capaz de reproduzir a transição entre climas tropicais e subtropicais nesta região, bem como a passagem de sistemas frontais, condição que impacta diretamente na simulação da precipitação.

Para os estados do Rio Grande do Sul e Santa Catarina, o subconjunto do CMIP6 apresenta os índices de Willmott e D_{PIELKE} inferior a 0,16 e superior a 2,43, respectivamente (Tabela 5). Esses valores indicam a dificuldade do modelo em simular a precipitação nesses estados. No estado do Paraná, o modelo teve um desempenho estatisticamente melhor.

4 CONCLUSÕES

Este estudo avaliou a capacidade do subconjunto de 40 modelos globais do CMIP6 (MOD) em simular o clima presente no Brasil e seus estados. Comparações entre as simulações e as observações anuais e sazonais de temperatura e precipitação sobre o Brasil foram feitas no período de 1985 a 2014. Apesar dos vieses nas simulações, o subconjunto do CMIP6 conseguiu simular satisfatoriamente o ciclo anual e sazonal da temperatura e

precipitação, bem como, captar a tendência das variáveis analisadas no Brasil. Além disso, apesar das incertezas inerentes a modelagem climática e vieses detectados, este estudo é relevante para indicar o comportamento dos modelos em simular o clima presente. Tal medida pode orientar os tomadores de decisão, com subsídios científicos sobre possíveis vieses dos modelos para o clima presente, sendo de grande ajuda na implementação de medidas de mitigação e/ou adaptação, quando análises de projeções futuras sejam desenvolvidas usando os modelos do CMIP6.

As principais conclusões são as seguintes:

- As avaliações das simulações mostram que o subconjunto do CMIP6 conseguiu capturar a variabilidade sazonal e a tendência da temperatura e precipitação, todavia existem diferenças significativas em relação aos dados observados;

- Aspectos como a má representação de alguns componentes hidrológicos (cobertura vegetal, umidade do solo, fluxos de superfície) e parametrização da convecção impactam o desempenho do subconjunto do CMIP6. Além desses fatores, existe uma dificuldade em simular os impactos das condições oceânicas e atmosféricas nos oceanos tropical Pacífico e Atlântico no clima regional. Isso pode ser observado na dificuldade em representar a intensidade e a posição média da ZCIT continental e oceânica.

- Ademais os modelos do CMIP6 apresentam relativa dificuldade de simulação da ZCAS e dos sistemas frontais e da atmosfera local, da mesma maneira, a resolução da topografia e a resolução dos dados podem contribuir no desempenho do modelo em questão;

- Em relação à temperatura do ar à superfície, o subconjunto do CMIP6 teve um melhor desempenho para as regiões Sul e Sudeste do Brasil;

- Os melhores índices de desempenho da simulação da temperatura são encontrados nos estados do Paraná, Santa Catarina e São Paulo;

- Para a Região Nordeste, os melhores desempenhos foram para os estados de Alagoas e Sergipe. Para os demais estados dessa região, o subconjunto do CMIP6 não apresentou desempenho satisfatório. No Nordeste, o modelo tende a subestimar as temperaturas;

- Na região Norte o subconjunto do CMIP6 teve o pior desempenho em relação à temperatura. A temperatura foi subestimada nos estados do Acre e Rondônia e os piores desempenhos foram verificados nos estados do Tocantins, Pará, Maranhão e Roraima;

- O melhor desempenho para a precipitação, com o subconjunto do CMIP6, foi verificado na Região Centro-Oeste do Brasil;

- Os estados do Mato Grosso, Acre, Rondônia, Goiás e Minas Gerais apresentaram os melhores índices de Willmott e D_{PIELKE} e também os melhores resultados estatísticos para a simulação da precipitação;

- As simulações de pior desempenho da precipitação foram encontradas nos estados de Pernambuco, Paraíba, Rio Grande do Norte, Rio Grande do Sul, Ceará e Santa Catarina. Fatores como relevo, parametrização, convecção e uso do solo podem estar impactando nesse desempenho, condição que deve ser analisada em estudo futuro;

- O subconjunto do CMIP6 teve dificuldade em simular a precipitação nas regiões Nordeste, Norte e Sul do Brasil. Para a primeira região, a precipitação foi superestimada; nas demais, a precipitação foi subestimada;

- Cabe destacar a dificuldade do subconjunto do CMIP6 em simular a temperatura e a precipitação no Nordeste do Brasil, subestimando a temperatura e superestimando a precipitação;

- Em relação às tendências de aquecimento no período de 30 anos do estudo, 1985-2014, todos os estados do Brasil apresentaram tendência de aquecimento, tanto para os dados do subconjunto do CMIP6, quanto para os dados observados, exceto para o estado de Santa Catarina, onde a base BR-DWGD apresentou uma leve tendência de redução da temperatura;

- A precipitação na região Norte não exibiu tendências claras para o período analisado; alguns estados apresentaram aumento e outros redução da precipitação. O subconjunto do CMIP6 apresentou redução para todos os estados, enquanto, os dados observacionais apresentaram redução no leste da Amazônia (Amapá, Pará e Tocantins) e aumento na porção oeste (Acre, Amazonas, Rondônia e Roraima);

- Nas regiões Centro-Oeste e Nordeste todos os estados apresentam tendência de redução da chuva. Na Região Sudeste, os estados do Espírito Santo e Rio de Janeiro apresentam tendência de aumento, enquanto São Paulo e Minas Gerais, tendência de queda;

- Na Região Sul, os três estados mostram tendência de aumento na chuva tanto no observado quanto no simulado. Entretanto, um leve decréscimo foi verificado pelo subconjunto do CMIP6 no estado do Paraná, assim como no estado do Rio Grande do Sul, com a base CRU.

5 AGRADECIMENTOS

Os autores deste trabalho agradecem a Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (FAPES) pelo financiamento e suporte ao projeto de nº 302/2022 – Plano Estadual de Mudanças Climáticas e a cooperação técnica e financeira Nº 002/2018 – VALE/ITV/UFES/FAPES-Climatologia. Os autores também agradecem ao CNPq pela bolsa PQ 312742/2021-5, ao Instituto Nacional de Ciência e Tecnologia para Mudanças Climáticas – Fase 2, sob o auxílio CNPq 465501/2014-1, a FAPESP 2014/50848-9 e a Coordenação Nacional de Ensino Superior e Capacitação (CAPES) Bolsa 88887.136402/2017-00. Também, agradecemos aos revisores e editores da revista, por nos permitirem a publicação do presente artigo.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- ACEITUNO, P. 1988. On the Functioning of the Southern Oscillation in the South American Sector. Part I: Surface Climate. *Monthly Weather Review*, 116(3): 505-524. [https://doi.org/10.1175/1520-0493\(1988\)116<0505:OTFOTS>2.0.CO;2](https://doi.org/10.1175/1520-0493(1988)116<0505:OTFOTS>2.0.CO;2)
- ALMAZROUI, M.; ASHFAQ, M.; ISLAM, M.N.; RASHID, I.U.; KAMIL, S.; ABID, M.A.; O'BRIEN, E.; ISMAIL, M.; REBOITA, M.S.; SÖRENSSON, A.A.; ARIAS, P.A.; ALVES, L.M.; TIPPETT, M.K.; SAEED, S.; HAARSMA, R.; DOBLAS-REYES, F.J.; SAEED, F.; KUCHARSKI, F.; NADEEM, I.; SYLLA, M. B. 2021. Assessment of CMIP6 Performance and Projected Temperature and Precipitation Changes Over South America. *Earth Systems and Environment*, 5(2): 155-183. <https://doi.org/10.1007/s41748-021-00233-6>
- ALMEIDA, C. T.; OLIVEIRA-JÚNIOR, J.F.; DELGADO, R.C.; CUBO, P.; RAMOS, M.C. 2017. Spatiotemporal rainfall and temperature trends throughout the Brazilian Legal Amazon, 1973-2013. *International Journal of Climatology*, 37(4): 2013-2026. <https://doi.org/10.1002/joc.4831>
- ALVES, J.M.B.; VASCONCELOS JUNIOR, F.C.; CHAVES, R.R.; SILVA, E.M.; SERVAIN, J.; COSTA, A.A.; SOMBRA, S.S.; BARBOSA, A.C.B.; DOS SANTOS, A.C.S. 2016. Evaluation of the AR4 CMIP3 and the AR5 CMIP5 model and projections for precipitation in northeast Brazil. *Frontiers in Earth Science*, 4:4. <https://doi.org/10.3389/feart.2016.00044>
- ALVES, L.M. 2016. *Análise estatística da sazonalidade e tendências das estações chuvosas e seca na Amazônia: Clima presente e projeções futuras*, Instituto de Pesquisas Espaciais, São José dos Campos, Tese de Doutorado, 140 p. <http://urlib.net/8JMKD3MGP3W34P/3L9KTPH>
- ALVES, L.M.; MARENGO, J. 2010. Assessment of regional seasonal predictability using the PRECIS regional climate modeling system over South America. *Theoretical and Applied Climatology*, 100(3): 337-350. <https://doi.org/10.1007/s00704-009-0165-2>
- ALVES, L.M.; CHADWICK, R.; MOISE, A.; BROWN, J.; MARENGO, J.A. 2021. Assessment of rainfall variability and future change in Brazil across multiple timescales. *International Journal of Climatology*, 41(S1): E1875-E1888. <https://doi.org/10.1002/joc.6818>
- ANDREOLI, R.V.; KAYANO, M.T. 2005. ENSO-related rainfall anomalies in South America and associated circulation features during warm and cold Pacific decadal oscillation regimes. *International Journal of Climatology*, 25(15): 2017-2030. <https://doi.org/10.1002/joc.1222>
- AVILA-DIAZ, A.; BENEZOLI, V.; JUSTINO, F.; TORRES, R.; WILSON, A. 2020. Assessing current and future trends of climate extremes across Brazil based on reanalyses and earth system model projections. *Climate Dynamics*, 55(5-6): 1403-1426. <https://doi.org/10.1007/s00382-020-05333-z>
- BENTSEN, M.; OLIVIÈ, D.J.L.; SELAND, Ø.; TONIAZZO, T.; GJERMUNDSEN, A.; GRAFF, L.S.; DEBERNARD, J. B.; GUPTA, A.K.; HE, Y.; KIRKEVÅG, A.; SCHWINGER, J.; TJIPUTRA, J.; AAS, K.S.; BETHKE, I.; FAN, M. 2019. *NCC NorESM2-MM model output prepared for CMIP6 CMIP historical*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.8040>

- BERGIER, I.; SILVA, A.P.S.; ABREU, U.G.P.; OLIVEIRA, L.O.F.; TOMAZI, M.; DIAS, F.R.T.; URBANETZ, C.; NOGUEIRA, E.; BORGES-SILVA, J. C. 2019. Could bovine livestock intensification in Pantanal be neutral regarding enteric methane emissions? *Science of the Total Environment*, 655: 463-472. <https://doi.org/10.1016/j.scitotenv.2018.11.178>
- BOUCHER, O.; DENVIL, S.; LEVAVASSEUR, G.; COZIC, A.; CAUBEL, A.; FOUJOLS, M.A.; MEURDESOFIF, Y.; CADULE, P.; DEVILLIERS, M.; GHATTAS, J.; LEBAS, N.; LURTON, T.; MELLUL, L.; MUSAT, I.; MIGNOT, J.; CHERUY, F. 2018. *IPSL IPSL-CM6A-LR model output prepared for CMIP6 CMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.1534>
- BUSTAMANTE, M.; NARDOTO, G.; PINTO, A.; RESENDE, J.; TAKAHASHI, F.; VIEIRA, L. 2012. Potential impacts of climate change on biogeochemical functioning of Cerrado ecosystems. *Brazilian Journal of Biology*, 72(3 suppl): 655-671. <https://doi.org/10.1590/s1519-69842012000400005>
- BYUN, Y.H.; LIM, Y.J.; SUNG, H. M.; KIM, J.; SUN, M.; KIM, B.H. 2019. *NIMS-KMA KACE1.0-G model output prepared for CMIP6 CMIP historical*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.8378>
- CAO, J.; WANG, B. 2019. *NUIST NESMv3 model output prepared for CMIP6 CMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.2021>
- CARVALHO, L.M.V. 2019. Assessing precipitation trends in the Americas with historical data: A review. *Wiley Interdisciplinary Reviews: Climate Change*, 11(2): 1-21. <https://doi.org/10.1002/wcc.627>
- CARVALHO, L.M.V.; JONES, C. 2013. CMIP5 simulations of low-level tropospheric temperature and moisture over the tropical Americas. *Journal of Climate*, 26(17): 6257-6286. <https://doi.org/10.1175/JCLI-D-12-00532.1>
- CAVALCANTI, I.F.A.; SHIMIZU, M.H. 2012. Climate Fields over South America and Variability of SACZ and PSA in HadGEM2-ES. *American Journal of Climate Change*, 1(3): 132-144. <https://doi.org/10.4236/ajcc.2012.13011>
- CHOU, S.C.; MARENGO, J.A.; LYRA, A.; SUEIRO, G.; PESQUERO, J.; ALVES, L.M.; KAY, G.; BETTS, R.; CHAGAS, D.; GOMES, J.L.; BUSTAMANTE, J.; TAVARES, P. 2012. Downscaling of South America present climate driven by 4-member HadCM3 runs. *Climate Dynamics*, 38(3-4): 635-653. <https://doi.org/10.1007/s00382-011-1002-8>
- CHOU, S.C.; LYRA, A.; MOURÃO, C.; DEREZYNSKI, C.; PILOTTO, I.; GOMES, J.; BUSTAMANTE, J.; TAVARES, P.; SILVA, A.; RODRIGUES, D.; CAMPOS, D.; CHAGAS, D.; SUEIRO, G.; SIQUEIRA, G.; NOBRE, P.; MARENGO, J. 2014. Evaluation of the Eta Simulations Nested in Three Global Climate Models. *American Journal of Climate Change*, 3(5): 438-454. <https://doi.org/10.4236/ajcc.2014.35039>
- CHOU, S.C.; DE ARRUDA LYRA, A.; GOMES, J.L.; RODRIGUEZ, D.A.; MARTINS, M.; RESENDE, N.; TAVARES, P.; DEREZYNSKI, C.P.; PILOTTO, I.; MARTINS, A.M.; CARVALHO, L.F.A.; ONOFRE, J.L.L.; MAJOR, I.; PENHOR, M.; SANTANA, A. 2020. Downscaling projections of climate change in Sao Tome and Principe Islands, Africa. *Climate Dynamics*, 54: 4021-4042. <https://doi.org/10.1007/s00382-020-05212-7>
- COELHO, C.A.S.; CARDOSO, D.H.F.; FIRPO, M.A.F. 2016a. A seca de 2013 a 2015 na região sudeste do Brasil. *Climanálise*, 1: 55-61. <http://climanalise.cptec.inpe.br/~rclimanl/revista/pdf/30anos/>
- COELHO, C.A.S.; OLIVEIRA, C.P.; AMBRIZZI, T.; REBOITA, M.S.; CARPENEDO, C.B.; CAMPOS, J.L.P.S.; TOMAZIELLO, A.C.N.; PAMPUCH, L.A.; CUSTÓDIO, M.S.; DUTRA, L.M.M.; ROCHA, R.P.; REHBEIN, A. 2016b. The 2014 southeast Brazil austral summer drought: regional scale mechanisms and teleconnections. *Climate Dynamics*, 46: 3737-3752. <https://doi.org/10.1007/s00382-015-2800-1>

- COSTA, R.L.; BAPTISTA, G.M.M, SILVA, F.; ROCHA JÚNIOR, R. L.; SALVADOR, M.A., HERDIES, D.L. 2020. Analysis of climate extremes indices over northeast Brazil from 1961 to 2014. *Weather and Climate Extremes*, 28: 100254. <https://doi.org/https://doi.org/10.1016/j.wace.2020.100254>
- COSTA, R.L.; BAPTISTA, G.M.M.; GOMES, H.B.; SILVA, F.D.S.; ROCHA JÚNIOR, R.L.; NEDEL, A.S. 2021. Analysis of future climate scenarios for northeastern Brazil and implications for human thermal comfort. *Anais da Academia Brasileira de Ciências*, 93(1): 1-23. <https://doi.org/10.1590/0001-3765202120190651>
- CUNHA, A.P.M.A.; TOMASELLA, J.; RIBEIRO NETO, G.G.; BROWN, M.; GARCIA; S.R.; BRITO, S.B.; CARVALHO, M.A.. 2018. Changes in the spatial-temporal patterns of droughts in the Brazilian Northeast. *Atmospheric Science Letters*, 19(10): 1-8. <https://doi.org/10.1002/asl.855>
- DA SILVA, G.A.M.; MENDES, D. 2015. Refinement of the daily precipitation simulated by the CMIP5 models over the north of the Northeast of Brazil. *Frontiers in Environmental Science*, 3:29. <https://doi.org/10.3389/fenvs.2015.00029>
- DA SILVA CRUZ, J.; BLANCO, C.J.C.; DE OLIVEIRA JÚNIOR, J.F. 2022. Modeling of land use and land cover change dynamics for future projection of the Amazon number curve. *Science of the Total Environment*, 811: 152348. <https://doi.org/10.1016/j.scitotenv.2021.152348>
- DANABASOGLU, G. 2019a. *NCAR CESM2-WACCM model output prepared for CMIP6 CMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.10024>
- DANABASOGLU, G. 2019b. *NCAR CESM2 model output prepared for CMIP6 CMIP historical*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.7627>
- DE ABREU, R.C.; TETT, S.F.B.; SCHURER, A.; ROCHA, H.R. 2019. Attribution of Detected Temperature Trends in Southeast Brazil. *Geophysical Research Letters*, 46(14): 8407-8414. <https://doi.org/10.1029/2019GL083003>
- DELBEKE, J.; RUNGE-METZGER, A.; SLINGENBERG, Y.; WERKSMAN, J. 2019. The Paris agreement. In: J. Delbeke & P. Vis (ed.) *Towards a Climate-Neutral Europe: Curbing the Trend*. London, Routledge, p. 24-45. <https://doi.org/10.4324/9789276082569-2>
- 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. 2020. Downscaling of climate extremes over South America - Part I: Model evaluation in the reference climate. *Weather and Climate Extremes*, 29: 100273. <https://doi.org/10.1016/j.wace.2020.100273>
- DIAS, C.G.; REBOITA, M.S. 2021. Assessment of CMIP6 Simulations over Tropical South America. *Revista Brasileira de Geografia Física*, 14(3): 1282-1295. <https://doi.org/10.26848/rbgf.v14.3.p1282-1295>
- DÍAZ, L.B.; SAURRAL, R.I.; VERA, C.S. 2021. Assessment of South America summer rainfall climatology and trends in a set of global climate models large ensembles. *International Journal of Climatology*, 41(S1): E59-E77. <https://doi.org/10.1002/joc.6643>
- DIX, M.; BI, D.; DOBROHOTOFF, P.; FIEDLER, R.; HARMAN, I.; LAW, R.; MACKALLAH, C.; MARSLAND, S.; O'FARRELL, S.; RASHID, H.; SRBINOVSKY, J.; SULLIVAN, A.; TRENHAM, C.; VOHRALIK, P.; WATTERSON, I.; WILLIAMS, G.; WOODHOUSE, M.; BODMAN, R.; DIAS, F.B.; YANG, R. 2019. *CSIRO-ARCCSS ACCESS-CM2 model output prepared for CMIP6 CMIP historical*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.4271>
- DOHLER, R.E.; KLIPPEL, A.H.; XAVIER, A.C. 2016. Efeito das mudanças climáticas na demanda de irrigação na cultura do café conilon e do mamoeiro no Espírito Santo. *Revista Agro@Mambiente On-Line*, 10(1): 83-87. <https://doi.org/10.18227/1982-8470ragro.v10i1.2961>

- DOS SANTOS, D.J.; PEDRA, G.U.; SILVA, M.G.B.; GUIMARÃES, C.A.; ALVES, L.M.; SAMPAIO, G.; MARENGO, J.A. 2020. Future rainfall and temperature changes in Brazil under global warming levels of 1.5°C, 2°C and 4°C. *Sustentabilidade Em Debate*, 11(3): 74-90. <https://doi.org/10.18472/SustDeb.v11n3.2020.33933>
- DOSS-GOLLIN, J.; MUÑOZ, Á.G.; MASON, S. J.; PASTÉN, M. 2018. Heavy rainfall in paraguay during the 2015/16 austral summer: Causes and subseasonal-to-seasonal predictive skill. *Journal of Climate*, 31(17): 6669-6685. <https://doi.org/10.1175/JCLI-D-17-0805.1>
- DUFFY, P.B.; BRANDO, P.; ASNER, G.P.; FIELD, C.B. 2015. Projections of future meteorological drought and wet periods in the Amazon. *Proceedings of the National Academy of Sciences of the United States of America*, 112(43): 13172-13177. <https://doi.org/10.1073/pnas.1421010112>
- EC-EARTH CONSORTIUM. 2019a. *EC-Earth-Consortium EC-Earth3 model output prepared for CMIP6 CMIP historical*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.4700>
- EC-EARTH CONSORTIUM. 2019b. *EC-Earth-Consortium EC-Earth3-Veg model output prepared for CMIP6 ScenarioMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.727>
- EYRING, V.; BONY, S.; MEEHL, G.A.; SENIOR, C.A.; STEVENS, B.; STOUFFER, R.J.; TAYLOR, K.E. 2016. Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geoscientific Model Development*, 9(5): 1937-1958. <https://doi.org/10.5194/gmd-9-1937-2016>
- FAN, X.; MIAO, C.; DUAN, Q.; SHEN, C.; WU, Y. 2020. The Performance of CMIP6 Versus CMIP5 in Simulating Temperature Extremes Over the Global Land Surface. *Journal of Geophysical Research: Atmospheres*, 125(18): 1-16. <https://doi.org/10.1029/2020JD033031>
- FEARNSIDE, P.M. 2009. Global warming in Amazonia: Impacts and Mitigation. *Acta Amazonica*, 39(4): 1003-1011. <https://doi.org/10.1590/s0044-59672009000400030>
- FERREIRA, A.G.; MELLO, N.G.S. 2005. Principais sistemas atmosféricos atuantes sobre a região Nordeste do Brasil e a influência dos Oceanos Pacífico e Atlântico no clima da região. *Revista Brasileira de Climatologia*, 1(1): 15-28. <https://doi.org/10.5380/abclima.v1i1.25215>
- FOGLI, P.G.; IOVINO, D.; LOVATO, T. 2020. *CMCC CMCC-CM2-SR5 model output prepared for CMIP6 OMIP omip1*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.13230>
- FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. 2015. The climate hazards infrared precipitation with stations - A new environmental record for monitoring extremes. *Scientific Data*, 2: 150066. <https://doi.org/10.1038/sdata.2015.66>
- GADELHA, A.N.; COELHO, V.H.R.; XAVIER, A.C.; BARBOSA, L.R.; MELO, D.C.D.; XUAN, Y.; HUFFMAN, G.J.; PETERSEN, W.A.; ALMEIDA, C.N. 2019. Grid box-level evaluation of IMERG over Brazil at various space and time scales. *Atmospheric Research*, 218: 231-244. <https://doi.org/https://doi.org/10.1016/j.atmosres.2018.12.001>
- GARCIA, B.N.; LIBONATI, R.; NUNES, A.M.B. 2018. Extreme drought events over the Amazon Basin: The perspective from the reconstruction of South American Hydroclimate. *Water*, 10(11): 1594. <https://doi.org/10.3390/w10111594>
- GATTI, L.V.; GLOOR, M.; MILLER, J.B.; DOUGHTY, C.E.; MALHI, Y.; DOMINGUES, L.G.; BASSO, L.S.; MARTINEWSKI, A.; CORREIA, C.S.C.; BORGES, V.F.; FREITAS, S.; BRAZ, R.; ANDERSON, L.O.; ROCHA, H.; GRACE, J.; PHILLIPS, O.L.; LLOYD, J. 2014. Drought sensitivity of Amazonian carbon balance revealed by atmospheric measurements. *Nature*, 506: 76-80. <https://doi.org/10.1038/nature12957>

- GATTI, L.V.; BASSO, L.S.; MILLER, J.B.; GLOOR, M.; DOMINGUES, L.G.; CASSOL, H.L.G.; TEJADA, G.; ARAGÃO, L.E.O.C.; NOBRE, C.; PETERS, W.; MARANI, L.; ARAI, E.; SANCHES, A.H.; CORRÊA, S.M.; ANDERSON, L.; RANDOW, C.V.; CORREIA, C.S.C.; CRISPIM, S.P.; NEVES, R.A.L. 2021. Amazonia as a carbon source linked to deforestation and climate change. *Nature* 595, 388–393. <https://doi.org/10.1038/s41586-021-03629-6>
- GRIMM, A.M. 2011. Interannual climate variability in South America: impacts on seasonal precipitation, extreme events, and possible effects of climate change. *Stochastic Environmental Research and Risk Assessment*, 25(4): 537-554. <https://doi.org/10.1007/s00477-010-0420-1>
- GUIMARÃES, S.O.; COSTA, A.A.; VASCONCELOS JÚNIOR, F.C.; DA SILVA, E.M.; SALES, D.C.; DE ARAÚJO JÚNIOR, L.M.; DE SOUZA, S.G. 2016. Projeções de mudanças climáticas sobre o nordeste brasileiro dos modelos do CMIP5 e do CORDEX. *Revista Brasileira de Meteorologia*, 31(3): 337-365. <https://doi.org/10.1590/0102-778631320150150>
- GULIZIA, C.; CAMILLONI, I. 2015. Comparative analysis of the ability of a set of CMIP3 and CMIP5 global climate models to represent precipitation in South America. *International Journal of Climatology*, 35(4): 583-595. <https://doi.org/10.1002/joc.4005>
- GUO, H.; JOHN, J.G.; BLANTON, C.; MCHUGH, C.; NIKONOV, S.; RADHAKRISHNAN, A.; RAND, K.; ZADEH, N.T.; BALAJI, V.; DURACHTA, J.; DUPUIS, C.; MENZEL, R.; ROBINSON, T.; UNDERWOOD, S.; VAHLENKAMP, H.; BUSHUK, M.; DUNNE, K.A.; DUSSIN, R.; GAUTHIER, P.P.G.; ZHANG, R. 2018. *NOAA-GFDL GFDL-CM4 model output*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.1402>
- HARRIS, I.; JONES, P.D.; OSBORN, T.J.; LISTER, D.H. 2014. Updated high-resolution grids of monthly climatic observations – the CRU TS3.10 Dataset. *International Journal of Climatology*, 34(3): 623-642. <https://doi.org/https://doi.org/10.1002/joc.3711>
- HARRIS, I.; OSBORN, T.J.; JONES, P.; LISTER, D. 2020. Version 4 of the CRU TS monthly high-resolution gridded multivariate climate dataset. *Scientific Data*, 7(1): 1-18. <https://doi.org/10.1038/s41597-020-0453-3>
- HAYLOCK, M.R.; PETERSON, T.C.; ALVES, L.M.; AMBRIZZI, T.; ANUNCIACÃO, Y.M.T.; BAEZ, J.; BARROS, V.R.; BERLATO, M.A.; BIDEGAIN, M.; CORONEL, G.; CORRADI, V.; GARCIA, V.J.; GRIMM, A.M.; KAROLY, D.; MARENGO, J.A.; MARINO, M.B.; MONCUNILL, D.F.; NECHET, D.; QUINTANA, J.; VINCENT, L.A. 2006. Trends in total and extreme South American rainfall in 1960-2000 and links with sea surface temperature. *Journal of Climate*, 19(8): 1490-1512. <https://doi.org/10.1175/JCLI3695.1>
- HOFMANN, G.S.; CARDOSO, M.F.; ALVES, R.J.V.; WEBER, E.J.; BARBOSA, A.A.; DE TOLEDO, P.M.; PONTUAL, F.B.; SALLES, L.O.; HASENACK, H.; CORDEIRO, J.L.P.; AQUINO, F.E.; DE OLIVEIRA, L.F.B. 2021. The Brazilian Cerrado is becoming hotter and drier. *Global Change Biology*, 27(17): 4060-4073. <https://doi.org/10.1111/gcb.15712>
- HUANG, W. 2019. *THU CIESM model output prepared for CMIP6 ScenarioMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.1357>
- IPCC. 2014. Climate Change 2014 Part A: Global and Sectoral Aspects. In: C. Field & V. R. Barros (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 (1^a)*. Cambridge University Press. <https://doi.org/10.1017/CBO9781107415379>
- IPCC. 2021. 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*. ONU.

- <https://www.ipcc.ch/report/sixth-assessment-report-working-group-ii/>
- JOETZJER, E.; DOUVILLE, H.; DELIRE, C.; CIAIS, P. 2013a. Present-day and future Amazonian precipitation in global climate models: CMIP5 versus CMIP3. *Climate Dynamics*, 41(11-12): 2921-2936. <https://doi.org/10.1007/s00382-012-1644-1>
- JONES, C.; CARVALHO, L.M.V. 2013. Climate change in the South American monsoon system: Present climate and CMIP5 projections. *Journal of Climate*, 26(17): 6660-6678. <https://doi.org/10.1175/JCLI-D-12-00412.1>
- JONES, C.; CARVALHO, L.M.V. 2018. The influence of the Atlantic multidecadal oscillation on the eastern Andes low-level jet and precipitation in South America. *Npj Climate and Atmospheric Science*, 1(1): 1-7. <https://doi.org/10.1038/s41612-018-0050-8>
- KELLEY, M.; SCHMIDT, G.A.; NAZARENKO, L.S.; BAUER, S.E.; RUEDY, R.; RUSSELL, G.L.; ACKERMAN, A.S.; ALEINOV, I.; BAUER, M.; BLECK, R.; CANUTO, V.; CESANA, G.; CHENG, Y.; CLUNE, T.L.; COOK, B.I.; CRUZ, C.A.; DEL GENIO, A.D.; ELSAESSER, G.S.; FALUVEGI, G.; KIANG, N.Y.; KIM, D.; LACIS, A.A.; LEBOSSETIER, A.; LEGRANDE, A.N.; LO, K.K.; MARSHALL, J.; MATTHEWS, E.E.; MCDERMID, S.; MEZUMAN, K.; MILLER, R.L.; MURRAY, L.T.; OINAS, V.; ORBE, C.; GARCÍA-PANDO, C.P.; PERLWITZ, J.P.; PUMA, M.J.; RIND, D.; ROMANOU, A.; SHINDELL, D.T.; SUN, S.; TAUSNEV, N.; TSIGARIDIS, K.; TSELIODIS, G.; WENG, E.; WU, J.; YAO, M. 2020. GISS-E2.1: Configurations and climatology. *Journal of Advances in Modeling Earth Systems*, 12: e2019MS002025. <https://doi.org/10.1029/2019MS002025>
- KRASTING, J.P.; JOHN, J.G.; BLANTON, C.; MCHUGH, C.; NIKONOV, S.; RADHAKRISHNAN, A.; RAND, K.; ZADEH, N.T.; BALAJI, V.; DURACHTA, J.; DUPUIS, C.; MENZEL, R.; ROBINSON, T.; UNDERWOOD, S.; VAHLENKAMP, H.; DUNNE, K.A.; GAUTHIER, P.P.G.; GINOUX, P.; GRIFFIES, S.M.; ZHAO, M. 2018. NOAA-GFDL GFDL-ESM4 model output prepared for CMIP6 CMIP. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.1407>
- LI, L. 2019. CAS FGOALS-g3 model output prepared for CMIP6 ScenarioMIP ssp370. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.3480>
- LIBONATI, R.; PEREIRA, J.M.C.; DACAMARA, C.C.; PERES, L.F.; OOM, D.; RODRIGUES, J.A.; SANTOS, F.L.M.; TRIGO, R.M.; GOUVEIA, C.M.P.; MACHADO-SILVA, F.; ENRICH-PRAST, A.; SILVA, J.M.N. 2021. Twenty-first century droughts have not increasingly exacerbated fire season severity in the Brazilian Amazon. *Scientific Reports*, 11(1): 4400. <https://doi.org/10.1038/s41598-021-82158-8>
- LIBONATI, R.; GEIRINHAS, J.O.L.; SILVA, P.S.; RUSSO, A.; RODRIGUES, J.A.; BELÉM, L.B.C.; NOGUEIRA, J.; ROQUE, F.O.; DA CAMARA, C.C.; NUNES, A.M.B.; MARENGO, J.A.; TRIGO, R.M. 2022. Assessing the role of compound drought and heatwave events on unprecedented 2020 wildfires in the Pantanal. *Environmental Research Letters*, 17: 015005. <https://doi.org/10.1088/1748-9326/ac462e>
- LIEBMANN, B.; VERA, C.S.; CARVALHO, L.M.V.; CAMILLONI, I.; BARROS, V.; HOERLING, M.P.; ALLURED, D. 2004. An observed trend in central South American precipitation. *Journal of Climate*, 17(22): 2071-2075. <https://doi.org/10.1175/3205.1>
- LORENÇONE, J.A.; APARECIDO, L.E.O.; LORENÇONE, P.A.; LIMA, R.F.; TORSONI, G.B. 2022. Assessment of climate change using humidity index of Thornthwaite climate classification in Pantanal biome. *Revista Brasileira de Meteorologia*, 37(1): 99-119. <https://doi.org/10.1590/0102-7786370075>
- LYRA, A.; TAVARES, P.; CHOU, S.C.; SUEIRO, G.; DEREZYNSKI, C.; SONDERMANN, M.; SILVA, A.; MARENGO, J.; GIAROLLA, A. 2018. Climate change projections over three metropolitan regions in Southeast Brazil using the non-hydrostatic Eta regional climate model at 5-km resolution. *Theoretical*

- and *Applied Climatology*, 132(1-2): 663-682. <https://doi.org/10.1007/s00704-017-2067-z>
- MARENGO, J.A. 2007. Mudanças climáticas globais e seus efeitos sobre a biodiversidade: caracterização do clima atual e definição das alterações climáticas para o território brasileiro ao longo do século XXI. *Série Biodiversidade*, 212p (número 26).
- MARENGO, J.A.; BERNASCONI, M. 2015. Regional differences in aridity/drought conditions over Northeast Brazil: present state and future projections. *Climatic Change*, 129(1-2): 103-115. <https://doi.org/10.1007/s10584-014-1310-1>
- MARENGO, J.A.; CAMARGO, C.C. 2008. Surface air temperature trends in Southern Brazil for 1960–2002. *International Journal of Climatology*, 28(7): 893-904. <https://doi.org/10.1002/joc.1584>
- MARENGO, J.A.; ESPINOZA, J.C. 2016. Extreme seasonal droughts and floods in Amazonia: Causes, trends and impacts. *International Journal of Climatology*, 36(3): 1033-1050. <https://doi.org/10.1002/joc.4420>
- MARENGO, J.A.; JONES, R.; ALVES, L.M.; VALVERDE, M.C. 2009. Future change of temperature and precipitation extremes in South America as derived from the PRECIS regional climate modeling system. *International Journal of Climatology*, 29(15): 2241-2255. <https://doi.org/10.1002/joc.1863>
- MARENGO, J.A.; AMBRIZZI, T.; DA ROCHA, R.P.; ALVES, L.M.; CUADRA, S.V.; VALVERDE, M.C.; TORRES, R.R.; SANTOS, D.C.; FERRAZ, S.E.T. 2010. Future change of climate in South America in the late twenty-first century: intercomparison of scenarios from three regional climate models. *Climate Dynamics*, 35(6): 1073-1097. <https://doi.org/10.1007/s00382-009-0721-6>
- MARENGO, J.A.; ALVES, L.M.; SOARES, W.R.; RODRIGUEZ, D.A.; CAMARGO, H.; RIVEROS, M.P.; PABLÓ, A.D. 2013. Two contrasting severe seasonal extremes in tropical South America in 2012: Flood in Amazonia and drought in Northeast Brazil. *Journal of Climate*, 26(22): 9137-9154. <https://doi.org/10.1175/JCLI-D-12-00642.1>
- 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. 2012. 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*, 38(9-10), 1829-1848. <https://doi.org/10.1007/s00382-011-1155-5>
- MARENGO, J.A.; TORRES, R.R.; ALVES, L.M. 2017. Drought in northeast Brazil-past, present, and future. *Theoretical and Applied Climatology*, 129(3-4): 1189-1200. <https://doi.org/10.1007/s00704-016-1840-8>
- MARENGO, J.A.; ALVES, L.M.; ALVALA, R.C.S.; CUNHA, A.P.; BRITO, S.; MORAES, O.L.L. 2018a. Climatic characteristics of the 2010-2016 drought in the semiarid northeast Brazil region. *Anais Da Academia Brasileira de Ciencias*, 90(2 Suppl 1): 1973-1985. <https://doi.org/10.1590/0001-3765201720170206>
- MARENGO, J.A.; SOUZA, C.M.; THONICKE, K.; BURTON, C.; HALLADAY, K.; BETTS, R.A.; ALVES, L.M.; SOARES, W.R. 2018b. Changes in Climate and Land Use Over the Amazon Region: Current and Future Variability and Trends. *Frontiers in Earth Science*, 6: 228. <https://doi.org/10.3389/feart.2018.00228>
- 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. 2020a. Assessing drought in the drylands of northeast Brazil under regional warming exceeding 4 °C. *Natural Hazards*, 103(2): 2589-2611. <https://doi.org/10.1007/s11069-020-04097-3>
- MARENGO, J.A.; AMBRIZZI, T.; ALVES, L.M.; BARRETO, N.J.C.; SIMÕES REBOITA, M.; RAMOS, A.M. 2020b. Changing Trends in rainfall extremes in the Metropolitan Area of São Paulo: causes and impacts. *Frontiers*

- in *Climate*, 2:1-13. <https://doi.org/10.3389/fclim.2020.00003>
- MARENGO, J.A.; CUNHA, A.P.; CUARTAS, L.A.; LEAL, K.R.D.; BROEDEL, E.; SELUCHI, M.E.; MICHELIN, C.M.; PRAGA BAIÃO, C.F.P.; ÂNGULO, E.C.; ALMEIDA, E.K.; KAZMIERCZAK, M.L.; MATEUS, N.P.A.; SILVA, R.C.; BENDER, F. 2021. Extreme drought in the Brazilian Pantanal in 2019-2020: characterization, causes, and impacts. *Frontiers in Water*, 3: 639204. <https://doi.org/10.3389/frwa.2021.639204>
- MARENGO, J.A.; JIMENEZ, J.C.; ESPINOZA, J.C.; CUNHA, A.P.; ARAGÃO, L.E.O. 2022. Increased climate pressure on the agricultural frontier in the eastern Amazonia – Cerrado transition zone. *Scientific Reports*, 12: 457. <https://doi.org/10.1038/s41598-021-04241-4>
- 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.; WILTSHIRE, A. 2011. The HadGEM2 family of Met Office Unified Model climate configurations. *Geoscientific Model Development*, 4: 723-757. <https://doi.org/10.5194/gmd-4-723-2011>
- MILLER, R.L.; SCHMIDT, G.A.; NAZARENKO, L.S.; BAUER, S.E.; KELLEY, M.; RETO, R.; RUSSELL, G.L.; ACKERMAN, A.S.; ALEINOV, I.; BAUER, M.; BLECK, R.; CANUTO, V.; CESANA, G.; CHENG, Y.; CLUNE, T.L.; COOK, B.I.; CRUZ, C.A.; DEL GENIO, A.D.; ELSAESSER, G.S.; FALUVEGI, G.; KIANG, N.Y.; KIM, D.; LACIS, A.A.; LEBOISSETIER, A.; LEGRANDE, A.N.; LO, K.K.; MARSHALL, J.; MATTHEWS, E.E.; MCDERMID, S.; MEZUMAN, K.; MURRAY, L.T.; OINAS, V.; ORBE, C.; GARCÍA-PANDO, C.P.; PERLWITZ, J.P.; PUMA, M.J.; RIND, D.; ROMANOU, A.; SHINDELL, D.T.; SUN, S.; TAUSNEV, N.; TSIGARIDIS, K.; TSELIODIS, G.; WENG, E.; WU, J.; YAO, M. 2021. CMIP6 historical simulations (1850–2014) with GISS-E2.1. *Journal of Advances in Modeling Earth Systems*, 13: e2019MS002034. <https://doi.org/10.1029/2019MS002034>
- MÜLLER, G.V.; REPINALDO, C.R.R.; ARANEO, D.C. 2018. Extreme cold events in South America analyzed from a GFDL model perspective: comparison between CMIP3 and CMIP5 climate scenarios. *Theoretical and Applied Climatology*, 134(1-2): 453-466. <https://doi.org/10.1007/s00704-017-2286-3>
- NOBRE, C.A.; OBREGÓN, G.O.; MARENGO, J.A.; FU, R.; POVEDA, G. 2009. Characteristics of Amazonian climate: main features. *Amazonia and Global Change*, 186: 149-162. <https://doi.org/10.1029/2009GM000903>
- NOBRE, C.A.; SAMPAIO, G.; BORMA, L.S.; CASTILLA-RUBIO, J.C.; SILVA, J.S.; CARDOSO, M. 2016. Land-use and climate change risks in the Amazon and the need of a novel sustainable development paradigm. *Proceedings of the National Academy of Sciences of the United States of America*, 113(39): 10759-10768. <https://doi.org/10.1073/pnas.1605516113>
- OBREGÓN, G.O.; MARENGO, J.A.; NOBRE, C.A. 2014. Rainfall and climate variability: Long-term trends in the Metropolitan Area of São Paulo in the 20th century. *Climate Research*, 61: 93-107. <https://doi.org/10.3354/cr01241>
- ORTEGA, G.; ARIAS, P.A.; VILLEGAS, J.C.; MARQUET, P.A.; NOBRE, P. 2021. Present-day and future climate over central and South America according to CMIP5/CMIP6 models. *International Journal of Climatology*, 41(15): 6713-6735. <https://doi.org/10.1002/joc.7221>
- PARADES-TREJO, F.J.; BARBOSA, H.A.; LAKSHMI KUMAR, T.V. 2017. Validating CHIRPS-based satellite precipitation estimates in northeast Brazil. *Journal of Arid Environments*, 139: 26-40. <https://doi.org/https://doi.org/10.1016/j.jaridenv.2016.12.009>
- PBMC–PAINEL BRASILEIRO DE MUDANÇAS CLIMÁTICAS. 2014. Contribuição do Grupo de Trabalho I 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, 464p. http://www.pbmc.coppe.ufrj.br/documentos/RAN1_completo_voll.pdf
- PEREIRA, M.F.R.; CHAFFE, P.L.B.; AMORIM, P.B.; RODRIGUES, R.R. 2022. A systematic analysis of climate model precipitation in southern Brazil. *International Journal of Climatology*, 42(8): 4240-4257. <https://doi.org/https://doi.org/10.1002/joc.7460>
- PIELKE, R.A.S. 2013. *Mesoscale Meteorological Modeling*. Elsevier, Amsterdam, 3rd, 570 p,
- QUADRO, M.F.L.; PEZZI, L.P.; ROSA, E.B. 2013. *O climanálise e o monitoramento da ZCAS nos últimos 30 anos*. p. 19-25. <http://climanalise.cptec.inpe.br/~reclimanl/revista/pdf/30anos/quadroetal.pdf>
- REBOITA, M.S.; GAN, M.A.; ROCHA, R.P.; AMBRIZZI, T. 2010. Regimes de precipitação na América do Sul: uma revisão bibliográfica. *Revista Brasileira de Meteorologia*, 25(2): 185-204. <https://doi.org/10.1590/S0102-77862010000200004>
- REBOITA, M.S.; KRUSCHE, N.; AMBRIZZI, T.; ROCHA, R.P. 2015. Entendendo o tempo e o clima na América do Sul. *Terrae Didactica*, 8(1): 34-50. <https://doi.org/10.20396/td.v8i1.8637425>
- REBOITA, M.S.; AMBRIZZI, T.; SILVA, B.A.; PINHEIRO, R.F.; ROCHA, R.P. 2019. The south atlantic subtropical anticyclone: Present and future climate. *Frontiers in Earth Science*, 7:8. <https://doi.org/10.3389/feart.2019.00008>
- REGOTO, P.; DEREZYNSKI, C.; CHOU, S.C.; BAZZANELA, A.C. 2021. Observed changes in air temperature and precipitation extremes over Brazil. *International Journal of Climatology*, 41(11): 5125-5142. <https://doi.org/10.1002/joc.7119>
- RIAH, K.; VAN VUUREN, D.P.; KRIEGLER, E.; EDMONDS, J.; O'NEILL, B.C.; FUJIMORI, S.; BAUER, N.; CALVIN, K.; DELLINK, R.; FRICKO, O.; LUTZ, W.; POPP, A.; CUARESMA, J.C.; KC, S.; LEIMBACH, M.; JIANG, L.; KRAM, T.; RAO, S.; EMMERLING, J.; EBI, K.; HASEGAWA, T.; HAVLIK, P.; HUMPENÖDER, F.; SILVA, L.A.; SMITH, S.; STEHFEST, E.; BOSETTI, V.; EOM, J.; GERNAAT, D.; MASUI, T.; ROGELJ, J.; STREFLER, J.; DROUET, L.; KREY, V.; LUDERER, G.; HARMSSEN, M.; BAUMSTARK, L.; DOELMAN, J.C.; KAINUMA, M.; KLIMONT, Z.; MARANGONI, G.; LOTZE-CAMPEN, H.; OBERSTEINER, M.; TABEAU, A.; TAVONI, M. 2017. The shared socioeconomic pathways and their energy, land use, and greenhouse gas emissions implications: an overview. *Global Environmental Change*, 42: 153-168. <https://doi.org/10.1016/j.gloenvcha.2016.05.009>
- ROBERTS, M. 2017a. *MOHC HadGEM3-GC31-LL model output prepared for CMIP6 HighResMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.1901>
- ROBERTS, M. 2017b. *MOHC HadGEM3-GC31-MM model output prepared for CMIP6 HighResMIP highresSST-present*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.6029>
- ROESCH, L.F.W.; VIEIRA, F.C.B.; PEREIRA, V.A.; SCHÜNEMANN, A.L.; TEIXEIRA, I.F.; SENNA, A.J.T.; STEFENON, V.M. 2009. The brazilian Pampa: A fragile biome. *Diversity*, 1(2): 182-198. <https://doi.org/10.3390/d1020182>
- RONG, X. 2019. *CAMS CAMS-CSM1.0 model output prepared for CMIP6 ScenarioMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.11004>
- SEFERIAN, R. 2018. *CNRM-CERFACS CNRM-ESM2-1 model output prepared for CMIP6 CMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.1391>
- SELAND, Ø.; BENTSEN, M.; OLIVIE, D.J.L.; TONIAZZO, T.; GJERMUNDSEN, A.; GRAFF, L.S.; DEBERNARD, J.B.; GUPTA, A.K.; HE, Y.; KIRKEVARAG, A.; SCHWINGER, J.; TJIPUTRA, J.; AAS, K.S.; BETHKE, I.; FAN, Y.; GRIESFELLER, J.; GRINI, A.; GUO, C.; ILICAK, M.; KARSET, I.H.H.; LANDGREN, O.A.; JOHAN, L.; MOISED, K.O.; NUMMELIN, A.; SPENSBERGER, C.; TANG, H.;

- ZHANG, Z.; HEINZE, C.; IVERSEN, T.; SCHULZ, M. 2019. *NCC NorESM2-LM model output prepared for CMIP6 CMIP historical*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.8036>
- SEMMLER, T.; DANILOV, S.; RACKOW, T.; SIDORENKO, D.; BARBI, D.; HEGEWALD, J.; SEIN, D.; WANG, Q.; JUNG, T. 2022. *IPCC DDC: AWI AWI-CM1.1MR model output prepared for CMIP6 CMIP historical*. World Data Center for Climate (WDCC) at DKRZ. <http://cera-www.dkrz.de/WDCC/ui/Compact.jsp?acronym=C6CMAWAWMhi>
- SHIOGAMA, H.; ABE, M.; TATEBE, H. 2019. *MIROC MIROC6 model output prepared for CMIP6 ScenarioMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.898>
- SILVA, C.B.; SILVA, M.E.S.; AMBRIZZI, T.; TOMMASELLI, J.T.G.; PATUCCI, N.N.; MATAVELI, G.A.V.; LIMA, B.S.; CORREA, W.S. C. 2019. Precipitação na América do Sul – dados obtidos por estações meteorológicas automáticas e por sistemas orbitais. *Revista Brasileira de Climatologia*, 15(25): 54-79. <https://doi.org/10.5380/abclima.v25i0.58813>
- SILVA, C.B.; SILVA, M.E.S.; AMBRIZZI, T.; PATUCCI, N.N.; LIMA, B.S.; CORREA, W.S.C. 2021. Spatial distribution of spectral SST oscillations over the equatorial pacific in the period 1888-2014. *International Journal of Climatology*, 41(7): 3841-3864. <https://doi.org/10.1002/joc.6774>
- SILVEIRA, C.S.; FILHO, F.A.S.; COSTA, A.A.; CABRAL, S.L. 2013. Performance assessment of CMIP5 models concerning the representation of precipitation variation patterns in the twentieth century on the northeast of Brazil, Amazon and Prata Basin and analysis of projections for the scenery RCP8.5. *Revista Brasileira de Meteorologia*, 28(3): 317-330. <https://doi.org/10.1590/S0102-77862013000300008>
- SIQUEIRA, M.F.; PETERSON, A.T. 2003. Consequences of global climate change for geographic distributions of cerrado tree species. *Biota Neotropica*, 3(2): 1-14. <https://doi.org/10.1590/s1676-06032003000200005>
- SKANSI, M. M.; BRUNET, M.; SIGRÓ, J.; AGUILAR, E.; GROENING, J.A.A.; BENTANCUR, O.J.; GEIER, Y.R.C.; AMAYA, R.L.C.; JÁCOME, H.; RAMOS, A.M.; ROJAS, C.O.; PASTEN, A.M.; MITRO, S.S.; JIMÉNEZ, C.V.; MARTÍNEZ, R.; ALEXANDER, L.V.; JONES, P.D. 2013. Warming and wetting signals emerging from analysis of changes in climate extreme indices over South America. *Global and Planetary Change*, 100: 295-307. <https://doi.org/10.1016/j.gloplacha.2012.11.004>
- SOARES, W.R., MARENGO, J.A. 2009. Assessments of moisture fluxes east of the Andes in South America in a global warming scenario. *International Journal of Climatology*, 29(10): 1395-1414. <https://doi.org/10.1002/joc.1800>
- SOLMAN, S.A.; SANCHEZ, E.; SAMUELSSON, P.; ROCHA, R.P.; LI, L.; MARENGO, J.; PESSACG, N.L.; REMEDIO, A.R.C.; CHOU, S.C.; BERBERY, H.; LE TREUT, H.; CASTRO, M.; JACOB, D. 2013. Evaluation of an ensemble of regional climate model simulations over South America driven by the ERA-Interim reanalysis: Model performance and uncertainties. *Climate Dynamics*, 41(5-6), 1139-1157. <https://doi.org/10.1007/s00382-013-1667-2>
- SONG, Z.; QIAO, F.; BAO, Y.; SHU, Q.; SONG, Y.; YANG, X. 2019. *FIO-QLNM FIO-ESM2.0 model output prepared for CMIP6 CMIP historical*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.9199>
- STOUFFER, R. 2019. *U of Arizona MCM-UA-1-0 model output prepared for CMIP6 CMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.2421>
- SWART, N.C.; COLE, J.N.S.; KHARIN, V.V.; LAZARE, M.; SCINOCCA, J.F.; GILLET, N.P.; ANSTEY, J.; ARORA, V.; CHRISTIAN, J.R.; JIAO, Y.; LEE, W.G.; MAJAESS, F.; SAENKO, O.A.; SEILER, C.; SEINEN, C.; SHAO, A.; SOLHEIM, L.; SALZEN, K.; YANG, D.; SIGMOND, M. 2019a. *CCCma CanESM5-CanOE model output prepared for CMIP6 CMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.10205>

- SWART, N.C.; COLE, J.N.S.; KHARIN, V.V.; LAZARE, M.; SCINOCCA, J.F.; GILLET, N.P.; ANSTEY, J.; ARORA, V.; CHRISTIAN, J.R.; JIAO, Y.; LEE, W.G.; MAJAESS, F.; SAENKO, O.A.; SEILER, C.; SEINEN, C.; SHAO, A.; SOLHEIM, L.; SALZEN, K.; YANG, D.; SIGMOND, M. 2019b. *CCCma CanESM5 model output prepared for CMIP6 ScenarioMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.1317>
- SWART, N.C.; COLE, J.N.S.; KHARIN, V.V.; LAZARE, M.; SCINOCCA, J.F.; GILLET, N.P.; ANSTEY, J.; ARORA, V.; CHRISTIAN, J.R.; HANNA, S.; JIAO, Y.; LEE, W.G.; MAJAESS, F.; SAENKO, O.A.; SEILER, C.; SEINEN, C.; SHAO, A.; SIGMOND, M.; SOLHEIM, L.; SALZEN, K.; YANG, D.; WINTER, B. 2019c. The Canadian Earth System Model version 5 (CanESM5.0.3). *Geoscientific Model Development*, 12(11): 4823-4873. <https://doi.org/10.5194/gmd-12-4823-2019>
- TACHIIRI, K.; ABE, M.; HAJIMA, T.; ARAKAWA, O.; SUZUKI, T.; KOMURO, Y.; OGOCHI, K.; WATANABE, M.; YAMAMOTO, A.; TATEBE, H.; NOGUCHI, M.A.; OHGAI, R.; ITO, A.; YAMAZAKI, D.; ITO, A.; TAKATA, K.; WATANABE, S.; KAWAMIYA, M. 2019. *MIROC MIROC-ES2L model output prepared for CMIP6 ScenarioMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.936>
- TANG, Y.; RUMBOLD, S.; ELLIS, R.; KELLEY, D.; MULCAHY, J.; SELLAR, A.; WALTON, J.; JONES, C. 2019. *MOHC UKESM1.0-LL model output prepared for CMIP6 CMIP historical*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.6113>
- TIAN, B.; DONG, X. 2020. The Double-ITCZ Bias in CMIP3, CMIP5, and CMIP6 Models Based on Annual Mean Precipitation. *Geophysical Research Letters*, 47(8): e2020GL087232. <https://doi.org/10.1029/2020GL087232>
- TORRES, R.R. 2014. *Análise de incertezas em projeções de mudanças climáticas na América do Sul*. Instituto de Pesquisas Espaciais, São José dos Campos, Tese de Doutorado, 239p. <http://urlib.net/8JMKD3MGP7W/3FHR358>
- TORRES, R.R.; MARENGO, J.A. 2014. Climate change hotspots over South America: From CMIP3 to CMIP5 multi-model datasets. *Theoretical and Applied Climatology*, 117(3-4), 579-587. <https://doi.org/10.1007/s00704-013-1030-x>
- UNFCCC. 2021. COP 26 Glasgow Climate Pact Advance unedited version Decision. *Cop26*, 1-8. https://unfccc.int/sites/default/files/resource/cop26_auv_2f_cover_decision.pdf
- VASCONCELLOS, F.C.; CAVALCANTI, I.F.A. 2010. Extreme precipitation over Southeastern Brazil in the austral summer and relations with the Southern Hemisphere annular mode. *Atmospheric Science Letters*, 11(1): 21-26. <https://doi.org/10.1002/asl.247>
- VINCENT, L.A.; PETERSON, T.C.; BARROS, V.R.; MARINO, M.B.; RUSTICUCCI, M.; CARRASCO, G.; RAMIREZ, E.; ALVES, L.M.; AMBRIZZI, T.; BERLATO, M.A.; GRIMM, A.M.; MARENGO, J.A.; MOLION, L.; MONCUNILL, D.F.; REBELLO, E.; ANUNCIACÃO, Y.M.T.; QUINTANA, J.; SANTOS, J.L.; BAEZ, J.; KAROLY, D. 2005. Observed trends in indices of daily temperature extremes in South America 1960-2000. *Journal of Climate*, 18(23): 5011-5023. <https://doi.org/10.1175/JCLI3589.1>
- VOLDOIRE, A. 2018. *CNRM-CERFACS CNRM-CM6-1 model output prepared for CMIP6 CMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.1375>
- VOLDOIRE, A. 2019. *CNRM-CERFACS CNRM-CM6-1-HR model output prepared for CMIP6 HighResMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.1387>
- VOLODIN, E.; MORTIKOV, E.; GRITSUN, A.; LYKOSOV, V.; GALIN, V.; DIANSKY, N.; GUSEV, A.; KOSTRYKIN, S.; IAKOVLEV, N.; SHESTAKOVA, A.; EMELINA, S. 2019a. *INM INM-CM4-8 model output prepared for CMIP6 CMIP piControl*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.5080>
- VOLODIN, E.; MORTIKOV, E.; GRITSUN, A.; LYKOSOV, V.; GALIN, V.; DIANSKY, N.;

- GUSEV, A.; KOSTRYKIN, S.; IAKOVLEV, N.; SHESTAKOVA, A.; EMELINA, S. 2019b. *NM INM-CM5-0 model output prepared for CMIP6 CMIP piControl*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.5081>
- 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.; ROECKNER, E. 2017. *MPI-M MPIESM1.2-HR model output prepared for CMIP6 HighResMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.762>
- WIENERS, K.H.; GIORGETTA, M.; JUNGCLAUS, J.; REICK, C.; ESCH, M.; BITTNER, M.; GAYLER, V.; HAAK, H.; DE VRESE, P.; RADDATZ, T.; MAURITSEN, T.; VON STORCH, J.S.; 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.; SIX, K.; STEVENS, B.; VOIGT, A.; ROECKNER, E. 2019. *MPI-M MPI-ESM1.2-LR model output prepared for CMIP6 ScenarioMIP ssp245*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.6693>
- WILLMOTT, C.J.; MATSUURA, K. 1995. Smart interpolation of annually averaged air temperature in the United States. *Journal of Applied Meteorology*, 34(12): 2577-2586. [https://doi.org/10.1175/1520-0450\(1995\)034<2577:SIOAAA>2.0.CO;2](https://doi.org/10.1175/1520-0450(1995)034<2577:SIOAAA>2.0.CO;2)
- WU, H.; ZOU, Y.; ALVES, L.M.; MACAU, E.E.N.; SAMPAIO, G.; MARENGO, J.A. 2020. Uncovering episodic influence of oceans on extreme drought events in Northeast Brazil by ordinal partition network approaches. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 30(5): 053104-1. <https://doi.org/10.1063/5.0004348>
- WU, T.; CHU, M.; DONG, M.; FANG, Y.; JIE, W.; LI, J.; LI, W.; LIU, Q.; SHI, X.; XIN, X.; YAN, J.; ZHANG, F.; ZHANG, J.; ZHANG, L.; ZHANG, Y. 2018. *BCC BCC-CSM2MR model output prepared for CMIP6 CMIP piControl*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.3016>
- XAVIER, A.C.; KING, C.W.; SCANLON, B.R. 2016. Daily gridded meteorological variables in Brazil (1980–2013). *International Journal of Climatology*, 36(6): 2644-2659. <https://doi.org/10.1002/joc.4518>
- XAVIER, A.C.; SCANLON, B.R.; KING, C.W.; ALVES, A.I. 2022. New improved Brazilian daily weather gridded data (1961–2020). *International Journal of Climatology*. <https://doi.org/https://doi.org/10.1002/joc.7731>
- YIN, L.; FU, R.; SHEVLIAKOVA, E.; DICKINSON, R.E. 2013. How well can CMIP5 simulate precipitation and its controlling processes over tropical South America? *Climate Dynamics*, 41(11-12): 3127-3143. <https://doi.org/10.1007/s00382-012-1582-y>
- YU, Y. 2019. *CAS FGOALS-f3-L model output prepared for CMIP6 CMIP 1pctCO2*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.3054>
- YUKIMOTO, S.; KOSHIRO, T.; KAWAI, H.; OSHIMA, N.; YOSHIDA, K.; URAKAWA, S.; TSUJINO, H.; DEUSHI, M.; TANAKA, T.; HOSAKA, M.; YOSHIMURA, H.; SHINDO, E.; MIZUTA, R.; ISHII, M.; OBATA, A.; ADACHI, Y. 2019. *MRI MRI-ESM2.0 model output prepared for CMIP6 CMIP*. Earth System Grid

- Federation. <https://doi.org/10.22033/ESGF/CMIP6.621>
- ZHANG, C. 2005. MADDEN-JULIAN OSCILLATION. *Reviews of Geophysics*, 43(2): 1-36. <https://doi.org/10.1029/2004RG000158.1>.INTRODUCTION
- ZIEHN, T.; CHAMBERLAIN, M.; LENTON, A.; LAW, R.; BODMAN, R.; DIX, M.; WANG, Y.; DOBROHOTOFF, P.; SRBINOVSKY, J.; STEVENS, L.; VOHRALIK, P.; MACKALLAH, C.; SULLIVAN, A.; O'FARRELL, S.; DRUKEN, K. 2019. *CSIRO ACCESS-ESM1.5 model output prepared for CMIP6 CMIP*. Earth System Grid Federation. <https://doi.org/10.22033/ESGF/CMIP6.2288>
- ZILLI, M.T.; CARVALHO, L.M.V. 2021. Detection and attribution of precipitation trends associated with the poleward shift of the South Atlantic Convergence Zone using CMIP5 simulations. *International Journal of Climatology*, 41(5): 3085-3106. <https://doi.org/10.1002/joc.7007>

Endereço dos autores:

Wesley de Souza Campos Correa*, Wagner Rodrigues Soares e Neyval Costa Reis Junior – Instituto de Estudos Climáticos – IEC-ES, Universidade Federal do Espírito Santo – UFES, Av. Fernando Ferrari, 514, Goiabeiras, CEP 29075-910, Vitória, ES, Brasil. *E-mails:* wesley.campos.correa@gmail.com, admcirrus@gmail.com, neyval@gmail.com

Georgynio Y. Rosales Aylas – Universidade Federal do Espírito Santo – UFES, Av. Fernando Ferrari, 514, Goiabeiras, CEP 29075-910, Vitória, ES, Brasil. *E-mail:* ragy3008@gmail.com

José A. Marengo – Centro Nacional de Monitoramento e Alertas de Desastres Naturais, Estrada Doutor Altino Bondensan, 500, Distrito de Eugênio de Melo, CEP 12630-000, São José dos Campos, SP, Brasil / Rodovia Presidente Dutra, Km 40 (SP-RJ), Cachoeira Paulista, SP, Brasil. *E-mail:* jose.marengo@cemaden.gov.br

Sin Chan Chou – Instituto Nacional de Pesquisas Espaciais – INPE, Avenida dos Astronautas, 1.758, Jd. Granja, CEP 12227-010, São José dos Campos, SP, Brasil. *E-mail:* chou.chan@inpe.br

Carlos Nobre – Instituto de Estudos Avançados – IEA, Universidade de São Paulo – USP, R. do Anfiteatro, 513, Butantã, CEP 05508-060, São Paulo, SP, Brasil. *E-mail:* cnobre.res@gmail.com

*Autor correspondente

Artigo submetido em 4 de outubro de 2022, aceito em 2 de dezembro de 2022.

