



## **Avaliação da performance dos Modelos Climáticos Globais do projeto CMIP6 em simular variáveis climáticas na região do Sistema Cantareira**

**Lucas Rickli de Oliveira**

Aluno de mestrado, UTFPR, Brasil  
lucasrickli@alunos.utfpr.edu.br

**Cesar Augusto Medeiros Destro**

Professor Doutor, UTFPR, Brasil.  
cesardestro@utfpr.edu.br

**Murilo Cesar Lucas**

Professor Doutor, Unicamp, Brasil.  
mlucas@unicamp.br

**RESUMO**

O Sistema Cantareira é altamente suscetível aos efeitos da variabilidade e de mudanças climáticas. Eventos extremos de seca afetam os níveis dos reservatórios bem como o abastecimento de água de milhões de pessoas. Portanto, gestores de recursos hídricos necessitam de informações confiáveis sobre a ocorrência de tais eventos e, assim, entender a capacidade dos modelos climáticos globais em simular as variáveis climáticas é essencial para obter previsões de confiança. Neste contexto, este trabalho busca avaliar e ranquear a performance de 10 modelos do recente Coupled Model Intercomparison Project Phase 6 (CMIP6) em simular as principais variáveis climáticas para a área do Sistema Cantareira. Para isso, foram utilizadas várias métricas estatísticas ( $r$ , RMSE, Pbias e KGE) a fim de avaliar o desempenho de cada modelo em relação ao período observado (2000-2013) e combinar os resultados para ranquear as performances. Os resultados mostram que os modelos com a melhor performance foram o EC-EARTH3, INM-CM4\_8, INM-CM5, ACCESS-ESM1-5 e MRI-ESM2, dependendo da variável climática. No geral, o estudo evidencia a importância da avaliação individual dos modelos e sua seleção adequada para gerar informações confiáveis em estudos climáticos.

**PALAVRAS-CHAVE:** CMIP6. Modelos Climáticos Globais. Mudanças Climáticas.

**1 INTRODUÇÃO**

As mudanças climáticas exercem um impacto significativo no sistema hidrológico das bacias. Existem fortes evidências que confirmam o papel destas na modificação das variáveis climáticas, como precipitação e temperatura, e dos regimes hidrológicos observados em reservatórios do mundo todo nas últimas décadas (Gudmundsson *et al.*, 2021).

De acordo com os últimos relatórios do Intergovernmental Panel on Climate Changes (IPCC) (IPCC, 2022), o clima global esquentou durante as últimas décadas em todas as regiões do mundo: a temperatura média da superfície global no início do século XXI já era 1.09°C maior do que a temperatura média do início do século anterior, o XIX. Os aumentos registrados na concentração de gases de efeito estufa (GEE) desde 1750 são inequivocadamente causados por atividades humanas (Dong *et al.*, 2016; Dong; Sutton; Shaffrey, 2017; King *et al.*, 2016).

Nos últimos anos, as mudanças climáticas têm causado uma série de impactos ambientais que se apresentam em condições adversas do clima, como o aumento na frequência e na intensidade de eventos extremos climáticos – secas e precipitações intensas (Siebers; Paillex; Robinson, 2019; Gudmundsson *et al.*, 2021).

Como diz o nome, seca é um período de clima anormalmente seco, que persiste por tempo o suficiente para causar desequilíbrios hidrológicos (Cook; Mankin; Anchukaitis, 2018). A maioria das secas começa com um déficit persistente de precipitação (“seca meteorológica”), que, ao longo do tempo, torna-se déficit de vazão dos rios e umidade do solo, levando a uma redução na capacidade de abastecimento de água (“seca hidrológica”). No contexto das mudanças climáticas, além da falta de precipitação, um clima mais quente pode ocasionar mudanças na evapotranspiração, que são componentes críticos da seca (Mcdowell; Allen, 2016; IPCC, 2022).

Recentemente, o estado de São Paulo sofreu duas secas prolongadas e severas. A primeira, no início dos anos 2000, foi responsável por uma grande crise energética. Na segunda, em 2013, a seca afetou gravemente o abastecimento de água de aproximadamente 9 milhões de pessoas na região metropolitana de São Paulo (RMSP) (Marengo *et al.*, 2010). Nesta época, o Sistema Cantareira teve uma queda em sua contribuição para o abastecimento na produção

de água em 56%, de 33 m<sup>3</sup>/s no início da crise para 14 m<sup>3</sup>/s, em março de 2015 (Custódio, 2015).

Os impactos hidrológicos das mudanças climáticas tendem a agravar os riscos existentes e futuros associados à gestão de recursos hídricos (Tiwari; Mishra, 2022). Neste contexto, para que os governantes possam planejar políticas públicas integradas à adaptação ante a estes impactos, é importante que existam projeções climáticas futuras confiáveis, a fim de que se elaborem estratégias eficientes e que se evitem mais retrocessos no aspecto das mudanças climáticas (Berhanu *et al.*, 2023a).

Os Modelos Climáticos Globais (MCGs) e Regionais (RCMs) são ferramentas essenciais para investigar os impactos das mudanças climáticas no regime hídrico de bacias, assim como a ocorrência futuras de eventos extremos. Além das projeções, também são utilizados para estudar a climatologia histórica e atual (Agyekum *et al.*, 2023).

No entanto, para o uso de GCMs (ou RCMs) em estudos sobre uma região específica em um determinado período, a sua capacidade de simular as condições climáticas observadas deve ser verificada. Geralmente, as avaliações das performances dos modelos são feitas para diversas variáveis climáticas, comparando períodos históricos observados com os dos modelos. Logo, métricas que investigam os erros médios, o viés, a correlação entre os dados são exemplos de métodos estatísticos utilizados no processo de avaliação (Agyekum *et al.*, 2022; Akinsanola; Ongoma; Kooperman, 2021; Faye; Akinsanola, 2022). A avaliação pode ser feita para uma ou mais variáveis, em escala temporal ou espacial (ou ambas); isto reduzirá incertezas associadas aos modelos e erros nas análises, bem como fornecerá projeções confiáveis para o futuro, usando modelos apropriados escolhidos a partir da avaliação de performance (IPCC, 2014).

Vários grupos de pesquisadores por todo o mundo têm desenvolvido modelos climáticos. O Projeto de Intercomparação de Modelos Acoplados (*Coupled Model Intercomparison Project – CMIP*) objetiva produzir e analisar os modelos climáticos globais e a melhor compreender as mudanças climáticas passadas, presentes e futuras (Eyring *et al.*, 2016). Os modelos produzidos no último ciclo de estudos do IPCC, o CMIP6, apresentam melhorias na resolução espacial e na representação dos processos físicos em comparação aos modelos prévios do CMIP5 (Eyring *et al.*, 2016).

São relativamente poucos os estudos que avaliaram a performance dos modelos do CMIP5 no Brasil ou América do Sul (Almagro *et al.*, 2020; Falco *et al.*, 2019; Llopart; Reboita; Rocha, 2020; Solman; Blázquez, 2019); os resultados mostram bom desempenho de conjuntos multimodelos em simular as variáveis climáticas, enquanto análises individuais apresentaram mais vieses, reforçando a necessidade de avaliação individual dos modelos.

Com relação a avaliação dos modelos do projeto CMIP6, a literatura é ainda mais escassa (Correa *et al.*, 2022; Dias; Reboita, 2021). Apesar da comprovada importância de avaliar a performance dos diferentes modelos do CMIP6, não existem estudos em nível nacional que realizem tal avaliação de forma relevante para estudos de impacto ante as mudanças climáticas, quanto mais para uma área importante, em termos de abastecimento de água, como o Sistema Cantareira, ou mesmo o estado de São Paulo.

O presente trabalho, então, busca preencher a referida lacuna na literatura ao realizar uma avaliação da performance dos Modelos Climáticos Globais do CMIP6 em simular variáveis climáticas na região do Sistema Cantareira. Este estudo avalia a capacidade dos modelos do CMIP6 em representar a climatologia local antes de utilizá-los para a análise de projeções

climáticas futuras, a fim de servir de apoio para estratégias de adaptação e mitigação de impactos decorrentes das mudanças climáticas. Também busca selecionar os melhores modelos do CMIP6 a serem utilizados em previsões climáticas confiáveis para a região do Sistema Cantareira.

### **1.1 Objetivo Geral**

O objetivo geral deste trabalho é avaliar a performance dos Modelos Climáticos Globais do projeto CMIP6 em simular as médias mensais de precipitação, umidade relativa do ar, radiação solar, velocidade do vento e temperatura máxima e mínima para a área do Sistema Cantareira.

#### **1.1.1 Objetivos específicos**

Primeiro: obter dados climáticos observados e dados dos modelos climáticos do CMIP6 para o período histórico.

Segundo: avaliar a performance individual dos modelos do CMIP6 para cada variável, com uso de análise estatística.

Terceiro: realizar ranqueamento da performance dos modelos climáticos combinando todas as métricas utilizadas.

## **2 METODOLOGIA**

Avaliação da performance dos modelos foi feita para as seguintes variáveis: precipitação, umidade relativa do ar, radiação solar, velocidade do vento e temperatura.

A metodologia de avaliação segue três etapas: inicialmente, a obtenção de dados climáticos observados do período histórico de 2000-2013 e dados dos modelos climáticos do CMIP6 referente ao mesmo período. Na segunda etapa, a avaliação da performance individual dos modelos do CMIP6 para cada variável, com uso de análise estatística. Na terceira etapa, foi realizado o ranqueamento da performance dos modelos climáticos combinando todas as métricas utilizadas.

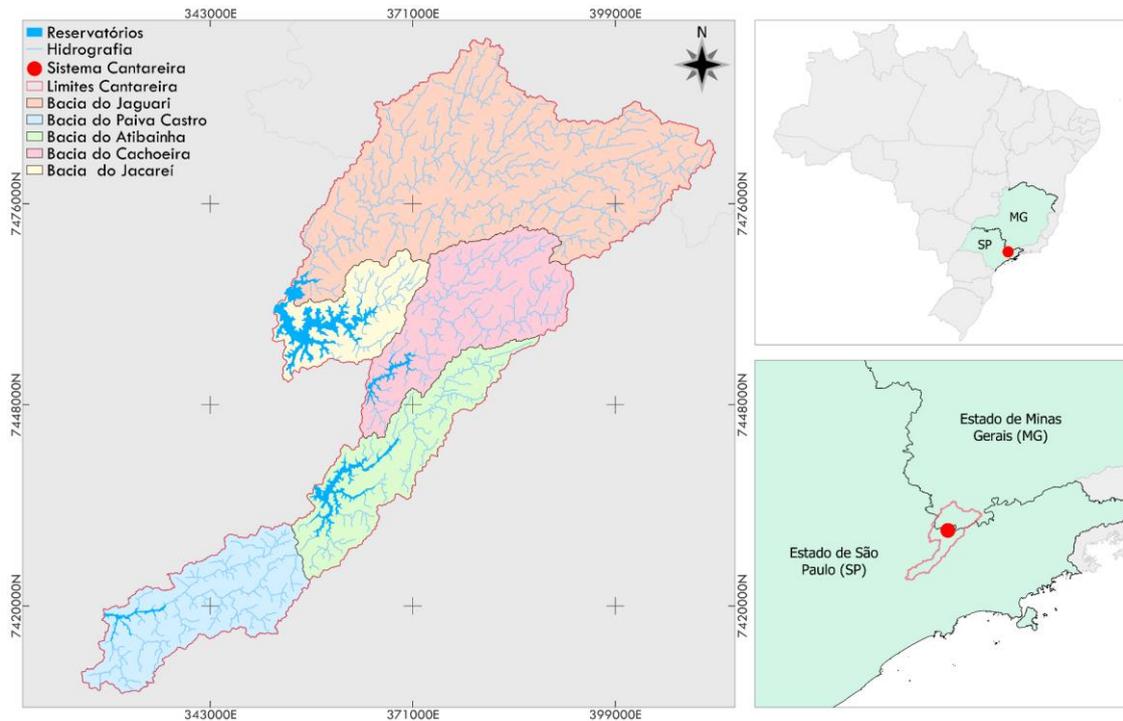
### **2.1 Área de estudo**

O Sistema Cantareira (Figura 1) localiza-se ao norte da Região Metropolitana de São Paulo e é um dos maiores sistemas de abastecimento público do mundo, com uma produção de água que chega a atingir 33mil litros por segundo, sendo responsável por abastecer cerca de 8,8 milhões de pessoas (46% da população da RMSP) (Whately; Cunha, 2006).

O Sistema Cantareira é composto por: cinco reservatórios (Jaguari, Jacareí, Cachoeira, Atibainha e Juquery); túneis e canais de interligação entre uma represa e outra à jusante; uma estação elevatória de água (Águas Claras); e uma estação de tratamento de água (ETA Guaraú). A água produzida no sistema é proveniente das cinco bacias citadas anteriormente, sendo que

a bacia do Jaguari-Jacaré (reservatórios interligados) é a maior delas (Gesualdo *et al.*, 2019; Whately; Cunha, 2006).

Figura 1 – Localização do Sistema Cantareira



Fonte: autoria própria.

## 2.2 Dados climáticos

### 2.2.1 Dados climáticos observados (período de 2000-2013)

Os dados climáticos observados de precipitação (*pr*), umidade relativa do ar (*hur*), radiação solar (*rss*), velocidade do vento (*sfcwind*) e temperatura (*tmax* e *tmin*) utilizados neste estudo foram obtidos de Xaxier *et al.* (2016), um dataset que contém dados diários abrangendo todo território brasileiro, em um grid com resolução espacial de 0.25° x 0.25° (latitude/longitude).

O dataset desenvolvido por Xavier, King e Scanlon (2016), devido ao controle de qualidade e à extensa rede de estações pluviométricas (3625) e climáticas (735) utilizadas em seu desenvolvimento, fornece informações confiáveis e já foi utilizado e validado em várias aplicações em território brasileiro (Dias; Martins; Martins, 2024; Silva *et al.*, 2023; Ferreira *et al.*, 2023; Marchezepe *et al.*, 2023).

### 2.2.2 Modelos do CMIP6

Para obtenção de dados diários dos modelos climáticos do projeto CMIP6, foi utilizado o dataset CLIMBra (Ballarin *et al.*, 2023), que fornece dados com correção de viés de 10 modelos do CMIP6 (Quadri 1), também em um grid de resolução espacial de 0.25° x 0.25° (latitude/longitude), não só para projeções futuras, mas também para períodos históricos, como é o presente caso.

O dataset desenvolvido por Ballarin *et al.* (2023) é recente, porém vem sendo utilizado e validado em estudos climáticos aplicados ao território brasileiro (Ballarin *et al.*, 2023a; Ferreira *et al.*, 2023; Monteiro; Cabral, 2023; Reboita *et al.*, 2023).

Quadro 1 – Lista dos MCGs utilizados no trabalho

Modelo	Instituição	País
ACCESS_ESM1	Australian Community Climate and Earth System Simulator Climate Model Version 1	Austrália
CMCC_ESM2	Centro Euro-Mediterraneo sui Cambiamenti Climatici	Itália
EC_EARTH3	EC Earth Consortium	Europa
INM_CM4_8	Institute of Numerical Mathematics of the Russian Academy of Sciences	Rússia
INM_CM5	Institute of Numerical Mathematics of the Russian Academy of Sciences	Rússia
IPSL_CM6A	Institut Pierre Simon Laplace (IPSL)	França
MIROC6	Atmosphere and Ocean Research Institute (The University of Tokyo), National Institute for Environmental Studies and Japan Agency for Marine-Earth Science and Technology (MIROC)	Japão
MPI_ESM1	Max Planck Institute for Meteorology (MPI-M)	Alemanha
MRI_ESM2	Meteorological Research Institute (MRI)	Japão
NorESM2	Norwegian Earth System Model	Noruega

Fonte: autoria própria.

## 2.3 Métodos de avaliação

### 2.3.1 Métricas estatísticas

Os modelos do CMIP6 foram avaliados por sua performance em simular a climatologia da área de estudo, comparando-os com os dados observados de precipitação (pr), umidade relativa do ar (hur), radiação solar (rss), velocidade do vento (sfcwind) e temperatura (tmax e tmin).

A performance individual dos modelos foi avaliada utilizando métodos estatísticos e a análise foi feita considerando médias mensais. As métricas estatísticas utilizadas neste trabalho incluem o coeficiente de correlação (r), o erro quadrático médio (RMSE), o percentual de viés (Pbias) e os coeficientes de eficiência de Kling-Gupta (KGE) – que são empregadas em estudos voltados à avaliação de modelos climáticos do CMIP6 em diversas regiões do planeta (Agyekum *et al.*, 2022; Akinsanola; Ongoma; Kooperman, 2021; Berhanu *et al.*, 2023b; Faye; Akinsanola, 2022; Ignacio-Reardon; Luo, 2023; Yazdandoost *et al.*, 2021).

Quadro 2 – Lista de métricas estatísticas utilizadas no trabalho

Métrica estatística	Equação	Amplitude	Melhor valor
Percentual de viés (Pbias)	$Pbias = \frac{\sum_{i=1}^n (Qobs - Qsim)^2}{\sum_{i=1}^n (Qobs)} \times 100$	$-\infty$ até $+\infty$	0
O Erro Quadrático Médio (RMSE)	$MSE = \sqrt{\frac{\sum_{i=1}^n (Qobs - Qsim)^2}{n}}$	0 até $\infty$	0
Coefficiente de correlação de Pearson (r)	$r = \frac{\sum_{i=1}^n (Qobs - Qmobs)^2 \times (Qsim - Qmsim)^2}{\sqrt{\sum_{i=1}^n (Qobs - Qmobs)^2 \times \sum_{i=1}^n (Qsim - Qmsim)^2}}$	-1 até 1	1
Coefficientes de eficiência de Kling-Kupta (KGE)	$KGE: 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2}$	$-\infty$ até 1	1

Fonte: autoria própria

### 2.3.2 Ranking dos MCGs

Para cada variável climática, os 10 modelos do CMIP6 foram ranqueados de acordo com sua performance referente às métricas estatísticas (r, RMSE, Pbias e KGE). O índice de classificação composto CRI (Composite Rating Index) foi utilizado para obter o ranking geral de performance dos modelos do CMIP6 na área de estudo. Um valor de CRI próximo a 1 indica um bom desempenho do modelo, enquanto valores próximos a 0 indicam mal desempenho. O ranking geral (CRI) dos Modelos Climáticos Globais foi calculado usando a seguinte equação:

$$CRI = 1 - \frac{1}{nm} \sum_{i=1}^n rank_i$$

Onde *n* e *m* representam o número de MCGs e de indicadores, respectivamente, e *i* representa o rank de desempenho do referido MCG para determinada variável e métrica. A abordagem de combinar e ranquear os modelos foi utilizada com sucesso em vários trabalhos (Berhanu *et al.*, 2023a; Iqbal *et al.*, 2021; Li *et al.*, 2022; Song *et al.*, 2023; Tong; Zheng; Fu, 2022).

## 3 RESULTADOS

### 3.1 Médias mensais de precipitação e temperatura

Ao analisar os dados de precipitação e temperatura máxima e mínima dos modelos climáticos do CMIP6 em comparação ao período histórico de 2000-2013 (Figuras 2-4), fica claro que, em geral, os modelos capturam as principais tendências sazonais. Percebe-se bem o contraste entre o período mais chuvoso (Figura 2) e quente (Figura 3 e 4), de outubro até abril,

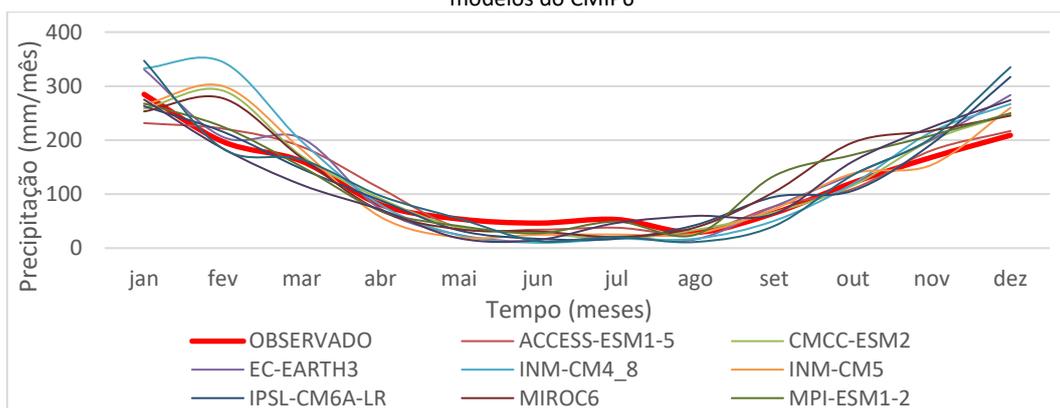
e o período mais seco e frio, entre os meses de maio e agosto, aproximadamente.

Para os padrões de precipitação, o INM-CM4\_8 foi o modelo que apresentou a maior discrepância, estimando os maiores valores de precipitação mensal, principalmente nos meses de dezembro (334,96mm) até fevereiro (344,56mm). No período compreendido entre os meses de abril até agosto (mais secos), a maioria dos modelos capturaram os valores observados com mais acurácia.

Para os dados de temperatura, tanto para valores máximos (Figura 3) quando para valores mínimos (Figura 4), os valores simulados pelos modelos apresentam pouca discrepância em comparação ao visto nos padrões de chuva. Para os dados de temperatura máxima ainda há certa variabilidade entre os valores simulados e observados, o NorESM2-MM, por exemplo, chegou a uma discrepância de +1,2°C em fevereiro e -1,0°C em relação às médias observadas.

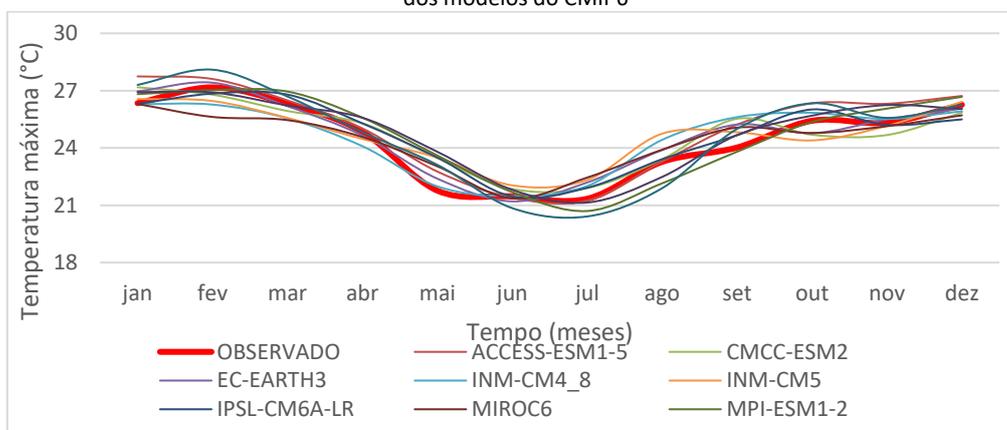
Para os valores de temperatura mínima, é possível constatar que os modelos foram mais consistentes em sua performance, não apresentando, a priori, grandes vieses e erros médios na maioria dos meses do ano.

Figura 2 – Comparação entre médias mensais de precipitação do período histórico observado e os dados dos modelos do CMIP6



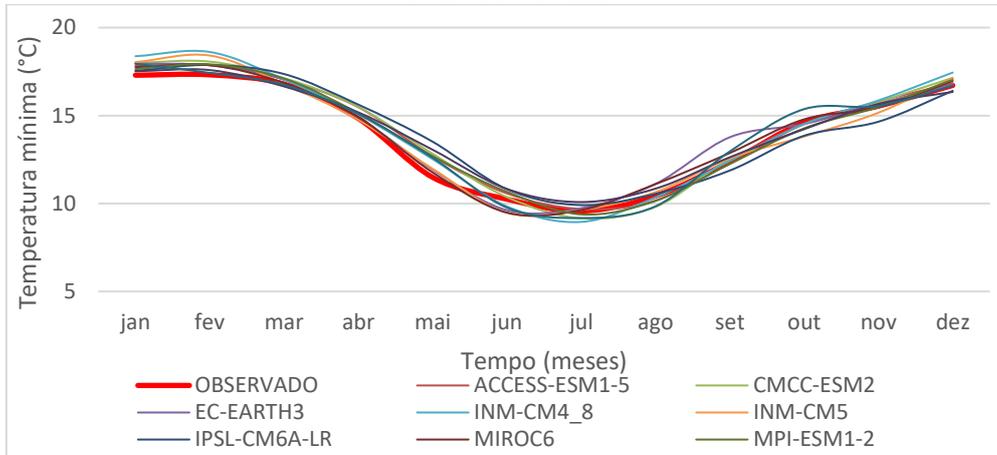
Fonte: autoria própria.

Figura 3 – Comparação entre médias mensais de temperatura máxima do período histórico observado e os dados dos modelos do CMIP6



Fonte: autoria própria.

Figura 4 – Comparação entre médias mensais de temperatura mínima do período histórico observado e os dados dos modelos do CMIP6



Fonte: autoria própria.

### 3.2 Análise estatística dos MCGs

Para a precipitação (pr), percebe-se boa correlação entre os padrões observados e simulados, com 9 dos modelos (90%) apresentando  $r$  acima de 0,65. Em contrapartida, alguns modelos apresentaram grandes vieses nos valores do Pbias, três (30%) dos modelos (INM-CM4\_8, MPI-ESM1-2 e MPI-ESM2) com valores de Pbias acima de 10%. O RMSE apontou magnitude considerável em relação aos valores médios dos dados observados; o maior valor de RMSE é de 3,19 para o modelo INM-CM4\_8, o que condiz com a visualização gráfica dos extremos de precipitação (Figura 2). O KGE apresentou valores inferiores em relação ao coeficiente de correlação: apenas dois (20%) modelos (MIROC6 e MPI-ESM1-2) apresentaram KGE acima de 0,60; isto deve-se ao fato de que o KGE não leva em consideração apenas correlação linear, que teve bons valores, mas também a variabilidade e viés dos dados, e foram constatadas grandes discrepâncias nestes dois quesitos anteriormente.

Os valores de umidade relativa do ar (hur) e velocidade do vento (sfcwind) foram aqueles que os modelos tiveram maior dificuldade em simular os padrões observados. Percebe-se tal situação, claramente, nas métricas de correlação e nos erros quadráticos médios. Nenhum modelo atingiu valores de  $r$  e KGE maior que 0,60 e em ambas as variáveis e todos os modelos tiveram erros médios da alta magnitude em relação as médias observadas.

Para os valores de radiação solar (rss), os modelos, em geral, desempenharam bem. Oito (80%) dos modelos apresentaram valores de  $r$  maiores que 0,65 e KGE maiores que 0,6. Vieses e erros quadráticos médios relativamente pequenos em comparação às médias observadas. Os únicos que obtiveram desempenho discrepante considerando a maioria das métricas foram MIROC6 e CMCC-ESM2.

Os valores de temperatura máxima tiveram desempenho razoável, porém consistentes, não havendo nenhum modelo discrepante em relação aos demais. A maioria dos modelos apresentou valores de  $r$  e KGE próximos a 0,6 e baixos valores de viés e erros médios. A temperatura mínima foi a variável a qual os modelos do CMIP6 tiveram a melhor performance, considerando todas as métricas e todas as variáveis. Todos os modelos (100%) apresentaram valores de  $r$  e KGE acima de 0,8; constatando, assim, alta correlação entre os dados,

considerando também a variabilidade, viés e magnitude dos erros. Destaque aos modelos CMCC-ESM2, INM-CM4\_8, INM-CM5 e NorESM2-NM: com altíssimos valores de correlação (0,88; 0,89; 0,89 e 0,87 respectivamente) e de KGE (0,86; 0,86; 0,88 e 0,86; respectivamente), o desempenho foi constatado graficamente (Figura 4) nas seções anteriores.

Quadro 3 – Análise estatística dos dados dos modelos do CMIP6

Variável	Métrica	ACCESS-ESM1-5	CMCC-ESM2	EC-EARTH3	INM-CM4_8	INM-CM5	IPSL-CM6A-LR	MIROC6	MPI-ESM1-2	MRI-ESM2	NorESM2-MM
pr	R	0,57	0,68	0,73	0,73	0,70	0,66	0,71	0,68	0,66	0,66
	Pbias	0,25	6,11	7,86	14,06	3,90	4,46	12,58	10,26	2,72	9,32
	KGE	0,55	0,56	0,53	0,40	0,56	0,56	0,61	0,61	0,59	0,40
	RMSE	2,99	2,91	2,82	3,19	2,83	2,91	2,67	2,74	2,82	3,37
hur	R	0,56	0,49	0,54	0,54	0,50	0,44	0,37	0,39	0,44	0,29
	Pbias	1,06	1,31	0,30	0,68	0,35	1,31	0,76	0,77	0,70	0,91
	KGE	0,38	0,28	0,25	0,30	0,20	0,15	0,19	0,31	0,27	0,21
	RMSE	4,84	5,40	5,34	5,15	5,65	6,01	5,83	5,22	5,42	5,69
rss	R	0,66	0,54	0,75	0,74	0,75	0,65	0,48	0,65	0,75	0,70
	Pbias	-0,82	-3,50	-2,30	-3,25	-1,97	-2,85	-3,82	-2,28	-2,50	-1,98
	KGE	0,63	0,50	0,74	0,73	0,74	0,65	0,38	0,64	0,73	0,69
	RMSE	2,30	2,33	1,92	1,98	1,88	2,16	2,38	2,12	1,80	2,08
sfcwind	R	0,57	0,42	0,31	-0,03	-0,07	0,41	0,55	0,37	0,55	0,44
	Pbias	-1,33	-2,36	-2,41	-4,49	-3,06	-0,96	-0,40	-0,25	-3,14	-2,56
	KGE	0,56	0,41	0,30	-0,06	-0,08	0,41	0,54	0,33	0,42	0,44
	RMSE	0,17	0,20	0,23	0,31	0,29	0,20	0,19	0,19	0,22	0,20
tasmax	R	0,64	0,66	0,55	0,55	0,61	0,59	0,57	0,64	0,69	0,75
	Pbias	2,24	1,03	0,99	0,49	0,99	1,14	-0,05	0,97	1,35	0,96
	KGE	0,61	0,64	0,55	0,54	0,58	0,58	0,53	0,63	0,69	0,71
	RMSE	2,25	1,89	2,32	2,16	1,99	2,11	2,03	2,12	1,86	1,84
tasmin	R	0,87	0,88	0,81	0,89	0,89	0,82	0,86	0,85	0,86	0,87
	Pbias	2,29	1,96	2,17	2,26	0,71	1,64	1,33	1,50	2,03	1,16
	KGE	0,87	0,86	0,81	0,86	0,88	0,81	0,86	0,84	0,84	0,86
	RMSE	1,59	1,59	1,92	1,56	1,49	1,82	1,63	1,72	1,58	1,61

Fonte: autoria própria.

### 3.3 Ranking dos MCGs

O ranking geral dos MCGs para cada variável foi calculado com base no índice de classificação composto CRI para ranquear a performance dos modelos. Para dados de precipitação (pr), o modelo melhor ranqueado foi o EC-EARTH3, seguido pelos modelos MIROC6 e INM-CM5. Os modelos INM-CM4\_8, ACCESS-ESM1-5 e EC-EARTH tiveram, nesta ordem, o melhor desempenho para os valores de umidade relativa do ar (hur). O modelo INM-CM5 foi o melhor ranqueado para os dados de radiação solar (rss), seguido pelos modelos EC-EARTH3 e MRI-ESM2.

Para a análise de temperatura máxima e mínima, o modelo com melhor performance foi o INM-CM5. O CMCC-ESM2 também teve ótimo desempenho para ambas as variáveis (rank 2 e 3, respectivamente).

Tabela 1 – Ranking dos modelos do CMIP6

Variável	Rank MCGs	r	Pbias	KGE	RMSE	Rank CRI
pr	EC-EARTH3	1	6	3	3	0,675
	MIROC6	2	9	1	1	0,675
	INM-CM5	4	2	4	4	0,650
	MPI-ESM1-2	5	8	2	2	0,575
	MRI-ESM2	8	1	5	5	0,525
	CMCC-ESM2	6	5	6	6	0,425
	IPSL-CM6A-LR	9	4	7	7	0,325
	ACCESS-ESM1-5	10	3	8	8	0,275
	INM-CM4_8	3	10	10	9	0,200
	NorESM2-MM	7	7	9	10	0,175
hur	INM-CM4_8	2	3	3	2	0,750
	ACCESS-ESM1-5	1	8	1	1	0,725
	EC-EARTH3	3	1	6	4	0,650
	MPI-ESM1-2	8	6	2	3	0,525
	INM-CM5	4	2	8	7	0,475
	MRI-ESM2	7	4	5	6	0,450
	CMCC-ESM2	5	10	4	5	0,400
	MIROC6	9	5	9	9	0,200
	NorESM2-MM	10	7	7	8	0,200
	IPSL-CM6A-LR	6	9	10	10	0,125
rss	INM-CM5	1	2	1	2	0,850
	EC-EARTH3	2	5	2	3	0,700
	MRI-ESM2	3	6	3	1	0,675
	NorESM2-MM	5	3	5	5	0,550
	INM-CM4_8	4	8	4	4	0,500
	ACCESS-ESM1-5	6	1	8	8	0,425
	MPI-ESM1-2	8	4	7	6	0,375
	IPSL-CM6A-LR	7	7	6	7	0,325
	CMCC-ESM2	9	9	9	9	0,100
	MIROC6	10	10	10	10	0,000
tasmax	ACCESS-ESM1-5	4	1	5	2	0,700
	MRI-ESM2	2	2	2	9	0,625
	CMCC-ESM2	3	4	3	8	0,550
	NorESM2-MM	1	8	1	10	0,500
	MPI-ESM1-2	5	7	4	4	0,500
	IPSL-CM6A-LR	7	3	6	5	0,475
	EC-EARTH3	10	5	8	1	0,400
	INM-CM5	6	6	7	7	0,350
	INM-CM4_8	9	9	9	3	0,250
	MIROC6	8	10	10	6	0,150

tasmin	ACCESS-ESM1-5	4	1	2	7	0,650
	CMCC-ESM2	3	5	3	6	0,575
	INM-CM4_8	1	2	6	9	0,550
	NorESM2-MM	5	9	4	5	0,425
	INM-CM5	2	10	1	10	0,425
	EC-EARTH3	10	3	10	1	0,400
	MIROC6	7	8	5	4	0,400
	MPI-ESM1-2	8	7	7	3	0,375
	MRI-ESM2	6	4	8	8	0,350
	IPSL-CM6A-LR	9	6	9	2	0,350
sfcwind	MRI-ESM2	1	4	1	1	0,825
	ACCESS-ESM1-5	2	2	2	2	0,800
	IPSL-CM6A-LR	7	1	7	3	0,550
	INM-CM5	5	5	5	4	0,525
	MIROC6	4	7	3	5	0,525
	MPI-ESM1-2	6	3	6	6	0,475
	CMCC-ESM2	3	9	4	7	0,425
	EC-EARTH3	8	6	8	8	0,250
	NorESM2-MM	10	8	10	9	0,075
	INM-CM4_8	9	10	9	10	0,050

Fonte: autoria própria.

#### 4 CONCLUSÕES

O foco deste trabalho foi avaliar a performance dos modelos climáticos do CMIP6 em simular as médias mensais de precipitação, umidade relativa do ar, radiação solar, velocidade do vento e temperatura máxima e mínima para o período observado de 2000-2013 para a área do Sistema Cantareira, localizado no estado de São Paulo, Brasil. Em geral, os modelos capturaram as principais tendências sazonais de chuva e temperatura. Os resultados também demonstraram uma ampla variação da performance dos modelos em sua capacidade de simular diferentes variáveis climáticas ao serem avaliados por diferentes métricas estatísticas.

Para a precipitação, o melhor modelo foi o EC-EARTH e, o pior, o NorESM2-MM. Para umidade relativa do ar, o melhor modelo foi o INM-CM4\_8; já o pior foi IPSL-CM6A-LR. O INM-CM5 apresentou melhor performance para simulação de dados de radiação solar e ACCESS-ESM1-5 a melhor para temperatura máxima; o MIROC6 teve o pior desempenho para ambas. ACCESS-ESM1-5 também foi o melhor avaliado para temperatura mínima, enquanto IPSL-CM6A-LR foi o pior. Os modelos MRI-ESM2 e INM-CM4\_8 tiveram o melhor e o pior desempenho para simulação de velocidade do vento, respectivamente.

Os modelos, em sua maioria, tiveram dificuldades em simular os valores de umidade relativa do ar e velocidade do vento, com mal desempenho em ambas as variáveis e em todas as métricas estatísticas. Para os dados de temperatura mínima, em contrapartida, todos os modelos apresentaram ótima performance, simulando com acurácia os valores observados, com boa correlação, pouco viés e baixa magnitude dos erros.

As variáveis de precipitação e temperatura podem ser consideradas as mais importantes, e são objeto de estudo de boa parte dos trabalhos que utilizam modelos climáticos

do CMIP6. Neste trabalho, os modelos climáticos mais bem ranqueados apresentaram boa performance na simulação destas variáveis, principalmente as temperaturas mínimas.

Nota-se que na maioria dos casos, os modelos piores ranqueados tiveram péssimo desempenho ante as métricas estatísticas, com pouca correlação com os dados observados e alta magnitude de erros e viés (principalmente em valores extremos). O uso de qualquer destes modelos poderá trazer um acúmulo desnecessário de incertezas ao trabalho.

Por mais que o uso de conjunto multimodelos ou *ensembles* seja uma prática comum na literatura, visto que o uso de mais modelos tende a reduzir e compensar as incertezas individuais. Percebe-se a importância da seleção adequada dos modelos a serem utilizados, em acordo com as particularidades do trabalho. O uso em conjunto de modelos, que passaram por prévia avaliação de performance, tende a tornar as estimativas mais precisas e confiáveis.

Os resultados deste trabalho fornecem importantes informações aos usuários e desenvolvedores de dados climáticos e *datasets* (como é o caso do CLIMBra e Xavier). Para os desenvolvedores, é evidente que ainda são necessários amplos estudos e pesquisas para melhoria nas performances dos modelos climáticos em diversas situações. Para os usuários finais, é essencial a prévia avaliação e seleção adequada dos modelos climáticos para estudos com projeções climáticas futuras.

## 5 REFERENCIAL TEÓRICO

AGYEKUM, Jacob; ANNOR, Thompson; QUANSAH, Emmanuel; LAMPTEY, Benjamin; AMEKUDZI, Leonard Kofitse; NYARKO, Benjamin Kofi. Extreme temperature indices over the Volta Basin: CMIP6 model evaluation. **Climate Dynamics**, [S. l.], v. 61, n. 1–2, p. 203–228, 2023. DOI: 10.1007/s00382-022-06503-x.

AGYEKUM, Jacob; ANNOR, Thompson; QUANSAH, Emmanuel; LAMPTEY, Benjamin; OKAFOR, Gloria. Extreme precipitation indices over the Volta Basin: CMIP6 model evaluation. **Scientific African**, [S. l.], v. 16, 2022. DOI: 10.1016/j.sciaf.2022.e01181.

AKINSANOLA, Akintomide Afolayan; ONGOMA, Victor; KOOPERMAN, Gabriel J. Evaluation of CMIP6 models in simulating the statistics of extreme precipitation over Eastern Africa. **Atmospheric Research**, [S. l.], v. 254, 2021. DOI: 10.1016/j.atmosres.2021.105509.

ALMAGRO, A.; OLIVEIRA, P. T. S.; ROSOLEM, R.; HAGEMANN, S.; NOBRE, C. A. Performance evaluation of Eta/HadGEM2-ES and Eta/MIROC5 precipitation simulations over Brazil. **Atmospheric Research**, [S. l.], v. 244, n. May, p. 105053, 2020. DOI: 10.1016/j.atmosres.2020.105053.

BALLARIN, André S. et al. Brazilian Water Security Threatened by Climate Change and Human Behavior. **Water Resources Research**, [S. l.], v. 59, n. 7, 2023. a. DOI: 10.1029/2023WR034914.

BALLARIN, André Simões; SONE, Jullian Souza; GESUALDO, Gabriela Chiquito; SCHWAMBACK, Dimaghi; REIS, Alan; ALMAGRO, André; WENDLAND, Edson Cezar. CLIMBra - Climate Change Dataset for Brazil. **Scientific Data**, [S. l.], v. 10, n. 1, 2023. b. DOI: 10.1038/s41597-023-01956-z.

BERHANU, D.; ALAMIREW, T.; TAYE, M. T.; TIBEBE, D.; GEBREHIWOT, S.; ZELEKE, G. Evaluation of CMIP6 models in reproducing observed rainfall over Ethiopia. **Journal of Water and Climate Change**, [S. l.], v. 14, n. 8, p. 2583-2605, 2023a. DOI: 10.2166/wcc.2023.502.

BERHANU, Daniel et al. Evaluation of CMIP6 models in reproducing observed rainfall over Ethiopia. **Journal of Water and Climate Change**, v. 14, n. 8, p. 2583-2605, 2023.

COOK, B. I.; MANKIN, J. S.; ANCHUKAITIS, K. J. Climate change and drought: from past to future. **Current Climate Change Reports**, v. 4, p. 164-179, 2018.

- CORREA, W. S. C.; SOARES, W. R.; AYLAS, G. Y. R.; REIS JUNIOR, N. C.; MARENGO, J. A.; CHOU, S. C.; NOBRE, C. Avaliação das simulações de temperatura e precipitação de um subconjunto de modelos do CMIP6 para o Brasil. **Derbyana**, [S. l.], v. 43, p. e774, 2022. DOI: 10.14295/derb.v43.774.
- CUSTÓDIO, Vanderli. A crise hídrica na região metropolitana de São Paulo (2014-2015). **GEOUSP Espaço e Tempo (Online)**, v. 19, n. 3, p. 445-463, 2015.
- DIAS, Cássia Gabriele; MARTINS, Fabrina Bolzan; MARTINS, Minella Alves. Climate risks and vulnerabilities of the Arabica coffee in Brazil under current and future climates considering new CMIP6 models. **Science of the Total Environment**, [S. l.], v. 907, 2024. DOI: 10.1016/j.scitotenv.2023.167753.
- DIAS, C. G.; REBOITA, M. S. Assessment of cmip6 simulations over tropical south america. **Revista Brasileira de Geografia Física**, [S. l.], v. 14, n. 3, p. 1282-1295, 2021. DOI: 10.26848/rbgf.v14.3.p1282-1295.
- DONG, Buwen et al. Abrupt summer warming and changes in temperature extremes over Northeast Asia since the mid-1990s: Drivers and physical processes. **Advances in Atmospheric Sciences**, v. 33, p. 1005-1023, 2016.
- DONG, B.; SUTTON, R. T.; SHAFFREY, L. Understanding the rapid summer warming and changes in temperature extremes since the mid-1990s over Western Europe. **Climate Dynamics**, v. 48, p. 1537-1554, 2017.
- DOS SANTOS SILVA, Fabrício Daniel et al. Intercomparison of Different Sources of Precipitation Data in the Brazilian Legal Amazon. **Climate**, [S. l.], v. 11, n. 12, 2023. DOI: 10.3390/cli1120241.
- EYRING, V.; BONY, S.; MEEHL, G. A.; SENIOR, C. A.; STEVENS, B.; STOUFFER, R. J.; TAYLOR, K. E. Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. **Geoscientific Model Development**, [S. l.], v. 9, n. 5, p. 1937-1958, 2016. DOI: 10.5194/gmd-9-1937-2016.
- FALCO, M.; CARRIL, A. F.; MENÉNDEZ, C. G.; ZANINELLI, P. G.; LI, L. Z. X. Assessment of CORDEX simulations over South America: added value on seasonal climatology and resolution considerations. **Climate Dynamics**, [S. l.], v. 52, n. 7/8, p. 4771-4786, 2019. DOI: 10.1007/s00382-018-4412-z.
- FAYE, A.; AKINSANOLA, A. A. Evaluation of extreme precipitation indices over West Africa in CMIP6 models. **Climate Dynamics**, [S. l.], v. 58, n. 3/4, p. 925-939, 2022. DOI: 10.1007/s00382-021-05942-2.
- FERREIRA, Glauber Willian de Souza; REBOITA, Michelle Simões; RIBEIRO, João Gabriel Martins; DE SOUZA, Christie André. Assessment of Precipitation and Hydrological Droughts in South America through Statistically Downscaled CMIP6 Projections. **Climate**, [S. l.], v. 11, n. 8, 2023. DOI: 10.3390/cli11080166.
- GESUALDO, G. C.; OLIVEIRA, P. T.; RODRIGUES, D. B. B.; GUPTA, H. V. Assessing water security in the São Paulo metropolitan region under projected climate change. **Hydrology and Earth System Sciences**, [S. l.], v. 23, n. 12, p. 4955-4968, 2019. DOI: 10.5194/hess-23-4955-2019.
- GUDMUNDSSON, Lukas et al. Globally observed trends in mean and extreme river flow attributed to climate change. **Science**, [S. l.], v. 371, n. 6534, p. 1159-1162, 2021. DOI: 10.1126/science.aba3996.
- IGNACIO-REARDON, Shelly Jo Igpuaara; LUO, Jing Jia. Evaluation of the Performance of CMIP6 Climate Models in Simulating Rainfall over the Philippines. **Atmosphere**, [S. l.], v. 14, n. 9, 2023. DOI: 10.3390/atmos14091459.
- IQBAL, Zafar; SHAHID, Shamsuddin; AHMED, Kamal; ISMAIL, Tarmizi; ZIARH, Ghaith Falah; CHUNG, Eun Sung; WANG, Xiaojun. Evaluation of CMIP6 GCM rainfall in mainland Southeast Asia. **Atmospheric Research**, [S. l.], v. 254, 2021. DOI: 10.1016/j.atmosres.2021.105525.
- IPCC. **Climate Change 2014**: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, R.K. Pachauri and L.A. Meyer (eds.)]. Geneva, Switzerland: IPCC, 2014.
- IPCC. Summary for policy makers. In: **Climate Change 2022**: Impacts, adaptation and vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge, United Kingdom and New York, NY, USA: IPCC, 2022.

LI, Ying; YAN, Denghua; PENG, Hui; XIAO, Shangbin. Evaluation of precipitation in CMIP6 over the Yangtze River Basin. **Atmospheric Research**, [S. l.], v. 253, 2021. DOI: 10.1016/j.atmosres.2020.105406.

LLOPART, M.; REBOITA, M. S.; ROCHA, R. P. Assessment of multi-model climate projections of water resources over South America CORDEX domain. **Climate Dynamics**, [S. l.], v. 54, n. 1/2, p. 99-116, 2020. DOI: 10.1007/s00382-019-04990-z.

KING, Andrew D. et al. Emergence of heat extremes attributable to anthropogenic influences. **Geophysical Research Letters**, v. 43, n. 7, p. 3438-3443, 2016.

MARCHEZEPE, B. K.; ALMAGRO, A.; BALLARIN, A. S.; OLIVEIRA, P. T. S. Streamflow prediction in ungauged catchments by using the Grunsky method. **International Soil and Water Conservation Research**, [S. l.], v. 11, n. 4, p. 700-712, 2023. DOI: 10.1016/j.iswcr.2023.06.004.

MARENGO, Jose A.; AMBRIZZI, Tercio; DA ROCHA, Rosmeri P.; ALVES, Lincoln M.; CUADRA, Santiago V.; VALVERDE, Maria C.; TORRES, Roger R.; SANTOS, Daniel C.; FERRAZ, Simone E. T. Future change of climate in South America in the late twenty-first century: Intercomparison of scenarios from three regional climate models. **Climate Dynamics**, [S. l.], v. 35, n. 6, p. 1089-1113, 2010. DOI: 10.1007/s00382-009-0721-6.

MCDOWELL, N. G.; ALLEN, C. D. Darcy's law predicts widespread forest mortality under climate warming. **Nature Climate Change**, v. 5, n. 7, p. 669-672, 2015.

MONTEIRO, P. B.; CABRAL, J. J. S. P. Groundwater management in the state of Piauí (Brazil) on the climate change context. **Revista Brasileira de Ciências Ambientais**, [S. l.], v. 58, n. 1, p. 45-58, 2023. DOI: 10.5327/z2176-94781485.

REBOITA, Michelle Simões; FERREIRA, Glauber Willian de Souza; RIBEIRO, João Gabriel Martins; DA ROCHA, Rosmeri Porfírio; RAO, Vadlamudi Brahmananda. South American Monsoon Lifecycle Projected by Statistical Downscaling with CMIP6-GCMs. **Atmosphere**, [S. l.], v. 14, n. 9, 2023. DOI: 10.3390/atmos14091380.

SIEBERS, A. R.; PAILLEX, A.; ROBINSON, C. T. Flow intermittency influences the trophic base, but not the overall diversity of alpine stream food webs. **Ecography**, v. 42, n. 9, p. 1523-1535, 2019.

SOLMAN, S. A.; BLÁZQUEZ, J. Multiscale precipitation variability over South America: Analysis of the added value of CORDEX RCM simulations. **Climate Dynamics**, [S. l.], v. 53, n. 3/4, p. 1547-1565, 2019. DOI: 10.1007/s00382-019-04689-1.

SONG, S.; ZHANG, X.; GAO, Z.; YAN, X. Evaluation of atmospheric circulations for dynamic downscaling in CMIP6 models over East Asia. **Climate Dynamics**, [S. l.], v. 60, n. 7/8, p. 2437-2458, 2023. DOI: 10.1007/s00382-022-06465-0.

TIWARI, A. D.; MISHRA, V. Sub-Seasonal Prediction of Drought and Streamflow Anomalies for Water Management in India. **Journal of Geophysical Research: Atmospheres**, v. 127, n. 3, p. e2021JD035737, 2022.

TONG, M.; ZHENG, Z.; FU, Q. Evaluation of East Asian Meiyu from CMIP6/AMIP simulations. **Climate Dynamics**, [S. l.], v. 59, n. 7/8, p. 2429-2444, 2022. DOI: 10.1007/s00382-022-06218-z.

WHATELY, M.; CUNHA, P. **Cantareira 2006**: Um olhar sobre o maior manancial de água da Região Metropolitana de São Paulo. São Paulo.

XAVIER, A. C.; KING, C. W.; SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980-2013). **International Journal of Climatology**, [S. l.], v. 36, n. 6, p. 2644-2659, 2016. DOI: 10.1002/joc.4518.

YAZDANDOOST, Farhad; MORADIAN, Sogol; IZADI, Ardalan; AGHAKOUCHAK, Amir. Evaluation of CMIP6 precipitation simulations across different climatic zones: Uncertainty and model intercomparison. **Atmospheric Research**, [S. l.], v. 250, 2021. DOI: 10.1016/j.atmosres.2020.105369.