UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AMBIENTAL

Maria Fernanda Rodrigues Pereima

AVALIAÇÃO SISTEMÁTICA DA PRECIPITAÇÃO DOS MODELOS DE CLIMA DO CMIP5 E CMIP6 NO SUL DO BRASIL

Florianópolis

Maio, 2021

Maria Fernanda Rodrigues Pereima

AVALIAÇÃO SISTEMÁTICA DA PRECIPITAÇÃO DOS MODELOS DE CLIMA DO CMIP5 E CMIP6 NO SUL DO BRASIL

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Ambiental da Universidade Federal de Santa Catarina para a obtenção do título de Mestre em Engenharia Ambiental.
Orientador: Prof. Dr. Pedro Luiz Borges Chaffe
Coorientadora: Prof. Dr. Regina Rodrigues Rodrigues

Florianópolis

Maio, 2021

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Pereima, Maria Fernanda Rodrigues
AVALIAÇÃO SISTEMÁTICA DA PRECIPITAÇÃO DOS MODELOS DE CLIMA DO CMIP5 E CMIP6 NO SUL DO BRASIL / Maria Fernanda Rodrigues Pereima ; orientador, Pedro Luiz Borges Chaffe, coorientador, Regina Rodrigues Rodrigues, 2021.
112 p.

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia Ambiental, Florianópolis, 2021.

Inclui referências.

1. Engenharia Ambiental. 2. CMIP5. 3. CMIP6. 4. desempenho. 5. sul do Brasil. I. Chaffe, Pedro Luiz Borges. II. Rodrigues, Regina Rodrigues. III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Ambiental. IV. Título.

Maria Fernanda Rodrigues Pereima

Avaliação sistemática da precipitação dos modelos de clima do CMIP5 e CMIP6 no sul do Brasil

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Profª. Alexandra R. Finotti, Drª.
Universidade Federal de Santa Catarina

Prof. Roberto Valmir da Silva, Dr.(a)
Universidade Federal da Fronteira Sul

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de mestre em Engenharia Ambiental

Documento assinado digitalmente
Leonardo Hoinaski
Data: 22/06/2021 20:25:44-0300
CPF: 007.028.269-28
Verifique as assinaturas em https://v.ufsc.br

Prof. Dr. Leonardo Hoinaski
Coordenador do Programa de Pós-Graduação

Documento assinado digitalmente
Pedro Luiz Borges Chaffe
Data: 22/06/2021 17:11:42-0300
CPF: 005.170.430-76
Verifique as assinaturas em https://v.ufsc.br

Prof. Dr. Pedro Luiz Borges Chaffe
Orientador

Prof.ª Drª. Regina Rodrigues Rodrigues
Coorientadora

Florianópolis, maio de 2021

.

AGRADECIMENTOS

Agradeço à Universidade Federal de Santa Catarina, por me proporcionar uma educação pública de de qualidade desde meus anos de graduação até agora. À Coordenação de Aperfeiçoamento de Pessoal de Nivel Superior (CAPES), pela bolsa de estudos que tornou este trabalho possível. Ao departamento de Engenharia Sanitária e Ambiental, minha casa pelos últimos 8 anos.

Agradeço ao Prof. Pedro Chaffe, pela cuidadosa orientação que teve início no TCC e se extende até hoje. Pela disponibilidade, paciência e pelo incentivo desde o início. À Prof. Regina Rodrigues, pela coorientação. Aos professores membros da banca, pelas valiosas considerações feitas ao trabalho.

Agradeço aos amigos do Laboratório de Hidrologia da UFSC, que foram fonte de inspiração e motivação para execução desse trabalho. Especialmente, gostaria de agradecer à Paula David e ao Gabriel Anzolin pela generosidade em doarem seu tempo para discussões e críticas a respeito deste trabalho.

Agradeço, enfim, à minha família e ao meu namorado pelo constante apoio, por compreenderem minha ausência nesses anos e por estarem sempre acreditando em mim.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

RESUMO

A precipitação simulada por modelos de clima é uma das principais variáveis de entrada em estudo de impacto hidrológico às mudanças climáticas. No entanto, características como frequência, sazonalidade e extremos não são simuladas adequadamente na escala regional, especialmente em climas tropicais. O objetivo deste trabalho foi avaliar o desempenho de modelos de clima em representar a precipitação observada na região sul do Brasil. O sul do Brasil encontra-se em área de transição entre o clima tropical e extratropical, estando susceptível à expansão dos trópicos no hemisfério Sul. Além disso, apresenta uma topografia complexa, ciclos sazonais diferentes ao longo da área e diferentes mecanismos de geração de precipitação. Este trabalho avaliou de maneira sistemática diferentes aspectos da precipitação simulada por modelos de clima da quinta e sexta fase do CMIP (*coupled model intercomparison project*). Foi desenvolvida uma ferramenta computacional que combina métricas de diferentes projetos para garantir uma visão geral dos aspectos marginais, temporais e espaciais da precipitação. Foram testados resultados das médias dos modelos (*multi model ensemble* – MME) e um conjunto ótimo de modelos (*constrained ensemble* – CE) que melhor representam a precipitação anual observada. O conjunto ótimo obtido minimiza a métrica de erro CRPS (*continuous ranked probability score*), que indica a distância entre a CDF observada e a simulada pelo conjunto. Os resultados mostram que modelos de clima apresentam um viés seco, simulando menores volumes precipitados, maior número de dias secos consecutivos e precipitações extremas menos intensas que as observadas. De uma maneira geral, resultados obtidos com o CE performam melhor ou igual àqueles obtidos com o MME. Modelos do CMIP6 apresentam uma performance melhor que os do CMIP5, especialmente na simulação do ciclo anual e da distribuição espacial da precipitação.

Palavras-chaves: modelos de clima, CMIP5, CMIP6, performance, CRPS, sul do Brasil.

ABSTRACT

Climate model (GCM) precipitation is one of the most important input for hydrological models in climate change risk assessment. However, precipitation characteristics such as frequency, seasonality, and extremes are usually not well simulated at the regional scale in the tropics. The objective of this study is to analize climate model performance in simulate the observed precipitation in southern Brazil (SB). Southern Brazil is a transitional zone between tropical and extratropical climates, being a susceptive area to the expansion of tropical climate characteristics. Beyond that, it has a complex topography, diversity in rainfall generation mechanisms, and uneven seasonality throughout the area. This study analized systematically different aspects of climate model precipitation from the fifth and sixth phases of CMIP (coupled model intercomparison project). A computational tool that combines different metrics was developed to guarantee an overview of marginal, temporal, and spatial aspects of climate model precipitation. Results from the multi-model-ensemble mean (MME), as well as from a constrained ensemble (CE) were tested. The CE is the one that minimizes the continuous ranked probability score (CRPS), a metric of distance between observed and simulated cumulative distributions. Results show a dry bias in all climate models with a dry bias characterized by lower precipitation amounts and higher consecutive dry days. Overall, CE equals or outperforms the MME and CMIP6 outperforms CMIP5 for most metrics, especially in the simulation of the seasonal cycle and the spatial distribution of precipitation.

Key-words: climate models, CMIP5, CMIP6, performance, CRPS, Southern Brazil.

LISTA DE FIGURAS

Figura 1: Esquema modelos de clima 25
Figura 2: Evolução dos modelos de clima 26
Figura 3: Evolução temporal dos cenários futuros da quinta e sextas fases do CMIP, tem termos de concentração de gás carbônico. 27
Figura 4: ascata de incertezas no processo de modelagem em estudos de impacto às mudanças climáticas 30
Figura 5: Aspectos para validação dos modelos de clima. 32
Figura 6: Genealogia dos modelos do (A) CMIP3 (marcados com asterisco) e CMIP5, (B) CMIP6. 34
Figura 7: (A) Localização da área de estudo, (B) elevação, (C) precipitação total anual em mm/ano, e (D) índice de sazonalidade de Markham. 37
Figura 8: Esquema do índice de sazonalidade de Makham 44
Figura 9:Geração do conjunto final com modelos do CMIP5. (A) Evolução do CRPS, linha azul escura é a primeira cadeia, linha azul clara é a segunda cadeia; (B) CDF observada (linha preta), CDF da média do multi-model-ensemble (linha roxa escura), CDF do conjunto final (linha roxa clara). Sombreado roxo escuro são todas as CDF dos modelos do CMIP5, sombreado roxo claro são todas as CDF dos modelos escolhidos para o conjunto final. Sombreado claro está sempre contido no sombreado escuro; (C) probabilidade α de cada modelo ser aceito no conjunto final. 54
Figura 10: Geração do conjunto final com modelos do CMIP6. (A) Evolução do CRPS, linha azul escura é a primeira cadeia, linha azul clara é a segunda cadeia; (B) CDF observada (linha preta), CDF da média do multi-model-ensemble (linha verde escura), CDF do conjunto final (linha verde clara). Sombreado verde escuro são todas as CDF dos modelos do CMIP6, sombreado verde claro são todas as CDF dos modelos escolhidos para o conjunto final. Sombreado claro está sempre contido no sombreado escuro; (C) probabilidade α de cada modelo ser aceito no conjunto final. 55
Figura 11: Resumo dos resultados dos índices calculados para $CMIP5_{MME}$ (primeira coluna), $CMIP5_{CE}$ (segunda coluna), $CMIP6_{MME}$ (terceira coluna) e $CMIP6_{CE}$ (quarta coluna) em termos de viés (porcentual). 57
Figura 12: Resultados para precipitação total anual. Padrão espacial para (A) $CMIP5_{MME}$, (B) $CMIP5_{CE}$, (D) $CMIP6_{MME}$, e (E) $CMIP6_{CE;}$ (D) QQplot para modelos de clima do CMIP5, círculos roxos escuro são $CMIP5_{MME}$, círculos roxos claro são $CMIP5_{CE}$, sombreado roxo

escuro são todos os modelos do CMIP5, sombreado roxo claro são somente os modelos do CMIP5 escolhidos para o conjunto final; (F) QQplot para modelos de clima do CMIP6, círculos verdes escuro são $CMIP6_{MME}$, círculos verdes claro são $CMIP6_{CE}$, sombreado verde escuro são todos os modelos do CMIP6, sombreado verde claro são somente os modelos do CMIP6 escolhidos para o conjunto final. 58
Figura 13: Correlação de Spearman entre observação e (A) $CMIP5_{MME}$, (B) $CMIP5_{CE}$, (C) $CMIP6_{MME}$ e (D) $CMIP6_{CE}$. Correlações foram computadas entre séries históricas pixel a pixel. 60
Figura 14: Resultados para (A) desvio padrão da precipitação diária e (B) assimetria da precipitação diária para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel. 60
Figura 15: Índices de percentis altos da precipitação. (A) Percentil 95 da precipitação diária, (B) percentil 98 da precipitação diária, (C) percentil 99 da precipitação diária, (D) contribuição anual de dias com precipitação acima do percentil 95, (E) contribuição anual de dias com precipitação acima do percentil 98, (F) contribuição anual de dias com precipitação acima do percentil 99 para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel, por ano. Distribuição do (G) volume anual precipitado acima do percentil 95, (H) volume anual precipitado acima do percentil 98, e (I) volume anual precipitado acima do percentil 99 para observação (linha preta), $CMIP5_{CE}$ (linha roxa) e $CMIP6_{CE}$ (linha verde). 61
Figura 16: Resultados para precipitações extremas com tempos de retorno de (A) 20 anos, e (B) 50 anos para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel. 62
Figura 17: Resultados da frequência anual de ocorrência de dias com precipitações (A) acima de 10mm/d, e (B) acima de 20 mm/d, e volumes anuais precipitados acima de (C) 10mm/d, e (D) 20mm/d para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por ano, por pixel. 63
Figura 18: Resultados para (A)frequência anual de dias chuvosos, (B) precipitação média em dias chuvosos, (C) precipitação diária, (D) percentil 95 da precipitação em dias chuvosos, (E) percentil 98 da precipitação em dias chuvosos, (F) percentil 99 da precipitação em dias

chuvosos para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por ano, por pixel. Distribuição do (G) volume anual precipitado acima do percentil chuvoso 95, (H) volume anual precipitado acima do percentil chuvoso 99, e (I) volume anual precipitado acima do percentil chuvoso 99, para observação (linha preta), $CMIP5_{CE}$ (linha roxa) e $CMIP6_{CE}$ (linha verde). 64
Figura 19: Resultados de autocorrelação com lag de (A) 1 dia, (B) 3 dias e (C) 7 dias para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel. 65
Figura 20: Resultados para ciclo sazonal. (A) Ciclo anual, observado (linha preta, sombreado cinza são todos os ciclos anuais observados) e simulado pelo $CMIP5_{MME}$ (barras roxas escuro), $CMIP5_{CE}$ (barras roxas claro), $CMIP6_{MME}$ (barras verdes escuro) e $CMIP6_{CE}$ (barras verdes claro), error bar são todos os ciclos anuais simulados; (B) Índice de sazonalidade de Markham para Observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel; e padrão espacial do índice de sazonalidade de Markham para (C) observação, (D) $CMIP5_{MME}$, (E) $CMIP5_{CE}$, (D) $CMIP6_{MME}$, e (F) $CMIP6_{CE}$. 66
Figura 21: Resultados para índices temporais de precipitação extrema. (A) Precipitação total anual, (B) dia médio da ocorrência do máximo anual, (C) máxima precipitação acumulada de 3 dias anual, (D) máxima precipitação acumulada de 5 dias anual, e (E) máxima precipitação acumulada de 7 dias anual para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por ano, por pixel – salvo (B), onde resultados são por pixel. 68
Figura 22: Resultados para dias consecutivos. Frequência de (A) dias secos consecutivos, e (B) dias chuvosos consecutivos para observação (barras pretas), $CMIP5_{MME}$ (barras roxas escuro), $CMIP5_{CE}$ (barras roxas claro), error bars são todos os modelos do CMIP5, $CMIP6_{MME}$ (barras verdes escuro) e $CMIP6_{CE}$ (barras verdes claro), error bars são todos os modelos do CMIP6. Média de (C) dias secos consecutivos e (D) dias chuvosos consecutivos para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel. Distribuição do (E) maior período anual de dias secos consecutivos e (F) maior período anual de dias chuvosos consecutivos para observação (linha preta), $CMIP5_{CE}$ (linha roxa) e $CMIP6_{CE}$ (linha verde) 69

Figura 23: Correlogramas de (A) correlação de Spearman, (B) informação mútua de ocorrência de dias chuvosos, e (C) informação mútua de excedência do percentil 95 da precipitação diária para observação. Linhas foram obtidas através de regressão polinomial local de 2 grau para observação (linha preta), $CMIP5_{MME}$ (linha roxa escuro), $CMIP5_{CE}$ (linha roxa claro), $CMIP6_{MME}$ (linha verde escuro), e $CMIP6_{CE}$ (linha verde claro). Círculos cinza são todos as correlações observadas, círculos roxos são todas as correlações simuladas pelos modelos do CMIP5 e círculos verdes são todas as correlações simuladas pelos modelos do CMIP6.....70

LISTA DE TABELAS

Tabela 1: Modelos de clima utilizados e suas instituições 39
Tabela 2: Métricas de performance marginal utilizadas 41
Tabela 3: Valores de θ_m em graus 44
Tabela 4: Métricas de performance temporal utilizadas 45
Tabela 5: Ferramentas utilizadas como base para a toolbox 48
Tabela 6: Descrição das funções da toolbox 49
Tabela 7: Descrição das variáveis de entrada e saída das funções 50
Tabela 8: Número de vezes que cada modelo do CMIP5 é incluído no conjunto final ($CMIP5_{CE}$) e suas resoluções 56
Tabela 9: Número de vezes que cada modelo do CMIP6 é incluído no conjunto final ($CMIP6_{CE}$) e suas resoluções 56
Tabela 10: Resultados para o teste de aderência de Kolmogorov-Smirnov 59

SUMÁRIO

1. **INTRODUÇÃO** 21

1.1. OBJETIVO GERAL 23

1.2. OBJETIVOS ESPECÍFICOS 23

2. **REVISÃO BIBLIOGRÁFIC**a 25

2.1. MODELOS DE CLIMA 25

2.2. MODELOS DE CLIMA E ESTUDOS DE IMPACTO 29

2.3. MÉTRICAS DE PERFORMANCE 30

2.4. GERAÇÃO DE CONJUNTO ÓTIMO DE MODELOS DE CLIMA 33

3. **MATERIAIS E MÉTODOS** 37

3.1. ÁREA DE ESTUDO E DADOS OBSERVADOS 37

3.2. MODELOS DE CLIMA 38

3.3. MÉTRICAS DE PERFORMANCE 40

3.3.1. **Aspectos marginais** 40

3.3.2. **Aspectos temporais** 43

3.3.3. **Aspectos espaciais** 46

3.3.4. I**mplementação numérica: a criação de uma toolbox para cálculo das métricas** 47

3.4. MÉTODO DE GERAÇÃO DO CONJUNTO ÓTIMO DE MODELOS DE CLIMA 50

4. **RESULTADOS E DISCUSSÃO** 53

4.1. GERAÇÃO DO CONJUNTO ÓTIMO DE MODELOS DE CLIMA 53

4.2. MÉTRICAS DE PERFORMANCE 57

4.2.1. **Aspectos marginais** 58

4.2.2. **Aspectos temporais** 65

4.2.3. **Aspectos espaciais** 70

5. **CONCLUSÕES** 73

6. **REFERÊNCIAS BIBLIOGRÁFICAS** 75

APÊNDICE A.....85

1. INTRODUÇÃO

A representação precisa da precipitação é essencial em estudos de impacto hidrológico às mudanças climáticas, sendo ela a variável de entrada mais importantes dos modelos hidrológicos. Estudos de impacto às mudanças climáticas em setores como agricultura, segurança hídrica e saúde pública também requerem dados de precipitação acurados (EEKHOUT et al., 2018; LOBELL et al., 2008; NISSEN; ULBRICH, 2017; ROSENZWEIG et al., 2002). Representar corretamente a precipitação, no entanto, não é uma tarefa fácil, uma vez que é dependente da variabilidade climática e de fenômenos dependentes da topografia (CLARK et al., 2016). Existe uma alta confiança que o aumento da temperatura média terrestre resulte em uma intensificação do ciclo hidrológico, levando à um maior contraste entre estações e regiões secas e chuvosas (COLLINS et al., 2013). A magnitude dessa mudança no ciclo hidrológico a longo prazo, no entanto, é dependende da concentração de gases do efeito estufa. Modelos de clima são a principal ferramenta para prever a resposta do sistema climático frente à diferentes cenários de emissões desses gases (JUN; KNUTTI; NYCHKA, 2008). Modelos de clima evoluem sincronamente às fases do CMIP (*Coupled Model Intercomparison Project*), e em cada fase evoluem em complexidade, número de estruturas representadas, capacidade computacional no seu desenvolvimento e número de base de dados observados (FLATO, G. et al., 2013).

Modelos de clima apresentam limitações na simulação da precipitação, devido à formulação, à dificuldade na simulação da variabilidade climática natural e à sua resolução espacial grosseira. Estes não conseguem capturar fenômenos na escala local dependentes da topografia (MARAUN et al., 2010). Inconsistências típicas incluem baixa precipitação no equador, alta precipitação nos oceanos, especialmente na zona de convergência sul, e alta frequência de dias chuvosos com intensidades muito baixas (FLATO, G. et al., 2013). Modelos do CMIP6 simulam de baixas precipitações na região subtropical, aumentando novamente em latitudes médias devido à simulação de sistemas frontais (BOCK et al., 2020). Eyring et al. (2020) encontraram que, na escala regional, modelos tendem a simular maiores precipitações em áreas de complexa topografia, ao passo que simulam baixas precipitações em regiões áridas subcontinentais, além de vieses maiores em precipitações extremas que em médias. Modelos anteriores não capturam o ciclo sazonal na zona de convergência intertropical (ITCZ) e, portanto, não conseguem simular o ciclo anual em regiões tropicais como a Amazônia (BOMBARDI;

CARVALHO, 2009). Embora haja uma evolução na formulação dos modelos, eles ainda são incertos e possuem viéses sistemáticos devido à formulação.

Via de regra, a utilização conjunta dos modelos (chamados de *ensembles*) resulta em simulações mais confiáveis (TEBALDI; KNUTTI, 2007) A maneira mais simples seria considerar a média aritmética das simulações (ou *multi-model-ensemble*, MME), independentemente de quantas versões um modelo pode ter ou de quantos modelos uma instituição desenvolve (FLATO, G. et al., 2013). Devido à interdependência das simulações, é improvável que este método gere resultados com o melhor desempenho possível, além de gerar uma falsa concordância entre modelos (HERGER et al., 2017). Instituições frequentemente partilham códigos na formulação de seus modelos e o uso do MME pode gerar um desequilíbrio na representação das diferentes estruturas do sistema climático (SANDERSON; KNUTTI; CALDWELL, 2015). Desta forma, outras abordagens que consideram o desempenho dos modelos na geração de um conjunto ótimo foram desenvolvidas (HERGER et al., 2017; MERRIFIELD et al., 2020; PIERCE et al., 2009; SANDERSON; KNUTTI; CALDWELL, 2015; VISSIO et al., 2020). De maneira geral, pesos são dados aos modelos de acordo com a sua concordância com a observação com o objetivo de gerar conjuntos com maior desempenho, chamados *constrained ensembles* (CE) (BISHOP; ABRAMOWITZ, 2013).

Considerando que os vieses associados à cada modelo se mantêm constantes entre rodadas históricas e futuras (LORENZ et al., 2018), sua caracterização pode ser entendida como um primeiro passo em estudos de impacto. Diferentes conjuntos de métricas foram sugeridas para garantir uma análise padronizada do desempenho de simulações de precipitação. Essas métricas foram pensadas não somente para determinar o desempenho de modelos de clima, mas também para outros tipos de simulações – produtos de reanálise, de satélite ou de *downscaling*. O PCMDI (*Program for Climate Model Diagnosis and Intercomparison*) coordena avaliações dos modelos dentro do CMIP, sugerindo quais métricas serão utilizadas e quais metodologias de avaliação serão utilizadas (GLECKLER; TAYLOR; DOUTRIAUX, 2008). O ETCDII (*Expert Team on Climate Change Detection and Indices*) sugere índices referentes à extremos de precipitação e temperatura (ZHANG et al., 2011). O projeto VALUE-COST foca em isolar a performance dos métodos de correção de escala, dividindo os resultados de uma maneira focada no usuário final (MARAUN et al., 2014). As métricas do projeto VALUE-COST são divididas em quatro frentes: aspectos marginais, temporais, espaciais e multivariados.

A região sul do Brasil (SB), por estar localizada entre os climas tropicais e extratropicais, pode sofrer alterações no regime de precipitação em decorrência da expansão das condições típicas dos trópicos de 2° à 4° no Hemisfério Sul (LUCAS; NGUYEN; TIMBAL, 2012). Extsitem diferenças no padrão de ocorrência de eventos extremos associados ao fenômeno *El Niño* Oscilação Sul (ENSO) nas regiões costeiras e interioranas do sul do Brasil (PSCHEIDT; GRIMM, 2009). Mudanças na intensidade e frequência de eventos extremos já foram detectadas, tanto na escala sazonal (FERNANDES; RODRIGUES, 2017), quanto anual (CHAGAS; CHAFFE, 2018). A região sul apresenta complexidade em sua topografia, o que favorece o surgimento de diferentes mecanismos de geração de precipitação, a depender da área e estação (e.g. chuva convectiva no verão, e chuva frontal em regiões montanhosas). O sul do Brasil apresenta diferentes regimes sazonais, com monções de verão no norte do Paraná e chuva bem distribuída no restante da região (CAVALCANTI et al., 2009). Estudos sugerem que modelos de clima não representam satisfatoriamente certas características da precipitação como sazonalidade, frequência e extremos, fazendo com que o sul do Brasil seja uma área favorável para testar a capacidade dos modelos de clima em representar a precipitação observada.

Este trabalho analisou de maneira sistemática o desempenho dos modelos de clima da quinta e sextas fases do CMIP em representar a precipitação observada no sul do Brasil. Foi encontrado conjunto de modelos que diminua o erro (CE) dos modelos de clima em relação à observação no sul do Brasil. Métricas de desempenho foram utilizadas para testar o os modelos do CMIP5 e CMIP6 no SB, para o MME e CE.

1.1. OBJETIVO GERAL

Avaliar o desempenho dos modelos de clima da quinta e sextas fases do CMIP em representar aspectos da precipitação na região sul do Brasil.

1.2. OBJETIVOS ESPECÍFICOS

- Avaliar o desempenho dos modelos de clima em representar os aspectos marginais, temporais e espaciais observados na precipitação no sul do Brasil;
- Comparar os resultados obtidos com o multi-model-ensemble e conjunto ótimo

- Comparar o desempenho dos modelos do CMIP5 e CMIP6 em representar aspectos da precipitação no sul do Brasil.

2. REVISÃO BIBLIOGRÁFICA

2.1. MODELOS DE CLIMA

Modelos de clima (GCM) são representações matemáticas dos processos físicos, químicos e biológicos que ocorrem entre a atmosfera, os oceanos, a massa continental e a criosfera (Figura 1) (MARAUN et al., 2017a). Estes modelos se baseiam em leis de conservação de massa, energia e momento. GCM foram desenvolvidos para representar padrões de circulação de grande escala e, portanto, apresentam dificuldades ao simular fenômenos com resoluções abaixo de 200 km (MARAUN et al., 2010). Variáveis com uma maior dependência da topografia e fenômenos de escala regional como a precipitação não são, portanto, adequadamente representados (BENESTAD, 2016). Em fenômenos microfísicos parametrizações são utilizadas, como transferência de calor latente entre massa oceânica e atmosfera ou formação de nuvens (EHRET et al., 2012).

Figura 1: Esquema modelos de clima

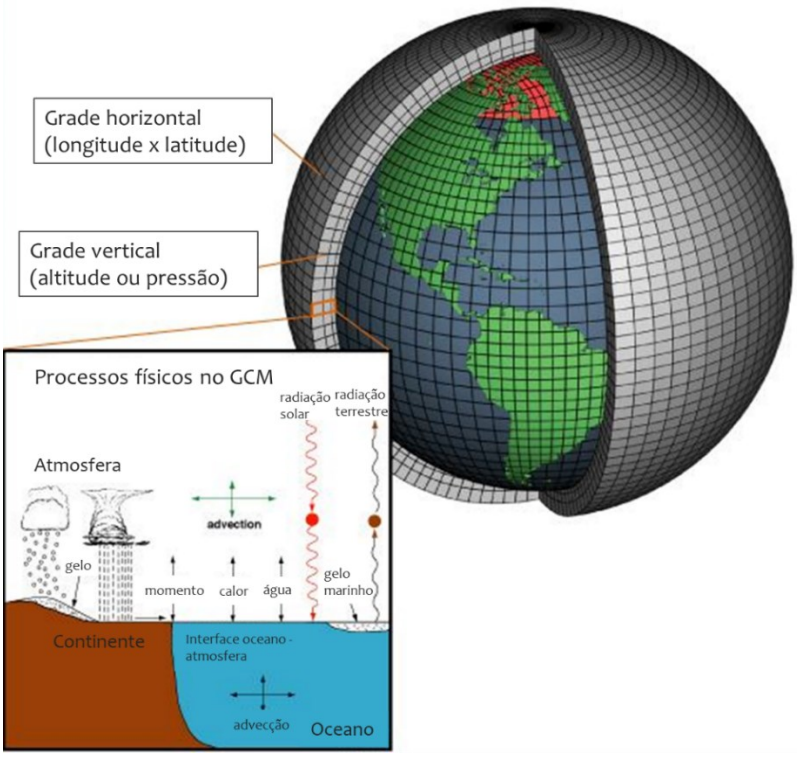

Fonte: traduzido de NOAA (2017)

Para que fosse possível determinar a resposta climática ao aumento médio da temperatura terrestre, instituições desenvolveram seus próprios modelos matemáticos em um esforço conjunto, e em 1995 iniciou-se o projeto *Coupled Model Intercomparison Project* (CMIP) do *World Climate Research Program.* Inicialmente como modelos acoplados de circulação geral de atmosfera e oceano (AOGCM), hoje os modelos de clima agregam diferentes estruturas como criosfera, ciclo do carbono, interações químicas e biológicas (Figura 2).

Figura 2: Evolução dos modelos de clima

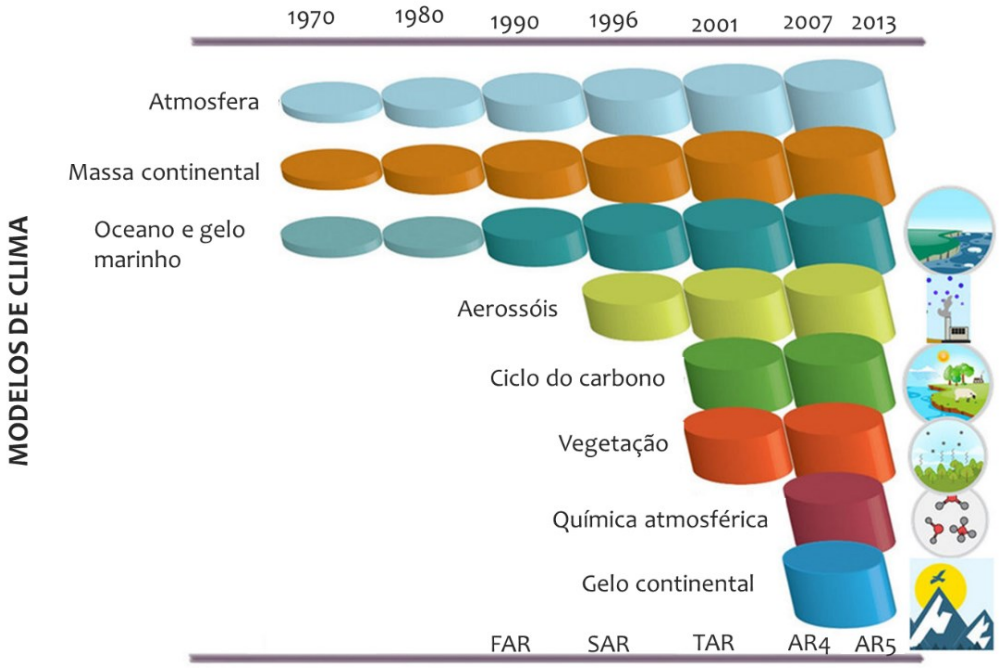

Fonte: Traduzido do Quinto Relatório de avaliação do IPCC

Modelos de clima são, hoje, a ferramenta mais utilizada para simular projeções climáticas com diferentes cenários de desenvolvimento socioeconômico (JUN; KNUTTI; NYCHKA, 2008). Eles são a base das projeções nos Relatórios de Avaliação (AR) do Painel Intergovernamental sobre Mudanças Climáticas (IPCC), vinculado ao Programa das Nações Unidas para o Meio Ambiente (UNEP) e à Organização Meteorológica Mundial (WMO). Relatórios de avaliação compilam o estado da arte de estudos com a temática mudanças climáticas, que vão desde estudos focados em compreender as interações das diferentes estruturas do sistema climático, as causas e impactos das mudanças climáticas, passando por projeções futuras e dedicando uma sessão às medidas de mitigação e adaptação (IPCC, 2000). Paralela-

mente, os modelos de clima evoluem em termos de estruturas representadas, quantidade e qualidade das bases de dados utilizadas, aumento da resolução e evolução na capacidade processamento de dados, tornando seu desenvolvimento cada vez mais sofisticado (BRUNNER et al., 2020).

Cada fase do CMIP corresponde a um conjunto de cenários futuros de desenvolvimento socioeconômico mundial, e suas consequências no sistema climático. Modelos do CMIP3 utilizavam cenários de emissão de gases do efeito estufa, aerossois e concentrações de CO_2, chamados de SRES (*Special Report on Emissions Scenarios*). Modelos do CMIP5 utilizam cenários em termos de aumento de energia no sistema global (em W/m²), chamados de RCP (*Representative Concentration Pathways*). Atualmente, modelos encontram-se na sua sexta fase (CMIP6), que serão utilizados no próximo relatório (AR6), com previsão de publicação entre 2021 e 2022. Projeções futuras do CMIP6, chamadas de SSP (*Shared Socioeconomic Pathways*), expandem os cenários RCP, continuando com aumento energético em W/m² (Figura 3).

Figura 3: Evolução temporal dos cenários futuros da quinta e sextas fases do CMIP, tem termos de concentração de gás carbônico.

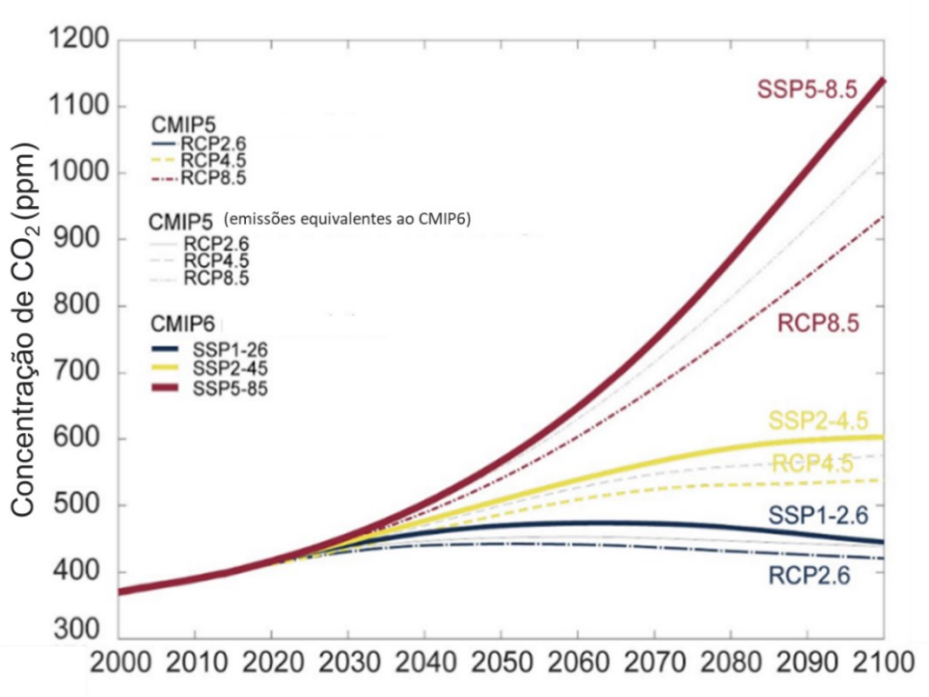

Traduzido de Tebaldi et al. (2021).

Os modelos do CMIP5 não seguem uma padronização no seu desenvolvimento em termos de resolução espacial, temporal, e quais elementos são considerados como forçantes de mudanças climáticas (e.g., quais gases do efeito estufa são incluídos). A janela temporal dessa fase é de 1950 a 2005 na rodada histórica e 2006 a 2100 nas projeções futuras. Modelos do CMIP5 também são divergentes em termos de calendário, havendo modelos que consideram anos bissextos, outros não, e outros consideram todos os meses com 30 dias.

Os modelos do CMIP6 já apresentam uma evolução em termos de documentação. Existe um esforço para uma maior transparência no processo de desenvolvimento de cada modelo nesta fase, sendo todos eles documentados no portal *Earth System Documentation* (ES-DOC, https://es-doc.org/cmip6/). Em termos de padronização, a grande maioria dos calendários consideram anos bissextos. Modelos ainda divergem em resolução espacial. A janela temporal foi expandida e bases de dados observacionais incluídos, e os modelos do CMIP6 vão de 1850 a 2014 em sua rodada histórica, embora existam modelos que se estendem até 2019. Projeções futuras nesta fase iniciam em 2015 e acabam em 2100.

Devido à forma com que são desenvolvidos, modelos de clima apresentam vieses epistêmicos. Estas incertezas estão vinculadas à falta de conhecimento do funcionamento do sistema climático, à representação de variabilidades climáticas e às parametrizações feitas ao longo do processo (HAUGHTON et al., 2015). Por questões principalmente (porém não restritas à) computacionais, os provedores dos modelos têm que fazer escolhas entre quais partes do sistema climático devem ser bem representadas, quais serão negligenciadas e quais serão parametrizadas (TEBALDI; KNUTTI, 2007). Embora essas parametrizações possam ser feitas por equações derivadas de outras variáveis dentro do sistema ou a partir de observações, existe a possibilidade de que sejam aceitas simplesmente por fazer sentido matematicamente (TEBALDI; KNUTTI, 2007). Além disso, instituições nem sempre são transparentes quanto ao seu processo de desenvolvimento dos modelos (FLATO, G. et al., 2013). Em última instância, modelos são reflexos das prioridades dos modeladores e de quais estruturas eles querem representar (BISHOP; ABRAMOWITZ, 2013).

Embora exista uma sobreposição de alguns anos entre projeções futuras dos GCM e observação (rodadas históricas do CMIP5 terminam em 2006 e do CMIP6 em 2014), seu desempenho não pode ser determinado desta forma. Instituições geram rodadas históricas dos modelos, que começam com níveis pré-industriais de emissão de gases do efeito estufa e evoluem de acordo com suas equações matemáticas e com a auxílio de observações. Desta forma,

considera-se que as estruturas descritas no modelo não mudem entre a rodada histórica e as futuras e que seus vieses se mantêm estacionários (LORENZ et al., 2018). Assim, é possível determinar o desempenho dos modelos de clima comparando sua rodada histórica com observações.

2.2. MODELOS DE CLIMA E ESTUDOS DE IMPACTO

Segundo o Plano Nacional de Adaptação à Mudança do Clima (MMA, 2016), a mudança no regime de precipitação pode afetar no planejamento e operação de obras de infraestrutura hídrica e medidas de prevenção ou mitigação de extremos climáticos. Estudos de impacto às mudanças climáticas sofrem uma cascata de incertezas ao longo do processo de modelagem (Figura 4). A caracterização das incertezas envolvidas no processo de modelagem hidrológica pode reduzir os riscos associados à eventos extremos como inundações e secas, especialmente quando a modelagem é associada ao uso de modelos de clima e diferentes cenários futuros. Estudos de impacto às mudanças climáticas que utilizam como base modelos de clima no Brasil na última década têm focado principalmente em geração de energia hidroelétrica e disponibilidade hídrica, porém dando pouca ou nenhuma ênfase na determinação das incertezas associadas (AMORIM; BORGES CHAFFE, 2019).

Essas incertezas podem ser decorrentes de diferentes etapas no processo de modelagem, que vai desde os cenários de mudança utilizados (i.e. SRES, RCP, ou SSP), do próprio modelo de clima e suas diferentes inicializações, pelo processo de correção na escala (i.e., *downscaling* ou correção de viés), pela modelagem hidrológica e finalmente nos parâmetros encontrados no modelo hidrológico (CLARK et al., 2016) Para disponibilidade hídrica a longo prazo (i.e., multidecadal), por exemplo, a principal fonte de incerteza no processo é decorrente dos modelos iniciais (PADRÓN; GUDMUNDSSON; SENEVIRATNE, 2019).

Figura 4: ascata de incertezas no processo de modelagem em estudos de impacto às mudanças climáticas

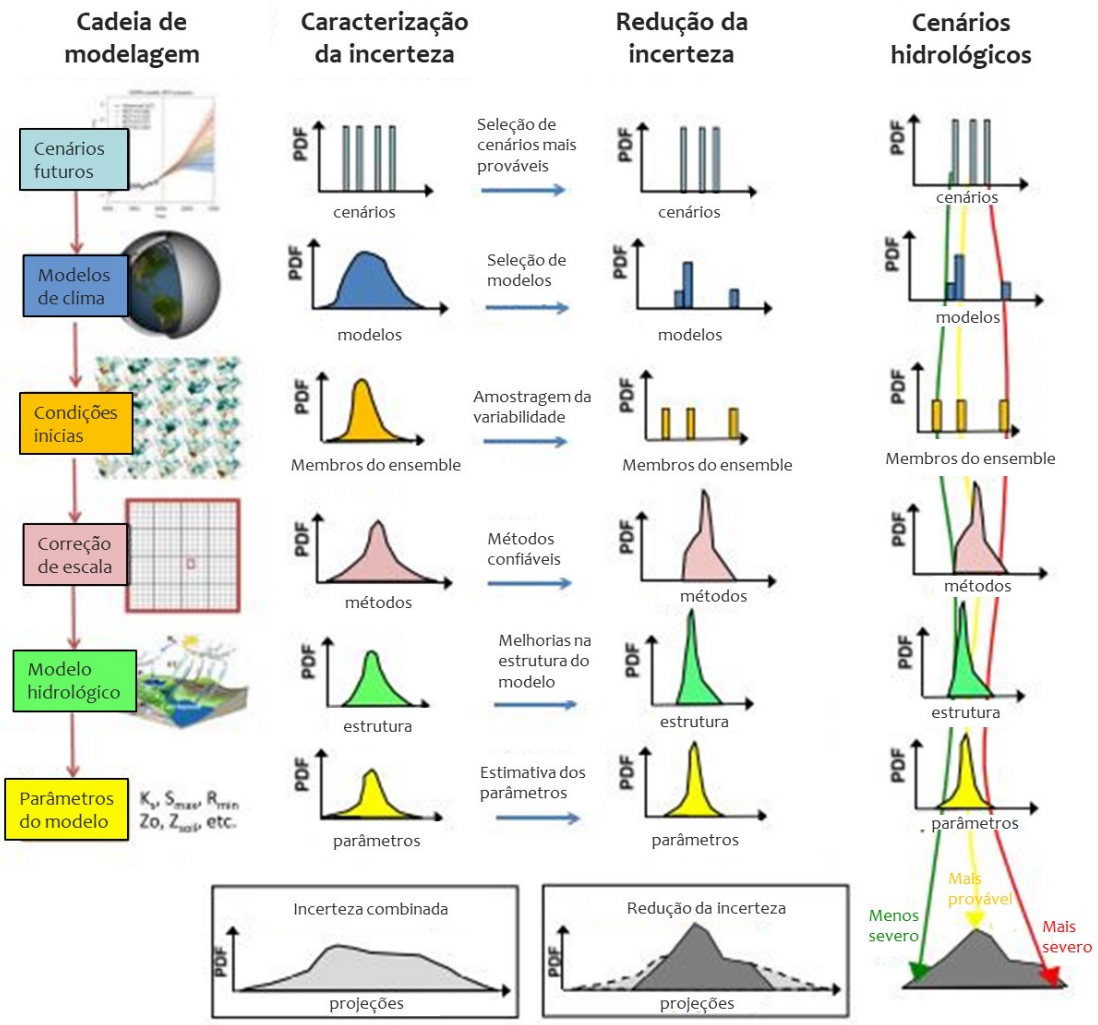

Fonte: Traduzido de Clark et al. (2016)

2.3. MÉTRICAS DE PERFORMANCE

Devido às diversas fontes de incertezas no desenvolvimento dos modelos de clima, o desempenho dos modelos na representação de fenômenos climáticos e meteorológicos pode variar não só temporal e espacialmente, como de fenômeno em fenômeno em um mesmo modelo (MARAUN; WIDMANN, 2018). Um modelo é considerado útil quando ele consegue representar condições médias, variabilidade e dinâmicas de fenômenos meteorológicos conhecidos (TEBALDI; KNUTTI, 2007). Considerando que os vieses associados à cada modelo se mantêm constantes entre rodadas históricas e futuras (LORENZ et al., 2018), sua caracterização pode ser entendida como um primeiro passo para determinar as incertezas associadas ao processo de modelagem. No desenvolvimento de modelos regionais (RCM), por exemplo, fre-

quentemente são escolhidos um ou alguns poucos modelos como condições de contorno iniciais (PARDING et al., 2020). Essa escolha é necessária uma vez que o desenvolvimento de RCM são computacionalmente dispendiosos devido à sua fina resolução e alta complexidade. A quantificação de erros em GCM é importante uma vez que pode poupar tempo, dinheiro e esforço em estudos de impacto às mudanças climáticas (CLARK et al., 2016). Greve et al. (2018) encontraram que a principal fonte de incerteza para disponibilidade hídrica em projeções futuras vem da estrutura dos modelos utilizados, e não de variabilidade climática ou dos cenários de emissão.

Diferentes projetos foram desenvolvidos com o objetivo de facilitar e padronizar a quantificação dos erros em estudos climáticos, seja em produtos de reanalise ou satélite, GCM ou produtos de Downscaling. O *Program for Climate Model Diagnosis and Intercomparison* (PCMDI) coordena os diagnósticos realizados nos modelos de clima do CMIP (GLECKLER; TAYLOR; DOUTRIAUX, 2008). Eles determinam quais métricas serão utilizadas e dão as diretrizes do procedimento de diagnóstico dos modelos. Além disso, o PCMDI é responsável pela disponibilização dos modelos através do portal ESGF (*Earth System Grid Federation*), pela padronização dos dados e pelo desenvolvimento de softwares para manipulação e diagnostico dos modelos de clima. As métricas determinadas pelo PCMDI são relativas à climatologia média, desvio padrão, correlação entre modelos e observação, quantificação de erros (viés, erro quadrático médio, erro médio absoluto) e ao diagnóstico de padrões de circulação geral como *El Niño*, modos extratropicais de variabilidade (*Extratropical Modes of Variability*), Osccilação de Madden-Julian (MJO) e monções.

O projeto *The Expert Team on Climate Change Detection and Indices* (ETCCDI) foca em índices que descrevam eventos extremos de temperatura e precipitação, que possa ser utilizado na comparação entre diferentes áreas. A maior parte dos índices sugeridos pelo ETCCDI busca quantificar eventos extremos moderados, que aconteçam uma ou mais vezes por ano e possam detectar variabilidades diárias (ZHANG et al., 2011). Ao longo dos anos, diferentes *softwares* e produtos foram desenvolvidos a partir desses índices. As métricas do ETCCDI foram utilizadas como base para o programa Climdex, que disponibiliza resultados em forma de grade e software para cálculo dos índices (DONAT et al., 2013, 2013; DUNN et al., 2020), além de adicionar índices à lista. O projeto INDECIS compila um total de 125 índices climáticos, divididos em áreas de aplicação (DOMÍNGUEZ-CASTRO et al., 2020).

Procurando orientar sobre como determinar a performance de métodos de *Downscaling* e correção de viés, a iniciativa europeia *European Union Cooperation in Science and Technology* (EU COST) *Action ES1102 VALUE* sugeriu um conjunto de índices focados nas necessidades do usuário final (MARAUN et al., 2014). A descrição de todos os índices pode ser verificada no portal de validação do projeto (Tabela 5). Para isolar as incertezas do método de correção utilizado, estes índices são calculados e comparados em diferentes designs experimentais. Esses índices são divididos em quatro frentes para garantir uma visão geral do desempenho da variável (Figura 5): aspectos marginais, que descrevem estatísticas básicas da variável; aspectos temporais; aspectos espaciais e aspectos multivariados, que determinam relações entre variáveis.

Figura 5: Aspectos para validação dos modelos de clima.

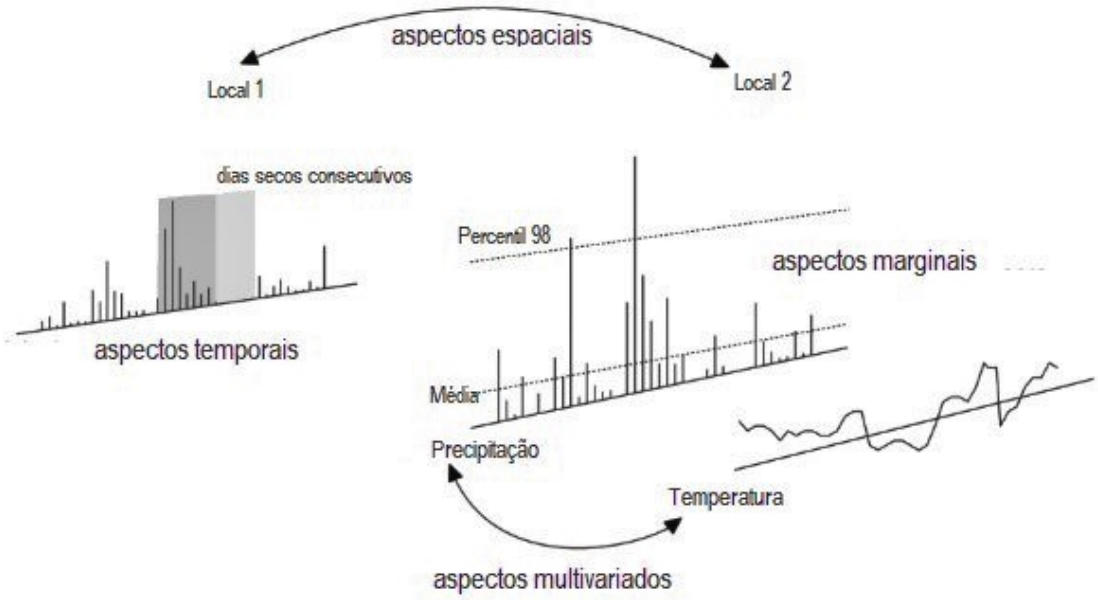

Fonte: Adaptado de Widmann & Maraun (2018)

Aspectos marginais são todos aqueles relacionados à distribuição estatística da precipitação, informando sobre comportamentos médios, variabilidade e extremos (MARAUN et al., 2014). Os aspectos temporais da precipitação variam de acordo com a escala, havendo desde variações diárias à mudanças de longo prazo (e.g. tendências) (MARAUN; WIDMANN, 2018). Métricas como tamanho do período seco ou chuvoso são dependentes de características locais como topografia do local (regiões montanhosas, por exemplo, podem determinar a persistência de dias chuvosos) e podem se alterar rapidamente. Para escalas temporais maiores, a

precipitação apresenta uma dependência aos padrões de circulação de larga escala, como massas de ar e pressão atmosférica (MARAUN et al., 2017b).

Diferente dos aspectos temporais, a dependência espacial tende a ser uma transição suave entre localidades, demonstrando a influência de fenômenos climáticos de larga escala, sendo as mudanças abruptas consequência da topografia (MARAUN; WIDMANN, 2018). No entanto, devido à sua resolução espacial grosseira, modelos de clima não conseguem captar nuances na topografia. Mudanças no padrão espacial simuladas pelos modelos tendem a ser mais suaves. Métricas de dependência espacial indicam a permanência geográfica de um fenômeno, e podem incluir métodos como correlação espacial e determinação de funções ortogonais (EOF), que representam padrões espaciais (BIAU et al., 1999).

2.4. GERAÇÃO DE CONJUNTO ÓTIMO DE MODELOS DE CLIMA

Existem diferentes fontes de incertezas no processo de modelagem que utilizam saídas de GCM. Uma forma eficaz de considerar as incertezas provenientes dos modelos no processo é utilizar um conjunto grande o bastante que englobe o maior número de representações possíveis (CLARK et al., 2016). No geral, a utilização conjunta de vários modelos (i.e, de um *ensemble*) resulta em simulações mais robustas e confiáveis (TEBALDI; KNUTTI, 2007). A forma mais comum de gerar um *ensemble* é através da abordagem chamada "um modelo, um voto", onde todos os modelos têm a mesma influência no resultado. Esta abordagem, chamada de *multi-model-ensemble* (MME), considera que erros de diferentes simulações se anulem no processo de modelagem (HAUGHTON et al., 2015). De fato, esta é a abordagem utilizada pelo IPCC nos seus Relatórios de Avaliação, onde conclusões são feitas a partir da média aritmética dos modelos e não dos modelos individuais(FLATO, G. et al., 2013). No Brasil, a utilização do MME em estudos hidrológicos ainda é limitada: aproximadamente 60% dos estudos realizados entre 2017 e 2019 utilizam até 2 modelos (BORGES; CHAFFE, 2019).

É importante considerar, no entanto, que pode haver troca de códigos entre instituições na formulação dos modelos e que a maioria dos modelos são muitas vezes atualizações dos modelos de fases anteriores (Figura 6), o que significa que GCM não são independentes e podem, portanto, apresentar vieses semelhantes (KNUTTI; MASSON; GETTELMAN, 2013). Consequentemente, a utilização da média aritmética de todos os modelos (i.e., MME) em estudos de impacto pode não ser a mais eficiente, embora seja uma melhor alternativa à utilização de um

único modelo (REICHLER; KIM, 2008). O MME é, portanto, enviesado em decorrência da interdependência dos modelos e pode simular uma determinada estrutura ou parametrização simplesmente por ela ser mais frequente entre os modelos, e não mais correta. A interdependência dos modelos pode também levar uma falsa confiança nos resultados, uma vez que existe uma concordância entre eles simplesmente por semelhanças no desenvolvimento e compartilhamento de códigos (SANDERSON; KNUTTI; CALDWELL, 2015).

Figura 6: Genealogia dos modelos do (A) CMIP3 (marcados com asterisco) e CMIP5, (B) CMIP6.

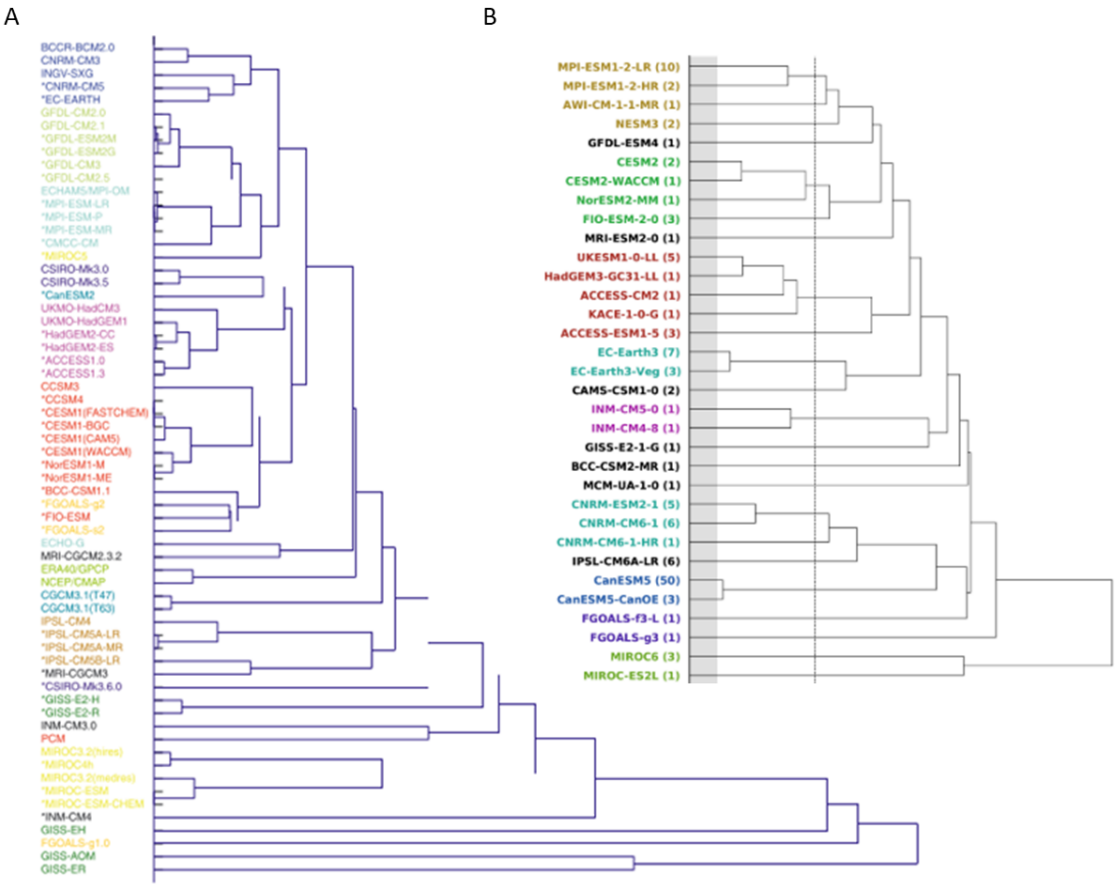

Fonte: (A) Knutti et al. (2013) e (B) Brunner et al. (2020)

A incerteza dos GCM pode ser atenuada atribuindo-se pesos aos modelos de acordo com sua concordância com a observação. Esses conjuntos são chamados de *contrained ensembles* (CE). Modelos com grandes vieses recebem pesos baixos (podendo ser, inclusive, excluídos) ao passo que os modelos que concordem com a observação recebem um maior peso (SANDERSON; KNUTTI, 2012). Um conjunto ótimo é aquele que otimiza a performance final ao mesmo tempo que reduz a ocorrência de informações duplicadas (HERGER et al., 2017).

Segundo o paradigma da "verdade mais erro" (*truth plus error*), um conjunto de modelos independentes é aquele que os erros não são correlacionados, e o erro médio tende à zero quanto maior for o tamanho conjunto. Frequentemente, este paradigma norteia as metodologias que buscam um conjunto ótimo de modelos que minimizem o erro (LEDUC et al., 2016).

Diferentes metodologias para encontrar um conjunto ótimo foram desenvolvidas. O *Ensemble Dependence Transformation* (EDP) (BISHOP; ABRAMOWITZ, 2013) almeja um conjunto de modelos que, à longo prazo, atribua o mesmo peso para cada modelo ao mesmo tempo que iguala as variâncias de cada modelo. Leduc et al. (2016) sugerem uma metodologia com base na hierarquia entre instituições responsáveis pelo desenvolvimento dos GCM, escolhendo um só modelo que melhor represente um subgrupo para compor um conjunto de modelos. Sanderson et al. (2015) sugerem a metodologia *Multidimensional Scaling* que representa os modelos e observações como uma superfície multidimensional, escolhendo o ponto de menor erro (i.e, mais próximo da observação). Padrón et al. (2019) sugerem uma metodologia de aceite ou descarte de modelos de acordo com a concordância da função de probabilidade acumulada (CDF) das simulações com a da observação.

A geração de um conjunto ótimo não é uma solução que não vem acompanhada de limitações. O conjunto final é sempre dependente da área de estudo, da variável escolhida e dos dados de observação utilizados (HAUGHTON et al., 2015). Métodos que utilizam o desempenho dos modelos baseados em apenas uma característica (no geral, precipitação média) não garantem uma melhora na representação de outras características. Assim, a geração de um CE deve ser feita de forma direcionada, uma vez que um desempenho satisfatório em uma área pode não funcionar em outra, da mesma forma que não existe garantias de que o CE gerado consiga captar mais de uma característica observada.

No entanto, esses métodos são mais frequentemente utilizados devido à menor complexidade e demanda computacional (HERGER et al., 2019). A determinação da performance do *ensemble* deve ser, idealmente, feita com uma base de dados diferente daquela utilizada na fase de desenvolvimento dos modelos, evitando que uma boa performance seja decorrente da base de dados observacionais e não da estruturação do modelo (TEBALDI; KNUTTI, 2007).

3. MATERIAIS E MÉTODOS

3.1. ÁREA DE ESTUDO E DADOS OBSERVADOS

A área de estudo (Figura 7) compreende a região sul do Brasil, com aproximadamente 7% do território nacional, com uma área de 576774 km². Embora seja a menor das regiões em extensão territorial, o sul do Brasil apresenta grande importância para o país por sua diversidade econômica, representando aproximadamente 17% do PIB (IBGE, 2017).

Figura 7: (A) Localização da área de estudo, (B) elevação, (C) precipitação total anual em mm/ano, e (D) índice de sazonalidade de Markham.

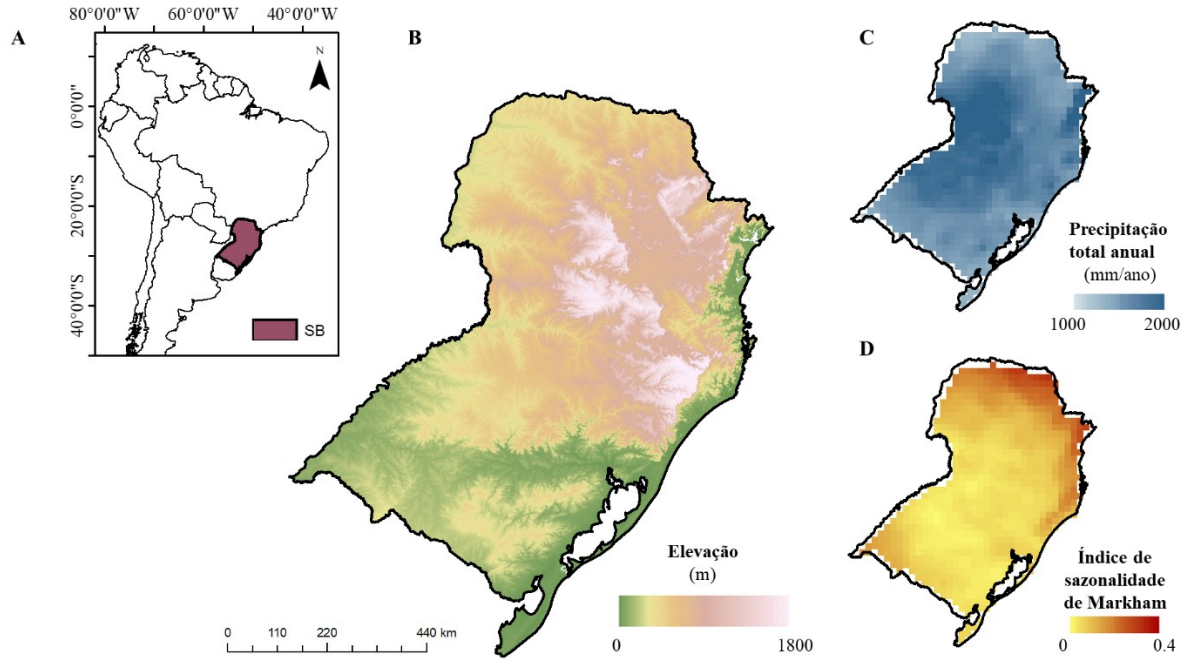

Fonte: dados de Xavier et al. (2016), anos 1980 à 2005

A precipitação total anual média pode variar entre 1200 mm/ano e 2500 mm/ano, com base em dados de 1980 a 2005 (Figura 7, C) (XAVIER; KING; SCANLON, 2015). A umidade que abastece a região é proveniente parcialmente pela Floresta Amazônica e parcialmente pelo Oceano Atlântico Sul. A umidade proveniente da região amazônica se dá principalmente no verão, devido à passagem de jatos decorrentes da *South American Monsoon System* (FERNANDES; RODRIGUES, 2017). A região sofre influência de padrões de circulação atmosférica, notadamente *El Niño* Oscilação Sul (ENSO) que provoca precipitações extremas na região e está associado a anos de enchente (BARREIRO; DÍAZ, 2011). O padrão de ocorrência

desses eventos, no entanto, difere entre regiões do sul do Brasil, sendo que eventos extremos raramente ocorrem de maneira simultânea entre a região costeira e o interior (PSCHEIDT; GRIMM, 2009). O regime de precipitação difere ao longo da região apresentando monções de verão no estado do Paraná, enquanto no restante do território as precipitações são mais bem distribuídas ao longo do ano (Figura 7, D) (CAVALCANTI et al., 2009). Esta é uma região com diferentes mecanismos de geração de precipitação, decorrente da sua complexa topografia.

A região do sul do Brasil demostra uma grande sensibilidade frente às mudanças climáticas, uma vez que se encontra em uma área de transição entre os climas tropicais e extratropicais (Cfa, segundo a classificação de Koppen-Geiger). A região pode sofrer alterações no regime de precipitação em decorrência da expansão da influência da borda sul da cédula de Hardley, uma vez que o aumento da concentração de gases do efeito estufa é responsável pela expansão das condições típicas dos trópicos de 2° à 4° no Hemisfério Sul (LUCAS; TIMBAL; NGUYEN, 2014).

A base de dados utilizada como referência é a grade de resolução espacial de 0,25° desenvolvida por Xavier et al. (2015). A base é composta por dados diários de precipitação e evapotranspiração no período de 01 de janeiro de 1980 à 31 de dezembro de 2013. Os dados foram obtidos através de 3625 estações pluviométricas e 735 estações meteorológicas no território brasileiro sob a responsabilidade do Instituto Nacional de Meteorologia (INMET), da Agência Nacional de Águas (ANA) e do Departamento de Energia Elétrica de São Paulo (DAEE).

3.2. MODELOS DE CLIMA

Neste estudo foram utilizados modelos da quinta e sextas fases do CMIP (Tabela 1). Modelos podem variar em resolução espacial, calendário utilizado, além de variar entre condições iniciais. De forma a padronizar os dados e permitir a comparação, os modelos foram interpolados bilinearmente para a resolução espacial da referência (0,25º x 0,25°). A janela temporal utilizada foi de 1980 a 2005, de forma a garantir que existisse uma sobreposição temporal entre os dados de referência, do CMIP5, e do CMIP6.

Instituições tem a prerrogativa de escolher o número de modelos que vão desenvolver, bem como o número de variantes de cada modelo (i.e., simulações de um mesmo modelo com diferentes condições iniciais). Não existe um padrão entre instituições sobre quais são condições iniciais de cada variante, portanto, a primeira variante de um modelo não necessariamente tem as mesmas características iniciais da primeira variante de outro modelo. Por esse motivo, apenas uma variante de cada modelo foi utilizada para conduzir as análises. Ao todo, foram utilizados 28 modelos do CMIP5 e 35 do CMIP6.

Tabela 1: Modelos de clima utilizados e suas instituições

Instituições	CMIP5	CMIP6
Commonwealth Scientific and Industrial Research Organisation (CSIRO), Bureau of Meteorology (BOM), e Queensland Climate Change Centre of Excellence, Australia	ACCESS1-0	ACCESS-CM2
	ACCESS1-3	
	CSIRO-Mk3-6-0	
Alfred Wegener Institute, Centre for Polar and Marine Research, Alemanha		AWI-ESM-1-1-LR
College of Global Change and Earth System Science, Beijing Normal University, China	BNU-ESM	
Beijing Climate Center China Meteorological Administration (BCC), China	BCC-CSM-1-1-m	BCC-ESM1
	BCC-CSM-1-1	
National Center for Atmospheric Research (NCAR), Climate and Global Dynamics Laboratory, Estados Unidos	CCSM4	CESM2
		CESM2-FV2
		CESM2-WACCM
		CESM2-WACCM-FV2
Centro Euro-Mediterraneo per i Cambiamenti Climatici (CMCC), Itália	CMCC-CESM	CMCC-CM2-SR5
	CMCC-CMS	CMCC-ESM2
	CMCC-CM	
Centre National de Recherches Météorologiques, França	CNRM-CM5	
Canadian Centre for Climate Modelling and Analysis, Canadá	CanESM2	CanESM5
EC-Earth-Consortium (AEMET, BSC, University of Santiago de Compostela, Espanha; CNR-ISAC, ENEA, ICTP, Itália; DMI, University of Copenhagen, Dinamarca; FMI, University of Helsinki, Finlândia; Geomar, KIT, Alemanha; ICHEC,Met Eireann, University College Dublin, Irlanda; IDL, IPMA, Portugal; IMAU, LNMI, NLeSC, surfSARA, Utrecht University, Vrije Universiteit Amsterdam, Wageningen University, Holanda; Lund University, SMHI, Stockholm University, Uppsala University, Suécia; NTNU, University of Bergen, Noruega; Oxford University, Reino Unido; Unite ASTR, Bélgica.)		EC-Earth3
		EC-Earth3-AerChem
		EC-Earth3-CC
		EC-Earth3-Veg
		EC-Earth3-Veg-LR
Institute of Atmospheric Physics (IAP), Chinese Academy of Sciences) and Tsinghua University, China	FGOALS-g2	
National Oceanic and Atmospheric Administration (NOAA), Geophysical Fluid Dynamics Laboratory (GFDL), Estados Unidos	GFDL-ESM2G	GFDL-CM4
	GFDL-ESM2M	GFDL-ESM4
NASA Goddard Institute for Space Studies (GISS), Estados Unidos	GISS-E2-H	
	GISS-E2-R	

Instituições	CMIP5	CMIP6
Met Office Hadley Centre, Reino Unido	HadGEM2-CC	
Centre for Climate Change Research, Indian Institute of Tropical Meteorology Pune, Índia		IITM-ESM
Institute for Numerical Mathematics (INM), Russian Academy of Science, Rússia	INMCM4	INM-CM4-8
		INM-CM5-0
Institut Pierre Simon Laplace, França		IPSL-CM5A2-INCA
Japan Agency for Marine-Earth Science and Technology (JAMSTEC), Atmosphere and Ocean Research Institute (AORI), National Institute for Environmental Studies (NIES), RIKEN Center for Computational Science (R-CCS), Japão	MIROC-ESM-CHEM	MIROC6
	MIROC-ESM	
	MIROC4h	
	MIROC5	
Meteorological Research Institute (MRI), Japão	MRI-CGCM3	MRI-ESM2-0
	MRI-ESM1	
Max Planck Institute for Meteorology, Alemanha	MPI-ESM-LR	MPI-ESM1-2-HR
	MPI-ESM-MR	MPI-ESM1-2-LR
HAMMOZ-Consortium (ETH Zurich Center for Climate Systems Modeling (C2SM), Suíça; Max Planck Institut fur Meteorologie, Forschungszentrum Julich, Leibniz Institute for Tropospheric Research, Alemanha; University of Oxford, Reino Unido; Finnish Meteorological Institute, Finlândia.)		MPI-ESM-1-2-HAM
Nanjing University of Information Science and Technology (NUIST), China		NESM3
NorESM Climate modeling Consortium (Center for International Climate and Environmental Research (CICERO), Norwegian Meteorological Institute, Nansen Environmental and Remote Sensing Center NERSC), Norwegian Institute for Air Research (NILU), University of Bergen, University of Oslo, Uni Research), Noruega	NorESM1-M	NorCPM1
		NorESM2-LM
		NorESM2-MM

3.3. MÉTRICAS DE PERFORMANCE

3.3.1.Aspectos marginais

Os índices utilizados neste trabalho estão descritos na Tabela 2. Além de verificar estatísticas básicas como média e desvio padrão, um dos índices calculados é o parâmetro de assimetria. Isto porque a assimetria é uma medida de distância entre a média e a mediana, indicando a ocorrência de precipitações altas. O viés na assimetria caracteriza a diferença na suavização das caudas da distribuição em relação à observação. Quanto mais distante de zero a assimetria, mais distante a média está da mediana e da moda. Também foi calculada a métrica *Simple Daily Intensity Index* (SDII), que é a precipitação média considerando somente dias com precipitações que igualem ou superem a marca de 1mm (ZHANG et al., 2011).

Para determinar a ocorrência de dias secos e chuvosos, foram calculadas as frequências anuais de dias com precipitação ≥ 1mm para dias chuvosos e dias com precipitação < 1mm para dias secos (GUTIÉRREZ et al., 2018). Estas são características especialmente relevantes para GCM, visto que a precipitação ocorrida é uma média em termos da resolução do modelo. Desta forma, em geral os GCM tendem a apresentar muitos dias chuvosos com precipitações muito pequenas, fenômeno chamado de *drizze effect* (VOLOSCIUK et al., 2017) .

Tabela 2: Métricas de performance marginal utilizadas

Métrica	Descrição	Referência
Média	$\bar{P} = \frac{\sum_i^N P_i}{N}$, onde P_i é a precipitação no tempo *i* no período *N*	Zhang et al. (2011), Maraun et al. (2015)
Desvio padrão (STD)	$STD = \frac{\sqrt{\sum_i^N (P_i - \bar{P})}}{N}$, onde P_i é a precipitação no tempo *i* no período *N* e $\bar{P}$ é a precipitação média no tempo *N*	
Simple intensity daily index (SDII)	$SDII = \frac{\sum_j^W P_j}{W}$, onde P_j é a precipitação em dias ≥ 1mm no período *j*, e *W* é o número total de dias ≥ 1mm	Zhang et al. (2011), Gutiérrez et al. (2018)
Skewness	$Skewness = \frac{\sum_i^N (P_i - \bar{P})^3}{(N-1)*STD^3}$, onde P_i é a precipitação no tempo *i* no período *N* e $\bar{P}$ é a precipitação média no tempo *N,* e STD é o desvio padrão.	Hertig et al. (2018)
Frequência de dias secos (WDF)	$WDF = \frac{W}{T}$, onde *W* é o número total de dias ≥ 1mm, e *T* é o total de dias no ano	Gutiérrez et al. (2018)
Frequência de dias chuvosos (DDF)	$DDF = \frac{D}{T}$, onde *D* é o número de dias < 1 mm, e *T* é o total de dias no ano	
Percentil x (Px)	Precipitação igualada ou excedida (100 – *x*) porcento do tempo	Maraun et al. (2015)
Volume acima do percentil x (VolPx)	$VolPx = \sum_i^N (P_i \geq Px)$, onde P_i é a precipitação no tempo *i* no período *N*, e P_x é o percentil	Zhang et al. (2011)
Percentil x de dias chuvosos (PxWet)	Precipitação igualada ou excedida (100 – *x*) porcento do tempo considerando somente dias ≥ 1mm	Hertig et al. (2018)
Volume acima do percentil chuvoso x (VolPxWet)	$VolPx = \sum_i^N (P_i \geq Px)$, onde P_i é a precipitação no tempo *i* no período *N*, e *Px* é o percentil chuvoso	Hertig et al. (2018)
Contribuição anual do percentil x (RxpTot)	$RxpTot = \frac{100*VolPx}{\bar{P}}$, onde $\bar{P}$ é a precipitação total anual, e *VolPx* é o total anual de dias ≥ percentil	Donat et al. (2013)
Frequência de dias acima de limiar (Rx)	$Rx = \frac{R}{T}$, onde *R* é p número de dias com precipitação ≥ *x* mm, e *T* é o número de dias no ano	Zhang et al. (2011), Hertig et al. (2018)
Volume acima de um limiar (VolRx)	$VolRx = \sum_i^N (P_i \geq x)$, onde P_i é a precipitação no tempo *i* no período *N*, e *x* é o limiar fixo	
Correlação temporal	Correlação de Spearman entre duas series temporais	Maraun et al. (2017)
Precipitação de x anos (TRx)	Precipitação com um período de retorno de *x* anos	Hertig et al. (2018)

Como forma de verificar a similaridade entre séries temporais da observação e do modelo de clima, pixel a pixel, calculamos a correlação de Spearman (Equação 1). O intervalo de confiança determinado é de 95%.

$$\rho = 1 - \frac{6\sum_{i=1}^{n} d_i}{n(n^2 - 1)} \quad (1)$$

Em que d_i é a diferença entre duas variáveis ranqueadas na posição i, e n o número de pontos da amostra e ρ é o índice de correlação de Spearman (GLASSER; WINTER, 1961; SPEARMAN, 1904).

Foram calculadas as excedências dos limiares de 10mm e 20mm, chamados respectivamente de *heavy precipitation day* (HPD) e *very heavy precipitation day* (VHPD), sugeridos pelo ETCCDI. A determinação de frequência e volume excedido de um limiar fixo pode ser utilizado para comparação entre áreas com comportamentos hidrológicos similares, ou como determinação de padrões em obras hidráulicas. No entanto, índices com limiares fixos não levam em consideração as particularidades do local estudado, e podem gerar comparações enganosas. Uma alternativa mais adequada de comparar extemos entre regiões diferentes é utilizar um limiar móvel na forma de percentil. A utilização de percentis como limiares também permite o monitoramento da intensidade e frequência de eventos extremos moderados levando em consideração a região (ZHANG et al., 2011).

Foram determinados os percentis 95, 98 e 99 da precipitação, bem os volumes anuais precipitados acima desses limiares e seus percentuais de contribuição anual. O percentil *x* da precipitação é aquele que é igualado ou superado 100 – *x* por cento do tempo, isto é, o percentil 95 da precipitação é aquela intensidade que é igualada ou excedida somente 5% do tempo (HERTIG et al., 2018). Da mesma forma, o volume anual desse percentil é o volume precipitado somente em dias com precipitações de intensidades acima ou iguais ao percentil. A contribuição anual desse percentil é o volume anual precipitado acima do percentil dividido pelo volume total anual precipitado, i.e., qual a fração desse percentil no volume precipitado anual.

Para determinar a intensidade de precipitações extremas foram calculadas precipitações com certos períodos de retorno (período médio de ocorrência do evento) e períodos de acumulação. Foram estimadas intensidades de precipitações com diferentes períodos de retorno através da curva GEV (*generalized extreme value*). As Curvas de Intensidade-Duração-Frequência

(IDF) são comumente utilizadas em obras hidráulicas e de infraestrutura para estimar a intensidade de eventos extremos (RAGNO et al., 2018). Embora seja comum o cálculo de forma estacionária (i.e, parâmetros da distribuição estatística das séries temporais são constantes), recentes estudos vêm explorando o conceito de não estacionariedade das curvas, considerando que parâmetros como a média, por exemplo, pode mudar com o tempo (AGHAKOUCHAK et al., 2014).

Finalmente, foi calculado o teste de aderência de Kolmogorov-Smirnov (MASSEY, 1951). O teste é realizado através da maior distância entre as funções de distribuição acumuladas de duas variáveis aleatórias (Equação 2). A hipótese nula é que duas variáveis aleatórias vêm de uma mesma distribuição estatística. O nível de significância (p-valor) adotado foi de 5%, isto é, a probabilidade de rejeitar a hipótese nula quando ela é verdadeira é de 5%.

$$\mathrm{KS} = \max |\, \mathrm{F}(x_1) - \mathrm{F}(x_2)| \tag{2}$$

Em que $\mathrm{F}(x_1)$ e $\mathrm{F}(x_2)$ são as funções de distribuição acumulada (CDF) das variáveis testadas.

3.3.2.Aspectos temporais

Os índices utilizados neste trabalho podem ser vistos na Tabela 4. Além da inspeção do ciclo anual, foi calculado o índice de sazonalidade. O Índice de Sazonalidade de Markham (Is) varia entre 0 e 1, sendo 1 uma concentração total da precipitação em um único mês (MARKHAM, 1970). O cálculo é realizado com base no ciclo anual, traduzido em vetores (Equação 3), onde sua direção é a expressão do mês (Figura 8). A direção do vetor final indica o período sazonal da precipitação enquanto a magnitude é uma expressão do quão sazonal a precipitação é variando de 0 a 1 (Equação 4).

Figura 8: Esquema do índice de sazonalidade de Makham

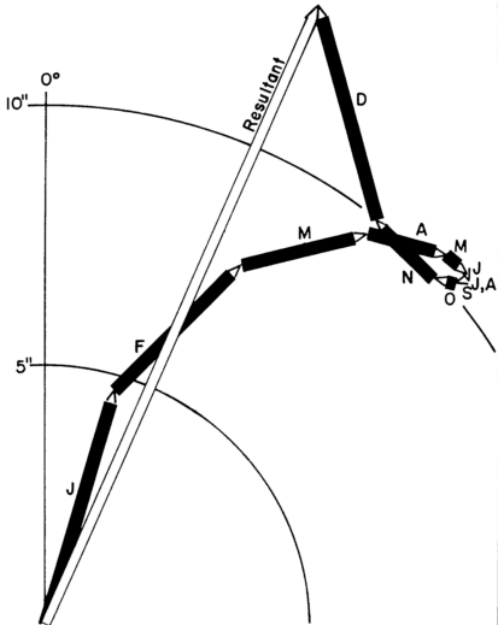

Fonte: Markham, 1970

$$\mathrm{Pr} = \sqrt{(\Sigma_{m=1}^{12} P_m * cos(\theta_m))^2 + (\Sigma_{m=1}^{12} P_m * cos(\theta_m))^2} \quad (3)$$

$$\mathrm{Is} = {}^{\mathrm{Pr}}/_{\Sigma_{m=1}^{12} P_m} \quad (4)$$

Em que P_m é a precipitação média de cada mês, e θ_m o ângulo referente ao mês. Os valores de θ_m utilizados para cada mês pode ser visto na Tabela 3 (DINGMAN, 2015).

Tabela 3: Valores de θ_m em graus

Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
15,8	44,9	74	104,1	134,1	164,2	194,3	224,9	225	285	315,1	345,2

O monitoramento de máximos anuais é necessário para cálculos de outros indicativos utilizados em obras hidráulicas, projetos de infraestrutura e estudos de risco hidrológico. Um exemplo são as chuvas de projeto, que são eventos os quais uma obra deve suportar baseado na curva IDF. Máximos anuais são índices de dependência temporal de longo período, portanto, são afetados por padrões de circulação atmosférica (MARAUN; WIDMANN, 2018). Foram

calculadas, além da máxima anual, as máximas precipitações anuais acumuladas de 3, 5 e 7 dias (ZHANG et al., 2011). O dia médio em que ocorre o máximo anual indica a sazonalidade dos maiores eventos anuais, sendo necessário em obras de engenharia, estudos de impacto na agricultura e até na proliferação de insetos (NISSEN; ULBRICH, 2017; ROSENZWEIG et al., 2002).

Tabela 4: Métricas de performance temporal utilizadas

Métrica	Descrição	Referência
Índice de sazonalidade de Markham (Is)	$\text{Is} = \frac{P_r}{\sum_1^{12} P_m}$, onde P_r é o vetor da precipitação anual e P_m é o vetor da precipitação no mês m.	Markham (1970)
Máxima precipitação anual (AnnualMax)	$AnnualMax = \max(P_i)$, onde P_i é a precipitação diária	Maraun et al. (2017)
Dia da máxima anual (DayofMax)	Dia onde acontece a maior precipitação diária.	Maraun et al. (2017)
Máxima precipitação acumulada de x dias (Rxday)	$Rx5day = \max(P_5)$, máxima precipitação acumulada de x dias.	Zhang et al. (2011), Donat et al. (2013)
Média de dias secos consecutivos	$\overline{DS} = \frac{\sum_i^M S_i}{M}$, onde S_i é o número de dias secos consecutivos no período M	Maraun et al. (2017)
Média de dias chuvosos consecutivos	$\overline{WS} = \frac{\sum_i^M S_i}{M}$, onde S_i é o número de dias chuvosos consecutivos no período M	Maraun et al. (2017)
Mediana de dias secos consecutivos	$DSmed = mediana\ (S_i)$, onde S_i é o número de dias secos consecutivos	Bedia et al. (2019)
Mediana de dias chuvosos consecutivos	$DWmed = mediana\ (S_i)$, onde S_i é o número de dias chuvosos consecutivos i	Bedia et al. (2019)
Maior período seco anual (CCD)	$CDD = \max\ (S_i)$, onde S_i é o número de dias secos consecutivos no período anual	Zhang et al. (2011)
Maior período chuvoso anual (CWD)	$CWD = \max\ (S_i)$, onde S_i é o número de dias chuvosos consecutivos no período anual	Zhang et al. (2011)
Autocorrelação de *lag* x	Autocorrelação de uma serie temporal com espaçamento (lag) de x dias	Maraun et al. (2017)

Foram calculados índices de autocorrelação com diferentes espaçamentos (JAMES D. HAMILTON, 1994) (Equação 5). Autocorrelação é definida como a correlação entre duas variáveis da mesma série temporal, com um espaçamento *lag* entre elas. Para determinar a dependência temporal de curto período, foi utilizado a autocorrelação com *lag* de 1 e 3 dias. Desta

forma, foi possível capturar mudanças diárias. Para capturar mudanças semanais, foi calculado a autocorrelação com *lag* de 7 dias.

$$\boldsymbol{r_k} = \frac{\sum_{t=1}^{T-k}(y_t - \bar{y})(y_{t+k} - \bar{y})}{T\ c_0} \quad (5)$$

Em que $\boldsymbol{r_k}$ é a autocorrelação de lag *k*, *T* é o tamanho da série temporal, c_0 é a variância da série temporal, $\bar{y}$ a média da série *y*.

O índice de duração de dias consecutivos determina a formação de agrupamentos no tempo de determinada condição, aqui dias secos (< 1mm/d) e chuvosos (≥ 1mm/d). Dias secos são todos os dias em que a precipitação é menor que 1mm, de forma a compensar os efeitos da resolução espacial em pequenas precipitações (i.e., *Drizzle Effect*). O parâmetro de média é muito sensível à presença de valores *outliers* e, portanto, podem apresentar resultados distorcidos. Uma alternativa para determinar a duração real de dias consecutivos do período é através da mediana (BEDIA et al., 2019). Em produtos de reanálise, satélite ou *Downscaling*, no entanto, é mais comum o cálculo da média, uma vez que eles não apresentam as limitações particulares aos modelos de clima. Já para produtos brutos de GCM, a comparação é interessante uma vez que modelos tendem a simular períodos muito compridos (EYRING et al., 2016).

Também são calculados os índices de CDD (*consecutive dry days*, em inglês) e CWD (*consecutive wet days*), índices sugeridos pelo ETCDII. Embora o nome não sugira, estes índices caracterizam os períodos mais longos de dias secos ou chuvosos consecutivos no ano.

3.3.3.Aspectos espaciais

Usualmente, para determinar a dependência espacial de uma variável, métodos convencionais de geoestatistica são utilizados, como krigagem (BIAU et al., 1999). Outra forma usual para determinar padrões espaciais é a análise de componentes principais (ADDOR et al., 2016; CAMUS et al., 2014; PEREZ et al., 2014; WIDMANN et al., 2019).

A metodologia utilizada neste trabalho para a determinação dos índices de dependência espacial segue a utilizada por Widmann et al. (2019). Esta metodologia é mais simples de ser aplicada, além de resultar em fácil compreensão ao usuário final. Para visualizar a dependência espacial da precipitação, correlogramas foram traçados. Estes correlogramas são gráficos da

correlação entre duas localidades no mapa pela distância entre elas. A partir dos pontos encontrados, uma curva é ajustada. Foi ajustada por uma regressão polinomial local (*Locally Estimated Scatterplot Smoothing*, LOESS) no conjunto de dados a fim de garantir uma curva flexível o suficiente para capturar diferentes links de correlação, não necessitando de conhecimento prévio do formato da distribuição.

Enquanto o cálculo da correlação de Spearman caracteriza a correlação espacial da série como um todo, para determinar a influência espacial de um evento extremo foi utilizado conceitos informação mútua (Equação 6). Tal conceito tem origem na teoria da informação, frequentemente utilizada em estatística para determinar o grau de relação entre duas variáveis aleatórias. Em ciências da terra e climatologia ele tem sido utilizado para determinar o grau de interferência da ocorrência de precipitação entre localidades (HLINKA et al., 2013).

$$\mathrm{I}(\mathbf{X},\mathbf{Y}) = \sum_{x}\sum_{y} p(x,y)\log\frac{p(x,y)}{p(x)p(y)} \tag{6}$$

Em que $p(x)$ é a probabilidade marginal de x, $p(y)$ a probabilidade marginal de y e $p(x,y)$ é a probabilidade conjunta de x e y. Desta forma, determinou-se o índice de informação mútua, que caracteriza a probabilidade conjunta de excelência de um limiar (neste caso, foi escolhido dias chuvosos e chuvas extremas). Correlogramas foram então novamente traçados, e a mesma metodologia foi aplicada. Uma vez que as curvas foram ajustadas, é possível encontrar a partir de qual ponto as correlações e informação mútua perdem a força e, portanto, a partir de qual distância a uma localidade deixa de influenciar em outra.

3.3.4.Implementação computacional: a criação de uma toolbox para cálculo das métricas

Para auxiliar nos cálculos das métricas de performance, um conjunto de funções foi desenvolvido com uso do software MATLAB®, formando uma toolbox de todas as métricas utilizadas. Todas as funções foram feitas com a versão 2017a, e algumas delas carregam outras funções embutidas no software original – portanto, é necessária uma versão do MATLAB® que sustente essas funções.

Diversas feramentas foram desenvolvidas ao longo dos anos com base nas métricas sugeridas pelos projetos PCMDI, ETCDII e VALUE. As funções foram desenvolvidas com

base em ferramentas já existentes, frequentemente utilizadas na literatura. Além disso, foram escolhidas como base as ferramentas que disponibilizam gratuitamente suas rotinas (Tabela 5).

Tabela 5: Ferramentas utilizadas como base para a toolbox

Ferramenta	Linguagem	Métricas	Descição	Rotinas
PCMDI Package	R	PCMDI	https://pcmdi.llnl.gov/	https://github.com/PCMDI/pcmdi_metrics
ESMValTool	Python	PCMDI	https://cmip-esmvaltool.dkrz.de/	https://github.com/ESMValGroup/ESMValTool
Climpact	R	ETCDII	https://www.climdex.org	https://github.com/ARCCSS-extremes/climpact
ClimInd	R	ETCDII	http://indecis.csic.es	https://gitlab.com/indecis-eu/indecis
VALUER	R	VALUE	http://www.value-cost.eu/validationportal	https://github.com/SantanderMetGroup/VALUE

As métricas são calculadas pixel a pixel. As funções têm como entrada, obrigatoriamente, uma matriz de dados 3D onde o eixo x e y são longitude e latitude, e o eixo z, a precipitação diária. A maior parte das funções necessitam de outras informações como entrada, como o calendário no formato de uma matriz de *n* x 3, na configuração [yyyy,mm,dd], onde *n* é o tamanho da série temporal. As funções têm, no geral, duas saídas: um mapa 2D com valores médios, e uma saída 3D com resultados por ano. A lista completa das funções, variáveis de entrada e saída, e ferramentas foram utilizadas de base estão descritas na Tabela 6.

As métricas de precipitação média e dias consecutivos (secos e chuvosos) precisam uma entrada com especificações da métrica – anual ou diário para média, e média ou mediana para dias consecutivos. Outras funções precisam de informações específicas às métricas calculadas, como é o caso da autocorrelação, que precisa de uma variável de *lag* chamada 'LagTime'. O mesmo acontece nos casos que precisam da determinação de um limiar, como no cálculo de percentis ou frequência acima de um limiar. No caso das funções que calculam métricas de aspectos espaciais, as saídas possíveis são as distâncias euclidianas entre pixels, as coordenadas desses pixels e os resultados de correlação ou informação mútua, todos como vetores onde o comprimento é o número de pares. A descrição de todas as variáveis de entrada e saída utilizadas na toolbox pode ser verificada na Tabela 7.

As métricas de precipitação média e dias consecutivos (secos e chuvosos) precisam uma entrada com especificações da métrica – anual ou diário para média, e média ou mediana para dias consecutivos. Outras funções precisam de informações específicas às métricas calculadas, como é o caso da autocorrelação, que precisa de uma variável de *lag* chamada 'LagTime'. O

mesmo acontece nos casos que precisam da determinação de um limiar, como no cálculo de percentis ou frequência acima de um limiar. No caso das funções que calculam métricas de aspectos espaciais, as saídas possíveis são as distâncias euclidianas entre pixels, as coordenadas desses pixels e os resultados de correlação ou informação mútua, todos como vetores onde o comprimento é o número de pares. A descrição de todas as variáveis de entrada e saída utilizadas na toolbox pode ser verificada na Tabela 7.

Tabela 6: Descrição das funções da toolbox

Função	Entradas	Saídas	Ferramentas originais
Mean	mdl, cal, 'metric'	PM_Map, PM_Series	PCMDI Package, Climpact
STD	mdl, cal	PM_Map, PM_Series	PCMDI Package
SDII	mdl, cal	PM_Map, PM_Series	Cimplact, VALUER
Skewness	mdl, cal	PM_Map, PM_Series	VALUER
WDF	mdl, cal	PM_Map, PM_Series	VALUER
DDF	mdl, cal	PM_Map, PM_Series	VALUER
Px	mdl, cal, PercTreshold	PM_Map, PM_Series	Cimplact, VALUER
Vol_Px	mdl, cal, PercTreshold	PM_Map, PM_Series	Cimplact, VALUER
PxWet	mdl, cal, PercTreshold	PM_Map, PM_Series	Cimplact, VALUER
Vol_PxWet	mdl, cal, PercTreshold	PM_Map, PM_Series	Cimplact, VALUER
RxpTot	mdl, cal	PM_Map, PM_Series	Cimplact
Rx	mdl, cal, Treshold	PM_Map, PM_Series	VALUER
Vol_Rx	mdl, cal, Treshold	PM_Map, PM_Series	Cimplact, VALUER
SpearmanCorr	mdl1, mdl2, cal	PM_Map	VALUER
TRx	mdl, cal	PM_Map, PM_Series	VALUER
KS	mdl1, mdl2	H_Map, pval_Map	VALUER
SeasonalityIndex	mdl, cal	PM_Map	
AnnualMax	mdl, cal	PM_Map, PM_Series	VALUER
Rxday	mdl,cal, Ac	PM_Map, PM_Series	Climpact
DayofAnnualMax	mdl, cal	PM_Map, PM_Series	VALUER
DrySpell	mdl, 'metric'	PM_Map	VALUER
WetSpell	mdl, 'metric'	PM_Map	VALUER
DrySpell_Max	mdl, cal	PM_Map, PM_Series	Cimplact, VALUER
WetSpell_Max	mdl,cal	PM_Map, PM_Series	Cimplact, VALUER
ACFx	mdl, Lag	PM_Map	VALUER
SpatialCorr	mdl, cal	euc_distances, correlations, coordenates	VALUER
MI	mdl, cal	euc_distances, MI, coordenates	VALUER

Tabela 7: Descrição das variáveis de entrada e saída das funções

Variável	Descrição
mdl	Matriz 3D de dados de precipitação diária, na configuração lon x lat x tempo
cal	Matriz *n* x 3 onde *n* é o tamanho da série temporal, na configuração [yyyy, mm, dd]
metric	Vetor *string* com opção escolhida utilizado nas funções 'Mean' (opções: 'annual' para total anual e 'daily' para chuva diária), DrySpell e WetSpell (opções: 'mean' para média e 'median' para mediana)
Treshold	Número real não-negativo. Determina o limiar utilização nas funções 'Rx', 'Vol_Rx', e 'MI'
PercTreshold	Número de 0 a 100, indicando o percentil a ser calculado. Utilizado nas funções 'Px', 'PxWet', 'Vol_Px', 'Vol_PxWet', 'RxpTot'
Ac	Número real não-negativo. Número de dias de acumulação. Utilizado nas funções 'TRx' e 'Rxday'
Rv	Tempo de retorno em anos, utilizado na função 'TRx'
LagTime	Intervalo de tempo utilizado para calcular autocorrelação. Utilizado na função 'ACFx'
corr_type	Vetor *string* com a opção de tipo de correlação (opções: 'Spearman', 'Kendall' e 'Pearson'). Utilizado na função 'SpatialCorr'
PM_Map	Matriz 2D de resultados
PM_Series	Matriz 3D de resultados por ano
TotalDaysAbove	Matriz 2D com resultados do total de dias acima do limiar na série, utilizado nas funções 'Vol_Px', 'Vol_PxWet' e 'Vol_Rx'
DaysAbove	Matriz 2D com resultados do total de dias acima do limiar por ano, utilizado nas funções 'Vol_Px', 'Vol_PxWet' e 'Vol_Rx'
euc_distances	Vetor de resultados com distâncias euclidianas entre pixels. Utilizado nas funções 'SpatialCorr' e 'MI'
coordenates	Matriz de resultados *n* x 4 com coordenadas dos pares de pixels, *n* é o número de pares. Utilizado nas funções 'SpatialCorr' e 'MI'
MI_s	Vetor de resultados de informação mútua entre pixels. Utilizado na função 'MI'
correlations	Vetor de resultados de correlação espacial entre pixels. Utilizado na função 'SpatialCorr'

3.4. MÉTODO DE GERAÇÃO DO CONJUNTO ÓTIMO DE MODELOS DE CLIMA

A metodologia utilizada na obtenção do conjunto ótimo de modelos foi a sugerida por Padrón et al. (2019). Ela baseia-se na ideia de que um conjunto que minimize o erro pode ser encontrado atribuindo pesos aos GCM de acordo com sua concordância com a observação. A métrica utilizada na avaliação do conjunto de modelos é o *Continuous Ranked Probability Score* (CRPS). O CRPS indica a maior distância entre a distribuição de probabilidade acumulada do conjunto e da observação. O peso dado a cada modelo individualmente é a probabilidade do modelo de ser incluído no conjunto final α (Equação 7).

$$n_{i,t-1} = \alpha_{i,t-1} * \frac{F}{\sum_{i=1}^{M} \alpha_{i,t-1}} \quad (7)$$

Em que $n_{i,t-1}$ é o número de vezes que cada modelo é incluído no conjunto, *M* o número inicial de modelos, *F* número de modelos do conjunto final, i é o indicativo do modelo e *t* é o número da iteração. Neste trabalho, adotamos F=100.

Este procedimento é repetido até que o CRPS (Equação 8) convirja para o mínimo global da função. Os valores de $\alpha_{i,t-1}$ são amostrados a partir de um amostrador do tipo Monte Carlo Markov Chain (MCMC), com uma distribuição normal com média 0,5 e desvio padrão de 0,2, inicialmente. Valores de α fora do conjunto (0,1) podem gerar resultados inconsistentes e, no caso de eles ocorrerem, são ajustados para dentro do conjunto.

O valor de α é mantido no caso do $\mathrm{CRPS_t}$ - $\mathrm{CRPS_{t\text{-}1}} \leq \mathcal{E}$ (valor de tolerância), que diminui de acordo com o número de iterações. Inicialmente, o valor de tolereância é de 1% do valor do CRPS calculado para todo o MME, i.e., o CRPS onde todos os α = 1.

O valor de CRPS de cada pixel é computado como:

$$\mathrm{CRPS_g} = \sum_{e=1}^{E} a_e * (e/E)^2 + \sum_{e=1}^{E} b_e * (1 - e/E)^2 \quad (8)$$

Onde *g* é o índice do pixel, *E* o número total de modelos incluídos no conjunto, *e* o índice do modelo individual, e a_e (Equação 9) e b_e (Equação 10) são parâmetros de diferenças entre o modelo e observação e entre o modelo e o restante dos modelos do conjunto (HERSBACH, 2000).

$$a_e = \begin{cases} 0 & \text{se} \quad x \leq x_e \\ (x - x_e) & \text{se} \quad x_e < x \leq x_{e+1} \\ (x_{e+1} - x_e) & \text{se} \quad x_{e+1} < x \end{cases} \quad (9)$$

$$b_e = \begin{cases} (x_{e+1} - x_e) & \text{se} \quad x \leq x_e \\ (x_{e+1} - x) & \text{se} \quad x_e < x \leq x_{e+1} \\ 0 & \text{se} \quad x_{e+1} < x \end{cases} \quad (10)$$

Em que *x* é o vetor de observação e x_e o vetor da simulação e. O valor final de CRPS, no caso desse estudo, é alcançado através de uma média aritmética entre o valor individual de CRPS em cada pixel.

Para a obtenção do conjunto otimizado, foram geradas duas cadeias de Markov, cada uma com 250000 iterações. Não foi escolhido um critério de parada, uma vez que a partir de um período inicial, as cadeias param de oscilar e convergem para um mesmo ponto rapidamente. Foi considerado como ponto de convergência o primeiro momento em que o CRPS encontrado não se alterou por 10% da cadeia final, isto é, por 2500 iterações. O valor final de α é a média de todos os valores após o ponto de convergência de todas as cadeias.

4. RESULTADOS E DISCUSSÃO

4.1. GERAÇÃO DO CONJUNTO ÓTIMO DE MODELOS DE CLIMA

Para os modelos do CMIP5, o valor de CRPS decai rapidamente e deixa de oscilar aproximadamente em 100 mil iterações. O valor final encontrado de CRPS do conjunto ótimo é de 0,5110. Ambas as MCMC convergem para o mesmo valor, não havendo diferença entre os valores finais de CRPS de cada uma delas (Figura 9, A). O valor de CRPS indica a distância entre as distribuições acumuladas simulada pelo conjunto ótimo e a observada. Portanto, a CDF otimizada é aquela que mais se aproxima da observada. Para os modelos do CMIP5, a CDF do conjunto final, embora seja mais próxima da observada que a CDF do *multi-model-ensemble*, ainda não consegue capturar o formato da curva observada (Figura 9, B).

Dentre os 28 modelos iniciais, somente 10 foram incluídos no conjunto final. O modelo com maior valor de α e, consequentemente, que aparece mais vezes no conjunto final é o bcc-csm1-1m, do *Beijing Climate Center* (Figura 9, C). O segundo modelo desta mesma instituição, o bcc-1-1-m, no entanto, foi descartado. Uma diferença entre esses dois modelos é a sua resolução – bcc-1-1 tem resolução de 2,8° (aproximadamente 310km, dependendo da latitude) e o bcc-1-1m tem resolução de 1,2° (aproximadamente 133 km, dependendo da latitude).

Embora não seja uma regra clara, e existam exceções, modelos do CMIP5 com resoluções mais finas tendem a não ser incluídos no CE encontrado através dessa metodologia (Tabela 8).

O valor de CRPS decai mais lentamente para os modelos do CMIP6 e deixa de oscilar aproximadamente em 150 mil iterações. O valor final encontrado é de 0,288 para ambas as cadeias (Figura 10, A). Para o CMIP6, a CDF do conjunto final ($CMIP6_{CE}$) consegue chegar muito próxima à CDF observada (Figura 10, B). Diferentemente do caso do CMIP5, a curva inicial da média do *multi-model-ensemble* ($CMIP5_{MME}$) já captura o formato da CDF observada, embora esteja deslocada. Dentre todos os 35 modelos participantes do *multi-model-ensemble* no CMIP6, somente 15 foram aceitos para participar do conjunto final, isto é, somente 15 modelos apresentam α maior que 0 (Figura 10, C).

Contrariamente ao que acontece com o $CMIP5_{CE}$, modelos do CMIP6 com resoluções mais finas tem um desempenho superior àqueles com resoluções grosseiras (Tabela 9). Com

exceção do modelo CanESM5, modelos com resoluções maiores à 2° são descartados. Os dois modelos com melhor performance são MPI-ESM1-2-HR, do Instituto Meteorológico Max Planck e EC-Earth3, do EC-Earth Consortium. Este consórcio de instituições possui 5 modelos no *multi-model-ensemble* e o único que é descartado no conjunto final é àquele com a maior resolução (0.7°x0.7° para os aceitos contra 1.12°x1.21° para o modelo descartado).

Figura 9:Geração do conjunto final com modelos do CMIP5. (A) Evolução do CRPS, linha azul escura é a primeira cadeia, linha azul clara é a segunda cadeia; (B) CDF observada (linha preta), CDF da média do multi-model-ensemble (linha roxa escura), CDF do conjunto final (linha roxa clara). Sombreado roxo escuro são todas as CDF dos modelos do CMIP5, sombreado roxo claro são todas as CDF dos modelos escolhidos para o conjunto final. Sombreado claro está sempre contido no sombreado escuro; (C) probabilidade α de cada modelo ser aceito no conjunto final.

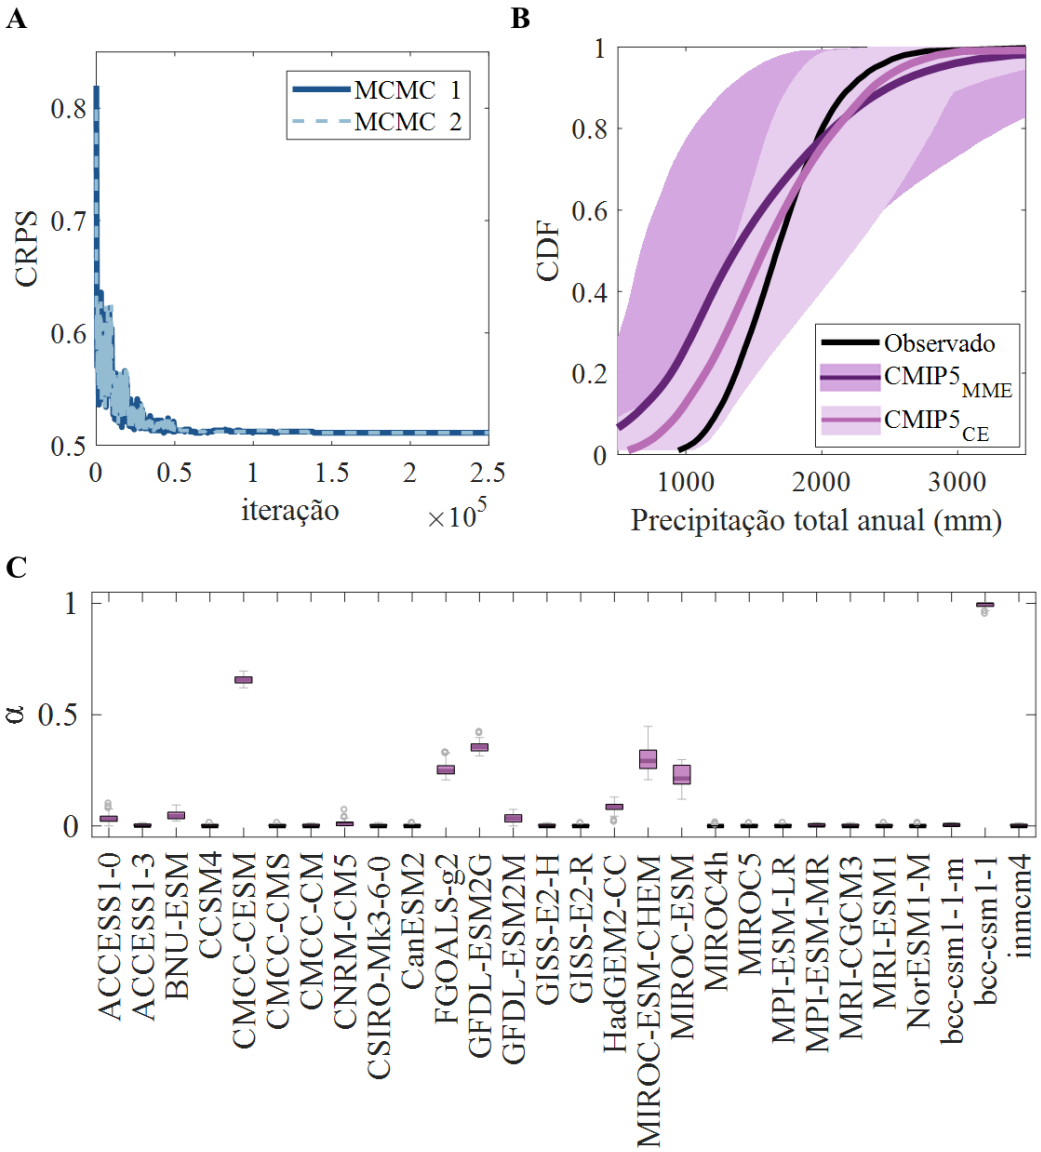

Figura 10: Geração do conjunto final com modelos do CMIP6. (A) Evolução do CRPS, linha azul escura é a primeira cadeia, linha azul clara é a segunda cadeia; (B) CDF observada (linha preta), CDF da média do multi-model-ensemble (linha verde escura), CDF do conjunto final (linha verde clara). Sombreado verde escuro são todas as CDF dos modelos do CMIP6, sombreado verde claro são todas as CDF dos modelos escolhidos para o conjunto final. Sombreado claro está sempre contido no sombreado escuro; (C) probabilidade α de cada modelo ser aceito no conjunto final.

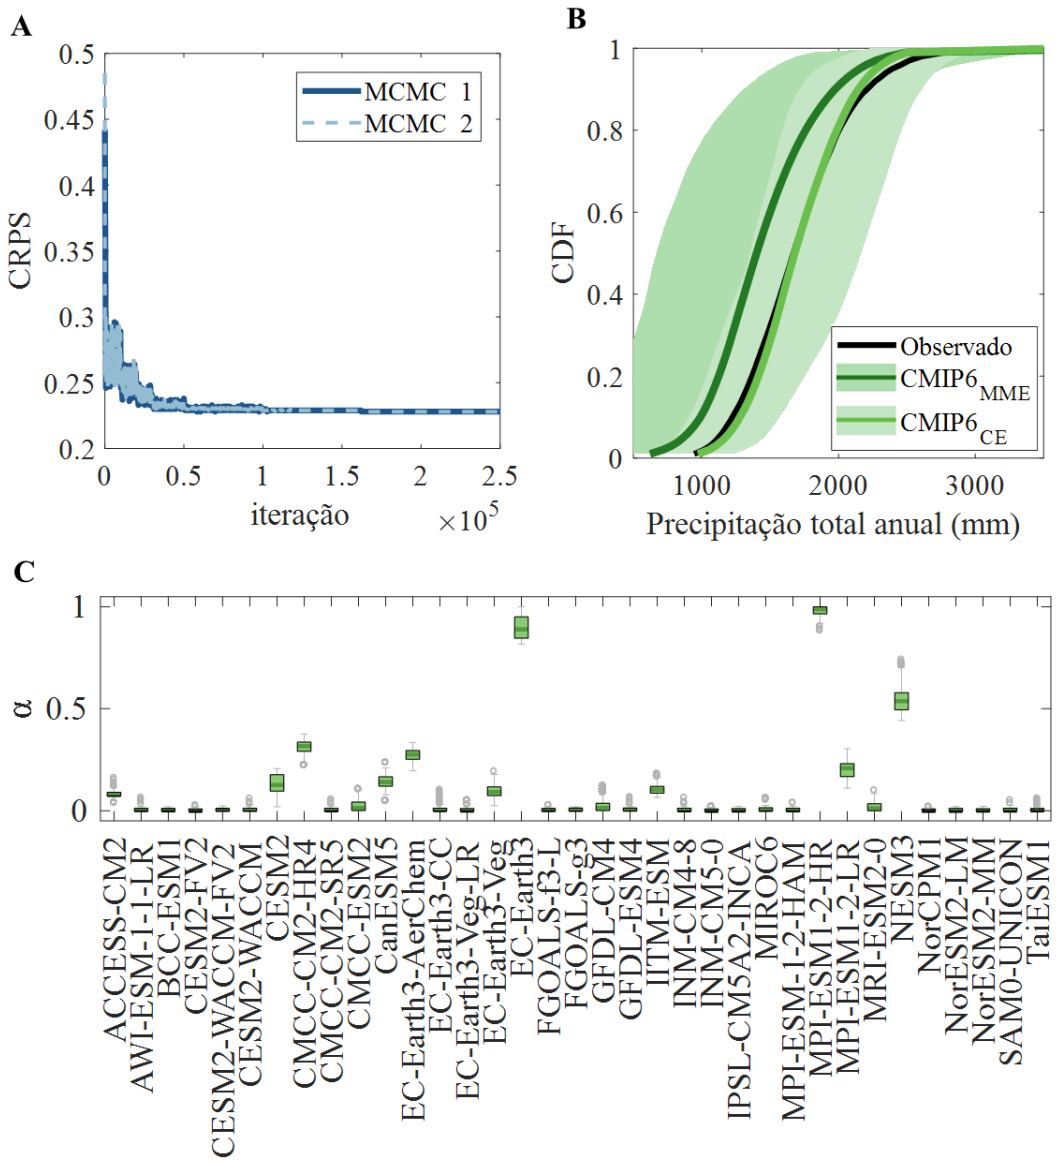

Certos modelos recebem o valor final de $\alpha = 0$ o que, na prática, quer dizer que esses modelos são descartados do conjunto final. Sendo assim, o conjunto otimizado reduz a incerteza associada à estruturação dos modelos. É preciso tomar cuidado, no entanto, uma vez que o conjunto final encontrado pode ser fruto de um viés inerente aos modelos coincidente com a observação, e não de uma melhor estruturação dos modelos (SANDERSON et al., 2021).

Tabela 8: Número de vezes que cada modelo do CMIP5 é incluído no conjunto final ($CMIP5_{CE}$) e suas resoluções

GCM	N	Tamanho do Grid (°)	GCM	N	Tamanho do Grid (°)
bcc-csm1-1-m	33	2.81°x2.79°	CNRM-CM5	0	1.40°x1.40°
CMCC-CESM	22	3.75°x3.72°	CSIRO-Mk3-6-0	0	1.87°x1.86°
GFDL-ESM2G	12	2.5°x2.02°	CanESM2	0	2.81°x2.79°
MIROC-ESM	10	2.81°x2.79°	GISS-E2-H	0	2.50°x2.00°
FGOALS-g2	8	2.81°x2.79°	GISS-E2-R	0	2.50°x2.00°
MIROC-ESM-CHEM	7	2.81°x2.79°	MIROC4h	0	0.56°x0.56°
HadGEM2-CC	3	1.87°x1.25°	MIROC5	0	1.40°x1.40°
BNU-ESM	2	2.81°x2.79°	MPI-ESM-LR	0	1.87°x1.86°
ACCESS1-0	1	1.87°x1.25°	MPI-ESM-MR	0	1.87°x1.86°
GFDL-ESM2M	1	2.50°x2.02°	MRI-CGCM3	0	1.12°x1.12°
ACCESS1-3	0	1.87°x1.25°	MRI-ESM1	0	1.12°x1.12°
CCSM4	0	1.25°x0.94°	NorESM1-M	0	2.50°x1.89°
CMCC-CM	0	0.75°x0.75°	bcc-csm1-1	0	1.12°x1.12°
CMCC-CMS	0	1.87°x1.87°	inmcm4	0	2.00°x1.50°

Tabela 9: Número de vezes que cada modelo do CMIP6 é incluído no conjunto final ($CMIP6_{CE}$) e suas resoluções

Modelo	N	Tamanho do Grid (°)	Modelo	N	Tamanho do Grid (°)
MPI-ESM1-2-HR	24	0.93°x0.93°	CESM2-WACCM-FV2	0	2.50°x1.89°
EC-Earth3	23	0.70°x0.70°	CESM2-WACCM	0	1.25°x0.95°
NESM3	14	1.87°x1.85°	CMCC-CM2-SR5	0	1.25°x0.95°
CMCC-CM2-HR4	7	1.25°x0.95°	EC-Earth3-Veg-LR	0	1.12°x1.21°
EC-Earth3-AerChem	7	0.70°x0.70°	FGOALS-f3-L	0	1.25°x1.00°
MPI-ESM1-2-LR	5	1.87°x1.85°	FGOALS-g3	0	2°x irregu-lar
CanESM5	4	2.81°x2.78°	GFDL-ESM4	0	1.25°x1.00°
IITM-ESM	3	1.87°x1.80	INM-CM4-8	0	2.00°x1.50°
ACCESS-CM2	2	1.87°x1.87°	INM-CM5-0	0	2.00°x1.50°
CESM2	2	1.25°x0.95°	IPSL-CM5A2-INCA	0	3.75°x1.89°
EC-Earth3-Veg	2	0.70°x0.70°	MIROC6	0	1.40°x1.40°
CMCC-ESM2	1	1.25°x0.95°	MPI-ESM-1-2-HAM	0	1.87°x1.85°
EC-Earth3-CC	1	0.70°x0.70°	NorCPM1	0	2.50°x1.89°
GFDL-CM4	1	1.25°x1.00°	NorESM2-LM	0	2.50°x1.89°
MRI-ESM2-0	1	1.12°x1.11°	NorESM2-MM	0	1.25°x0.95°
AWI-ESM-1-1-LR	0	1.87°x1.86°	SAM0-UNICON	0	1.25°x0.95°
BCC-ESM1	0	2.81°x2.78°	TaiESM1	0	1.25°x0.95°

4.2. MÉTRICAS DE PERFORMANCE

De uma maneira geral, modelos de clima apresentam um viés seco em todos os quatro casos (MME e CE para as duas fases do CMIP). Modelos de clima do CMIP6 são mais exatos que modelos do CMIP5. A utilização do CE pode resultar em uma melhor performance que a média do *multi-model-ensemble*, porém, por vezes o desempenho não se altera. A principal consequência de se utilizar o conjunto otimizado é o fato de ele reduzir a incerteza comparado com o *multi-model-ensemble*, uma vez que ele pode ser considerado um subconjunto dos modelos presentes no MME. O resumo das performances dos modelos de clima em termos de viés percentual pode ser verificado na Figura 11.

Figura 11: Resumo dos resultados dos índices calculados para $CMIP5_{MME}$ (primeira coluna), $CMIP5_{CE}$ (segunda coluna), $CMIP6_{MME}$ (terceira coluna) e $CMIP6_{CE}$ (quarta coluna) em termos de viés (porcentual).

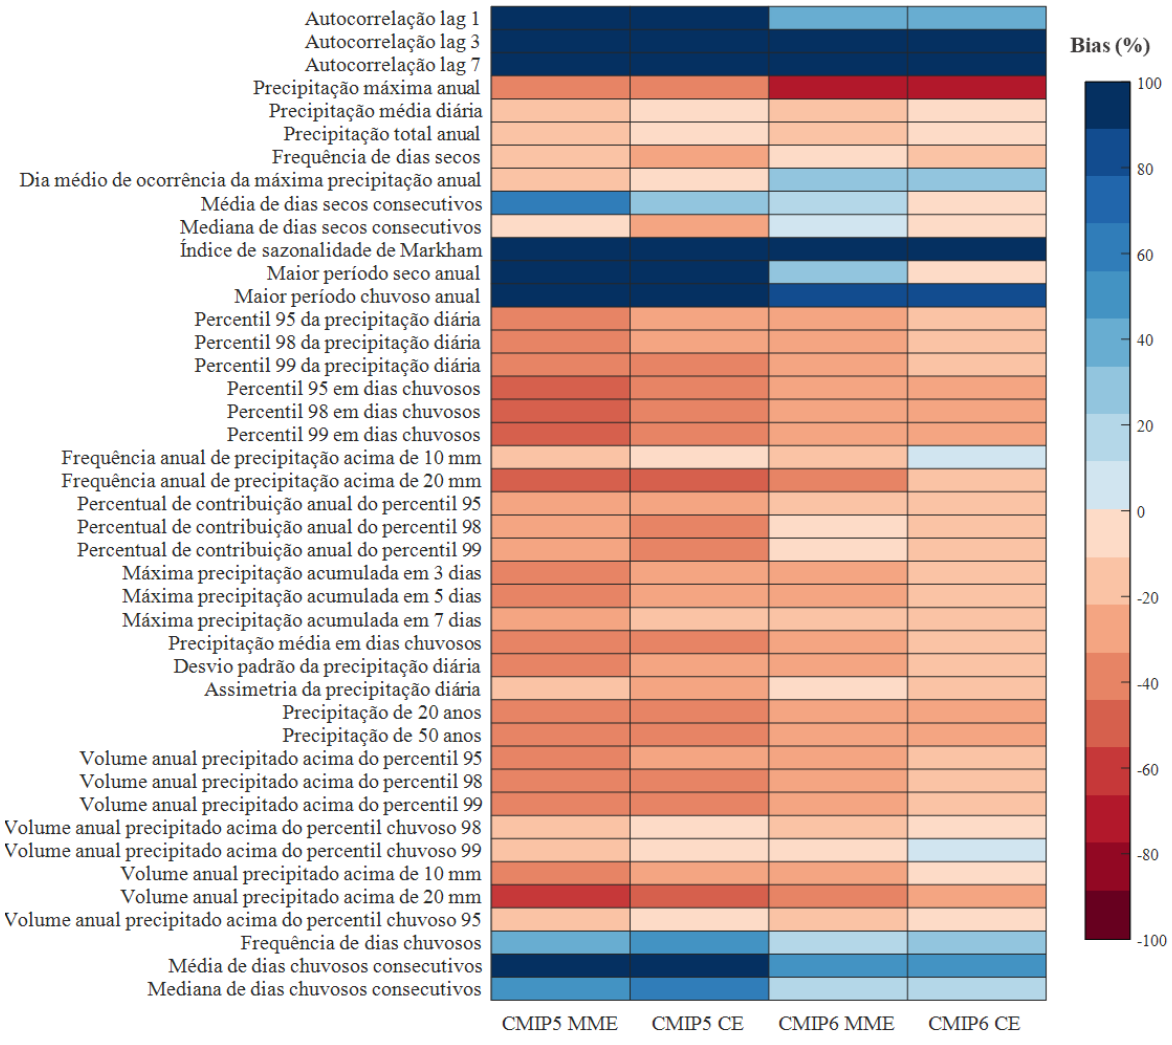

4.2.1.Aspectos marginais

O padrão espacial da precipitação total anual não é capturado por nenhum caso ($CMIP5_{MME}$, $CMIP5_{CE}$, $CMIP6_{MME}$ ou $CMIP6_{CE}$). Modelos do CMIP5 concentram o volume precipitado na porção que vai do oeste catarinense à região da Lagoa dos Patos (RS). Especialmente no caso do $CMIP5_{MME}$, existe um grande contraste entre áreas com grandes volumes precipitados e áreas mais secas. (Figura 12, A). O $CMIP5_{CE}$ reduz este contraste, embora o padrão não seja completamente perdido (Figura 12, B). O procedimento de geração do conjunto final para o CMIP5, portanto, tem um efeito de melhora na representação do padrão espacial da precipitação total anual observada. Já no caso do CMIP6, existe pouca diferença entre os padrões espaciais encontrados no $CMIP6_{MME}$ e $CMIP6_{CE}$ (Figura 12, D e E). A diferença, neste caso é na magnitude do volume precipitado. O $CMIP6_{MME}$ simula volumes menores do que o $CMIP6_{CE}$. O impacto da otimização, aqui, é a diminuição do viés seco.

Figura 12: Resultados para precipitação total anual. Padrão espacial para (A) $CMIP5_{MME}$, (B) $CMIP5_{CE}$, (D) $CMIP6_{MME}$, e (E) $CMIP6_{CE;}$ (D) QQplot para modelos de clima do CMIP5, círculos roxos escuro são $CMIP5_{MME}$, círculos roxos claro são $CMIP5_{CE}$, sombreado roxo escuro são todos os modelos do CMIP5, sombreado roxo claro são somente os modelos do CMIP5 escolhidos para o conjunto final; (F) QQplot para modelos de clima do CMIP6, círculos verdes escuro são $CMIP6_{MME}$, círculos verdes claro são $CMIP6_{CE}$, sombreado verde escuro são todos os modelos do CMIP6, sombreado verde claro são somente os modelos do CMIP6 escolhidos para o conjunto final.

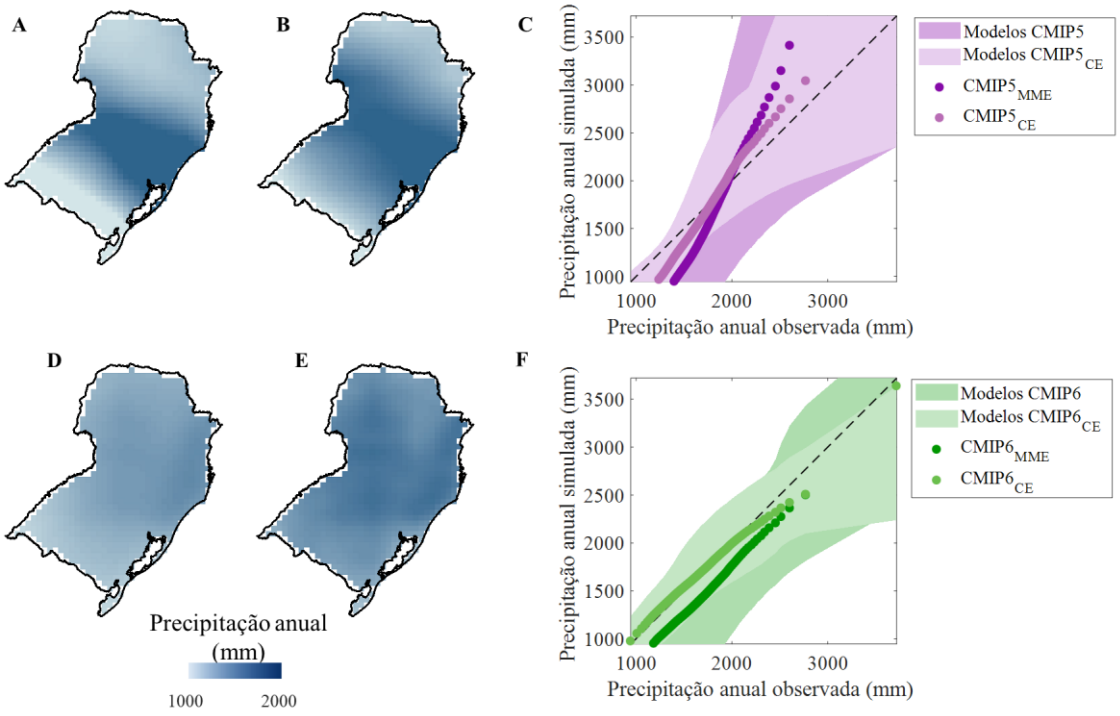

Em termos de precipitação média, ou total anual, o único caso em que a precipitação simulada é igualada à observada é para o conjunto final do CMIP6 ($CMIP6_{CE}$). Modelos do CMIP5, tanto para a média do *multi-model-ensemble* ($CMIP5_{MME}$) quanto para o conjunto final ($CMIP5_{CE}$) simulam mais frequentemente volumes baixos de precipitação anual ao passo que diminuem a representação de valores altos, acima de 2000 mm/ano (Figura 12, C). Para os modelos do CMIP6, especialmente para a média do *multi-model-ensmeble* ($CMIP6_{MME}$), a precipitação total anual é subestimada para todas as magnitudes (Figura 12, F). O *ensemble* final do CMIP6 ($CMIP6_{CE}$), no entanto, quase sobrepõe a distribuição da precipitação observada, chegando muito perto da linha 1:1.

O teste de aderência de Kolmogorov-Smirnov foi calculado pixel a pixel, na escala anual. Os resultados, em termos de porcentagem de rejeição da hipótese nula (i.e., não pertencem a mesma distribuição) podem ser verificados na Tabela 10. Aproximadamente 89% dos pixels do $CMIP5_{MME}$ não apresentam a mesma distribuição de probabilidade acumulada que a observação. Este número cai para 64,4% no $CMIP5_{CE}$, demostrando uma redução de 25,5% decorrente da escolha de quais modelos devem ser considerados no conjunto final. Os valores encontrados para os modelos do CMIP6 são inferiores àqueles encontrados no CMIP5, tanto para o MME quanto para o CE. Os modelos do CMIP6 rejeitam a hipótese de serem de uma mesma distribuição da observação em 77,5% dos pixels para o $CMIP6_{MME}$, e somente 34% dos pixels no $CMIP6_{CE.}$ Desta forma, o $CMIP6_{CE}$ é o caso que mais se aproxima da observação estatisticamente.

Tabela 10: Resultados para o teste de aderência de Kolmogorov-Smirnov

$CMIP5_{MME}$	$CMIP5_{CE}$	$CMIP6_{MME}$	$CMIP6_{CE}$
88,9%	64,4%	77,5%	34,0%

Foram computadas as correlações de Spearman entre as séries históricas simuladas pelos modelos de clima e observadas. Para todos os quatro casos, o padrão espacial da correlação segue o mesmo: existe uma maior correlação entre simulação e observação na fronteira norte do estado do Paraná que vai diminuindo em direção ao extremo sul do País (Figura 13). O padrão espacial da correlação é similar ao padrão espacial observado de sazonalidade – locais sob a influência de monções de verão apresentam uma maior correlação com os modelos de clima. Isto porque, de uma maneira geral, modelos de clima são mais sazonais. O caso que apresenta os maiores valores de correlação é àquele que também é mais sazonal: o $CMIP5_{MME}$.

Aqui, modelos do CMIP5, especialmente o $CMIP5_{MME}$, apresentam uma maior correlação em todo o território que modelos do CMIP6.

Figura 13: Correlação de Spearman entre observação e (A) $CMIP5_{MME}$, (B) $CMIP5_{CE}$, (C) $CMIP6_{MME}$ e (D) $CMIP6_{CE}$. Correlações foram computadas entre séries históricas pixel a pixel.

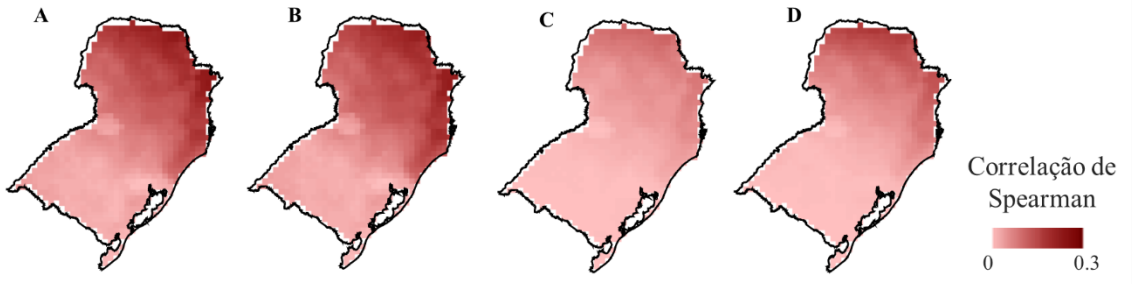

Em termos de variância, modelos de clima analisados simularam valores mais homogêneos em suas séries históricas que a observação (Figura 14, A). Modelos simulam menores valores de desvio padrão da precipitação diária em todos os casos, embora o CMIP6 apresente uma leve melhora no desempenho desta métrica. Tanto para o CMIP5 quanto para o CMIP6, o conjunto final (CE) melhora a representação da variabilidade, simulando valores brevemente maiores de desvio padrão que as médias do *multi-model-ensemble*.

Figura 14: Resultados para (A) desvio padrão da precipitação diária e (B) assimetria da precipitação diária para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel.

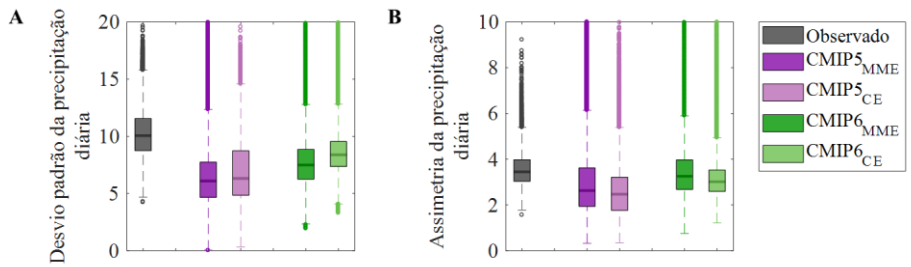

O contrário acontece para a assimetria da precipitação diária: em ambas as fases, a média do *multi-model-ensemble* simula uma distribuição mais assimétrica do que a simulada pelo conjunto final (CE) (Figura 14, B). A distribuição observada da precipitação é mais assimétrica

do que a simulada pelos modelos de clima – embora modelos do CMIP6 se aproximem mais da realidade do que os modelos do CMIP5.

Foram calculados índices de três percentis que caracterizam precipitações altas na literatura: o percentil 95, 98 e 99. Modelos de clima não capturam corretamente altas intensidades de precipitação observada, simulando sempre intensidades menores (Figura 15, A, B e C). Resultados similares foram encontrados por Eyring et al. (2020) para modelos do CMIP5 em escala regional, onde viésses progressivamente maiores foram encontrados em percentis progressivamente mais altos de precipitação.

Figura 15: Índices de percentis altos da precipitação. (A) Percentil 95 da precipitação diária, (B) percentil 98 da precipitação diária, (C) percentil 99 da precipitação diária, (D) contribuição anual de dias com precipitação acima do percentil 95, (E) contribuição anual de dias com precipitação acima do percentil 98, (F) contribuição anual de dias com precipitação acima do percentil 99 para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel, por ano. Distribuição do (G) volume anual precipitado acima do percentil 95, (H) volume anual precipitado acima do percentil 98, e (I) volume anual precipitado acima do percentil 99 para observação (linha preta), $CMIP5_{CE}$ (linha roxa) e $CMIP6_{CE}$ (linha verde).

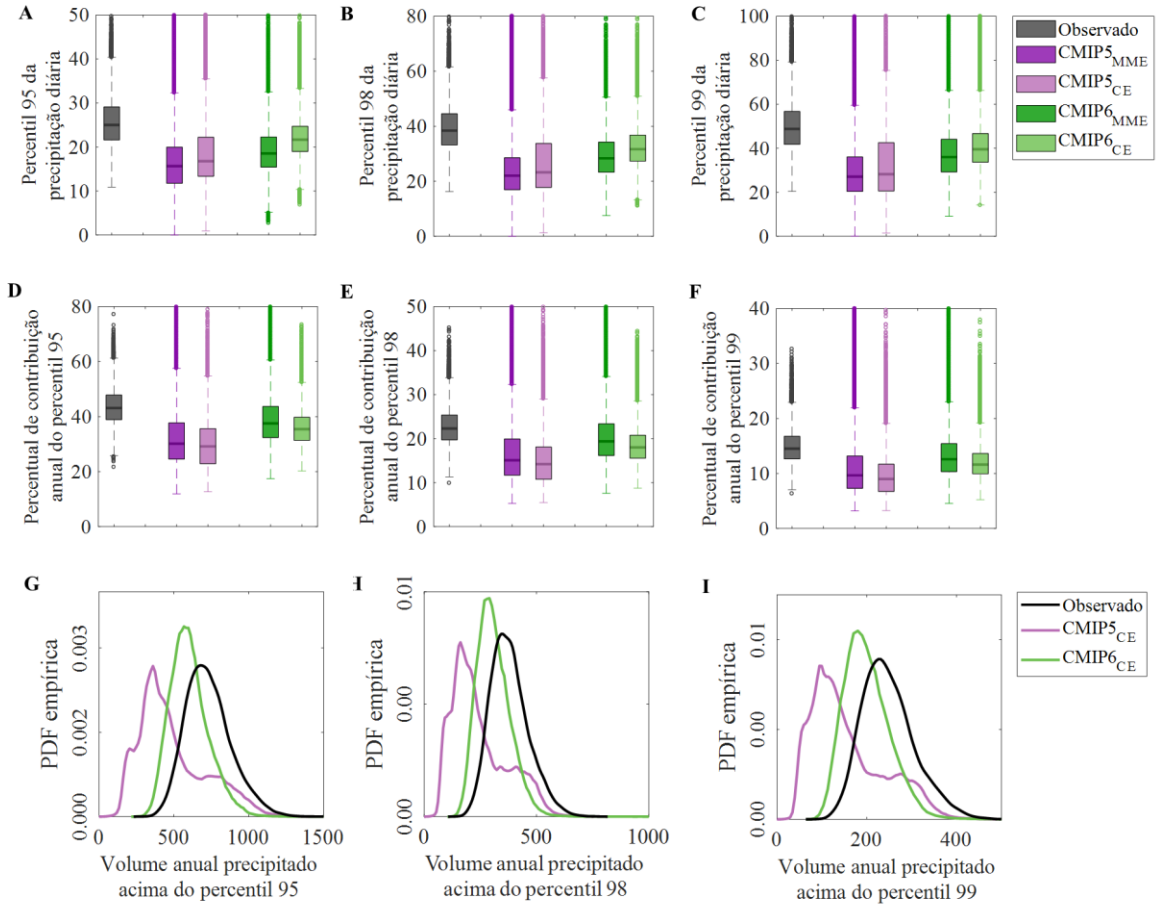

Modelos do CMIP6 tem uma melhor performance que modelos do CMIP5, e os conjuntos finais apresentam uma melhor performance que as médias do *multi-model-ensemble*. O $CMIP6_{CE}$ consegue capturar o formato da distribuição dos volumes anuais precipitados acima dos percentis 95, 98 e 99 (Figura 15, D, E e F), embora a distribuição esteja deslocada à esquerda da observada, portanto, simulando volumes menores. Já o $CMIP5_{CE}$ simula uma distribuição diferente da observada, sendo mais assimétrica e com um achatamento na cauda direita. Consequentemente, o percentual do volume precipitado anual atribuído aos dias acima dos percentis (Figura 15, G, H e I) seguem o mesmo padrão. Modelos do CMIP6 se aproximam mais da realidade que modelos do CMIP5, especialmente no caso do percentil 95 e 98.

Como consequência da incapacidade dos modelos de clima de simular percentis altos, todas as métricas que caracterizam extremos são, também, prejudicadas. Foram calculadas precipitações extremas com tempos de retorno de 20 e 50 anos (Figura 16). Novamente, modelos de clima do CMIP6 performam melhor que modelos do CMIP5. Aqui, no entanto, não existe um grande impacto do processo de otimização, especialmente no caso do CMIP5. $CMIP5_{MME}$ e $CMIP5_{CE}$ não apresentam diferença para este índice, salvo a presença de valores *outliers* que é maior no $CMIP5_{MME}$. Similarmente, a diferença entre o $CMIP6_{MME}$ e $CMIP6_{CE}$ para precipitações extremas é o tamanho do quadrante inferior (25), indicando que o $CMIP6_{CE}$ chega a simular valores inferiores aos simulados pelo $CMIP6_{MME}$.

Figura 16: Resultados para precipitações extremas com tempos de retorno de (A) 20 anos, e (B) 50 anos para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel.

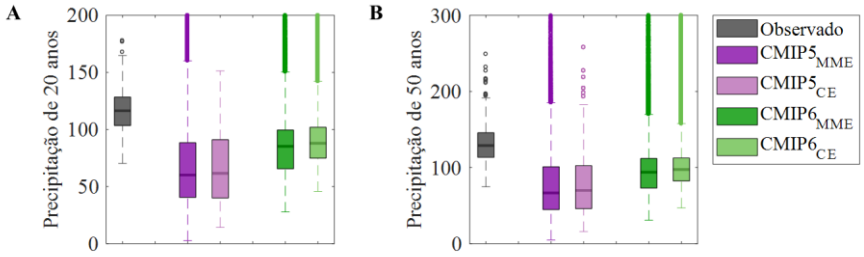

Embora os limiares de 10 mm/d e 20 mm/d sejam representantes de precipitações altas e muito altas respectivamente (ZHANG et al., 2011), no caso do sul do Brasil estes limiares não encontram-se nos extremos da distribuição,– especialmente o limiar de 10mm/d. Tanto

para a frequência anual de dias com precipitação acima de 10mm, quanto para dias com precipitação acima de 20mm, modelos do CMIP6 conseguem se aproximar da frequência observada, embora estejam ainda levemente descoladas para a baixo, simulando frequências menores (Figura 17, A e B). Para a métrica de R10, no entanto, $CMIP6_{CE}$ simula frequência acima da observada. Os volumes anuais precipitados acima dos limiares de 10 e 20 mm/d (Figura 17, C e D) simulados pelos modelos de clima são menores dos observados, para os quatro casos. O formato da distribuição deste índice é capturado pelos modelos do CMIP6, ao passo que, para os modelos do CMIP5, a distribuição é distorcida.

Figura 17: Resultados da frequência anual de ocorrência de dias com precipitações (A) acima de 10mm/d, e (B) acima de 20 mm/d, e volumes anuais precipitados acima de (C) 10mm/d, e (D) 20mm/d para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por ano, por pixel.

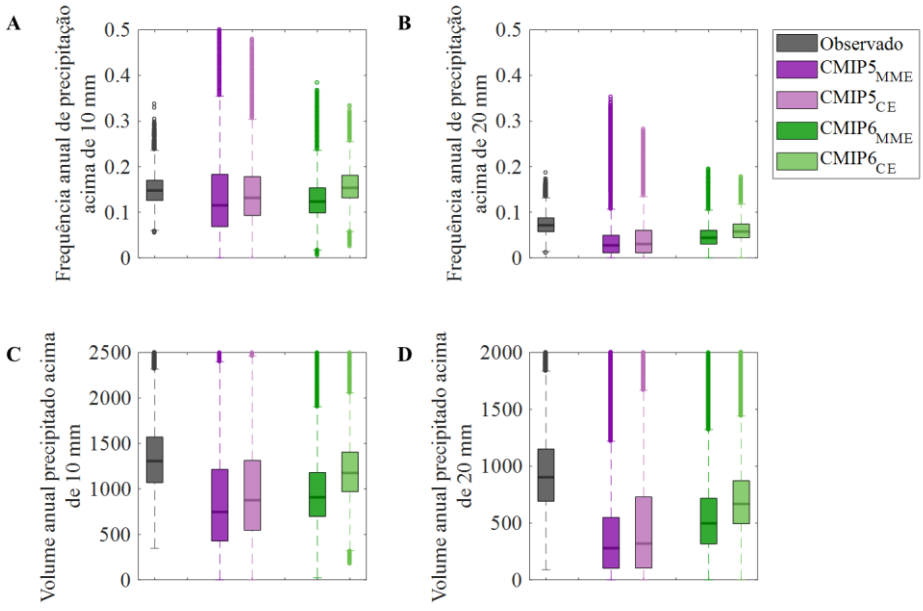

De uma maneira geral, modelos de clima simulam com maior frequência dias chuvosos (Figura 18, A). No entanto, existe uma clara melhora na performance dos modelos do CMIP6 quando comparados aos do CMIP5. Curiosamente, para ambas as fases, as médias do *multi-model-ensemble* performam melhor que os conjuntos finais (CE). Embora os modelos simulem dias chuvosos com maior frequência, tanto a precipitação média quanto a precipitação média em dias chuvosos nunca são maiores que as observadas (Figura 18, B e C). Portanto, precipi-

tações simuladas pelos modelos de clima são menos intensas e mais frequentes que a observação, e consequentemente apresentam uma menor variabilidade (Figura 14, B). Não existe diferença entre a precipitação média em dias chuvosos simulada pelo $CMIP5_{MEE}$ e $CMIP5_{CE}$.

Figura 18: Resultados para (A)frequência anual de dias chuvosos, (B) precipitação média em dias chuvosos, (C) precipitação diária, (D) percentil 95 da precipitação em dias chuvosos, (E) percentil 98 da precipitação em dias chuvosos, (F) percentil 99 da precipitação em dias chuvosos para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por ano, por pixel. Distribuição do (G) volume anual precipitado acima do percentil chuvoso 95, (H) volume anual precipitado acima do percentil chuvoso 99, e (I) volume anual precipitado acima do percentil chuvoso 99, para observação (linha preta), $CMIP5_{CE}$ (linha roxa) e $CMIP6_{CE}$ (linha verde).

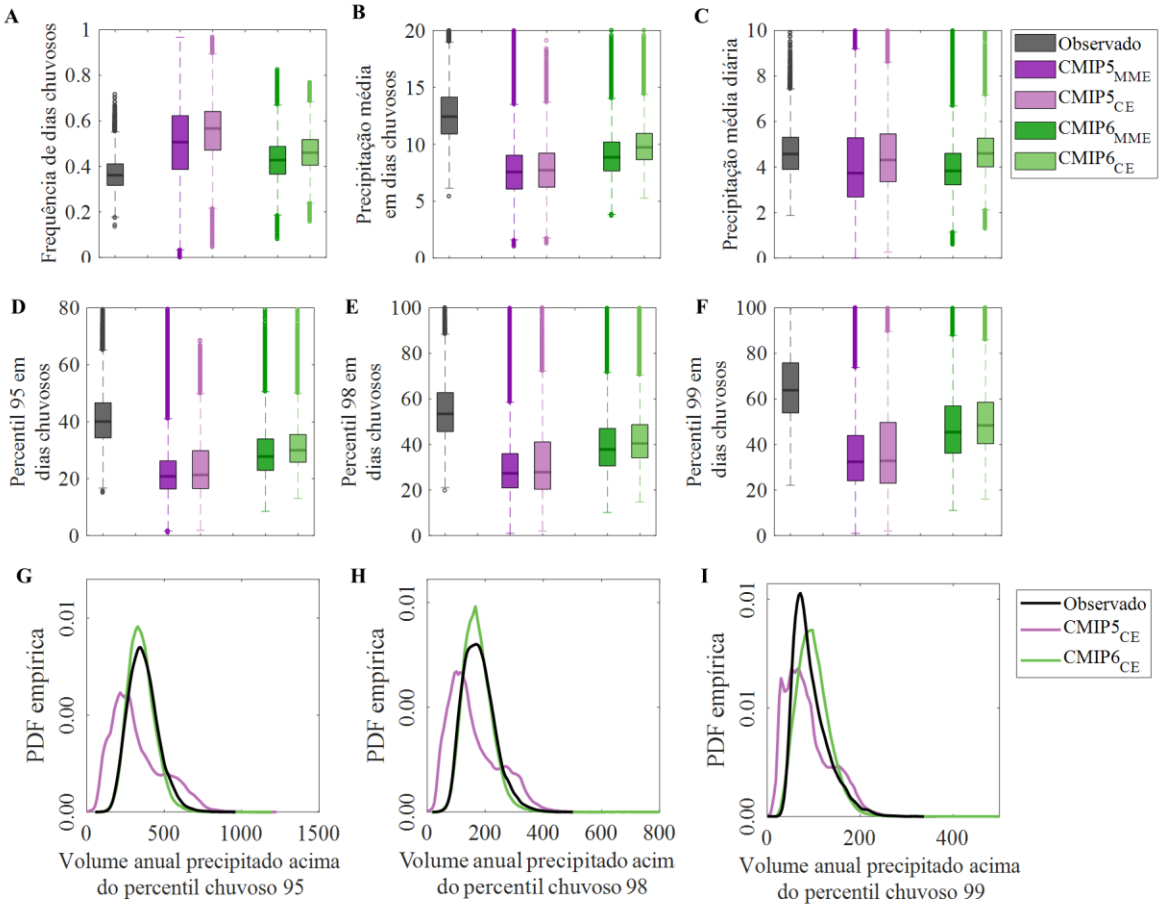

Similarmente aos índices de precipitação alta, os percentis chuvosos 95, 98 e 99 simulados pelos modelos de clima tem intensidades menores (Figura 18, D, E e F). Existe uma maior variabilidade na simulação dos percentis altos de dias chuvosos no $CMIP5_{CE}$ do que no

$CMIP5_{MME}$, o que pode indicar que o contraste entre localidades (i.e., pixels) é maior. As distribuições dos volumes anuais precipitados (Figura 18, G, H e I) simuladas pelo $CMIP6_{CE}$ se assemelham àquelas observadas, especialmente no caso do volume anual precipitado acima dos percentis 95 e 98. No entanto, as distribuições do $CMIP6_{CE}$ estendem a cauda superior além dos valores observados e, no caso do volume anual precipitado acima do percentil chuvoso 99, a distribuição é levemente assimétrica à direita. As distribuições do $CMIP5_{CE}$, similarmente ao que acontece para os volumes acima de percentis altos, são distorcidas – embora de uma maneira suavizada. É possível notar que o os volumes precipitados anualmente acima dos percentis chuvosos para o $CMIP5_{CE}$ são sempre menores, ao passo que o $CMIP6_{CE}$ consegue simular valores similares aos observados.

4.2.2.Aspectos temporais

A autocorrelação pode ser utilizada para determinar dependência temporal de curto prazo. Aqui, foi calculado a autocorrelação de 1 dia, 3 dias e 7 dias. As autocorrelações de 1 e 3 indicam a dependência diária da precipitação, e já a autocorrelação de 7 dias indica a dependência temporal em uma escala semanal. Todos os modelos de clima têm uma maior correlação para todos os lags, embora o CMIP6 apresente valores menores do que os modelos do CMIP5. O $CMIP5_{CE}$ é àquele com maior autocorrelação de lag 1 dia, seguido do $CMIP5_{MME}$ e dos modelos do CMIP6 (Figura 19, A). A autocorrelação cai entre os lags de 1 e 3 dias para todos os casos, e continua ligeiramente constante entre os lags de 3 e 7 dias para os modelos de clima (Figuras 19, B e C). Para o lag de 7 dias, a autocorrelação observada beira o valor de 0, os modelos do CMIP6 apresentam valores abaixo de 0,1 enquanto para os modelos do CMIP5, ainda existe uma dependência maior.

Figura 19: Resultados de autocorrelação com lag de (A) 1 dia, (B) 3 dias e (C) 7 dias para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel.

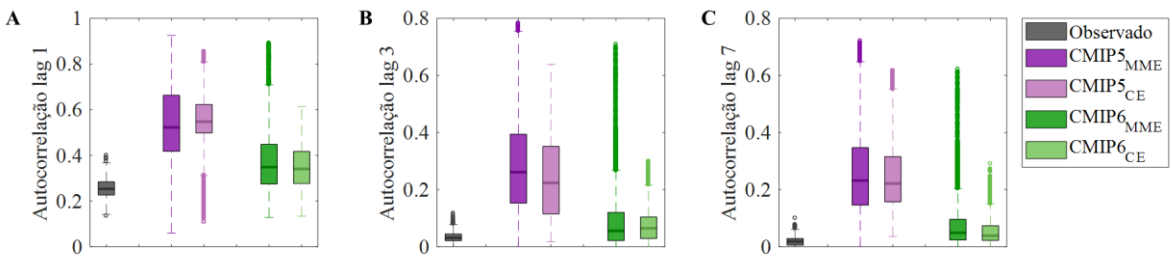

Modelos de clima têm, no geral, um ciclo mais sazonal que a observação (Figura 20, A). Tanto o $CMIP5_{MME}$ quanto o $CMIP5_{CE}$ apresentam uma grande dificuldade em representar o ciclo anual real. Modelos do CMIP5 simulam verões chuvosos e invernos secos, ao passo que a precipitação é na realidade bem distribuída ao longo do ano. Modelos do CMIP6 apresentam uma superioridade de desempenho na simulação do ciclo anual, especialmente nos meses entre maio e setembro, onde modelos do CMIP5 mal conseguem alcançar o mínimo observado. No caso do CMIP5, não existe muita diferença entre o $CMIP5_{MME}$ e $CMIP5_{CE}$, ao passo que o $CMIP6_{CE}$ representa melhor os valores de precipitação mensal que o $CMIP6_{MME}$.

Figura 20: Resultados para ciclo sazonal. (A) Ciclo anual, observado (linha preta, sombreado cinza são todos os ciclos anuais observados) e simulado pelo $CMIP5_{MME}$ (barras roxas escuro), $CMIP5_{CE}$ (barras roxas claro), $CMIP6_{MME}$ (barras verdes escuro) e $CMIP6_{CE}$ (barras verdes claro), error bar são todos os ciclos anuais simulados; (B) Índice de sazonalidade de Markham para Observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel; e padrão espacial do índice de sazonalidade de Markham para (C) observação, (D) $CMIP5_{MME}$, (E) $CMIP5_{CE}$, (D) $CMIP6_{MME}$, e (F) $CMIP6_{CE}$.

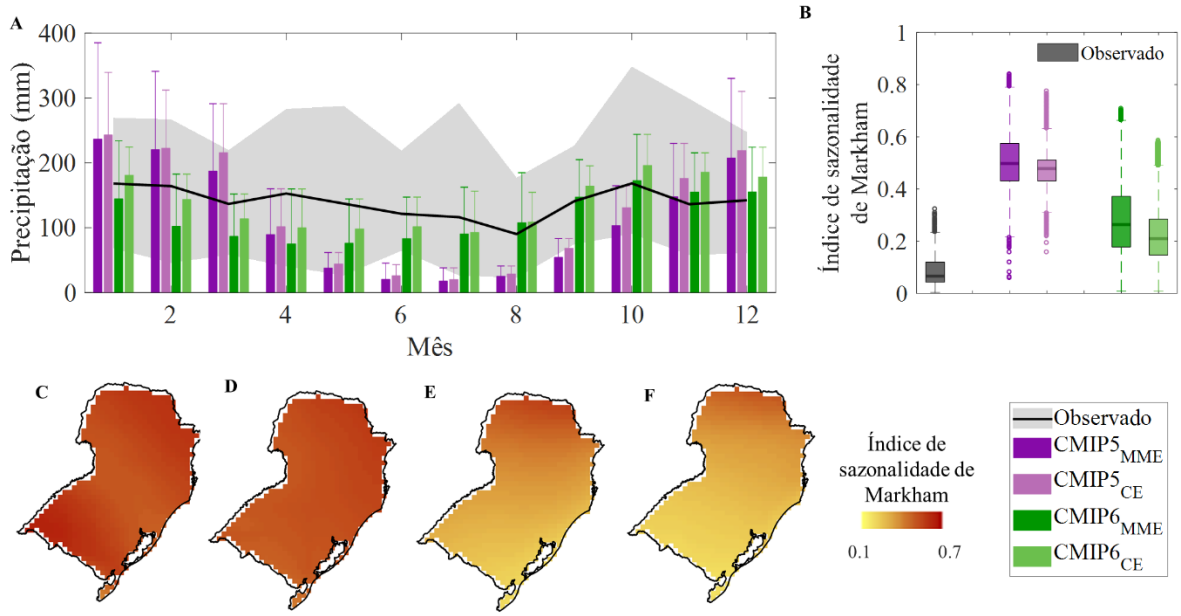

Consequentemente à representação do ciclo anual, o índice de sazonalidade de Markham simulado pelos modelos de clima é sempre maior do que aquele observado (Figura 20, B). O caso que mais se aproxima da realidade é o $CMIP6_{CE}$, e, novamente, modelos de CMIP5 ficam bastante longe do índice sazonal observado. O mesmo pode ser visto na distri-

buição espacial da sazonalidade, onde modelos do CMIP5 apresentam altos índices de sazonalidade por todo o território (Figura 20, C e D). É interessante notar, no entanto, que no caso do $CMIP5_{MME}$, os locais onde se concentram os menores índices de sazonalidade são, também, os locais onde há concentração de volume precipitado. Não existe grande diferença entre a distribuição espacial da sazonalidade entre o $CMIP6_{MME}$ e o $CMIP6_{CE}$ (Figura 20, E e F), embora os valores absolutos do $CMIP6_{CE}$ sejam menores e, consequentemente, mais próximos da realidade. A distribuição espacial da sazonalidade para os modelos do CMIP6 se aproxima da realidade, embora suavizadas, concentrando maiores valores na fronteira norte do Paraná e valores menores gradativamente ao sul.

Contrariamente ao que ocorre nos índices marginais de precipitações altas, para a precipitação máxima anual, modelos do CMIP5 têm um melhor desempenho do que modelos do CMIP6 (Figura 21, A). Não existe diferença nas simulações de máximas anuais do $CMIP6_{MME}$ e $CMIP6_{ME}$, e ambos simulam valores consideravelmente inferiores à observação. Para esta métrica, o $CMIP5_{MME}$ é o que mais se aproxima da realidade. O mesmo acontece no caso do dia médio de ocorrência do máximo anual (Figura 21, B). Aqui, modelos do CMIP6 erram o dia médio por aproximadamente 2 meses, ao passo que modelos do CMIP5 simulam corretamente o mês em que ocorre, na média, o dia do máximo anual (junho).

Valores máximos anuais de precipitação acumulada foram calculados para os períodos de 3, 5 e 7 dias. Para os três índices, modelos do CMIP6 apresentam uma melhora no desempenho quando comparados aos modelos do CMIP5. Dentre os três índices, o caso em que há uma distância mais evidente entre observação e simulação é no caso da precipitação máxima acumulada de 3 dias (Figura 21, C). No caso da máxima precipitação acumulada de 5 dias, $CMIP6_{MME}$ consegue capturar o valor observado e o $CMIP6_{CE}$ consegue ultrapassá-lo ligeiramente (Figura 21, D). No caso da máxima precipitação acumulada anual de 7 dias, valores simulados pelo $CMIP5_{CE}$ se aproximam dos simulados pelo $CMIP6_{MME}$, embora o primeiro apresente uma maior variabilidade. O caso em que mais se assemelha à realidade é o $CMIP6_{CE}$. Similarmente ao que ocorre nos percentis chuvosos de precipitações altas, o $CMIP5_{CE}$ apresenta uma maior variabilidade espacial que o $CMIP5_{MME}$ em todas as métricas de precipitações máximas anuais, acumuladas ou não.

Figura 21: Resultados para índices temporais de precipitação extrema. (A) Precipitação total anual, (B) dia médio da ocorrência do máximo anual, (C) máxima precipitação acumulada de 3 dias anual, (D) máxima precipitação acumulada de 5 dias anual, e (E) máxima precipitação acumulada de 7 dias anual para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por ano, por pixel – salvo (B), onde resultados são por pixel.

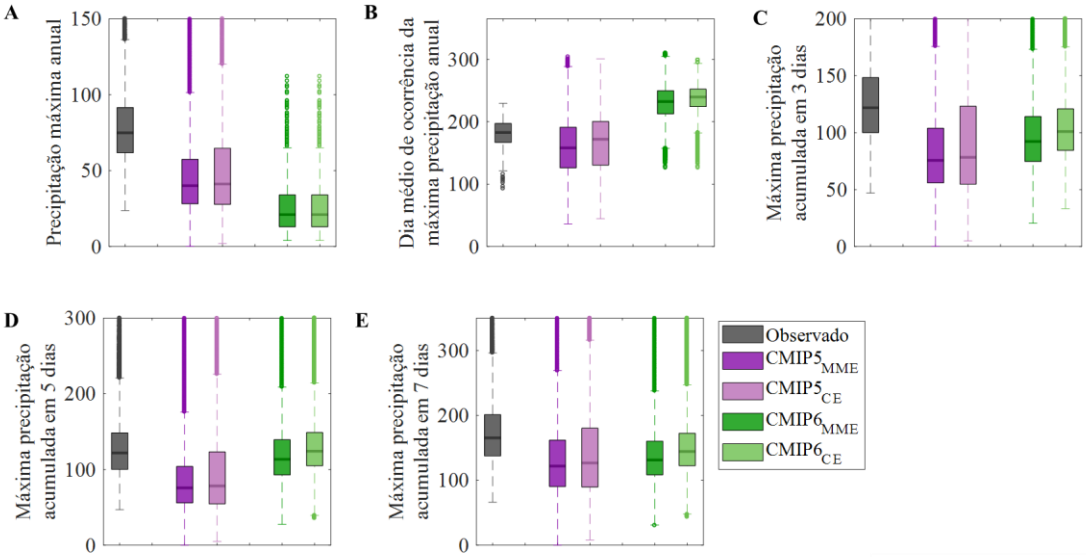

As distribuições de dias secos e chuvosos consecutivos simuladas pelos modelos de clima conseguem se aproximar do formato das distribuições observadas, especialmente no intervalo entre 2 e 15 dias. Existe pouca diferença entre o MME e CE, para ambas as fases do CMIP. Particularmente no caso de dias secos consecutivos, modelos do CMIP6 apresentam um maior desempenho na simulação da distribuição. Modelos do CMIP5 simulam maiores frequências de intervalos curtos, como 2-3, para dias secos consecutivos (Figura 22, A). Além disso, $CMIP5_{CE}$ exagera na simulação do maior período seco anual (Figura 22 C). $CMIP5_{CE}$ consegue simular períodos secos muito longos, podendo ultrapassar a marca de 80 dias. O mesmo não ocorre para o $CMIP6_{CE}$ que, embora ainda simule períodos secos mais cumpridos que os observados, consegue grosseiramente capturar a distribuição dos maiores períodos secos anuais (Figura 22, E).

Embora os modelos de clima consigam capturar o formato da distribuição dos dias chuvosos consecutivos, as frequências observadas não são corretamente simuladas. Modelos tendem a simular menos frequentemente intervalos curtos, ao passo que simulam maiores intervalos a partir de 7 dias (Figura 22, B). Similarmente à frequência de dias secos, modelos de

clima simulam períodos de dias chuvosos consecutivos maiores que aqueles observados. Assim como no caso do maior período seco anual, $CMIP5_{CE}$ consegue aglomerar dias chuvosos temporalmente, fazendo com que a simulação do maior período chuvoso anual seja inverossímil (Figura 22, F).

Figura 22: Resultados para dias consecutivos. Frequência de (A) dias secos consecutivos, e (B) dias chuvosos consecutivos para observação (barras pretas), $CMIP5_{MME}$ (barras roxas escuro), $CMIP5_{CE}$ (barras roxas claro), error bars são todos os modelos do CMIP5, $CMIP6_{MME}$ (barras verdes escuro) e $CMIP6_{CE}$ (barras verdes claro), error bars são todos os modelos do CMIP6. Média de (C) dias secos consecutivos e (D) dias chuvosos consecutivos para observação (caixa preta), $CMIP5_{MME}$ (caixa roxa escura), $CMIP5_{CE}$ (caixa roxa clara), $CMIP6_{MME}$ (caixa verde escura) e $CMIP6_{CE}$ (caixa verde clara). Caixas são resultados por pixel. Distribuição do (E) maior período anual de dias secos consecutivos e (F) maior período anual de dias chuvosos consecutivos para observação (linha preta), $CMIP5_{CE}$ (linha roxa) e $CMIP6_{CE}$ (linha verde)

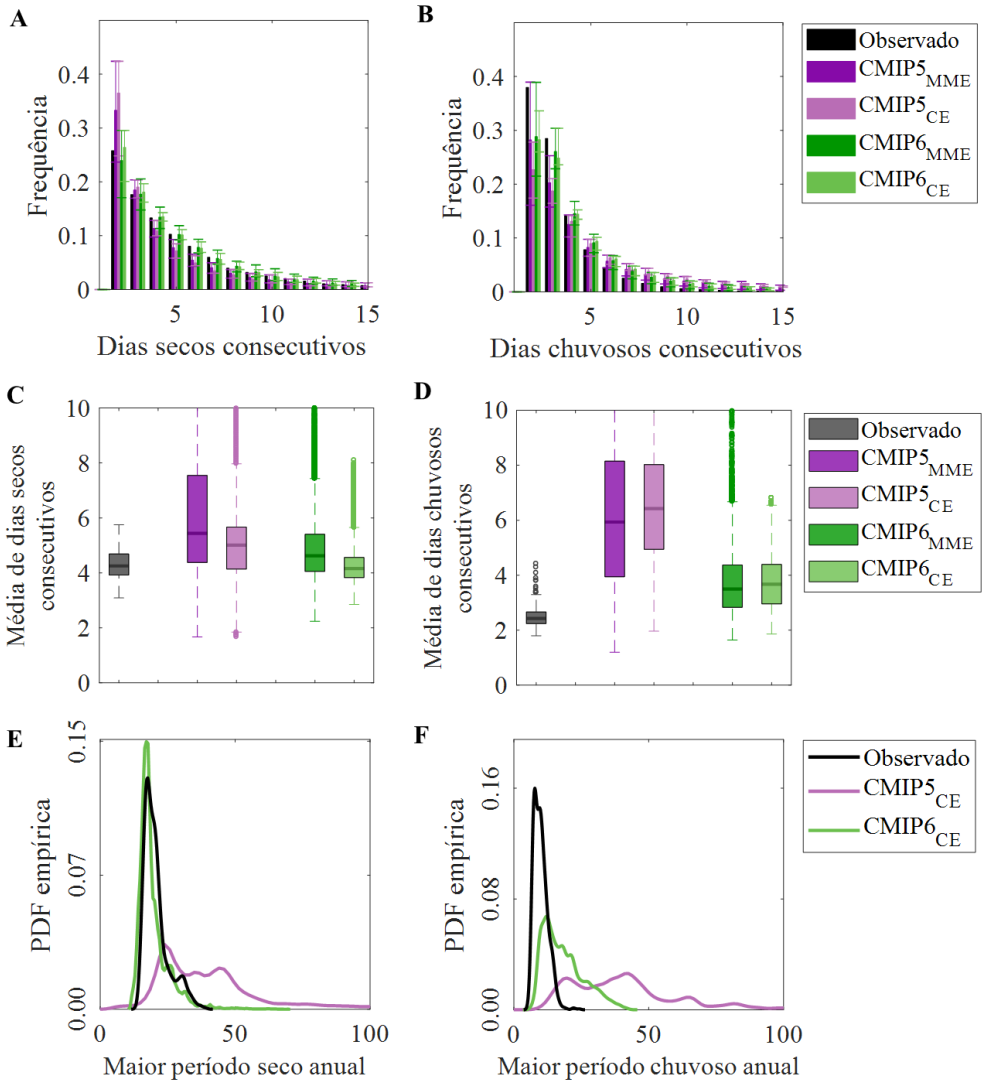

O fato de modelos do CMIP5 simularem períodos secos e chuvosos muito longos interfere na média de dias secos e chuvosos consecutivos (Figura 22, C e D). Isto porque a média é muito sensível à presença de *outliers*, portanto, resultando em valores que não são realistas. No caso do CMIP5 portanto, uma métrica mais adequada seria a mediana, que não sofre tanto com a presença de valores *outliers*. Como $CMIP6_{CE}$ se aproxima mais das distribuições dos maiores períodos secos anuais, ele também consegue simular com maior desempenho valores médios de dias secos e chuvosos consecutivos.

4.2.3.Aspectos espaciais

Os resultados encontrados através dos correlogramas traçados sugerem que a área total utilizada neste trabalho ainda é muito pequena para encontrar resultados robustos de dependência espacial. Isto porque, especialmente no caso da correlação espacial (Figura 23, A), não foi encontrado um padrão claro de decaimento da curva e, consequentemente, a partrir de qual distância um pixel deixa de afetar em outro. Idealmente, portanto, a abrangência espacial deveria ser expandida.

Figura 23: Correlogramas de (A) correlação de Spearman, (B) informação mútua de ocorrência de dias chuvosos, e (C) informação mútua de excedência do percentil 95 da precipitação diária para observação. Linhas foram obtidas através de regressão polinomial local de 2 grau para observação (linha preta), $CMIP5_{MME}$ (linha roxa escuro), $CMIP5_{CE}$ (linha roxa claro), $CMIP6_{MME}$ (linha verde escuro), e $CMIP6_{CE}$ (linha verde claro). Círculos cinza são todos as correlações observadas, círculos roxos são todas as correlações simuladas pelos modelos do CMIP5 e círculos verdes são todas as correlações simuladas pelos modelos do CMIP6.

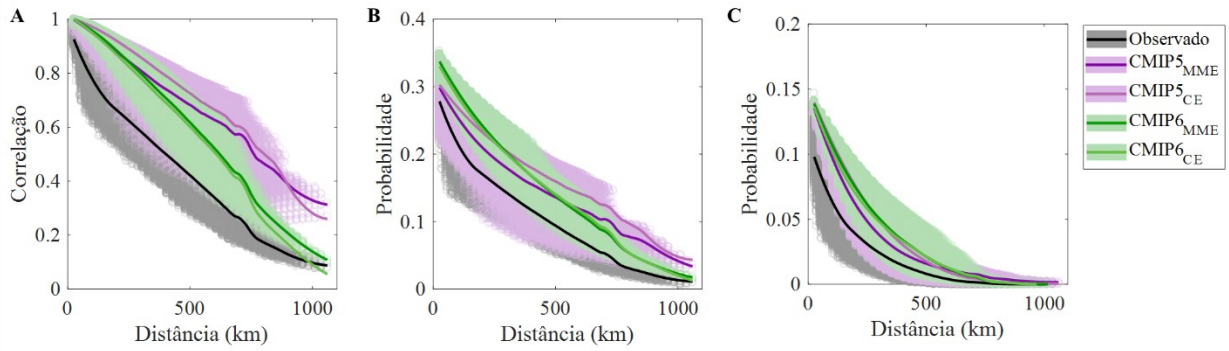

Em todos os correlogramas traçados, os modelos de clima analisados apresentam uma relação espacial mais forte entre localidades que a observação. Isto pode ser devido à resolução

grosseira dos modelos de clima, que simulam uma transição mais suave entre localidades que a observação, com uma resolução mais fina. Em todos os três correlogramas, existe pouca diferença entre o $CMIP6_{MME}$ e o $CMIP6_{CE}$.

Para caracterizar as relações de dependência espacial gerais, as correlações de Spearman entre pixels crescentemente mais distantes foram calculadas (Figura 23, A). A curva observada decai com uma maior inclinação que as curvas dos modelos de clima. Aqui, $CMIP6_{MME}$, $CMIP6_{CE}$, e $CMIP5_{MME}$ simulam curvas muito próximas em distâncias até 250km, e, a partir deste ponto, modelos do CMIP6 decaem mais à uma taxa maior. Ao longo de toda a área de estudo, a curva simulada pelo $CMIP5_{CE}$ é a que apresenta uma maior correlação espacial entre localidades.

Para determinar relações espaciais mais específicas entre localidades, foram calculados os índices de informação mútua para ocorrência de dias chuvosos (dias com precipitação ≥ 1mm) e excedência de precipitações altas (aqui, foi utilizado o limiar do percentil 95). Quanto mais próximo de 0, menor a influência da ocorrência de um fenômeno de um pixel em outro. Para o caso da ocorrência de dias chuvosos, o padrão das curvas encontradas foi similar ao padrão visto na correlação espacial tanto para a observação, quanto para as curvas do CMIP6 (Figura 23, B). A curva do $CMIP5_{MME}$ começa como a mais próxima à observação até a distância de aproximadamente 500km, onde é ultrapassada pelas curvas do CMIP6. O decaimento das curvas do CMIP6 acontece à uma taxa maior que das curvas do CMIP5, as curvas do CMIP6 se aproximam ao formato da curva observada.

Para determinar a influência da ocorrência de uma precipitação alta em um pixel em outro, foi calculada a informação mútua de excedência do percentil 95 (Figura 23, C). Aqui, o padrão das curvas muda e os valores encontrados são baixos, próximos de 0. As curvas apresentam um formato de dependência mais claro, que se assemelham às curvas de decaimento exponencial. Os valores baixos encontrados sugerem uma dependência fraca, indicando que não existe grande influência da ocorrência de precipitações altas de pixel em outro. No caso da observação, isto pode ser devido às mudanças abruptas na topografia, gerando diferentes mecanismos de geração de precipitação (e.g., chuva frontal). Devido à resolução mais grosseira dos modelos de clima, nuances como estas não são capturadas e a dependência espacial tende a ser, de fato, maior. Aqui, todos os quatro casos apresentam curvas muito similares entre si, embora a curva do $CMIP5_{MME}$ seja ligeiramente mais próxima da observada em algumas distâncias.

5. CONCLUSÕES

Este trabalho teve como objetivo analisar de maneira sistemática a precipitação simulada por modelos de clima para o sul do Brasil. O desempenho foi testado através de métricas referentes aos aspectos marginais, temporais e espaciais da precipitação entre fases do CMIP, bem como entre o MME e CE. A região sul foi escolhida por ser uma área desafiadora de ser simulada pelos modelos de clima, devido à sua complexa topografia, diferentes mecanismos de geração de precipitação e diferentes regimes sazonais. De uma maneira geral, foi encontrado que viés seco na precipitação simulada, com valores inferiores àqueles observados. Modelos têm dificuldade na simulação da sazonalidade, tendendo a aglomerar a precipitação tanto temporal quanto espacialmente.

Foram encontradas correlações fracas entre os modelos de clima analisados e a observação, embora o CMIP5 apresente maiores correlações que o CMIP6. Os modelos simulam precipitação inferiores à observada, com menores volumes totais precipitados e mais dias chuvosos (dias com precipitação $\geq$ 1mm/d), fazendo com que precipitações baixas sejam simuladas com maior frequência. Salvo o $CMIP6_{CE}$, modelos simulam volumes anuais precipitados menores. Embora a variabilidade simulada seja menor que a observada para todos os modelos, os do CMIP6 se aproximam mais da realidade que os modelos da fase anterior. Especialmente para precipitações altas, existe um viés seco que persiste entre fases e entre o MME e CE.

Modelos do CMIP5 não capturaram a sazonalidade observada, simulando invernos secos e verões chuvosos enquanto os do CMIP6 apresentam uma melhor representação do ciclo anual, simulando uma precipitação mais bem distribuída ao longo dos meses. O padrão espacial da sazonalidade é, também, capturado pelos modelos do CMIP6 – maiores sazonalidades são encontradas na fronteira norte do estado do Paraná, e valores vão gradativamente diminuindo rumo à fronteira sul do País. Modelos do CMIP5 apresentam uma particular dificuldade em representar a distribuição espacial da precipitação anual, com o $CMIP5_{MME}$ concentrando maiores volumes na porção central e, embora esse padrão seja suavizado no $CMIP5_{CE}$, ele não é completamente perdido. Modelos do CMIP6 distribuem espacialmente a precipitação, chegando mais perto do padrão observado. De uma maneira geral, modelos de clima analisados apresentam uma maior dependência espacial que a observada, e não há muita diferença entre fases do CMIP, nem entre MME e CE.

Este trabalho demostra uma análise sistemática do desempenho dos modelos de clima. Mesmo para o caso do conjunto com melhor performance ($CMIP6_{CE}$), os resultados demonstram uma limitação dos modelos de clima em capturar características da precipitação observada, como sazonalidade, dependência espacial e eventos extremos. Diferentes metodologias de obtenção de um conjunto ótimo devem ser testadas, especialmente àquelas que ajustam mais de uma variável simultaneamente. Da mesma forma, métodos de correção de escala podem ser considerados para ajustar simulações dos modelos de clima à observação. A utilização de modelos de clima em estudos de impacto às mudanças climáticas deve ser feita de maneira cuidadosa. A incerteza associada à estruturação dos modelos deve ser levada em consideração, bem como a performance desses modelos em representar corretamente a variável estudada.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ADDOR, N.; ROHRER, M.; FURRER, R.; SEIBERT, J. Propagation of biases in climate models from the synoptic to the regional scale: Implications for bias adjustment. *Journal of Geophysical Research*, v. 121, n. 5, p. 2075–2089, 2016.

AGHAKOUCHAK, A.; CHENG, L.; MAZDIYASNI, O.; FARAHMAND, A. Global warming and changes in risk of concurrent climate extremes: Insights from the 2014 California drought. *Geophysical Research Letters*, v. 41, n. 24, p. 8847–8852, 2014.

AMORIM, P. B. DE; BORGES CHAFFE, P. L. Integrating climate models into hydrological modelling : What ' s going on in Brazil ? *Brazilian Journal of Water Resources*, p. 1–17, 2019.

BARREIRO, M.; DÍAZ, N. Land-atmosphere coupling in El Niño influence over South America. *Atmospheric Science Letters*, v. 12, n. 4, p. 351–355, 2011.

BEDIA, J.; BAÑO-MEDINA, J.; LEGASA, M. N.; ITURBIDE, M.; MANZANAS, R.; CASANUEVA, A.; SAN-MARTÍN, D.; COFIÑO, A. S.; GUTIÉRREZ, J. M. Statistical downscaling with the downscaleR package : Contribution to the VALUE intercomparison experiment. n. September, p. 1–33, 2019.

BENESTAD, R. *Downscaling Climate Information*. [s.l: s.n.]. v. 1

BIAU, G.; ZORITA, E.; VON STORCH, H.; WACKERNAGEL, H. Estimation of precipitation by kriging in the EOF space of the sea level pressure field. *Journal of Climate*, v. 12, n. 4, p. 1070–1085, 1999.

BISHOP, C. H.; ABRAMOWITZ, G. Climate model dependence and the replicate Earth paradigm. *Climate Dynamics*, n. May 2012, p. 885–900, 2013.

BOCK, L.; LAUER, A.; SCHLUND, M.; BARREIRO, M.; BELLOUIN, N.; JONES, C.; MEEHL, G. A.; PREDOI, V.; ROBERTS, M. J.; EYRING, V. Quantifying Progress Across Different CMIP Phases With the ESMValTool. *Journal of Geophysical Research: Atmospheres*, v. 125, n. 21, p. 1–28, 2020.

BOMBARDI, R. J.; CARVALHO, L. M. V. IPCC global coupled model simulations

of the South America monsoon system. *Climate Dynamics*, v. 33, n. 7–8, p. 893–916, 2009.

BORGES, P. DE A.; CHAFFE, P. B. Towards a comprehensive characterization of evidence in synthesis assessments : the climate change impacts on the Brazilian water resources. *Climatic Change*, 2019.

BRUNNER, L.; PENDERGRASS, A. G.; LEHNER, F.; MERRIFIELD, A. L.; LORENZ, R.; KNUTTI, R. Reduced global warming from CMIP6 projections when weighting models by performance and independence. *Earth System Dynamics*, v. 11, n. 4, p. 995–1012, 2020.

CAMUS, P.; MENENDEZ, M.; MENDEZ, F. J.; IZAGUIRRE, C.; ESPEJO, A.; CANOVAS, V.; PEREZ, J.; RUEDA, A.; LOSADA, I. J.; MEDINA, R. A weather-type statistical downscaling framework for ocean wave climate. *Journal of Geophysical Research : Oceans*, n. i, p. 7389–7405, 2014.

CAVALCANTI, I. F. DE A.; FERREIRA, N. J.; DIAS, M. A. F. DA S.; SILVA, M. G. A. J. DA. *Tempo e clima no Brasil*. [s.l: s.n.].

CHAGAS, V. B. P.; CHAFFE, P. L. B. The Role of Land Cover in the Propagation of Rainfall Into Streamflow Trends. *Water Resources Research*, v. 54, n. 9, p. 5986–6004, 2018.

CLARK, M. P.; WILBY, R. L.; GUTMANN, E. D.; VANO, J. A.; GANGOPADHYAY, S.; WOOD, A. W.; FOWLER, H. J.; PRUDHOMME, C.; ARNOLD, J. R.; BREKKE, L. D. Characterizing Uncertainty of the Hydrologic Impacts of Climate Change. *Current Climate Change Reports*, v. 2, n. 2, p. 55–64, 2016.

COLLINS, M.; KNUTTI, R.; ARBLASTER, J.; DUFRESNE, J.-L.; FICHEFET, T.; FRIEDLINGSTEIN, P.; GAO, X.; GUTOWSKI, W. J.; JOHNS, T.; KRINNER, G.; SHONGWE, M.; TEBALDI, C.; WEAVER, A. J.; WEHNER, M. Long-term Climate Change: Projections, Commitments and Irreversibility. *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, p. 1029–1136, 2013.

DINGMAN, S. L. *Physical Hydrology*. Third Edit ed. Long Grove, Illinois: Waveland Press, Inc, 2015.

DOMÍNGUEZ-CASTRO, F.; REIG, F.; VICENTE-SERRANO, S. M.; AGUILAR, E.; PEÑA-ANGULO, D.; NOGUERA, I.; REVUELTO, J.; VAN DER SCHRIER, G.; EL KENAWY, A. M. A multidecadal assessment of climate indices over Europe. *Scientific Data*, v. 7, n. 1, p. 1–7, 2020.

DONAT, M. G.; ALEXANDER, L. V.; YANG, H.; DURRE, I.; VOSE, R.; DUNN, R. J. H.; WILLETT, K. M.; AGUILAR, E.; BRUNET, M.; CAESAR, J.; HEWITSON, B.; JACK, C.; KLEIN TANK, A. M. G.; KRUGER, A. C.; MARENGO, J.; PETERSON, T. C.; RENOM, M.; ORIA ROJAS, C.; RUSTICUCCI, M.; SALINGER, J.; ELRAYAH, A. S.; SEKELE, S. S.; SRIVASTAVA, A. K.; TREWIN, B.; VILLARROEL, C.; VINCENT, L. A.; ZHAI, P.; ZHANG, X.; KITCHING, S. Updated analyses of temperature and precipitation extreme indices since the beginning of the twentieth century: The HadEX2 dataset. *Journal of Geophysical Research Atmospheres*, v. 118, n. 5, p. 2098–2118, 2013.

DUNN, R. J. H.; ALEXANDER, L. V.; DONAT, M. G.; ZHANG, X.; BADOR, M.; BIN HJ YUSSOF, M. N. A.; et al. Development of an Updated Global Land In Situ-Based Data Set of Temperature and Precipitation Extremes: HadEX3. *Journal of Geophysical Research: Atmospheres*, v. 125, n. 16, p. 1–28, 2020.

EEKHOUT, J.; HUNINK, J.; TERINK, W.; DE VENTE, J. Why increased extreme precipitation under climate change negatively affects water security. *Hydrology and Earth System Sciences Discussions*, p. 1–16, 2018.

EHRET, U.; ZEHE, E.; WULFMEYER, V.; LIEBERT, J. HESS Opinions " Should we apply bias correction to global and regional climate model data ?" p. 3391–3404, 2012.

EYRING, V.; GLECKLER, P. J.; HEINZE, C.; STOUFFER, R. J.; TAYLOR, K. E.; BALAJI, V.; GUILYARDI, E.; JOUSSAUME, S.; KINDERMANN, S.; LAWRENCE, B. N.; MEEHL, G. A.; RIGHI, M.; WILLIAMS, D. N. Towards improved and more routine Earth system model evaluation in CMIP. *Earth System Dynamics*, v. 7, n. 4, p. 813–830, 2016.

EYRING, V.; BOCK, L.; LAUER, A.; RIGHI, M.; SCHLUND, M.; ANDELA, B.; ARNONE, E.; BELLPRAT, O.; CARVALHAIS, N.; CIONNI, I.; CORTESI, N.; CREZEE, B.; L. DAVIN, E.; DAVINI, P.; DEBEIRE, K.; DE MORA, L.; DESER, C.; DOCQUIER, D.; EARNSHAW, P.; EHBRECHT, C.; K. GIER, B.; GONZALEZ-REVIRIEGO, N.; GOODMAN, P.; HAGEMANN, S.; HARDIMAN, S.; HASSLER, B.; HUNTER, A.;

KADOW, C.; KINDERMANN, S.; KOIRALA, S.; KOLDUNOV, N.; LEJEUNE, Q.; LEMBO, V.; LOVATO, T.; LUCARINI, V.; MÜLLER, B.; PANDDE, A.; PHILLIPS, A.; PREDOI, V.; RUSSELL, J.; SELLAR, A.; SERVA, F.; STACKE, T.; SWAMINATHAN, R.; VEGAS-REGIDOR, J.; VON HARDENBERG, J.; WEIGEL, K.; ZIMMERMANN, K. Earth System Model Evaluation Tool (ESMValTool) v2.0 - An extended set of large-scale diagnostics for quasi-operational and comprehensive evaluation of Earth system models in CMIP. *Geoscientific Model Development*, v. 13, n. 7, p. 3383–3438, 2020.

FERNANDES, L. G.; RODRIGUES, R. R. Changes in the patterns of extreme rainfall events in southern Brazil. *International Journal of Climatology*, 2017.

FLATO, G., J.; MAROTZKE, B.; ABIODUN, P.; BRACONNOT, S. C.; CHOU, W.; COLLINS, P.; COX, F. D.; S. EMORI, V. E.; C. FOREST, P. G.; E. GUILYARDI, C. J.; KATTSOV, V.; REASON, C.; RUMMUKAINEN, M. Evaluation of climate models. *Climate Change 2013 the Physical Science Basis: Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, v. 9781107057, p. 741–866, 2013.

GLASSER, G. J.; WINTER, R. F. Critical Values of the Coefficient of Rank Correlation for Testing the Hypothesis of Independence. *Biometrika*, v. 48, n. 3, p. 444–448, 1961.

GLECKLER, P. J.; TAYLOR, K. E.; DOUTRIAUX, C. Performance metrics for climate models. *Journal of Geophysical Research Atmospheres*, v. 113, n. 6, p. 1–20, 2008.

GUTIÉRREZ, J. M.; MARAUN, D.; WIDMANN, M.; HUTH, R.; HERTIG, E.; BENESTAD, R.; ROESSLER, O.; WIBIG, J.; WILCKE, R.; KOTLARSKI, S.; SAN MARTÍN, D.; HERRERA, S.; BEDIA, J.; CASANUEVA, A.; MANZANAS, R.; ITURBIDE, M.; VRAC, M.; DUBROVSKY, M.; RIBALAYGUA, J.; PÓRTOLES, J.; RÄTY, O.; RÄISÄNEN, J.; HINGRAY, B.; RAYNAUD, D.; CASADO, M. J.; RAMOS, P.; ZERENNER, T.; TURCO, M.; BOSSHARD, T.; ŠTĚPÁNEK, P.; BARTHOLY, J.; PONGRACZ, R.; KELLER, D. E.; FISCHER, A. M.; CARDOSO, R. M.; SOARES, P. M. M.; CZERNECKI, B.; PAGÉ, C. An intercomparison of a large ensemble of statistical downscaling methods over Europe: Results from the VALUE perfect predictor cross-validation experiment. *International Journal of Climatology*, n. January, p. 1–36, 2018.

HAUGHTON, N.; ABRAMOWITZ, G.; PITMAN, A.; PHIPPS, S. J. Weighting climate model ensembles for mean and variance estimates. *Climate Dynamics*, v. 45, n. 11–12, p. 3169–3181, 2015.

HERGER, N.; ABRAMOWITZ, G.; KNUTTI, R.; ANGÉLIL, O.; LEHMANN, K.; SANDERSON, B. M. Selecting a climate model subset to optimise key ensemble properties. *Earth System Dynamics Discussions*, n. April, p. 1–24, 2017.

HERGER, N.; ABRAMOWITZ, G.; SHERWOOD, S.; KNUTTI, R.; ANGÉLIL, O.; SISSON, S. A. Ensemble optimisation , multiple constraints and overconfidence : a case study with future Australian precipitation change. *Climate Dynamics*, v. 53, n. 3, p. 1581–1596, 2019.

HERSBACH, H. Decomposition of the Continuous Ranked Probability Score for Ensemble Prediction Systems. p. 559–570, 2000.

HERTIG, E.; MARES, I.; GUTIÉRREZ, J. M.; WIBIG, J.; PONGRACZ, R.; VRAC, M. Comparison of statistical downscaling methods with respect to extreme events over Europe : Validation results from the perfect predictor experiment of the COST Action VALUE. n. October 2016, p. 1–22, 2018.

HLINKA, J.; HARTMAN, D.; VEJMELKA, M.; RUNGE, J.; MARWAN, N.; KURTHS, J.; PALŬS, M. Reliability of inference of directed climate networks using conditional mutual information. *Entropy*, v. 15, n. 6, p. 2023–2045, 2013.

JAMES D. HAMILTON. *Time series analysis*. [s.l: s.n.].

JUN, M.; KNUTTI, R.; NYCHKA, D. W. Spatial analysis to quantify numerical model bias and dependence: How many climate models are there? *Journal of the American Statistical Association*, v. 103, n. 483, p. 934–947, 2008.

KNUTTI, R.; FURRER, R.; TEBALDI, C.; CERMAK, J.; MEEHL, G. A. Challenges in combining projections from multiple climate models. *Journal of Climate*, v. 23, n. 10, p. 2739–2758, 2010.

KNUTTI, R.; MASSON, D.; GETTELMAN, A. Climate model genealogy: Generation CMIP5 and how we got there. *Geophysical Research Letters*, v. 40, n. 6, p. 1194–1199, 2013.

LEDUC, M.; LAPRISE, R.; DE ELÍA, R.; ŠEPAROVIĆ, L. Is institutional democracy

a good proxy for model independence? *Journal of Climate*, v. 29, n. 23, p. 8301–8316, 2016.

LOBELL, D. B.; BURKE, M. B.; TEBALDI, C.; MASTRANDREA, M. D.; FALCON, W. P.; NAYLOR, R. L. Prioritizing climate change adaptation needs for food security in 2030. *Science*, v. 319, n. 5863, p. 607–610, 2008.

LORENZ, R.; HERGER, N.; KNUTTI, R.; SEDLÁˇ, J.; EYRING, V.; FISCHER, E. M. Prospects and Caveats of Weighting Climate Models for Summer Maximum Temperature Projections Over North America. 2018.

LUCAS, C.; NGUYEN, H.; TIMBAL, B. An observational analysis of Southern Hemisphere tropical expansion. *Journal of Geophysical Research Atmospheres*, v. 117, n. 17, p. 1–18, 2012.

LUCAS, C.; TIMBAL, B.; NGUYEN, H. The expanding tropics: A critical assessment of the observational and modeling studies. *Wiley Interdisciplinary Reviews: Climate Change*, v. 5, n. 1, p. 89–112, 2014.

MARAUN, D.; WETTERHALL, F.; CHANDLER, R. E.; KENDON, E. J.; WIDMANN, M.; BRIENEN, S.; RUST, H. W.; SAUTER, T.; THEMESSL, M.; VENEMA, V. K. C.; CHUN, K. P.; GOODESS, C. M.; JONES, R. G.; ONOF, C.; VRAC, M.; THIELE-EICH, I. Precipitation downscaling under climate change: Recent developements to bridge the gap between dynamical models and the end user. *Reviews of Geophysics*, v. 48, n. 2009RG000314, p. 1–38, 2010.

MARAUN, D.; WIDMANN, M.; GUTIÉRREZ, J. M.; KOTLARSKI, S.; CHANDLER, R. E.; HERTIG, E.; WIBIG, J.; HUTH, R.; WILCKE, R. A. I. Earth ’ s Future VALUE : A framework to validate downscaling approaches for climate change studies Earth ’ s Future. p. 1–14, 2014.

MARAUN, D.; SHEPHERD, T. G.; WIDMANN, M.; ZAPPA, G.; WALTON, D.; GUTIÉRREZ, J. M.; HAGEMANN, S.; RICHTER, I.; SOARES, P. M. M.; HALL, A.; MEARNS, L. O. Towards process-informed bias correction of climate change simulations. *Nature Climate Change*, v. 7, n. 11, p. 764–773, 2017a.

MARAUN, D.; HUTH, R.; GUTIERREZ, J. M.; MARTIN, D. S.; DUBROVSKY, M.; FISCHER, A.; HERTIG, E.; SOARES, P. M.; BARTHOLY, J.; PONGRACZ, R.;

WIDMANN, M.; CASADO, M. J. The VALUE perfect predictor experiment : evaluation of temporal variability Supplementary Information. 2017b.

MARAUN, D.; WIDMANN, M. *Statistical Downscaling and Bias Correction for Climate Research*. Cambridge: Cambridge University Press, 2018.

MARKHAM, C. G. Seasonality of precipitation i n the united states. *Annals of the Association of American Geographers*, v. 3, p. 593–597, 1970.

MASSEY, F. J. The Kolmogorov-Smirnov Test for Goodness of Fit. *Journal of the American Statistical Association*, v. 46, n. 253, p. 68–78, 1951.

MERRIFIELD, A. L.; BRUNNER, L.; LORENZ, R.; MEDHAUG, I.; KNUTTI, R. An investigation of weighting schemes suitable for incorporating large ensembles into multi-model ensembles. *Earth System Dynamics*, v. 11, n. 3, p. 807–834, 2020.

MINISTÉRIO DO MEIO AMBIENTE. *Plano Nacional de Adaptação à Mudança Climática Vol. I: Estratégia Geral*. [s.l: s.n.].

NISSEN, K. M.; ULBRICH, U. Increasing frequencies and changing characteristics of heavy precipitation events threatening infrastructure in Europe under climate change. *Natural Hazards and Earth System Sciences*, v. 17, n. 7, p. 1177–1190, 2017.

PADRÓN, R. S.; GUDMUNDSSON, L.; SENEVIRATNE, S. I. Observational Constraints Reduce Likelihood of Extreme Changes in Multidecadal Land Water Availability. *Geophysical Research Letters*, 2019.

PARDING, K. M.; DOBLER, A.; MCSWEENEY, C. F.; LANDGREN, O. A.; BENESTAD, R.; ERLANDSEN, H. B.; MEZGHANI, A.; GREGOW, H.; RÄTY, O.; VIKTOR, E.; EL ZOHBI, J.; CHRISTENSEN, O. B.; LOUKOS, H. GCMeval – An interactive tool for evaluation and selection of climate model ensembles. *Climate Services*, v. 18, n. March, p. 100167, 2020.

PEREZ, J.; MENENDEZ, M.; MENDEZ, F. J.; LOSADA, I. J. Evaluating the performance of CMIP3 and CMIP5 global climate models over the north-east Atlantic region. p. 2663–2680, 2014.

PIERCE, D. W.; BARNETT, T. P.; SANTER, B. D.; GLECKLER, P. J. Selecting

global climate models for regional climate change studies. *Proceedings of the National Academy of Sciences of the United States of America*, v. 106, n. 21, p. 8441–8446, 2009.

PSCHEIDT, I.; GRIMM, A. M. Frequency of extreme rainfall events in Southern Brazil modulated by interannual and interdecadal variability. *International Journal of Climatology*, v. 2029, n. March 2008, p. 2011–2029, 2009.

RAGNO, E.; AGHAKOUCHAK, A.; LOVE, C. A.; CHENG, L.; VAHEDIFARD, F.; LIMA, C. H. R. Quantifying Changes in Future Intensity-Duration-Frequency Curves Using Multimodel Ensemble Simulations. *Water Resources Research*, p. 1751–1764, 2018.

REICHLER, T.; KIM, J. How well do coupled models simulate today's climate? *Bulletin of the American Meteorological Society*, v. 89, n. 3, p. 303–311, 2008.

ROSENZWEIG, C.; TUBIELLO, F. N.; GOLDBERG, R.; MILLS, E.; BLOOMFIELD, J. Increased crop damage in the US from excess precipitation under climate change. *Global Environmental Change*, v. 12, n. 3, p. 197–202, 2002.

SANDERSON, B. M.; PENDERGRASS, A.; KOVEN, C. D.; BRIENT, F.; BEN, B.; BOOTH, B.; FISHER, R. A.; KNUTTI, R. On structural errors in emergent constraints. *Earth System Dynamics Discussions*, n. February, p. 1–30, 2021.

SANDERSON, B. M.; KNUTTI, R. On the interpretation of constrained climate model ensembles. v. 39, n. August, p. 1–6, 2012.

SANDERSON, B. M.; KNUTTI, R.; CALDWELL, P. Addressing interdependency in a multimodel ensemble by interpolation of model properties. *Journal of Climate*, v. 28, n. 13, p. 5150–5170, 2015.

SPEARMAN, C. The Proof and Measurement of Association between Two Things. *The American Journal of Psychology*, v. 15, n. 1, p. 72–101, 1904.

TEBALDI, C.; DEBEIRE, K.; EYRING, V.; FISCHER, E.; FYFE, J.; FRIEDLINGSTEIN, P.; KNUTTI, R.; LOWE, J.; NEILL, B. O.; SANDERSON, B. Climate model projections from the Scenario Model Intercomparison Project (ScenarioMIP) of CMIP6. n. Cmcc, p. 253–293, 2021.

TEBALDI, C.; KNUTTI, R. The use of the multi-model ensemble in probabilistic

climate projections. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, v. 365, n. 1857, p. 2053–2075, 2007.

VISSIO, G.; LEMBO, V.; LUCARINI, V.; GHIL, M. Evaluating the Performance of Climate Models Based on Wasserstein Distance. *Geophysical Research Letters*, v. 47, n. 21, 2020.

VOLOSCIUK, C.; MARAUN, D.; VRAC, M.; WIDMANN, M. A combined statistical bias correction and stochastic downscaling method for precipitation. *Hydrology and Earth System Sciences*, v. 21, n. 3, 2017.

WIDMANN, M.; BEDIA, J.; GUTIÉRREZ, J. M.; BOSSHARD, T.; HERTIG, E.; MARAUN, D.; CASADO, M. J.; RAMOS, P.; CARDOSO, R. M.; SOARES, P. M. M.; RIBALAYGUA, J.; PAGÉ, C.; FISCHER, A. M.; HERRERA, S.; HUTH, R. Validation of spatial variability in downscaling results from the VALUE perfect predictor experiment. *International Journal of Climatology*, v. 39, n. 9, p. 3819–3845, 2019.

XAVIER, A. C.; KING, C. W.; SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980-2013). *International Journal of Climatology*, v. 2659, n. October 2015, p. 2644–2659, 2015.

ZHANG, X.; ALEXANDER, L.; HEGERL, G. C.; JONES, P.; TANK, A. K.; PETERSON, T. C.; TREWIN, B.; ZWIERS, F. W. Indices for monitoring changes in extremes based on daily temperature and precipitation data. *Wiley Interdisciplinary Reviews: Climate Change*, v. 2, n. 6, p. 851–870, 2011.

APÊNDICE A

Média

```
function [PM_Map, PM_Series] = Mean(mdl, cal, metric)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
    % metric: ou 'daily' para media diária ou 'annual' para
total anual
% Argumentos de saída:
    % PM_Map: Mapa 2D da precipitação média
    % PM_Series: Matriz 3D da precipitação media diária ou to-
tal annual, com eixo z em anos.
%
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1)
        S = squeeze(mdl(row,col,:));
        % determina se o pixel é vazio
        emptyrow = isnan(S); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % faz matriz 3D de size(mdl,3)x4, com colunas 1 à
3 de calendário e coluna 4 com os dados
            S = [cal,S];
            % cria vetor com o número de anos para ser
preenchido
            y_target = NaN(length(years),1);
            % seleciona se a escala é diária
             if  strcmp(metric,'daily')
                % abre ano k
                for k = 1:length(years)
                    % seleciona todos os dados por ano
                    idx_year = S(:,1)==years(k);
                    % faz a média desconsiderando eventuais
valores NaN e aloca na posição do ano k
                    y_target(k) = nanmean(S(idx_year,4));
                end
                % faz a media da série toda e aloca no pixel
correto
                PM_Map(row,col) = nanmean(S(:,4));
            % seleciona se a escala é anual
```

```
            elseif strcmp(metric,'annual')
                % abre ano k
                for k = 1:length(years)
                    % seleciona todos os dados por ano
                    idx_year = S(:,1)==years(k);
                    % faz o total anual do ano k
                    y_target(k) = nansum(S(idx_year,4));
                end
                % faz o total anual médio e aloca no pixel
correto
                PM_Map(row,col) = nan-
sum(S(:,4))./length(years);
            end
            % aloca a série annual no pixel correto
            PM_Series(row,col,:) = y_target;
        end
    end
end
end
```

Desvio padrão

```
function [PM_Map, PM_Series] = STD (mdl, cal)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % cria vetor com o número de anos para ser preen-
chido
            y_target = NaN(length(years),1);
            % abre ano k
            for k = 1:length(years)
```

```
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                year_S = S(idx_year,4);
                % faz o desvio padrão desconsiderando eventu-
ais valores NaN e aloca na posição do ano k
                y_target(k) = nanstd(year_S);
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_target;
            % faz o desvio padrão da série toda e aloca no
pixel correto
            PM_Map(row,col) = nanstd(S(:,4));
        end
    end
end
end
```

1.2.3. Precipitação média em dias chuvosos

```
function [PM_Map, PM_Series] = SDII (mdl, cal)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % cria vetor com o número de anos para ser preen-
chido
            y_target = NaN(length(years),1);
            % abre ano k
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                year_S = S(idx_year,4);
```

```
                % seleciona somente dias chuvosos com preci-
pitação ≥ 1mm/d
                isWet_yS = year_S(year_S >= 1);
                % faz a media somente dos dias chuvosos e
aloca no ano k
                y_target(k) = nanmean(isWet_yS);
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_target;
            % seleciona toda a série, por pixel
            S_aux = S(:,4);
            % seleciona somente dias chuvosos com precipitação
≥ 1mm/d
            isWet_S = S_aux(S_aux >= 1);
            % faz a media dos dias chuvosos e aloca no pixel
correto
            PM_Map(row,col) = nanmean(isWet_S);
        end
    end
end
end
```

1.2.3. Assimetria

```
function [PM_Map, PM_Series] = Skewness (mdl, cal)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN


if emptyrow(1) == 0
```

```
            % cria vetor com o número de anos para ser preen-
chido
            y_target = NaN(length(years),1);
            % abre ano k
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                % faz a assimetria e aloca no ano k
                y_target(k) = skewness(S(idx_year,4));
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_target;
            % faz a assimetria de toda a série no pixel cor-
reto
            PM_Map(row,col) = skewness(S(:,4));
        end
    end
end
end
```

Frequência anual de dias secos

```
function [PM_Map, PM_Series] = DDF (mdl, cal)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
if emptyrow(1) == 0
            % cria vetor com o número de anos para ser preen-
chido
            y_S = NaN(length(years),1);
            % abre ano k
            for k = 1:length(years)
```

```
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                year_S = S(idx_year,4);
                % faz o número de dias com precipitação <
1mm/d dividido pelo numero de dias ano k
                y_S(k) = sum(year_S < 1)/ length(year_S);
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_S;
            % faz a media das frequências anuais de dias secos
consecutivos
            PM_Map(row,col) = nanmean(y_S);
        End
    end
end
end
```

Frequência anual de dias chuvosos

```
function [PM_Map, PM_Series] = WDF (mdl, cal)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN

if emptyrow(1) == 0
            % cria vetor com o número de anos para ser preen-
chido
            y_S = NaN(length(years),1);
            % abre ano k
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
```

```
                year_S = S(idx_year,4);
                % faz o número de dias com precipitação ≥
1mm/d dividido pelo numero de dias ano k
                y_S(k) = sum(year_S >= 1)/ length(year_S);
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_S;
            % faz a media das frequências anuais de dias chu-
vosos consecutivos
            PM_Map(row,col) = nanmean(y_S);
        end
    end
end
end
```

Maior período seco anual

```
function [PM_Map, PM_Series] = MaxDS (mdl, cal)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % cria vetor com o número de anos para ser preen-
chido
            y_S = NaN(length(years),1);
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                year_S = S(idx_year,:);
                % faz vetor boleano com dias com precipitação
< 1 mm/d
                IsDry_S = (year_S(:,4) < 1);
```

```
                % determina o tamanho de cada período com va-
lores = 1 consecutivos no ano
                DrySpell_S = cell2mat(struct2cell(re-
gionprops(IsDry_S,'Area')))';
                % determina o maior período consecutivo e
aloca no ano k
                y_S(k) = max(DrySpell_S);
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_S
            % faz a media da série annual e aloca no pixel
correto
            PM_Map(row,col) = nanmean(y_S);
        end
    end
end
end
```

Maior período chuvoso anual

```
function [PM_Map, PM_Series] = MaxWS (mdl, cal)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % cria vetor com o número de anos para ser preen-
chido
            y_S = NaN(length(years),1);
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                year_S = S(idx_year,:);
```

```
                % faz vetor boleano com dias com precipitação
< 1 mm/d
                IsWet_S = (year_S(:,4) >= 1);
                % determina o tamanho de cada período com va-
lores = 1 consecutivos no ano
                WetSpell_S = cell2mat(struct2cell(re-
gionprops(IsWet_S,'Area')))';
                % determina o maior período consecutivo e
aloca no ano k
                y_S(k) = max(WetSpell_S);
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_S
            % faz a media da série annual e aloca no pixel
correto
            PM_Map(row,col) = nanmean(y_S);
        end
    end
end
end
```

Máximo anual

```
function [PM_Map, PM_Series] = AnnualMaxima (mdl, cal)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
           % cria vetor com o número de anos para ser preen-
chido
            Max_S = NaN(length(years),1);
            for k = 1:length(years)
```

```
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                year_S = S(idx_year,:);
                % determina a maior precipitação no ano
                Max_S(k) = max(year_S(:,4),[],1);
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = Max_S;
            % faz a media da série annual e aloca no pixel
correto
            PM_Map(row,col) = nanmean(Max_S);
        end
    end
end
end
```

Dia médio do máximo anual

```
function [PM_Map, PM_Series] = DayofAnnualMax (mdl, cal)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN

if emptyrow(1) == 0
            % cria vetor com o número de anos para ser preen-
chido
            MaxSeries_S = nan(length(yrs),1);
            for k = 1:length(yrs)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==yrs(k));
                year_S = S(idx_year,:);
```

```
                % determina o dia em que acontece a maior pre-
cipitação e aloca no ano k
                MaxSeries_S(k) = find(year_S(:,4) ==
max(year_S(:,4),[],1));
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = MaxSeries_S;
            % faz a media da série annual e aloca no pixel
correto
            PM_Map(row,col) = nanmean(MaxSeries_S);
        end
    end
end
end
```

Percentil

```
function [PM_Map, PM_Series] = Px (mdl, cal, PercTreshold)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
    % PercTreshold: percentil a ser calculado, de 0 a 100
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
           % cria vetor com o número de anos para ser preenchido
            y_S = NaN(length(years),1);
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                % faz o percentil para os dados por ano
                y_S(k) = prctile(S(idx_year,4), PercTreshold);
            end
```

```
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_S;
            % faz o percentil da série toda e aloca no pixel
correto
            PM_Map(row,col) = prctile(S(:,4), PercTreshold);
        end
    end
end
end
```

Percentil Chuvoso

```
function [PM_Map, PM_Series] = PxWet (mdl, cal, PercTreshold)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
    % PercTreshold: percentil a ser calculado, de 0 a 100
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % cria vetor com o número de anos para ser preen-
chido
            y_target = NaN(length(years),1);
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                S_aux = S(idx_year,4);
                % seleciona os dias com precipitação ≥ 1mm/d
                WetDays_S = S_aux(S_aux >= 1);
                % faz o percentil dos dias chuvosos
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_target;
```

```
            % faz o percentil chuvoso da série toda e aloca no
pixel correto

            S_aux2 = S(:,4); isWet_S1 = S_aux2(S_aux2 >= 1);
            PM_Map(row,col) = prctile(isWet_S1,PercTreshold);
        end
    end
end
end
```

Contribuição anual de um percentil

```
function [PM_Map, PM_Series] = RxpTot(mdl, cal, PercTreshold)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
    % PercTreshold: percentil a ser calculado, de 0 a 100
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % cria vetor com o número de anos para ser preen-
chido
            y_S = NaN(length(years),1);
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                S_aux = S(idx_year,4);
                % faz a soma das precipitações acima do per-
centil chuvoso
                SPerc_aux = nansum(S_aux( S_aux > prc-
tile(S_aux,PercTreshold)));
                % faz a soma de todos os dias no ano
                STot_aux = nansum(S_aux);
```

```
                % faz a razão entre o precipitado acima do
percentil e o total anual
                y_S(k) = SPerc_aux./STot_aux;
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_S;
            % faz a media da série annual e aloca no pixel
correto
            PM_Map(row,col) = nanmean(y_S);
        end
    end
end
end
```

Frequência de excedência de um limiar

```
function [PM_Map, PM_Series] = Rx(mdl, cal, Treshold)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
    % Treshold: limiar escolhido > 0
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % cria vetor com o número de anos para ser preen-
chido
            y_S = NaN(length(years),1);
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                S_aux = S(idx_year,4);
                % conta o número de dias com precipitação
acima do limiar e divide pelo numero total de dias do ano
```

```
                y_S(k) = numel(S_aux(S_aux > Tresh-
old))/length(S_aux);
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_S;
            % faz a media da série annual e aloca no pixel
correto
            PM_Map(row,col) = nanmean(y_S);
        end
    end
end
end
```

Volume anual acima de um percentil

```
function [PM_Map, PM_Series, TotalDaysAbove, DaysAbove] =
Vol_Px(mdl, cal, PercTreshold)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
    % PercTreshold: percentil a ser calculado, de 0 a 100
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
    % TotalDaysAbove: Mapa 2D todos os dias acima do percentil
    % DaysAbove: Matriz 3D o numero de dias acima do percentil
por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
TotalDaysAbove = nan(size(mdl,1),size(mdl,2));
DaysAbove = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % cria dois vetores com o número de anos para ser
preenchido
            y_S = NaN(length(years),1); d_S =
NaN(length(years),1);
            for k = 1:length(years)
```

```
                % seleciona todos os dados por ano
                S_aux = S(idx_year,4);
                % soma todos os dias com precipitação acima do
limiar no ano
                y_S(k) = nansum(S_aux( S_aux > prc-
tile(S_aux,PercTreshold)));
                % soma o número de dias com precipitação acima
do limiar no ano
                d_S(k) = length(S_aux( S_aux > prc-
tile(S_aux,PercTreshold)));
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_S;
            DaysAbove(row,col,:) = d_S;
            % determina quais os dias com precipitação acima
do limiar para a série toda
            S1_aux2 = S(:,4);
            DaysAbove_S1 = S1_aux2( S1_aux2 > prc-
tile(S1_aux2,PercTreshold));
            % soma o todos os dias com precipitação acima do
limiar para a série toda e aloca no pixel correto
            PM_Map(row,col) = nansum(DaysAbove_S1);
            % determina o número de dias com precipitação
acima do limiar para a série toda e aloca no pixel correto
            TotalDaysAbove(row,col) = length(DaysAbove_S1);
        end
    end
    end
end
end
```

Volume anual acima de um percentil chuvoso

```
function [PM_Map, PM_Series, TotalDaysAbove, DaysAbove] =
Vol_PxWet(mdl, cal, PercTreshold)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
    % PercTreshold: percentil a ser calculado, de 0 a 100
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
    % TotalDaysAbove: Mapa 2D todos os dias acima do percentil
    % DaysAbove: Matriz 3D o numero de dias acima do percentil
por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
```

```
TotalDaysAbove = nan(size(mdl,1),size(mdl,2));
DaysAbove = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % cria dois vetores com o número de anos para ser
preenchido
            y_S = NaN(length(years),1); d_S =
NaN(length(years),1);
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                % seleciona os dias chuvosos ( precipitação ≥
1mm/d)
                isWet_yS1 = S(idx_year,4); isWet_yS1 =
isWet_yS1(isWet_yS1>=1);
                % soma a precipitação em dias chuvosos
                y_S(k) = nansum(isWet_yS1( isWet_yS1 > prc-
tile(isWet_yS1,PercTreshold)));
                % determina o número de dias chuvosos no ano
                d_S(k) = length(isWet_yS1);
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_S; DaysAbove(row,col,:) =
d_S;
            % soma o todos os dias com precipitação acima do
percentil chuvoso para a série toda e aloca no pixel correto
            isWet_S = S(:,4); isWet_S = isWet_S(isWet_S>=1);
            PM_Map(row,col) = nansum(isWet_S( isWet_S > prc-
tile(isWet_S,PercTreshold)));
            % determina o número de dias com precipitação
acima do percentil chuvoso para a série toda e aloca no pixel
correto
            TotalDaysAbove(row,col) = length(isWet_S( isWet_S
> prctile(isWet_S,PercTreshold)));
        end
    end
end
end
```

Volume anual acima de um limiar

```
function [PM_Map, PM_Series, TotalDaysAbove, DaysAbove] =
Vol_Rx(mdl, cal, Treshold)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
    % Treshold: limiar escolhido, >0 mm
% Argumentos de saída:
    % PM_Map: Mapa 2D da media da métrica
    % PM_Series: Matriz 3D com a métrica por ano
    % TotalDaysAbove: Mapa 2D todos os dias acima do limiar
    % DaysAbove: Matriz 3D o numero de dias acima do limiar
por ano
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
TotalDaysAbove = nan(size(mdl,1),size(mdl,2));
DaysAbove = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % cria dois vetores com o número de anos para ser
preenchido
            y_S = NaN(length(years),1); d_S =
NaN(length(years),1);
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                S_aux = S(idx_year,4);
                % soma todas as precipitações acima do limiar
no ano
                y_S(k) = nansum(S_aux( S_aux > Treshold));
                % encontra o número de dias com precipitações
acima do limiar no ano
                d_S(k) = length(S_aux( S_aux > Treshold));
            end
            % aloca a série anual no pixel correto
            PM_Series(row,col,:) = y_S;  DaysAbove(row,col,:)
= d_S;
```

```
            % soma o todos os dias com precipitação acima do
limiar para a série toda e aloca no pixel correto
            S_aux2 = S(:,4);
            PM_Map(row,col) = nansum(S_aux2( S_aux2 > Tresh-
old));
            % determina o número de dias com precipitação
acima do limiar para a série toda e aloca no pixel correto
            TotalDaysAbove(row,col) = length(S_aux2( S_aux2 >
Treshold));
        end
    end
end
end
```

Dias secos consecutivos

```
function [PM_Map, PM_Series] = DrySpell (mdl, metric)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % metric: ou 'mean' para media ou 'median' para a mediana
% Argumentos de saída:
    % PM_Map: Mapa 2D da precipitação média
    % PM_Series: Matriz 3D com todos os dias consecutives da
série
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1)
        S = squeeze(mdl(row,col,:));
        % determina se o pixel é vazio
        emptyrow = isnan(S); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % faz vetor boleano com dias com precipitação < 1
mm/d
            IsDry_S = (S < 1);
                % determina o tamanho de cada período com va-
lores = 1 consecutivos
            Spells_S = cell2mat(struct2cell(regionprops(Is-
Dry_S,'Area')))';
                % aloca todos os períodos secos no pixel cor-
reto
            PM_Series(row,col, 1:length(Spells_S)) = Spells_S;
```

```
            % se 'metric' é media, faz a media dos períodos
secos e aloca no pixel correto
            if  strcmp(metric,'mean')
                PM_Map(row,col) = nanmean(Spells_S);
            % se 'metric' é mediana, faz a mediana dos perío-
dos secos e aloca no pixel correto
            elseif strcmp(metric,'median')
                PM_Map(row,col) = nanmedian(Spells_S);
            end
        end
    end
end
end
```

Dias chuvosos consecutivos

```
function [PM_Map, PM_Series] = WetSpell (mdl, metric)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % metric: ou 'mean' para media ou 'median' para a mediana
% Argumentos de saída:
    % PM_Map: Mapa 2D da precipitação média
    % PM_Series: Matriz 3D com todos os dias consecutives da
série
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1)
        S = squeeze(mdl(row,col,:));
        % determina se o pixel é vazio
        emptyrow = isnan(S); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % faz vetor boleano com dias com precipitação ≥ 1
mm/d
            IsWet_S = (S >= 1);
                % determina o tamanho de cada período com va-
lores = 1 consecutivos
            Spells_S = cell2mat(struct2cell(re-
gionprops(IsWet_S,'Area')))';
            PM_Series(row,col, 1:length(Spells_S)) = Spells_S;
            % se 'metric' é media, faz a media dos períodos
chuvosos e aloca no pixel correto
            if  strcmp(metric,'mean')
```

```
                PM_Map(row,col) = nanmean(Spells_S);
            % se 'metric' é mediana, faz a mediana dos perío-
dos chuvosos e aloca no pixel correto
            elseif strcmp(metric,'median')
                PM_Map(row,col) = nanmedian(Spells_S);
            end
        end
    end
end
end
```

Índice de sazonalidade de Markham

```
function [PM_Map] = SeasonalityIndex (mdl, cal)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % cal: calendario [yyyy,mm,dd]
% Argumentos de saída:
    % PM_Map: Mapa 2D de resultados
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
        if emptyrow(1) == 0
            % determina os anos e meses
            years = unique(cal(:,1));
            months = unique(cal(:,2));
            % cria uma matriz com o numero de anos pelo numero
de meses para ser preenchida com a precipitação mensal
            Pmonth_S = NaN(length(years),length(months));
            for k = 1:length(years)
                % seleciona todos os dados por ano
                idx_year = find(S(:,1)==years(k));
                year_S = S(idx_year,:);
                for j = 1:length(months)
                % seleciona todos os dados por mês, por ano
                    idx_month = find(year_S(:,2)==months(j));
                    month_S = year_S(idx_month,:);
```

```
                    % faz a precipitação total mensal, e aloca
no ano e mês corretos
                    Pmonth_S(k,j) =  nansum(month_S(:,4));
                end
            end
             % faz a precipitação media mensal
            Pmean_S = sum(Pmonth_S,1)./size(Pmonth_S,1);
            % determina o ângulo de cada mês
            theta_d = [15.8; 44.9; 74; 104.1; 134.1; 164.2;
194.3; 224.9;  255; 285; 315.1; 345.2];
            theta = deg2rad(theta_d)';
            % calcula os parâmetros S e C
            S_S = sum(Pmean_S .* sin(theta));
            C_S = sum(Pmean_S .* cos(theta));
            % calcula a precipitação total anual, Pr² = S² +
C²
            Pr_S = ((S_S * S_S) + (C_S * C_S))^(1/2);
            %calcula o índice de sazonalidade de Makham (Is),
dividindo a precipitação annual pela somatória das precipita-
ções mensais
            PM_Map(row,col) = Pr_S/sum(Pmean_S);
        end
    end
end
end
```

Autocorrelação

```
function [PM_Map] = Autocorr(mdl, LagTime)
% Argumentos de entrada:
    % mdl: matriz 3D de dados
    % LagTime: espaçamento (lag) em dias
% Argumentos de saída:
    % PM_Map: Mapa 2D de resultados
%seleciona anos
years = unique(cal(:,1));
% abre mapas para serem preenchidos
PM_Map = nan(size(mdl,1),size(mdl,2));
PM_Series = nan(size(mdl,1),size(mdl,2), length(years));
% abre pixel por pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % transforma pixel 3D (1x1xsize(mdl,3) em 2D
size(mdl,3)x1), e faz matriz 3D de size(mdl,3)x4, com colunas
1 à 3 de calendário e coluna 4 com os dados
        S = squeeze(mdl(row,col,:)); S = [cal,S];
       % determina se o pixel é vazio
        emptyrow = isnan(S(:,4)); emptyrow = unique(emptyrow);
        % condição: se o pixel não é totalmente feito de NaN
```

```
        if emptyrow(1) == 0
            % calcula a autocorrelação da série e aloca no
pixel correto
            Aux_S = autocorr(S, LagTime);
            PM_Map(row,col) = Aux_S;

        end
    end
end
end
```

Tempos de retorno

```
function [ PM_Map ] = TR( mdl, cal, Rv, Ac )
%argumentos de entrada:
%mdl: matriz 3D de dados
%cal: matriz de calendário na configuração [yyyy,mm,dd]
%Rv: período de retorno e manos
%tempo de acumulação em dias
        if emptyrow(1) == 0
            % faz vetores a serem preenchidos com a precipita-
ção máxima anual e parâmetros p da GEV
            AMS_S = NaN(nYears,1);pGEV_S = NaN(1,3);
            % abre por ano
            for y = 1:length(yrs)
                idxYear = find(S(:,3) == yrs(y));
                S_target = S(idxYear,:);
                % faz soma móvel de acordo com o perído de
acumulação Ac
                Ac_S = movsum(S_target(:,4),Ac);
                % determina precipitação máxima anual
                AMS_S(y,1)= max(Ac_S)./Ac;
            end
            % ajusta curva GEV (generalized extreme values)
para a série annual de precipitações máximas
            pGEV_S = gevfit(AMS_S);
            % acha parâmetros da GEV
            p = 0.01:0.005:0.995;
            qGEV_S= gevinv(p',pGEV_S(1),pGEV_S(2),pGEV_S(3));
            % acha localização do perido de retorno Rv
            [idxTR, ~] = ismember(p',[1-1./Rv]','Rows');
            % acha intensidade da precipitação com período de
retorno Rv
            ReturnLevel_S = qGEV_S(idxTR);
            % aloca valor no pixel correto
            PM_Map(row,col,:) = ReturnLevel_S;
        end
    end
end
end
```

Teste KS

```
function [H_KS, pvalue_KS] = KSTest( mdl1, mdl2)
% argumentos de entrada:
    % mdl1: matriz de dados 3D
    % mdl2: matriz de dados 3D
    % Nível de significancia: 0.05
% argumentos de saída:
    % H_KS: mapa com os resultados do H0 por pixel
    % pvalue_KS: mapa com os resultados do pvalor por pixel
   % faz matrizes de saída para serem preenchidas
H_KS  = nan(size(mdl2,1),size(mdl2,2));
pvalue_KS = nan(size(mdl1,1),size(mdl1,2));
   % abre pixel por pixel
for row = 1:size(mdl2,1)
    for col = 1:size(mdl2,2)
        S1 = squeeze(mdl1(row,col,:));
        S2 = squeeze(mdl2(row,col,:));
        % determina se coluna é feita de NaN
        emptyrow = isnan(S1); emptyrow = unique(emptyrow);
        %condição: se a coluna não é feita inteiramente de NaN
        if emptyrow(1) == 0
            %faz o teste KS entre as variáveis
            [H, p_value] = kstest2(S2,S1);
            %aloca os resultados no pixel correto
            H_KS(row,col) = H;
            pvalue_KS(row,col)=  p_value;
        end
    end
end
end
```

Correlação de Spearman

```
function [PM_Map] = SpearmanCorr( mdl1, mdl2, cal )
% argumentos de entrada:
    % mdl1: matriz de dados 3D
    % mdl2: matriz de dados 3D
    % cal: matriz de calendário na configuração [yyyy,mm,dd]
% argumentos de saída:
    % PM_Map: mapa da correlação de Spearman
    % PM_Series: matriz 3D com as correlações de spearman por
ano
   % determina anos
years = unique(cal(:,1));
   % faz matrizes de saída para serem preenchidas
PM_Series  = nan(size(mdl1,1),size(mdl1,2),length(years));
```

```
PM_Map = nan(size(mdl1,1),size(mdl1,2));
   % abre pixel por pixel
for lon = 1:size(mdl2,1)
    for lat = 1:size(mdl2,2)
        S1 = squeeze(mdl1(lon,lat,:)); S1 = [cal,S1];
        S2 = squeeze(mdl2(lon,lat,:)); S2 = [cal,S2];
         % determina se coluna é feita de NaN
        emptyrow = isnan(S1(:,4)); emptyrow = unique(emp-
tyrow);
        %condição: se a coluna não é feita inteiramente de NaN
        if emptyrow(1) == 0
            %faz vetor de correlações para ser preenchido por
ano
            corr_y = NaN(length(years),1);
            %abre por ano e determina dados
            for k = 1:length(years)
                idx_year = find(S1(:,1)==years(k));
                year_S1 = S1(idx_year,4);
                year_S2 = S2(idx_year,4);
                %faz a correlação de Spearman entre os dois
vetores
                corr_y(k) =  corr(year_S1,year_S2, 'Type',
'Spearman');
            end
            %aloca o vetor anual no pixel correto
            PM_Series(lon,lat,:) = corr_y;
            %faz a correlação entre as series dos pixels
            S1_aux = S1(:,4); S2_aux = S2(:,4);
            %aloca o resultado no pixel correto
            PM_Map(lon,lat) =
corr(S1_aux,S2_aux,'Type','Spearman','rows','complete');
         end
    end
end
end
```

Correlação espacial

```
function [ euc_distances, correlations, coordenates ] = Spati-
alCorr(mdl, corr_type)
% argumentos de entrada:
    % mdl: matriz de dados 3D
    % corr_type: tipo de correlação, opções 'Spearman', 'Ken-
dall' e 'Pearson'
% argumentos de saída:
    % euc_distances: distância euclidiana entre os pares de
pixel
    % correlation: correlação entre pixels
    % coordanates: coordenadas dos dois pixels
% inicializa variáveis
```

```
euc_distances = [];
correlations = [];
coordenates = [];
% abre pixel a pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % determina vetor 1
        position1 = squeeze(mdl(row,col,:));
        % verifica se vetor 1 não é composto somente por NaN
        emptyrow = isnan(position1); emptyrow = unique(emp-
tyrow);
        % condição: se vetor 1 contém números
        if emptyrow(1) == 0
            % abre novo pixel
            for row2 = row:size(mdl,1)
                for col2 = (col+1):(size(mdl,2)-1)
                    % deterina vetor 2
                    position2 = squeeze(mdl(row2,col2,:));
                    % verifica se vetor 2 não é composto so-
mente por NaN
                    emptyrow2 = isnan(position2); emptyrow2 =
unique(emptyrow2);
                    % condição: se vetor 2 contém números
                    if emptyrow2(1) == 0
                      % faz correlação entre vetores
                        corr_position12 = corr(position1,posi-
tion2, 'Type', corr_type,'rows','complete');
                        % determina coordenadas dos vetores
                        coor_aux = [row,col,row2,col2];
                        % determina distância euclidiana entre
os vetores
                        delta_x = row2 - row; delta_y = col2 -
col;
                        eucdist = sqrt(delta_x.^2 +
delta_y.^2);
                        % aloca coordenadas dos vetores
                        coordenates = [coordenates; coor_aux];
                        % aloca distancias euclidianas
                        euc_distances = [euc_distances ; eu-
cdist];
                        % aloca correlações
                        correlations = [correlations; corr_po-
sition12];
                    end
                end
            end
        end
    end
end
end
```

Informação mútua

```
function [ euc_distances, MI_s, coordenates ] = MI( mdl,
Treshold )
% argumentos de entrada:
    % mdl: matriz de dados 3D
    % Treshold: limiar, pode ser um número ou um mapa com li-
miares por pixel (e.g., Percentil)
% argumentos de saída:
    % euc_distances: distância euclidiana entre os pares de
pixel
    % MI: informação mútua entre pixels
    % coordanates: coordenadas dos dois pixels
% inicializa variáveis
Treshold_aux = Treshold;
euc_distances = [];
MI_s = [];
coordenates = [];
idx_aux = 0; idx_save = [];
% abre pixel a pixel
for row = 1:size(mdl,1)
    for col = 1:size(mdl,2)
        % determina vetor 1
        position1 = squeeze(mdl(row,col,:));
        % verifica se vetor 1 não é composto somente por NaN
        emptyrow = isnan(position1); emptyrow = unique(emp-
tyrow);
        % condição: se o vetor 1 contém números
        if emptyrow(1) == 0
            % determina se limiar é um número ou um mapa
            % condição: se limiar for um mapa, selecionar
pixel correto
            if length(Treshold_aux)>1.2
                Treshold = Treshold_aux(row,col);
            end
            % acha probabilidade marginal 1
            bit_1 = double(position1 >= Treshold);
            idx_bit1 = find(bit_1);
            margprob_1 = sum(bit_1)/length(bit_1);
            % abre pixel 2
            for row2 = row:size(mdl,1)
                for col2 = (col+1):(size(mdl,2)-1)
                    % determina vetor 2
                    position2 = squeeze(mdl(row2,col2,:));
                    % verifica se vetor 2 é composto somente
po NaN
                    emptyrow2 = isnan(position2); emptyrow2 =
unique(emptyrow2);
                    % condição: se vetor 2 contém números
                    if emptyrow2(1) == 0
```

```
                        % determina se limiar é um número ou
um mapa
            % condição: se limiar for um mapa, selecionar
pixel correto
                        if length(Treshold_aux)>1.2
                            Treshold = Tresh-
old_aux(row2,col2);
                        end
                        % acha probabilidade marginal 2
                        bit_2 = double(position2 >= Treshold);
                        margprob_2 = sum(bit_2)/length(bit_2);
                        % acha probabilidade conjunta 2 e 1
                        probcond_21 =
sum(bit_2(idx_bit1,:))/sum(bit_1);
                        % acha probabilidade conjunta 1 e 2
                        jointprob_12 = margprob_1*probcond_21;
                        % acha informalão mútua
                        MutualInfo = jointprob_12 * log(join-
tprob_12/(margprob_1*margprob_2));
                        % determina coordenadas
                        coor_aux = [row,col,row2,col2];
                        % faz distância euclidiana
                        delta_x = row2 - row; delta_y = col2 -
col;
                        eucdist = sqrt(delta_x.^2 +
delta_y.^2);
                        % aloca coordenadas
                        coordenates = [coordenates; coor_aux];
                        % aloca distâncias euclidianas
                        euc_distances = [euc_distances ; eu-
cdist];
                        % aloca informação mútua
                        MI_s = [MI_s; MutualInfo];
                    end
                end
            end

        end
    end
end
```