

Universidade Federal de Itajubá
Instituto de Recursos Naturais
Mestrado em Meio Ambiente e Recursos Hídricos

**MUDANÇAS DE EXTREMOS CLIMÁTICOS NA AMÉRICA DO SUL:
PROJEÇÕES PARA O SÉCULO XXI E ANÁLISE DE INCERTEZAS**

Carolina Daniel Gouveia

Itajubá
2018

Universidade Federal de Itajubá
Instituto de Recursos Naturais
Mestrado em Meio Ambiente e Recursos Hídricos

**MUDANÇAS DE EXTREMOS CLIMÁTICOS NA AMÉRICA DO SUL:
PROJEÇÕES PARA O SÉCULO XXI E ANÁLISE DE INCERTEZAS**

Carolina Daniel Gouveia

Dissertação submetida ao Programa de Pós-Graduação em Meio Ambiente e Recursos Hídricos como parte dos requisitos para obtenção do Título de Mestre em Meio Ambiente e Recursos Hídricos

Orientador: Prof. Dr. Roger Rodrigues Torres

Itajubá
2018

AGRADECIMENTOS

A meu orientador, professor Dr. Roger Rodrigues Torres, por todo incentivo, dedicação e paciência em transmitir conhecimentos necessários não apenas no mestrado, mas também durante toda carreira. Cada ensinamento contribuiu muito para meu amadurecimento.

A meus pais, irmão, tios e primos, por todo amor incondicional, apoio e orações nos momentos os quais fraquejei, em especial a minha mãe, Ambrozina R. Daniel Gouveia, que nunca desistiu de mim e da minha educação, e ao meu pai Ailton Gouveia pela proteção.

A meus amigos Vanessa Siqueira, Cássia Dias, Tatiana Amaro, Ana Caroline Penna, Hallan Souza, por toda força quando eu mais precisei, pelos conselhos, pelas inúmeras ajudas e por trazerem momentos descontraídos aos meus dias.

Aos professores do Mestrado em Meio Ambiente e Recursos Hídricos que contribuíram tanto para meu crescimento profissional quanto pessoal, pela disposição em ajudar e dividir experiências com seus alunos.

Aos membros da banca de mestrado, Dr^a. Fabrina Bolzan Martins, Dr. Cristiano Prestrelo de Oliveira e Dr. Weber Andrade Gonçalves, por aceitarem prontamente o convite.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo auxílio financeiro durante o mestrado, e a Universidade Federal de Itajubá (UNIFEI), pela estrutura e possibilidade de estudo.

Sobretudo a Deus, por sempre guiar meus caminhos, mostrando quais devo percorrer, e me concedendo coragem, saúde e fé para enfrentar as fases da vida.

A todos que, direta ou indiretamente, contribuíram de alguma maneira para que tudo isso fosse possível, meu agradecimento!

RESUMO

Este estudo avaliou as incertezas envolvidas nas projeções de índices extremos climáticos de precipitação e temperatura na América do Sul, por meio de climatologias do período 1961-1990 utilizando dados de Reanálise do NCEP/NCAR (assumidos como observação), além de simulações e projeções de 31 Modelos de Circulação Geral (MCG) pertencentes ao *Coupled Model Intercomparison Project Phase 5* (CMIP5) para os quatro cenários RCPs de forçantes radiativas. O método para avaliar as incertezas foi a Inferência Bayesiana e os índices utilizados foram dias secos consecutivos (CDD), dias de precipitação intensa (R10mm), dias muito úmidos (R95p), máximo de precipitação em 5 dias (Rx5Day), noites muito frias (TN10p), noites muito quentes (TN90p), dias muito frios (TX10p) e dias muito quentes (TX90p). Os resultados para os índices de precipitação mostram heterogeneidade nos vieses (simulação menos observação), sendo negativos sobre os Andes para CDD e positivos sobre a região amazônica (exceto R10mm). Sobre o noroeste da América do Sul, Nordeste, Centro-oeste e Sudeste brasileiros, também foi observado que os modelos superestimam todos os 4 índices de precipitação. Já os índices de temperatura apresentaram os menores vieses, sendo a superestimativa dos modelos mais pronunciada na região equatorial. Através da análise conjunta de viés, Diagrama de Taylor e Índice de concordância de Willmott, fica evidente que as observações são melhor representadas pelos MCGs para os índices extremos de temperatura em relação aos de precipitação. Em relação às projeções para o final do século XXI, elas indicam aumento de CDD, principalmente no Centro-oeste e Nordeste, e mudanças tanto positivas (maior parte do Brasil) quanto negativas (Equador, Peru e Sul do Brasil) para R10mm. Haverá um aumento de R95p sobre todo o continente, sendo mais evidente no extremo leste da região equatorial e no Sul do Brasil. Já Rx5Day apresenta projeções positivas sobre toda a América do Sul, exceto sul do Chile. Para os índices de temperatura, notou-se uma distribuição latitudinal, na qual os maiores valores de mudança serão na região equatorial, diminuindo em relação às latitudes mais elevadas. No geral, pode-se observar uma diminuição de TN10p e TX10p, e um aumento de TN90p e TX90p. Aplicando-se a Inferência Bayesiana sobre a média das projeções, as mudanças nos índices de precipitação diminuiriam ligeiramente em relação à média simples dos MCGs, suavizando em extensão e magnitude as projeções sobre o continente, o que significa que aos modelos com mudanças mais discrepantes foram atribuídos menores pesos, diferentemente dos índices de temperatura, onde não notou-se diferença considerável na média com o método bayesiano. Por meio de Funções Densidades de Probabilidade (PDFs), a fim de observar a concordância entre os modelos e cenários (incertezas quanto aos cenários RCPs), os resultados mostram predomínio de curvas multimodais (largas) para os índices de precipitação, evidenciando maiores incertezas dos modelos nas projeções, contrariamente ao índice de temperatura, o qual mostrou curvas unimodais (estreitas), revelando boa concordância entre os modelos quanto às projeções de mudanças, além de concluir que as menores incertezas foram encontradas para projeções do cenário RCP8.5 e as maiores incertezas para os cenários mais otimistas RCP2.5 e RCP4.5. Por fim, avaliando as distribuições posteriores dos parâmetros de precisão λ_i , a fim de observar as incertezas intermodelos, notou-se que os MCGs possuem diferentes ponderamentos nas sub-regiões e índices, sendo CanESM2 o modelo de menor credibilidade das projeções de extremos de precipitação, enquanto para os índices de temperatura, o modelo de maior credibilidade foi MPI-ESM-MR e o que apresentou maiores incertezas foi FGOALS-g2.

Palavras-chave: Extremos Climáticos, Incertezas, Projeções, Modelos, América do Sul.

ABSTRACT

Changes in climatic extremes in South America: Projections for the twenty-first century and analysis of uncertainties

This study proposes to available the uncertainties involved in the projections of precipitation and temperature extreme indices on South America through the climatologies of the period 1961-1990 using data from NCEP/NCAR reanalysis (assumed as observation), beyond simulations and projections of 31 General Circulation Models (GCM) participating in the Coupled Model Intercomparison Project Phase 5 (CMIP5) for the forcing scenarios radiative RCPs. The method to available the uncertainties was Bayesian Inference and the indices used are consecutive dry days (CDD), days of intense precipitation (R10mm), very humid days (R95p), maximum precipitation in 5 days (Rx5Day), very cold nights (TN10p), very hot nights (TN90p), very cold days (TX10p) and very hot days (TX90p). The results for the precipitation indices show heterogeneity in bias (simulation minus observation), being negative on the Andes for CDD and positive on the Amazon region (except R10mm). On the northwest of South America, Northeast, Midwest and Southeast of Brazil, it was also observed that the models overestimate all 4 precipitation indices. On the other hand, the temperature indices showed the smallest biases, being the overestimation of the models more pronounced in the equatorial region. Through the joint analysis of bias, Taylor's Diagram and Willmott's Concordance Index, it is evident that the observations are better represented by GCMs for extreme temperature indices than those for precipitation. About to the projections for the end of the 21st century, they indicate an increase in CDD, mainly in the Midwest and Northeast, and changes both positive (mostly from Brazil) and negative (Ecuador, Peru and South of Brazil) to R10mm. There will be an increase of R95p over the whole continent, being more evident in the extreme east of the equatorial region and in the South of Brazil. Already Rx5Day show positive projections on all of South America, except southern Chile. For the temperature indices, a latitudinal distribution was observed, in which the highest values of change will be in the equatorial region, decreasing in relation to the higher latitudes. In general, a decrease of TN10p and TX10p, and an increase of TN90p and TX90p, can be observed. Applying the Bayesian Inference on the average of the projections, the changes in the precipitation indices decreased slightly in relation to the simple average of the GCMs, smoothing in extent and magnitude the projections on the continent, which means that to the models with more discrepant changes were attributed lower weights. When the temperature indices were analyzed, there was no significant difference in the mean with the Bayesian method. In order to observe the agreement between the models and scenarios (uncertainties regarding RCPs scenarios), the results of Probability Densities Functions (PDFs), show a predominance of multimodal curves (wide) for the precipitation indices, evidencing greater uncertainties of the models, which showed unimodal curves (narrow), revealing good agreement between the models regarding the projections of changes, in addition to concluding that the smaller uncertainties were found for projections of the RCP8.5 scenario and the larger ones uncertainties for the more optimistic scenarios RCP2.5 and RCP4.5. Finally, evaluating the posterior distributions of the precision parameters λ_i , in order to observe the inter-model uncertainties, observed that the GCMs have different weigh ents in the sub-regions and indices, show CanESM2 the model of lower credibility of projections extreme precipitation, while for the temperature indices, the most credible model was MPI-ESM-MR and the one with the greatest uncertainties was FGOALS-g2.

Keywords: Climatic Extremes, Uncertainties, Projections, Models, South America.

LISTA DE FIGURAS

- Figura 1** – Simulações (1950-2005) e projeções (2006-2100) dos modelos do CMIP5 para (a) mudança na temperatura média global, (b) variação da precipitação, (c) pH oceânico, (d) elevação do nível médio do mar e (e) extensão do gelo marinho no Hemisfério Norte. As séries temporais das projeções e suas incertezas (sombreado) são mostradas para os cenários RCP2.6 (azul) e RCP8.5 (vermelho). A linha preta e os sombreados cinza correspondem à evolução histórica média simulada pelos modelos e suas variações. O número acima de cada trajetória representa a quantidade de modelos do CMIP5 utilizados no cálculo da média e todas as projeções são em relação ao período 1986-2005. As barras verticais coloridas representam a média e as incertezas das projeções referentes ao período 2081-2100 para os quatro cenários RCPs. Na figura da variação de precipitação (b), o tracejado diagonal indica regiões onde a média dos modelos é pequena em comparação à variabilidade interna natural (menor que um desvio padrão); o pontilhado mostra as regiões onde a média dos modelos é grande em comparação com a variabilidade interna natural (maior que dois desvios padrão) e indica que pelo menos 90% dos modelos concordam com o sinal da mudança; também, o número de modelos do CMIP5 utilizados no cálculo da média pode ser visto no canto superior direito de cada mapa. Para a extensão do gelo marinho (e), é dada a média e as incertezas projetadas (faixa mínima-máxima) do subconjunto de modelos que reproduzem mais fielmente o estado médio climatológico, e a tendência do gelo marinho no Ártico entre 1979 e 2012 (número de modelos entre parênteses). A média dos modelos é representada pelas trajetórias pontilhadas. A linha tracejada representa condições quase isentas de gelo, indicando que a extensão do gelo marinho é inferior a 10^6 km² durante, pelo menos, cinco anos consecutivos..... 24
- Figura 2** - Cascata de incertezas em uma projeção de mudanças climáticas. A região delimitada pela linha tracejada engloba o segmento de simulação climática da cascata. A sigla AOGCMs significa *Atmosphere-Ocean General Circulation Models*. 34
- Figura 3** – Domínio de estudo. As áreas delimitadas pelos retângulos azuis indicam as sub-regiões nas quais foram aprofundadas as análises: Leste e Oeste da Amazônia (EAMZ e WAMZ, respectivamente), Nordeste do Brasil (NEB) e Bacia do Prata (LPB). 39
- Figura 4** - Trajetórias das emissões de CO₂ (a), CH₄ (b), e N₂O (c) referentes aos quatro cenários RCPs (2.6, 4.5, 6.0, 8.5). As áreas em cinza representam os percentis 98° (cinza claro) e 90° (cinza escuro) encontrados na literatura. As linhas tracejadas indicam quatro dos cenários SRES (A2, A1b, B2, e B1). 42
- Figura 5** – Distribuição Normal ou Gaussiana (a) e Distribuição Gamma (b). 48
- Figura 6** – Climatologia média anual observada (superior), simulada (central) e viés associado (inferior) dos índices extremos de precipitação, resultantes, respectivamente, dos dados de reanálises do NCEP, da média de todos os modelos do CMIP5 e da diferença entre ambos (simulado menos observado), utilizados para o período de 1961 a 1990. As unidades estão em dias para os índices CDD (a, e e i) e R10mm (b, f e j), e em mm para os índices R95p (c, g e k) e Rx5Day (d, h e l). 53
- Figura 7** – Climatologia média anual observada (superior), simulada (central) e viés associado (inferior) dos índices extremos de temperatura, resultantes, respectivamente, dos dados de reanálises do NCEP, da média de todos os modelos do CMIP5 e da diferença entre ambos (simulado menos observado), utilizados para o período de 1961 a 1990. As unidades estão em % para os índices TN10p (a, e e i), TN90p (b, f e j), TX10p (c, g e k) e TX90p (d, h e l). 56
- Figura 8** – Diagramas de Taylor para as simulações de Dias Secos Consecutivos (CDD) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11

modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990..... 58

Figura 9 – Diagramas de Taylor para as simulações de Dias de Precipitação Intensa (R10mm) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990..... 59

Figura 10 – Diagramas de Taylor para as simulações de Dias Muito Úmidos (R95p) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990..... 60

Figura 11 – Diagramas de Taylor para as simulações de Máximo de Precipitação em 5 dias (Rx5Day) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990..... 61

Figura 12 – Diagramas de Taylor para as simulações de Noites Muito Frias (TN10p) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990..... 62

Figura 13 – Diagramas de Taylor para as simulações de Noites Muito Quentes (TN90p) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990..... 63

Figura 14 – Diagramas de Taylor para as simulações de Dias Muito Frios (TX10p) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990..... 64

Figura 15 – Diagramas de Taylor para as simulações de Dias Muito Quentes (TX90p) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990..... 65

Figura 16 – Índice de Concordância de Willmott para os índices extremos de precipitação (CDD, R10mm, R95p, Rx5Day) e temperatura (TN10p, TN90p, TX10p, TX90p). Esse índice varia entre 0 e 1, com valores próximos a 1 indicando maior concordância entre os modelos e valores próximos a 0, menor concordância das simulações numa dada área..... 68

Figura 17 – Mudança anual do índice extremo Dias Secos Consecutivos (CDD) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-

se a Inferência Bayesiana (inferior). As mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990..... 70

Figura 18 – Mudança anual do índice extremo Dias de Precipitação Intensa (R10mm) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em dias e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990..... 71

Figura 19 – Mudança anual do índice extremo Dias Muito Úmidos (R95p) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em mm e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990..... 73

Figura 20 – Mudança anual do índice extremo de Máximo de Precipitação em 5 dias (Rx5Day) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em mm e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990..... 75

Figura 21 – Mudança anual do índice extremo de Noites Muito Frias (TN10p) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em % e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990..... 76

Figura 22 – Mudança anual do índice extremo de Noites Muito Quentes (TN90p) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em % e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990..... 77

Figura 23 – Mudança anual do índice extremo de Dias Muito Frios (TX10p) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em % e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990..... 78

Figura 24 – Mudança anual do índice extremo de Dias Muito Quentes (TX90p) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em % e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990..... 79

Figura 25 – Funções Densidade de Probabilidade para as mudanças anuais dos índices extremos de precipitação (CDD, R10mm, R95p, Rx5Day) para o final do século XXI nas regiões EAMZ (a - d), WAMZ (e - h), NEB (i - l) e LPB (m - p). As PDFs foram obtidas através do método de Inferência Bayesiana aplicado ao conjunto de modelos do CMIP5 e as linhas referem-se aos cenários RCP2.6 (azul-marinho), RCP4.5 (azul ciano), RCP6.0 (laranja) e RCP8.5 (vermelho). As unidades de medida de CDD e R10mm é em dias do ano, enquanto R95p e RxDay são dados em milímetros (mm) por ano. 82

Figura 26 – Funções Densidade de Probabilidade (PDF) para as mudanças anuais dos índices extremos de temperatura (TN10p, TN90p, TX10p, TX90p) para o final do século XXI nas

regiões EAMZ (*a - d*), WAMZ (*e - h*), NEB (*i - l*) e LPB (*m - p*). As PDFs foram obtidas através do método de Inferência Bayesiana aplicado ao conjunto de modelos do CMIP5 e as linhas referem-se aos cenários RCP2.6 (azul-marinho), RCP4.5 (azul ciano), RCP6.0 (laranja) e RCP8.5 (vermelho). A unidade de medida desses índices é dada em porcentagem (%) de dias do ano. 84

Figura 27 – Distribuição posterior dos parâmetros de precisão específicos de cada MCG (λ_i) pertencentes ao CMIP5 e relativos aos índices extremos de precipitação CDD, R10mm, R95p e RxDay referentes ao cenário RCP 4.5, para cada uma das quatro sub-regiões de estudo analisadas, ordenados por sua mediana. As caixas azuis indicam os dez primeiros MCGs, as pretas os nove intermediários, e as vermelhas os nove últimos. 87

Figura 28 – Distribuição posterior dos parâmetros de precisão específicos de cada MCG (λ_i) pertencentes ao CMIP5 e relativos aos índices extremos de temperatura TN10p, TN90p, TX10p e TX90p referentes ao cenário RCP 4.5, para cada uma das quatro sub-regiões de estudo analisadas, ordenados por sua mediana. As caixas azuis indicam os dez primeiros MCGs, as pretas os nove intermediários, e as vermelhas os nove últimos. 89

LISTA DE TABELAS

- Tabela 1** – Lista de modelos, resolução espacial aproximada e área do pixel relativo a cada um deles e simulações do clima presente (Historical, 1900 - 2005) e projeções futuras (2006 - 2100) em diferentes cenários forçantes (RCPs 2.6, 4.5, 6.0, e 8.5) advindas do conjunto CMIP5 utilizados. Em azul são apresentados os 9 modelos com menores áreas do pixel; em preto, os 11 de áreas intermediárias e em vermelho, os 11 modelos de menor área. 40
- Tabela 2** - Índices de extremos de precipitação e temperatura utilizados com suas respectivas descrições. 43
- Tabela 3** – Modelos com as maiores e menores medianas dos parâmetros de precisão (λ_i) para os índices extremos de precipitação CDD, R10mm, R95p e Rx5Day em cada sub-região. O valor da mediana de λ_i é apresentado entre parênteses. Em vermelho são representados os modelos com menores áreas do pixel, em preto, com as áreas intermediárias, e em azul, os modelos com maiores áreas..... 88
- Tabela 4** – Modelos com as maiores e menores medianas dos parâmetros de precisão (λ_i) para os índices extremos de temperatura TN10p, TN90p, TX10p e TX90p em cada sub-região. O valor da mediana de λ_i é apresentado entre parênteses. Em vermelho são representados os modelos com menores áreas do pixel, em preto, com as áreas intermediárias, e em azul, os modelos com maiores áreas..... 90

LISTA DE ABREVIATURAS E SIGLAS

CDD	– Dias secos consecutivos
CH ₄	– Metano
CMIP3	– <i>Coupled Model Intercomparison Project Phase 3</i>
CMIP5	– <i>Coupled Model Intercomparison Project Phase 5</i>
CO ₂	– Dióxido de carbono
EAMZ	– Região Leste da Amazônia
ENSO	– <i>El Niño-Southern Oscillation</i>
GEEs	– Gases do Efeito Estufa
HFCs	– Hidrofluorcarbonos
IPCC	– <i>Intergovernmental Panel on Climate Change</i>
IPCC AR5	– <i>IPCC Fifth Assessment Report</i>
LPB	– Região da Bacia do Prata
MCGs	– Modelos de Circulação Geral
MCMC	– <i>Markov Chain Monte Carlo</i>
NCAR	– <i>National Center for Atmospheric Research</i>
NCEP	– <i>National Centers for Environmental Prediction</i>
NEB	– Região Nordeste do Brasil
NF ₃	– Trifluoreto de nitrogênio
N ₂ O	– Óxido nitroso
PCDMI	– <i>Program for Climate Model Diagnosis and Intercomparison</i>
PDF	– <i>Probability Distribution Function</i>
PDO	– <i>Pacific Decadal Oscillation</i>
PFCs	– Perfluorcarbonos
RCPs	– <i>Representative Concentration Pathways</i>
Rx5Day	– Precipitação anual máxima em 5 dias consecutivos
R10mm	– Dias de precipitação intensa
R95p	– Dias muito úmidos
SF ₆	– Hexafluoreto de enxofre
SMAS	– Sistema de Monção da América do Sul
SRES	– <i>Special Report on Emission Scenarios</i>
TN10p	– Noites muito frias

TN90p	– Noites muito quentes
TSM	– Temperatura da superfície do mar
TX10p	– Dias muito frios
TX90p	– Dias muito quentes
WAMZ	– Região Oeste da Amazônia
ZCAS	– Zona de Convergência do Atlântico Sul
ZCIT	– Zona de Convergência Intertropical

LISTA DE SÍMBOLOS

n	– Número total de modelos
N	– Distribuição Gaussiana
\bar{O}	– Valor médio das observações
X_i	– Índice de extremo climático ξ simulado para o clima presente pelo modelo i
X_o	– Índice de extremo climático ξ observado
X_{o_max}	– Maior valor da série temporal observada
X_{o_min}	– Menor valor da série temporal observada
Y_i	– Índice de extremo climático ξ projetado para o clima futuro pelo modelo i
$\Delta\xi$	– Mudança esperada em um índice de extremo climático ξ
μ	– Valor médio do índice extremo climático ξ no clima presente
ν	– Valor médio do índice extremo climático ξ no clima futuro
ε	– Variabilidade natural
λ_i	– Recíproco da variância referido como precisão da distribuição de X_i
λ_o	– Recíproco da variabilidade natural ao quadrado referido como função da variabilidade natural específica de cada região
θ	– Parâmetro adicional multiplicando λ_i para compor a precisão da distribuição de Y_i

SUMÁRIO

Pág.

1 INTRODUÇÃO	15
1.1 Objetivos	18
2 REVISÃO BIBLIOGRÁFICA	20
2.1 Sistema Terrestre e Mudanças Climáticas	20
2.2 Impactos de eventos extremos na América do Sul.....	26
2.3 Modelos de Circulação Geral (MCGs) e incertezas associadas	30
3 METODOLOGIA	38
3.1 Área de estudo e Dados	38
3.2 Métodos.....	42
3.2.1 Índices Extremos	43
3.2.2 Análise das simulações e projeções de mudança nos índices de extremos.....	44
3.2.3 Avaliação das incertezas via Inferência Bayesiana.....	44
4 RESULTADOS E DISCUSSÃO	50
4.1 Avaliação dos MCGs	50
4.2 Projeções Climáticas e Incertezas associadas	68
5 CONCLUSÕES	91
5.1 Sugestões de trabalhos futuros	94
6 REFERÊNCIAS	95

1 INTRODUÇÃO

O clima da Terra apresenta variabilidades em quase todas as escalas temporais, desde a escala sazonal até multi-decenal. Em algumas dessas escalas, a variabilidade climática é devido a processos de natureza randômica do sistema, ou devido a inúmeras e complexas causas (muitas vezes desconhecidas ou pouco entendidas cientificamente), o que dificulta a sua previsão. Portanto, o uso e entendimento das informações climáticas são frequentemente baseados em análises estatísticas de séries históricas observadas das variáveis climáticas (BARROS; CLARKE; DIAS, 2006).

Várias décadas atrás, o uso de informações climáticas era baseado na hipótese de que o clima era estacionário, pelo menos na escala decenal e, portanto, as condições climáticas futuras poderiam ser previstas utilizando somente uma série robusta de dados observados nas décadas anteriores. Entretanto, a hipótese de estacionariedade do clima não é mais aceita pela comunidade científica, dada as abundantes evidências de que as atividades humanas contribuíram para uma rápida mudança dos padrões climáticos conhecidos (GIORGI, 2005).

Neste contexto, segundo IPCC (2007, 2013), o termo Mudanças Climáticas refere-se a uma mudança no estado do clima local ou global, que pode ser identificado (por exemplo, pelo uso de métodos estatísticos) por mudanças na média e/ou na variabilidade de suas propriedades, como precipitação, temperatura, vento; e que persiste por um longo período de tempo, tipicamente décadas ou mais. Mudanças climáticas podem ser devido a processos internos naturais do sistema climático¹ (por exemplo, devido à ocorrência de eventos de El Niño/ La Niña nas escalas sazonal e interanual) ou forçantes externas (por exemplo, mudanças na quantidade de radiação que chega ao topo da atmosfera), ou ainda devido a mudanças antropogênicas na composição da atmosfera ou no uso da terra.

Desde a formação da Terra, por volta de 4,6 bilhões de anos atrás, seu clima sofreu inúmeras mudanças devido à variabilidade natural do sistema climático. Segundo Hartmann (1994) e Torres (2014), estas mudanças naturais ocorreram principalmente devido as seguintes forçantes:

- Mudanças na estrutura e composição da atmosfera terrestre durante a sua formação;

¹ O **sistema climático** consiste de cinco componentes principais que interagem entre si: a atmosfera, hidrosfera, criosfera, litosfera, e biosfera. O sistema climático muda no decorrer do tempo pela influência de sua própria dinâmica interna e por causa de forçantes externas naturais e antropogênicas.

- Deriva dos continentes;
- Variações na excentricidade, inclinação do eixo, e precessão da Terra (ciclos de Milankovitch);
- E erupções vulcânicas, as quais causam a liberação de partículas na atmosfera, especialmente aerossóis, que podem permanecer suspensas por vários meses em níveis mais elevados da atmosfera.

Tais fatores, os quais são cíclicos em sua maioria, modificam o balanço de radiação no sistema climático e causam grandes mudanças na temperatura do planeta. Entretanto, exceto para as erupções vulcânicas, estas mudanças ocorrem na escala de milhares de anos, o que é muito lento para ser percebido durante a vida dos seres humanos. Por essa razão, as mudanças no clima observadas nas últimas décadas, e que estão incluídos nos vários relatórios do Painel Intergovernamental de Mudanças Climáticas (IPCC), são mais intensas e rápidas do que aquelas que seriam observadas por algum fator natural conhecido (MARENGO et al., 2010a; TORRES, 2014).

Em contrapartida, outra forçante climática que também pode contribuir significativamente para uma mudança no clima é aquela advinda das atividades humanas, tais como variações na composição da atmosfera e uso da terra², os quais podem ocorrer em escalas temporais compatíveis com aquelas mudanças abruptas observadas no clima da Terra nas últimas décadas (MEEHL et al., 2007). Estas forçantes são as principais responsáveis pelo chamado Efeito Estufa.

De acordo com o IPCC (2013), as variações no clima são uma realidade, e seus efeitos aos ecossistemas já são evidentes. Observações mostram que, desde meados do século XVIII, no início da Revolução Industrial, houve elevação da temperatura média global, modificações no ciclo de chuvas e aumento do nível médio do mar, sendo compatíveis com as concentrações

² **Uso da terra** refere-se ao total de arranjos, atividades e insumos realizados em um determinado tipo de cobertura do solo (um conjunto de ações humanas). O termo uso da terra também é usado no sentido dos propósitos sociais e econômicos pelos quais a terra é administrada (por exemplo, pastoreio, extração e conservação de madeira). **A mudança do uso da terra** refere-se a uma mudança no uso ou na gerência da terra pelos seres humanos, que podem conduzir a uma mudança na cobertura da terra. A cobertura do solo e a alteração do uso da terra podem ter impacto no albedo de superfície, na evapotranspiração, nas fontes e nos sumidouros de gases de efeito estufa ou em outras propriedades do sistema climático e podem, assim, ocasionar uma forçante radiativa e / ou outros impactos no clima local ou global (IPCC, 2007).

crescentes de gases de efeito estufa (GEE) antropogênicos emitidos. Essas mudanças podem ocasionar danos aos ecossistemas marinhos e terrestres, aumento da incidência de tempestades severas, ciclones tropicais, inundações, estiagem, acidificação dos oceanos, ondas de frio e calor, prejuízos agrícolas e à saúde humana, podendo ser ainda mais frequentes caso as projeções futuras se concretizem.

Para mensurar os efeitos que as Mudanças Climáticas ocasionam, utilizam-se comumente os Modelos de Circulação Geral (MCG), os quais são compostos por parametrizações que representam os processos ocorridos em cada uma das partes do Sistema Terrestre e as interações entre elas. Através de projeções geradas pelos modelos, é possível avaliar o comportamento do clima no futuro, facilitando a proposta de medidas de adaptação e mitigação para tais implicações (GROTCH; MACCRACKEN, 1991; WILBY; WIGLEY, 1997).

Os efeitos poderão ser (e em alguns casos, já são) sentidos em diversas regiões do mundo; porém as áreas de maior vulnerabilidade são as subdesenvolvidas econômica, social e ambientalmente (IPCC, 2014a). A América do Sul é considerada uma das regiões mais vulneráveis do planeta, por ser grande produtora agrícola (GASQUES et al., 2014) e possuir base energética renovável, as quais dependem majoritariamente das condições de chuva, temperatura e vento (TORRES et al., 2012; SILLMANN et al., 2013a, 2013b; TORRES; MARENGO, 2014; MME, 2015). As projeções indicam que algumas tendências já encontradas na região podem ser agravadas pelas mudanças climáticas, como é o caso da diminuição de precipitação na porção sul da Bacia Amazônica, aumentando a possibilidade de secas e avanço do Cerrado sobre a área; secas severas no Nordeste do Brasil; chuvas intensas no Sudeste, ocasionando inundações mais frequentes; aumento das amplitudes térmicas no sul do continente; dentre outras (IPCC, 2014a).

O aumento da intensidade de precipitação e temperatura, por exemplo, e sua recorrência podem caracterizar extremos climáticos, os quais são eventos que se apresentam fora do padrão médio climatológico e são provocados por fatores naturais e antropogênicos, causando grandes impactos ambientais e sociais. Apesar de serem comumente realizados, estudos que analisam as projeções de extremos climáticos utilizando informações de vários modelos climáticos são escassos (VALVERDE; MARENGO, 2014; SILVA et al., 2014, 2015; NATIVIDADE, 2015; NATIVIDADE; GARCIA; TORRES, 2017). Além disso, nenhum destes estudos abordam as incertezas envolvidas nas projeções dos extremos que possam vir a ocorrer na América do Sul.

Essa escassa quantidade de trabalhos a respeito dos extremos climáticos pode ser decorrente de sua natureza, pois trata-se de variáveis derivadas, as quais são calculadas a partir de outras variáveis utilizando estatísticas complexas. Assim, além do cálculo desses índices ser mais trabalhoso, as incertezas relacionadas a eles tornam-se maiores (ZHANG et al., 2011).

Mesmo sendo fisicamente consistente e tendo grande probabilidade de ocorrerem, as projeções de mudanças nas variáveis climáticas médias e de extremos climáticos são acompanhadas de incertezas. Essas incertezas são decorrentes das diversas etapas envolvidas em uma projeção climática e dependem de inúmeros fatores, como: condições iniciais e de fronteira; representações numéricas dos processos físicos, químicos e biológicos; falta de conhecimento das interações das inúmeras componentes do sistema climático; variações naturais não-lineares; escolha dos cenários de emissão, entre outros (STOTT; KETTLEBOROUGH, 2002; KNUTTI et al. 2010). Nas projeções de extremos climáticos, principalmente quando se refere à precipitação, as incertezas associadas são ainda maiores, fazendo-se necessário conhecer suas características e possíveis formas de diminuir tais incertezas (KNUTTI, 2008; GIORGI, 2005; NATIVIDADE, 2015; NATIVIDADE; GARCIA; TORRES, 2017).

Apesar de ser um tema bastante discutido na atualidade pelos cientistas e tomadores de decisão, medidas de adaptação³ e mitigação⁴ para tais mudanças no clima ainda são incipientes, e não são difundidas como deveriam para a população. Dessa maneira, estudos sobre a temática são importantes, uma vez que podem auxiliar na identificação de regiões vulneráveis, incentivar as autoridades a tomar medidas adaptativas mais efetivas e envolver mais a população nas decisões, procurando diminuir seu impacto e evitar consequências mais graves. Tratando-se de extremos climáticos e suas incertezas associadas, a abordagem torna-se ainda mais significativa, uma vez que tais eventos são de magnitude superior e causam impactos mais devastadores à sociedade.

1.1 Objetivos

O objetivo geral dessa dissertação é avaliar as principais incertezas envolvidas nas projeções de índices de extremos climáticos na América do Sul geradas por Modelos de

³ **Adaptação** refere-se ao ajuste nos sistemas naturais ou humanos em resposta às variações climáticas e seus efeitos, procurando moderar os danos causados e explorar oportunidades benéficas.

⁴ **Mitigação** refere-se a ações tomadas para diminuir as emissões líquidas de GEEs, objetivando reduzir as mudanças climáticas e preservar e aumentar os sumidouros e reservatórios desses gases (IPCC, 2007).

Circulação Geral (MCGs). Além disso, identificar como as incertezas se distribuem geograficamente, no intuito de fornecer subsídios importantes para os estudos de impacto, adaptação e vulnerabilidade desta região. Especificamente, os objetivos são:

- Avaliar a climatologia simulada (1961-1990) dos extremos climáticos utilizando dados diários de precipitação e temperatura do ar próximo à superfície na América do Sul por 31 modelos integrantes do conjunto CMIP5 (*Coupled Model Intercomparison Project Phase 5*);
- Avaliar as projeções de mudanças nos extremos climáticos na região para o final do século XXI (2071-2100) produzidos pelos modelos analisados em diferentes cenários de emissões de gases de efeito estufa e aerossóis;
- Identificar as incertezas envolvidas nas projeções de extremos climáticos para a região de estudo no final do século XXI (2071-2100), focando-se principalmente naquelas incertezas relacionadas às variabilidades inter-modelos e devido aos diferentes cenários de emissões;
- Produzir projeções médias e probabilísticas de mudanças nos extremos climáticos das variáveis precipitação e temperatura para a América do Sul, levando-se em consideração as incertezas envolvidas através de Inferência Bayesiana.

2 REVISÃO BIBLIOGRÁFICA

2.1 Sistema Terrestre e Mudanças Climáticas

O sistema climático terrestre é altamente complexo, constituído por cinco grandes componentes: atmosfera, hidrosfera, criosfera, litosfera e biosfera. Embora essas componentes naturais sejam muito diferentes em sua composição, propriedades físicas, estrutura e comportamento, elas são ligadas por fluxos de massa, energia e momento, havendo constantes interações entre elas. A atmosfera é a componente essencial da vida na Terra, determinante chave de seu clima, e é nela que ocorrem as principais trocas e processos entre as partes. Composta por gases, aerossóis e nuvens, a atmosfera tem como papel principal controlar a quantidade de energia radiante que adentra ao sistema e que é emitida de volta para o espaço. Através desse balanço radiativo é que ocorrem os outros processos de interação, formando assim a dinâmica do planeta (HARTMANN, 1994).

As componentes do sistema climático podem, com o tempo, sofrer variações decorrentes de sua própria dinâmica interna ou por forçantes naturais e antropogênicas externas a ele. Essas perturbações são percebidas através de alterações no valor médio do clima e/ou na variabilidade de elementos, como precipitação, intensidade do vento, temperatura, entre outros, em uma dada região ou mesmo no planeta como um todo. Essa mudança climática, assim como se denomina, deve persistir por um longo período, geralmente superior a diversas décadas (MOSS et al., 2010).

As mudanças naturais do clima acontecem e aconteceram durante toda a história evolutiva da Terra em escala de tempo de milhares de anos em sua maioria, não sendo claramente percebidas pelos humanos. Como exemplos de processos que influenciam a mudança no clima podemos citar: i) mudanças na atmosfera relacionadas à sua estrutura e composição durante o processo de formação do planeta; ii) a deriva dos continentes e afastamento das placas tectônicas; iii) erupções vulcânicas, iv) além de variações temporais no campo magnético, na inclinação do eixo de rotação e nas características da órbita terrestre ao redor do Sol. Embora os fatores supracitados alterem o balanço de radiação no sistema climático e influenciem na variação de temperatura no planeta, as erupções vulcânicas são, dentre elas, as mudanças mais perceptíveis aos humanos, uma vez que são frequentes e suas partículas lançadas no ambiente podem permanecer nos vários níveis da atmosfera por diversos meses,

dependendo de sua composição, podendo contribuir com um resfriamento, uma vez que a densa pluma atenua a radiação solar (MEEHL et al., 2007).

Adicionalmente, existem mecanismos naturais que influenciam a dinâmica e interação entre continentes, oceanos e atmosfera e podem determinar mudanças nos padrões de circulação, temperatura, precipitação, vento, dentre outros. Alguns desses mecanismos que possuem significativa influência sobre diversas regiões do globo e atuam diretamente na América do Sul são El Niño-Oscilação Sul (do inglês, ENSO) e Oscilação Decenal do Pacífico (do inglês, PDO).

Segundo Bjerknes (1969), o ENSO é caracterizado pela alteração nos padrões normais de temperatura da superfície do mar (TSM), causando mudança de intensidade dos ventos alísios na região do Pacífico Equatorial, além da relação inversa de pressão atmosférica na superfície entre as Ilhas Darwin (Austrália) e Tahiti (Pacífico Sul). Sua fase positiva é chamada de El Niño e corresponde ao aquecimento anômalo das águas superficiais no Pacífico Equatorial Oriental; já a fase negativa é denominada La Niña, na qual ocorre um resfriamento anômalo no Pacífico Equatorial central e leste. A duração de uma das fases do ENSO pode variar entre 12 e 18 meses, dependendo das condições que determinam a manutenção do fenômeno, e sua influência é sentida em grande parte do mundo, principalmente nas regiões adjacentes ao Oceano Pacífico (TRENBERTH, 1997; COLLINS et al., 2010; WANG et al., 2016).

Por sua vez, a PDO possui escala multidecenal (20 a 30 anos) e segue padrões parecidos com ENSO, porém sendo mais visíveis seus efeitos no setor norte do Oceano Pacífico e do continente americano, influenciando secundariamente os trópicos. A fase positiva da PDO está associada com aumento das condições favoráveis ao desenvolvimento de El Niño e a fase negativa tende a favorecer os eventos de La Niña (MANTUA et al., 1997; ALEXANDER, 2010).

Além dos fatores supracitados, a ação antropogênica pode interferir também nas mudanças do clima e intensificar ou atenuar os efeitos da variabilidade natural. Indústrias, veículos, mineração, pecuária e geração de energia possuem processos que liberam gases do efeito estufa (GEE) e aerossóis na atmosfera, os quais interferem no balanço energético do planeta. A emissão desses poluentes aumentou desde a era pré-industrial, devido ao crescimento populacional e econômico. O vapor d'água, principal GEE, provém dos processos naturais, porém o dióxido de carbono (CO₂), metano (CH₄), óxido nitroso (N₂O), hidrofluorcarbonos

(HFCs), perfluorcarbonos (PFCs), hexafluoreto de enxofre (SF_6) e trifluoreto de nitrogênio (NF_3) são GEEs resultantes das ações antropogênicas e apresentam-se como grandes absorvedores de calor, potencializando o efeito estufa (processo natural) e causando um aquecimento adicional ao sistema climático (WMO, 2016). Assim, a energia adicionada (retirada) ao sistema climático de forma natural ou antropogênica é considerada como uma forçante radiativa positiva (negativa).

Dentre os GEEs, a liberação e concentração de CO_2 , CH_4 e N_2O na atmosfera têm se mostrado muito elevada ao longo do tempo, sendo que os níveis atingidos não possuem precedentes nos últimos 800 mil anos, evidenciando a influência da ação humana (IPCC, 2014a). Os aerossóis, em sua maioria, refletem a radiação solar incidente, diminuindo a quantidade de energia que adentra ao sistema; exceto o *black carbon*, que tem origem da queima incompleta dos combustíveis fósseis e, quando na atmosfera, são grandes absorvedores de radiação e agem como aquecedores do planeta. Além do espalhamento radiativo, os aerossóis podem servir como núcleos de condensação de nuvens, afetando tanto a microfísica quanto o tempo de residência das nuvens e favorecendo o aumento de precipitação (ARTAXO et al., 2006). Outro fator que pode servir como forçante radiativa positiva (absorve radiação) ou negativa (reflete radiação) são as mudanças de albedo da superfície, as quais geralmente ocorrem devido ao desmatamento, urbanização, substituição da vegetação ou mesmo derretimento do gelo (PBMC, 2014).

Para mensurar os possíveis efeitos que essas variabilidades naturais e antrópicas terão no clima futuro, utiliza-se comumente os Modelos de Circulação Geral (MCGs), os quais são representações numéricas do sistema climático baseado nas propriedades físicas, químicas e biológicas terrestres, suas interações e processos de *feedback* (GROTCH; MACCRACKEN, 1991; WILBY; WIGLEY, 1997). Tais modelos têm como condições de entrada diferentes cenários de emissões, que projetam as possíveis emissões futuras de GEEs, aerossóis e outros poluentes na atmosfera e, acompanhado de informações de cobertura e uso do solo, geram projeções a respeito de variáveis climáticas como a temperatura, a umidade, a precipitação, o vento e possibilitam o conhecimento de condições que podem favorecer possíveis eventos extremos durante um longo período (IPCC, 2013).

O Painel Intergovernamental de Mudanças Climáticas (do inglês, IPCC) é um grupo de apoio das Nações Unidas sobre assuntos relacionados ao sistema climático e possui um comitê de economistas, políticos e cientistas de diferentes áreas do conhecimento. Com base nas

observações até o presente e nos resultados dos modelos climáticos para o clima presente e futuro, esses especialistas elaboram relatórios com a base científica, os possíveis impactos e vulnerabilidades que as mudanças climáticas podem causar, sugerindo medidas de adaptação e mitigação para as mesmas. O relatório de avaliação mais recente, publicado pelo IPCC em 2013/2014, é o AR5, que tem como subsídio os MCGs do conjunto CMIP5 (*Coupled Model Intercomparison Project Phase 5*). Neste relatório são apresentadas projeções de variáveis climáticas para todo o globo, baseando-se em quatro cenários de forçante radiativa que consideram um aumento de $2,6 \text{ Wm}^{-2}$ (RCP2.6), $4,5 \text{ Wm}^{-2}$ (RCP4.5), $6,0 \text{ Wm}^{-2}$ (RCP6.0) e $8,5 \text{ Wm}^{-2}$ (RCP8.5) de energia armazenada no sistema (IPCC, 2013).

Segundo o IPCC (2014b), pode-se afirmar com 95% de confiança que o aquecimento global verificado desde a década de 1950 é decorrente das atividades humanas, uma vez que, dentre outros motivos, ele ocorre em escala de tempo menor que as mudanças naturais e de forma mais acentuada e sem precedentes na história recente. Até a atualidade, verificou-se que a concentração de GEEs na atmosfera aumentou significativamente, sendo que os principais deles, CO_2 , NH_4 e N_2O , sofreram aumentos de 44%, 156% e 21%, respectivamente, comparados aos níveis observados em 1750 (WMO, 2016). Tal crescimento contribuiu para a mudança em características médias do clima, assim como em eventos extremos. Aproximadamente um terço do CO_2 emitido pelas atividades antropogênicas é absorvido pelos oceanos, porém tal absorção já levou à um decréscimo de 0,1 no pH de suas águas desde o início da era industrial, provocando acidificação dos mesmos. As últimas três décadas apresentaram sucessivamente temperaturas, tanto para a atmosfera quanto para o oceano, mais quentes desde 1850; houve uma tendência de aumento de precipitação na América do Norte, sudeste da América do Sul, norte da Europa e da Austrália, ocorrendo em contrapartida um deficit de chuva em boa parte da África, sul da Europa e sudeste da Ásia e Austrália. A extensão de gelo na Groenlândia e Antártica tem diminuído consideravelmente, o que colaborou com um aumento de cerca de 19 cm no nível médio do mar global. Também, observou-se perda de espécies e alteração nos ecossistemas em diferentes partes do globo (IPCC, 2013).

Em concordância, as projeções climáticas apontam continuidade e progressivo aumento dessas mudanças até o final do século XXI, comparado aos níveis observados entre 1986 e 2005 (Figura 1). Para o cenário de forçante radiativa com baixa emissão (RCP 2.6), as projeções indicam que a temperatura média global sofrerá aumento de 1°C , a precipitação média anual não modificará mais que 20%, o pH diminuirá em 0,15 e ocorrerá uma elevação de 0,40 m no

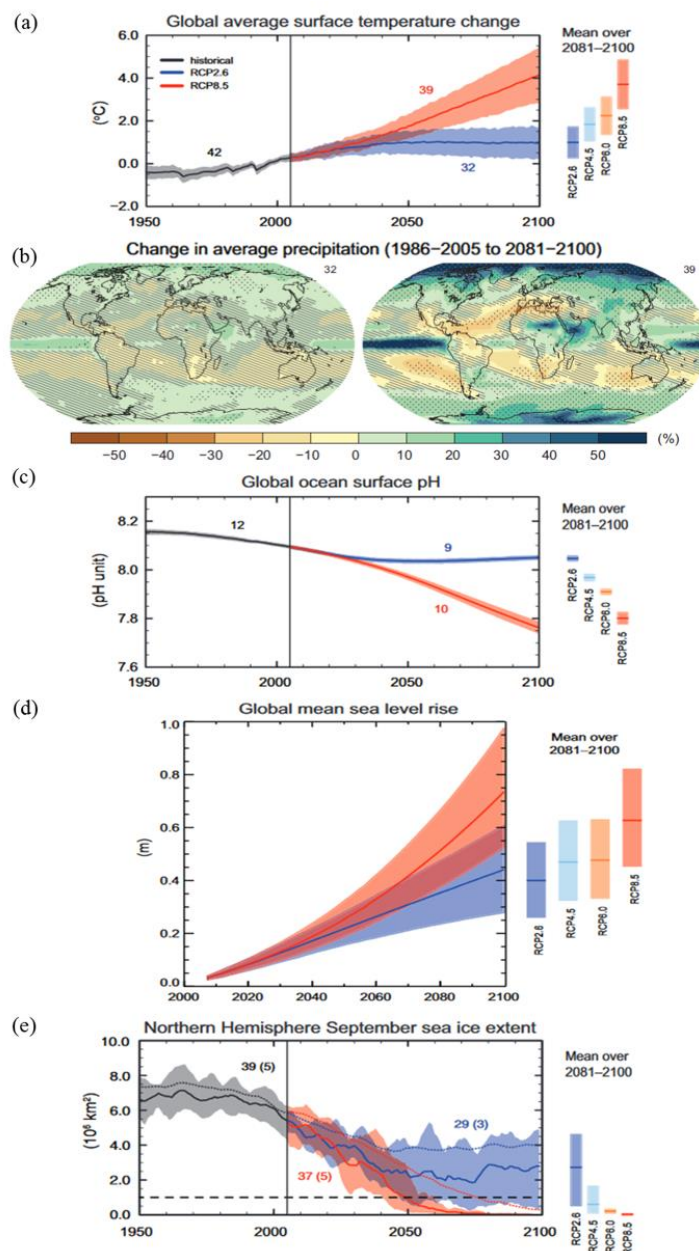


Figura 1 – Simulações (1950-2005) e projeções (2006-2100) dos modelos do CMIP5 para (a) mudança na temperatura média global, (b) variação da precipitação, (c) pH oceânico, (d) elevação do nível médio do mar e (e) extensão do gelo marinho no Hemisfério Norte. As séries temporais das projeções e suas incertezas (sombreado) são mostradas para os cenários RCP2.6 (azul) e RCP8.5 (vermelho). A linha preta e os sombreados cinza correspondem à evolução histórica média simulada pelos modelos e suas variações. O número acima de cada trajetória representa a quantidade de modelos do CMIP5 utilizados no cálculo da média e todas as projeções são em relação ao período 1986-2005. As barras verticais coloridas representam a média e as incertezas das projeções referentes ao período 2081-2100 para os quatro cenários RCPs. Na figura da variação de precipitação (b), o tracejado diagonal indica regiões onde a média dos modelos é pequena em comparação à variabilidade interna natural (menor que um desvio padrão); o pontilhado mostra as regiões onde a média dos modelos é grande em comparação com a variabilidade interna natural (maior que dois desvios padrão) e indica que pelo menos 90% dos modelos concordam com o sinal da mudança; também, o número de modelos do CMIP5 utilizados no cálculo da média pode ser visto no canto superior direito de cada mapa. Para a extensão do gelo marinho (e), é dada a média e as incertezas projetadas (faixa mínima-máxima) do subconjunto de modelos que reproduzem mais fielmente o estado médio climatológico, e a tendência do gelo marinho no Ártico entre 1979 e 2012 (número de modelos entre parênteses). A média dos modelos é representada pelas trajetórias pontilhadas. A linha tracejada representa condições quase isentas de gelo, indicando que a extensão do gelo marinho é inferior a 10^6 km² durante, pelo menos, cinco anos consecutivos.

Fonte: IPCC (2013).

nível médio do mar. Já para o cenário de forçante radiativa mais pessimista (RCP 8.5), onde não haveria nenhuma mitigação a respeito das mudanças climáticas, a temperatura média global pode alcançar um aumento de mais de 4°C; as altas latitudes e o Oceano Pacífico Equatorial sofrerão aumento na precipitação média anual, enquanto muitas regiões com escassez de chuvas em latitudes médias e subtropicais se tornarão ainda mais secas; a acidificação dos oceanos será mais pronunciada, podendo variar de 0,30 a 0,32 a diminuição do pH; a elevação no nível médio do mar alcançará 0,65 m e a calota de gelo do Ártico pode sofrer derretimento quase completo no mês de Setembro, quando as temperaturas são mais elevadas na região (IPCC, 2013). Tais projeções são apresentadas na Figura 1, a qual compara os diferentes cenários RCPs.

Ademais, as projeções indicam a possibilidade de aumento na frequência e intensidade de eventos extremos, o que acarreta diversos outros impactos às componentes do sistema climático. De acordo com o Quarto Relatório do IPCC (2012), os eventos extremos são eventos raros que acometem determinados locais e épocas do ano e, normalmente, são caracterizados por estarem fora do padrão médio climatológico (abaixo do 10º percentil ou acima do 90º percentil da distribuição observada). Quando o padrão de extremos meteorológicos persiste em uma época (durante a mesma estação do ano por vários anos, por exemplo), ele pode ser classificado como evento extremo climático, provocando impactos de grande magnitude, dependentes da vulnerabilidade e da resiliência das regiões e populações. Ainda, segundo IPCC (2012) e Marengo et al. (2010a), o número de dias e noites frias têm diminuído e de dias e noites quentes têm aumentado em escala global. Isso faz com que as ondas de calor sejam mais recorrentes em determinadas localidades que já são mais quentes e diminui as possíveis ondas de frio. Em relação aos extremos positivos de precipitação, estes são susceptíveis de se tornarem mais intensos e frequentes nas porções de terra localizadas em latitudes médias e tropicais úmidas.

As projeções mostram um aumento na frequência de extremos de chuva no oeste da Amazônia e sudeste da América do Sul para o final do século XXI, possivelmente devido ao maior aquecimento na região equatorial, causando intensificação dos alísios e, conseqüentemente, do jato de baixos níveis à leste dos Andes, o qual é responsável pelo transporte de umidade para essas regiões. No leste da Amazônia e nordeste do Brasil, as características da precipitação não sofrerão modificações abruptas, mantendo a pouca quantidade de eventos. Por fim, o aumento do número de dias secos consecutivos poderá ser observado no Altiplano chileno e no Platô brasileiro, podendo favorecer o avanço do Cerrado

na região sul da Amazônia. (MARENGO et al., 2009; SOARES; MARENGO, 2009; KITO; KUSUNOKI; NAKAEGAWA, 2011; IPCC, 2012).

2.2 Impactos de eventos extremos na América do Sul

As regiões mais impactadas, tanto por mudanças na média quanto nos extremos, serão os países de clima quente, com economia subdesenvolvida e em desenvolvimento, e as populações marginalizadas no geral (IPCC, 2014a). A América do Sul, por exemplo, é composta por países de economia agrícola e, por se tratar de uma região com parte subdesenvolvida e parte em desenvolvimento, com grande desigualdade social e falta de infraestrutura, características anômalas no regime de precipitação e nas temperaturas podem prejudicar a biodiversidade, a agricultura, a pecuária, além do fornecimento energético, abastecimento de água e causar prejuízos econômicos, sociais e humanos (MARENGO et al., 2010a; DEBORTOLI et al., 2017).

Vale ressaltar que as mudanças climáticas não devem ser consideradas causa de todos os eventos extremos, principalmente os isolados, uma vez que estes também ocorrem de forma natural e podem ser causados por uma combinação de fatores. Assim, faz-se necessário investigar a recorrência histórica desses eventos e as regiões atingidas, para associar a possível relação de causa e efeito.

Eventos extremos já podem ser observados em diversas partes da América do Sul, não necessariamente sendo decorrentes das mudanças climáticas. Em julho de 2010, por exemplo, uma intensa onda de frio polar se estendeu desde o sul da Argentina e Chile até Sul do Brasil, Paraguai, Bolívia e Peru. Tal episódio esteve associado à um centro de alta pressão atmosférica, pouco comum, instalado sobre a província de Buenos Aires e Uruguai. Essa onda de frio polar deixou ao menos 80 mortos (principalmente moradores de ruas, idosos e bebês) nesses países, tanto por hipotermia quanto por intoxicação com dióxido de carbono, devido aos sistemas de calefação defeituosos. Também, o frio foi responsável pela suspensão de inúmeros voos regionais no aeroporto em Buenos Aires, provocou estragos agrícolas e isolamentos por nevasca no sul do Chile e causou morte de centenas de gados no Mato Grosso do Sul. Os Serviços Meteorológicos locais informaram que as temperaturas mínimas alcançaram -11°C na Patagônia argentina, -5°C no centro e norte da Argentina, oscilaram entre -10 e -15°C em Santiago, atingiram -5°C nas regiões central e leste do Uruguai, e em Urupema (SC), chegou a

-7,8°C, sendo a menor temperatura registrada no Brasil no ano de 2010 (BBC BRASIL, 2010; GLOBO, 2010).

Em dezembro de 2015, chuvas torrenciais favorecidas pelo fenômeno El Niño ocasionaram enchentes no Uruguai, no Paraguai, na Argentina e em municípios no Sul do Brasil, os quais fazem fronteira com o território argentino. Segundo a Defesa Civil, mais de 150 mil pessoas precisaram deixar suas casas e foram encaminhadas para abrigos improvisados nos quatro países, a grande maioria delas no Paraguai, onde a situação foi mais grave principalmente na capital Assunção. O rio Paraguai subiu quase 8 metros com as chuvas e atingiu o nível mais alto desde 1995. No Brasil, 43 municípios gaúchos foram atingidos, sendo em 25 deles decretados situação de emergência (FOLHA DE SÃO PAULO, 2015; GLOBO, 2015).

Já em novembro de 2016, a Bolívia foi acometida por uma estiagem considerada a pior em 25 anos. As grandes represas que abastecem La Paz e cidades adjacentes à capital são mantidas com a água de degelo das montanhas dos Andes. Porém, essas geleiras têm diminuído rapidamente devido ao aumento das temperaturas (SHI et al., 2013) e, conseqüentemente, levou o nível de água nos reservatórios quase a zero, o que já vinha provocando seca na região e acarretou em um severo racionamento de água nesse ano. Diversas cidades decretaram estado de emergência, milhares de famílias foram prejudicadas pela seca e o setor agropecuário foi fortemente atingido (EXTRA, 2016).

No Brasil, no que se refere aos extremos positivos de precipitação, em escala de dias, a região Serrana do estado do Rio de Janeiro foi atingida, em janeiro de 2011, por chuvas intensas, as quais causaram enchentes em diversas cidades e graves deslizamentos de terra. A enxurrada foi bastante forte, arrastando carros, árvores, pedras nas encostas e até mesmo casas, o que causou o soterramento de centenas de pessoas. Os municípios mais afetados foram Nova Friburgo, Teresópolis, Petrópolis, Sumidouro, São José do Vale do Rio Preto e Bom Jardim, que contabilizaram juntos 947 mortes e milhares de desabrigados, segundo a Secretaria Estadual de Saúde e a Defesa Civil do Rio de Janeiro (DOURADO; ARRAES, SILVA, 2012; BANCO MUNDIAL, 2012). O volume acumulado de precipitação registrado em 24 horas atingiu aproximadamente 183 mm em Nova Friburgo, cidade com maior número de vítimas fatais, porém outras estações meteorológicas também chegaram a medir precipitação superior a 100 mm nos municípios adjacentes. Neste caso, o grande volume de chuva foi decorrente de uma atmosfera instável e úmida associada à Zona de Convergência do Atlântico Sul (ZCAS), caracterizada por uma banda de nebulosidade que se estende da Amazônia ao Sudeste do país,

o que possibilitou a formação de nuvens convectivas profundas. Combinado a isso, fatores como o crescimento populacional, moradias em áreas irregulares e a saturação do solo e elevação do nível dos rios devido às chuvas ocorridas na região Sudeste nos meses anteriores contribuíram com a dimensão do desastre (EGLER; GUSMÃO, 2014; PINHEIRO; ANDRADE; MOURA, 2011).

Quanto ao ciclo de precipitação e sua variabilidade, a região Nordeste do Brasil sempre sofreu com períodos severos de estiagem. A escala espacial e temporal de chuva nessa região está relacionada com a variação na circulação atmosférica de grande escala e na interação oceano-atmosfera nos Oceanos Atlântico e Pacífico. Um fenômeno que causa grande impacto não só no Nordeste, como em outras regiões do Brasil e do mundo, é o ENSO (WANG et al., 2016). A fase positiva deste fenômeno, chamada de El Niño, provoca altas temperaturas e chuvas na costa oeste da América do Sul e, no Brasil, altas temperaturas na região Sudeste, chuvas intensas no Sul e altas temperaturas e tempo seco no Nordeste. Já a fase negativa, denominada La Niña, também reflete nas condições de tempo de diversas regiões do mundo, trazendo frio para o Sudeste, tempo seco no Sul e chuvas no Nordeste (KOUSKY; CAVALCANTI, 1984; FEDOROVA; CARVALHO, 2000; GRIMM, 2003; GRIMM, 2004; SHIMIZU; AMBRIZZI; LIEBMANN, 2017). Nos anos 1982 e 1983 houve um episódio bastante intenso de El Niño, que provocou significativas modificações no regime pluviométrico do Nordeste, estabelecendo-se uma estiagem que se estendeu por cerca de 4 anos e é considerada uma das mais severas e longas na região, chegando a ser decretado estado de calamidade pública na época. Em 2011-2012, a região Nordeste foi novamente acometida por uma seca de características semelhantes à citada anteriormente, porém a La Niña estava estabelecida nesse período. O resfriamento estava concentrado no Pacífico central e as águas quentes se encontravam no Atlântico tropical norte, favorecendo uma migração da ZCIT para o norte e causando estiagem no Nordeste (SANTOS et al., 2012; MARENGO et al., 2013; RODRIGUES; MCPHADEN, 2014). Essa estiagem, a qual iniciou-se mais amena em 2010, vem se prolongando no semiárido nordestino. Devido as perdas agropecuárias, problemas no abastecimento de água e prejuízo nas economias locais, foi necessário a liberação de recursos para que a população possa se manter. Os efeitos da seca foram agravados em 2015 com o fenômeno El Niño e as anomalias negativas de precipitação em 2016 podem ser comparadas as de 2012 (MARENGO et al., 2017).

Também, a região da Bacia Amazônica foi acometida em 2010 por uma seca drástica. Por meio da análise de séries históricas da pluviosidade na região, cientistas do Instituto Nacional de Pesquisas Espaciais (INPE) concluíram que esta foi a maior seca já registrada desde 1902. Segundo estudos, o processo iniciou-se com o El Niño no começo do verão, mas foi intensificado pelo aquecimento das águas tropicais no Atlântico Norte. As consequências, principalmente para o sul da Amazônia, foram a diminuição severa dos níveis de água, chegando até mesmo à seca completa de cursos d'água, o que causou graves problemas socioambientais, em especial às comunidades ribeirinhas (MARENGO et al., 2011).

Mais recentemente, entre o verão de 2014 e 2015, a Região Metropolitana de São Paulo (RMSP) vivenciou uma crise hídrica de grandes proporções. A combinação de baixos índices de chuva sobre a região da Cantareira (principal reservatório de abastecimento da região), o crescimento da demanda de água e energia e a falta de conscientização da população prejudicou a distribuição de água, havendo seu racionamento e aumento do custo da energia elétrica. Além disso, essa situação agravou o número de focos de queimadas e causou impactos nas áreas turística, agrícola e pecuária. Segundo evidências, essa crise hídrica na RMSP foi gerada por fatores diversos, como um sistema de alta pressão que se estabeleceu sobre o Sudeste durante os meses de verão e anomalias na circulação que afetam os padrões de chuva, modificam o transporte de umidade proveniente da Amazônia, as brisas marítimas vindas do Oceano Atlântico Sul e a ação das frentes que vêm do sul do país (MARENGO et al., 2015; COELHO et al., 2016; COELHO; CARDOSO; FIRPO, 2016; MARENGO; ALVES, 2016; NOBRE et al., 2016). Esse bloqueio na atmosfera, por impedir outros sistemas de alcançarem as regiões do Brasil e inibir a formação de nuvens de chuva, contribuiu também para a elevação das temperaturas no verão de 2014, principalmente no mês de fevereiro, em diversas cidades do Centro-oeste, Sul e Sudeste. Segundo o CPTEC, o Rio de Janeiro registrou temperatura recorde para o período desde 2010; São Paulo e Porto Alegre não sofriram condições tão extremas positivas de temperatura desde a década de 1940. Como o ciclo normal de precipitação foi impedido, o solo tornou-se mais seco e a radiação solar o esquentava mais rapidamente, aquecendo conseqüentemente a atmosfera adjacente e elevando ainda mais as temperaturas (SILVA; NASCIMENTO; MENEZES, 2015). Além disso, parte das cidades nessas regiões do país são grandes centros urbanos, compostos por poucas áreas florestadas e inúmeras construções de concreto, ferro, asfalto, cimento, as quais absorvem facilmente o calor, tornando a sensação térmica desconfortável e formando as ilhas de calor (GARTLAND, 2010).

Em contraste, a região Sul do Brasil sofre, em geral, com as ondas de frio e grandes volumes de chuvas. Fatores geográficos como latitude, altitude, continentalidade e maritimidade exercem importante papel na temperatura e precipitação, porém deve-se considerar também as variações nos padrões atmosféricos locais (FIRPO; SANSIGOLO; ASSIS, 2012). O Sul do Brasil, mais especificamente o Rio Grande do Sul, está localizado em latitudes subtropicais e por se tratar de uma zona de transição do clima, possui majoritária influência de sistemas extratropicais, como frentes e massas polares provenientes do continente Antártico, embora sistemas intertropicais possam agir sobre a região. Essas massas e sistemas frontais transportam ar frio polar para o sul da América do Sul e, principalmente no inverno, quando há maior formação de bloqueios atmosféricos na área, tornam-se mais intensos por sua influência estar confinada à região (SARTORI, 2003). Quando as temperaturas permanecem por diversos dias abaixo de um limiar específico para cada localidade, dependendo também dos parâmetros geográficos citados inicialmente, são denominadas ondas de frio, identificada por diversos métodos (ALVES et al., 2017), e estas, acompanhado de condições de céu claro, resfriamento radiativo noturno e baixo nível de umidade devido ao sistema de alta pressão, por exemplo, podem ocasionar geadas, prejudicando não só a agricultura e pecuária na região, como também a saúde e conforto térmico da população (ESCOBAR, 2007; REBOITA et al., 2012). Em julho de 2017, um evento de onda de frio associada à uma frente fria acometeu o Sul do Brasil, diminuindo as temperaturas durante o dia e atingindo até 3,6°C durante a madrugada em algumas cidades, com consequentes geadas em regiões gaúchas (CLIMATEMPO, 2017).

2.3 Modelos de Circulação Geral (MCGs) e incertezas associadas

Para representar as componentes do sistema climático e identificar os efeitos das mudanças climáticas na variabilidade dos aspectos médios e de eventos extremos, os MCGs são bastante utilizados. Diversos estudos têm analisado a dinâmica climática simulada nos períodos observados e projetados desses modelos. Em relação aos extremos, Frich et al. (2002) identificaram mudanças na frequência e intensidade desses eventos nas últimas décadas. A partir de 10 índices de temperatura e precipitação e de uma rede fixa de observações de alta qualidade, composta por 181 estações meteorológicas espalhadas por todo o globo, os autores constataram que os resultados convergem para um aquecimento na Austrália e no Hemisfério Norte após meados do século XX, evidenciando a diminuição geral do número de dias frios. No que diz respeito a precipitação, observou-se que houve um aumento da quantidade de

eventos intensos no leste dos Estados Unidos, oeste da Rússia, partes da Europa e sul da África, enquanto a região da Sibéria e o leste da Rússia apresentaram diminuição das precipitações.

Marengo et al. (2010a), utilizando dados de 9 modelos globais do CMIP3, referentes às simulações do presente (1960-2000), e observações provenientes de 104 estações meteorológicas espalhadas pelo continente Sul americano, estudaram o comportamento dos índices climáticos noites muito quentes (TN90p), dias de precipitação intensa (R10mm) e dias secos consecutivos (CDD), definidos por Frich et al. (2002). As observações mostram uma significativa tendência positiva na frequência de TN90p em todo o território ao sul de 10°S; já para R10mm, tendências positivas também foram observadas no sudeste da América do Sul, norte e centro da Argentina, noroeste do Peru e Equador, enquanto tendências negativas no sul do Chile. Para o índice CDD, as tendências foram menos evidentes, sendo levemente negativas em grande parte do sudeste da América do Sul e na pequena extensão entre o sul do Peru, Bolívia e norte da Argentina. Quando analisadas as simulações, notou-se diferenças entre os modelos e, apesar do aquecimento ser evidenciado, todos os modelos tendem a superestimar a magnitude de TN90p e a subestimar a tendência de R10mm em algumas regiões. Os autores concluíram, através das funções densidade de probabilidade, que os modelos representavam bem o aumento de noites muito quentes (TN90p), sugerindo que a maior parte da América do Sul se aqueceu de forma semelhante. Por fim, ficou aparente que as mudanças para o índice de precipitação extrema (R10mm) são menos coerentes que o índice de temperatura, sendo menor sua capacidade de representar as observações.

Também, a partir de dados de modelos do CMIP5, Sillmann et al. (2013a; 2013b) analisaram alguns índices e observaram, para os cenários RCP 2.6, 4.5 e 8.5, uma tendência de aumento do número de dias (TX90p) e noites muito quentes (TN90p), e uma diminuição do percentual de dias (TX10p) e noites muito frios (TN10p). Além disso, os modelos conseguiram capturar razoavelmente bem características do padrão de eventos extremos como precipitação anual máxima em 5 dias consecutivos (Rx5day) e dias muito úmidos (R95p), e indicaram maior quantidade de dias secos consecutivos (CDD) e menor incidência de dias úmidos consecutivos (CWD) no futuro.

Natividade (2015), utilizando simulações e projeções de 19 MCGs pertencentes ao conjunto CMIP5 e dados de reanálise do NCEP/NCAR, também analisou os 8 índices extremos de precipitação e temperatura, utilizados por Sillmann et al. (2013a, 2013b), para todo o território brasileiro. As simulações dos índices de precipitação superestimaram as observações

em todo o Brasil, com uma distribuição espacial heterogênea entre os modelos. Já as simulações dos extremos de temperatura apresentaram-se bem próximas as observações em magnitude e extensão territorial. Quanto às projeções climáticas, o autor observou um pequeno aumento de CDD no Nordeste, diminuição de CWD principalmente no Norte e Nordeste. Para R95p e Rx5Day, a tendência será de aumento para o final do século XXI, sobretudo com maior frequência no Centro-Sul brasileiro para este último índice, podendo ambos colaborar com um aumento nos casos de enchentes e deslizamentos de terra. E caracterizando aspectos do aumento da temperatura global, TN10p e TX10p apresentaram tendência negativa e TN90p e TX90p, positiva, ou seja, no final desse século, as noites e dias frios serão menos frequentes, enquanto as noites e dias quentes sofrerão aumento.

Muitas vezes, os padrões sinóticos e a variabilidade climática associados aos eventos extremos de temperatura e precipitação são razoavelmente representados pelos MCGs, mas, ainda assim, possuem incertezas. O sistema climático é complexo e composto por diversos processos não-lineares, sofrendo influência das variações naturais e antropogênicas do clima, além de possuir características sobre as partes e suas interações pouco compreendidas pelos cientistas ou, até mesmo, ainda desconhecidas. Isso faz com que, os modelos climáticos, os quais são representações aproximadas desse sistema, possuam uma cadeia de incertezas, que podem ser amenizadas, porém não eliminadas, com a evolução científica e novas descobertas sobre suas características (KNUTTI, 2008).

O processo de projeção climática possui algumas etapas pertencentes a áreas diversas do conhecimento: i) adoção de hipóteses socioeconômicas; ii) produção de cenários de emissões; iii) cálculos de concentrações de GEE e aerossóis no sistema climático, produzidos por modelos químicos e biogeoquímicos; iv) simulações de mudanças climáticas utilizando MCGs, e conseqüente cálculo das forçantes radiativas associadas; v) simulações regionais de mudanças climáticas utilizando técnicas de regionalização (*downscaling*); e vi) avaliação dos possíveis impactos na sociedade e na biodiversidade do planeta, geralmente utilizando também modelos numéricos (Figura 2). Cada uma dessas etapas possui uma incerteza associada, a qual é transmitida para a próxima etapa e, juntamente com outras considerações adicionais (respostas políticas quanto à adaptação e mitigação, interações e *feedbacks* entre as partes do sistema, mudanças de uso do solo e forçantes naturais), determina a incerteza total das projeções (MEARNS et al., 2001; GIORGI, 2005; TORRES, 2014).

Segundo Giorgi (2005), as incertezas associadas às etapas de simulação e projeção climática com MCGs, especificamente das variabilidades intermodelos e dos diferentes cenários de emissões de GEEs e aerossóis, podem ser devido à três fatores:

- a) configurações dos modelos: incertezas relacionadas com a escolha da resolução espacial, das parametrizações físicas de nuvens, superfície, relevo, oceano, dos valores de parâmetros e dos algoritmos numéricos utilizados. Como a escolha de configuração depende não somente das características físicas como também computacionais, que diferem entre os modelos de um conjunto (e.g. CMIP3 e CMIP5), modelos distintos podem projetar diferentes resultados para uma mesma forçante climática (IPCC 2001, 2007, 2013). Este é considerado o fator dominante da cascata de incertezas;
- b) variabilidade interna dos modelos: atribuída à dependência das simulações em relação à variabilidade não forçada do sistema (e.g. ENOS, PDO) e às condições iniciais de representação dos oceanos e superfícies;
- c) natureza estocástica das forçantes naturais futuras: as forçantes naturais podem apresentar ciclos, porém muitas vezes estes não são bem definidos, evidenciando a característica de aleatoriedade desse fator. Embora possa ser expressiva, as incertezas relacionadas às forçantes antropogênicas são maiores.

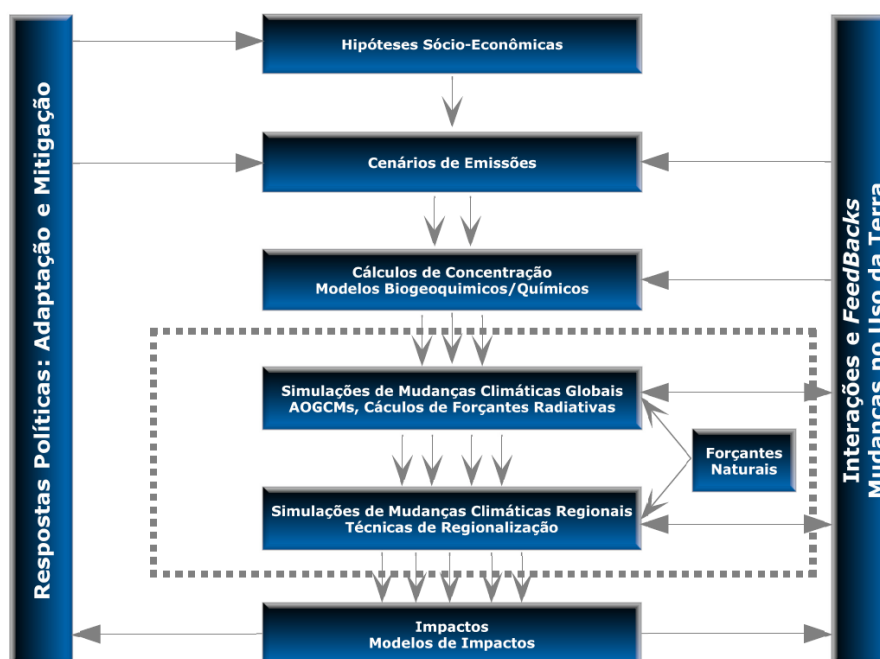


Figura 2 - Cascata de incertezas em uma projeção de mudanças climáticas. A região delimitada pela linha tracejada engloba o segmento de simulação climática da cascata. A sigla AOGCMs significa *Atmosphere-Ocean General Circulation Models*.

Fonte: Torres (2014). Adaptada de Mearns et al. (2001) e Giorgi (2005).

Já as incertezas associadas às simulações climáticas regionais dependem das condições iniciais e de fronteira para alimentar o processo de *downscaling*, da representação da topografia e linha costeira e da escolha da técnica de regionalização utilizada (GIORGI, 2005).

Para sintetizar o resultado das inúmeras etapas de uma projeção climática e aumentar sua confiabilidade, tem-se utilizado comumente o cálculo de uma média aritmética simples, onde para cada membro é atribuído igual probabilidade de ocorrência. Tal média tem mostrado resultados mais próximos das observações do que quando utilizado um membro individual (EBERT, 2001; KNUTTI et al., 2010). Também, outra técnica é o uso de aproximações probabilísticas, onde os diferentes modelos ou suas integrações resultam na produção de uma Função Densidade de Probabilidade (PDF). O espalhamento de uma PDF representa a incerteza e a integral entre dois limiares indica a probabilidade de ocorrência das projeções (COLLINS, 2007).

Nos últimos anos, alguns estudos analisaram as incertezas das projeções climáticas. Blázquez e Nuñez (2013) avaliaram incertezas na variabilidade interna e inter-modelos para as projeções de temperatura e precipitação de 8 MCGs do conjunto CMIP3 e CMIP5. Utilizando os cenários intermediários A1B e RCP 4.5, respectivamente pertencentes ao CMIP3 e CMIP5, os autores identificaram para a América do Sul melhoramentos no novo conjunto de modelos, como uma redução na variabilidade inter-modelos da temperatura projetada para o verão do período 2071-2100 sobre o nordeste da Argentina, Paraguai e norte do Brasil. A confiabilidade das projeções de temperatura mostrou-se alta para ambos os conjuntos na maioria do continente sul-americano. No que se refere à precipitação, a confiabilidade é baixa como um todo, porém os modelos do CMIP5 têm desempenho superior no leste da Argentina, Uruguai e sul do Brasil e sua variabilidade é menor sobre o leste e norte do Brasil no verão.

Joetzjer et al. (2013) avaliaram a precipitação simulada e projetada sobre a bacia Amazônica utilizando 13 MCGs do CMIP3 e CMIP5, nos seus respectivos cenários de maior forçante A2 e RCP 8.5. Os resultados mostraram melhoramentos significativos entre as simulações de precipitação do CMIP5 em comparação ao CMIP3. O viés negativo no ciclo anual foi reduzido, o ciclo sazonal e a distribuição espacial de precipitação foi melhor

representado, e houve uma ligeira melhora na variabilidade interanual em simular o fenômeno ENSO e as anomalias de temperatura da superfície do mar no Atlântico Tropical Norte. Contudo, as projeções ainda permaneceram com grandes incertezas, havendo pequeno consenso apenas na intensificação e prolongamento da estação seca, em especial no leste da bacia amazônica.

Por sua vez, Jones e Carvalho (2013) analisaram as características de grande escala (início, fim, duração) do Sistema de Monção da América do Sul (SMAS). Utilizando simulações históricas (1951-2005) e projeções climáticas (2006-2100) de 10 MCGs do CMIP5 para o cenário RCP 8.5, constatou-se que houve deficiência em simular esse sistema meteorológico por parte de alguns deles. Grande parte das simulações e projeções mostraram um gradual adiantamento do início e atraso do fim da monção, evidenciando um aumento significativo na amplitude sazonal do sistema. Por outro lado, referindo-se ao total de precipitação na estação chuvosa para o final do século, foi identificado falta de concordância das projeções dos modelos, sendo que o padrão mais consistente observado foi a elevação no total de precipitação para o sul do Brasil, norte da Argentina e Uruguai.

Com o intuito de avaliar as principais incertezas envolvidas nas projeções climáticas e identificar como se distribuem na América do Sul, Torres (2014) utilizou dados de simulações e projeções de 24 MCGs do CMIP3 e 24 MCGs do CMIP5 referentes à precipitação e temperatura. As simulações foram comparadas com os dados observados de temperatura e precipitação provenientes do conjunto CRU TS 3.0 do *Climate Research Unit* (CRU) – *University of East Anglia* (UEA). Para minimizar a contribuição das simulações que tem baixo desempenho de representação do clima, averiguando as regiões de maior ou menor confiabilidade, o autor fez uso do método *Reliability Ensemble Averaging* (REA), e para combinar as informações dos MCGs e observações por meio de distribuições de probabilidade, utilizou-se a Inferência Bayesiana. Todas as análises foram feitas para a América do Sul como um todo e para as sub-regiões leste e oeste da Amazônia, nordeste do Brasil e Bacia do Prata. Os resultados indicaram que ambos os conjuntos de MCGs representaram bem a média sazonal e o ciclo anual de temperatura e precipitação, sendo identificado somente alguns vieses sobre os Andes, noroeste da América do Sul, nordeste brasileiro e bacia amazônica. Os modelos do CMIP5 apresentaram maior confiabilidade, uma vez que suas simulações estavam mais próximas das observações quando comparado aos do CMIP3. Considerando o desempenho de cada modelo em representar o clima passado e a consistência de suas projeções em relação à

média do conjunto, como proposto pelo método REA e intrinsicamente pela Inferência Bayesiana, notou-se que a média das projeções de temperatura decrescem entre 0,5°C e 1°C sobre todo o continente, comparado à média aritmética simples. Isto significa que, aos modelos cujas projeções de aumento de temperatura eram mais elevadas, foram atribuídos pesos menores. A maior confiabilidade para a temperatura foi encontrada na Bacia do Prata, enquanto os maiores intervalos de incertezas estão sobre a Amazônia. A probabilidade de um aumento de temperatura exceder 2°C no final do século XXI é superior a 90% para todo o território nas 4 estações do ano, quando analisados os cenários A2 do CMIP3 e RCP 8.5 do CMIP5, além de haver mais de 50% de probabilidade desse aumento ser superior a 4°C na faixa de latitudes 10°N-25°S. No que se refere à precipitação, ambos os métodos não resultam em padrões de mudanças muito diferentes dos obtidos com a média aritmética simples. Portanto, o autor concluiu que existe uma alta confiabilidade que a projeção da precipitação sazonal média seja bastante pequena ou inexistente sobre a América do Sul, porém os resultados somente se aplicam para os valores médios e não para os extremos climáticos.

Santos (2015) avaliou as incertezas envolvidas nas projeções climáticas de precipitação e temperatura provenientes de 10 modelos do CMIP5 e utilizou Redes Neurais Artificiais (RNA) como método de aferição das incertezas encontradas para três regiões da América do Sul: Amazônia, Nordeste do Brasil e Bacia do Prata. As simulações foram comparadas com dados de precipitação do *Climate Research Unit (CRU) TS 3.0 – University of East Anglia (UEA)* para o período 1901-2005. Também, o método REA foi utilizado para averiguar a confiabilidade nas regiões. Os resultados indicam que, levando em consideração o desempenho das simulações e a convergência das projeções com relação à média dos conjuntos de modelos, como proposto pelo método REA, a média das projeções de mudança de temperatura geralmente sofre um ligeiro decréscimo sobre todas as regiões, comparado a média aritmética simples, assemelhando-se com resultados obtidos por Torres (2014). Para a temperatura, houve alta confiabilidade de projeção para todas as regiões analisadas, e para a precipitação, essa confiabilidade foi elevada na região da Bacia do Prata. Por fim, em todas as análises realizadas observou-se que os intervalos de incertezas das projeções diminuíram quando usou-se o método REA aferido com as RNAs, indicando confiabilidades 6% superior para a precipitação e 17% superior para a temperatura comparadas ao uso apenas do REA. Esse aumento das confiabilidades pode ser decorrente da minimização da contribuição de *outliers* ou da diminuição da má simulação dos modelos.

Silveira et al. (2016) analisaram os impactos que as mudanças no clima podem causar nas variáveis meteorológicas precipitação e temperatura sobre a região da bacia do Rio São Francisco. Utilizando observações de estações meteorológicas da região para o período de 1961 a 2000, disponibilizados pelo INMET, dados históricos e projeções climáticas para 27 modelos do conjunto CMIP5 (cenários RCP 4.5 e RCP 8.5), foram feitas avaliações da sazonalidade dos modelos para o século XX e análises das anomalias médias anuais e tendência da precipitação anual. Os resultados mostraram que 7 modelos não representaram bem a sazonalidade da precipitação em comparação com os outros. Também, para o período 2011-2100, observou-se tendência positiva para as anomalias de temperatura e, apesar da divergência entre os modelos e significativa incerteza em relação a precipitação, conjuntamente os modelos projetam anomalias de chuva entre $\pm 20\%$ em cada período de 30 anos (futuro próximo 2041-2070 e futuro distante 2071-2100). Os dados do CMIP5 indicam que deve haver anomalia positiva de temperatura no futuro, sendo de aproximadamente 2°C para o cenário RCP 4.5 e podendo ultrapassar os 4°C no cenário RCP 8.5. Por fim, para o final do século XXI (2071-2100), nota-se maior amplitude de oscilações das séries, indicando um possível aumento da ocorrência de eventos extremos.

Referindo-se às representações da intensidade de eventos extremos climáticos, principalmente no caso da precipitação, as estimativas são pouco precisas e acompanhadas de incertezas ainda maiores. Apesar de poucos, há estudos que analisam as projeções de extremos especificamente para regiões da América do Sul utilizando modelos climáticos regionais ou globais (TEBALDI et al., 2006; MARENGO et al., 2009; MARENGO; VALVERDE; OBREGON, 2013; SILVA et al., 2014, 2015; VALVERDE; MARENGO, 2014; NATIVIDADE, 2015; NATIVIDADE; GARCIA; TORRES, 2017), porém nenhum aborda as incertezas envolvidas, evidenciando a importância do presente trabalho.

3 METODOLOGIA

3.1 Área de estudo e Dados

A área de estudo foi a América do Sul, compreendida entre as latitudes 13,75°N-57,5°S e as longitudes 84°W-32,5°W. Porém, algumas análises espaciais das simulações e projeções dos índices de extremos climáticos foram avaliadas mais profundamente para 4 sub-regiões no continente sul-americano (Figura 4): Oeste da Amazônia - WAMZ (lat 5°N-15°S/lon 75°W-60°W), Leste da Amazônia - EAMZ (lat 5°N-15°S/lon 60°W-45°W), Nordeste do Brasil - NEB (lat 2,5°S-15°S/lon 45°W-35°W) e Bacia do Prata - LPB (lat 15°S-35°S/lon 65°W-40°W). Estas sub-regiões foram escolhidas por apresentarem condições climáticas diferentes durante eventos de El Niño e La Niña, assim como durante anomalias de TSM no Atlântico tropical (AMBRIZZI; SOUZA; PULWARTY, 2004; NOBRE et al., 2006), além de apresentarem sinais de mudança de precipitação distintos para o final do século XXI projetadas por diversos modelos climáticos (MARENGO et al., 2010b; MEEHL et al., 2007). Também, Torres (2014) utilizou as mesmas sub-regiões, facilitando assim a comparação dos resultados com esse estudo.

Utilizou-se índices extremos calculados a partir de dados de temperatura e precipitação provenientes da Reanálise I do *National Centers for Environmental Prediction - NCEP / National Center for Atmospheric Research – NCAR* (KALNAY et al., 1996), os quais foram considerados nesse estudo como as observações. Esses dados abrangem o período de 1948 a 2011, e possuem uma resolução espacial de 2,5° x 2,5° de latitude/longitude. As reanálises são produtos da recuperação, controle e assimilação de dados observados (temperatura, umidade específica, geopotencial, vento zonal e vento meridional) em todo o planeta, podendo estes serem provenientes de satélites, radiossondas, aviões, navios, dentre outros. Esses dados são importantes para melhorar os estudos sobre o clima, uma vez que a quantidade e qualidade de estações meteorológicas para coleta de informações não é suficiente para se obter uma série histórica consistente e sem falhas (KISTLER et al., 2001). Vale ressaltar que reanálises de temperatura média diária e mensal têm mostrado resultados satisfatórios comparados aos dados de estações, sugerindo potencial para ampliar o uso, ainda diminuto, desses dados nas análises de extremos climáticos. Porém, deve-se ter cautela na utilização de tais dados nos índices extremos de precipitação, devido a maior complexidade de reprodução da mesma, uma vez que a precipitação observada não é considerada como *input* do modelo que gera as reanálises, além desses índices extremos serem variáveis derivadas da temperatura e precipitação (ZHANG et al., 2011).

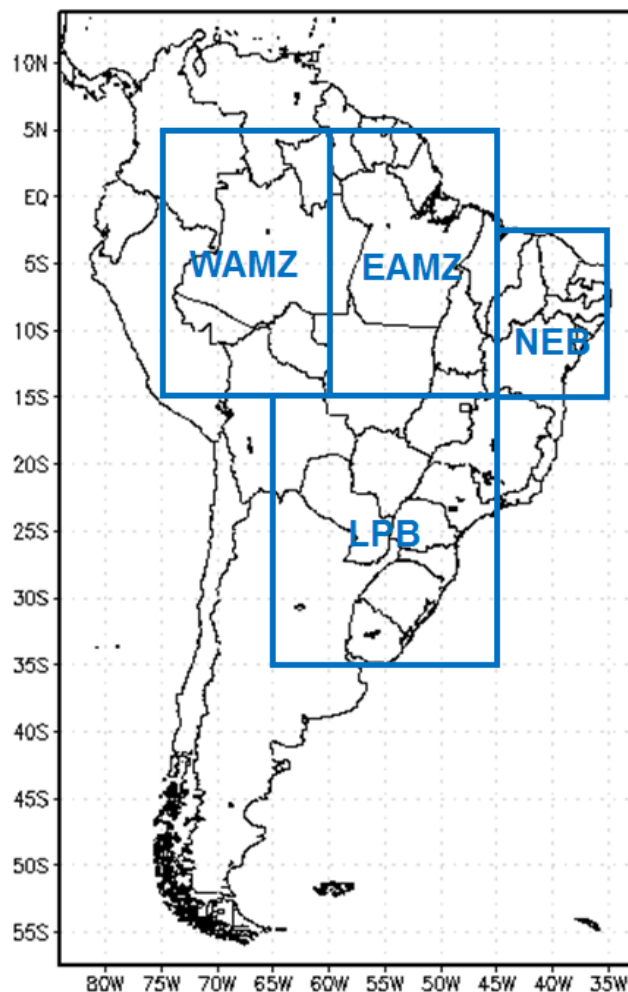


Figura 3 – Domínio de estudo. As áreas delimitadas pelos retângulos azuis indicam as sub-regiões nas quais foram aprofundadas as análises: Leste e Oeste da Amazônia (EAMZ e WAMZ, respectivamente), Nordeste do Brasil (NEB) e Bacia do Prata (LPB).

Para comparar com as observações, foram utilizados índices extremos calculados a partir das médias diárias de precipitação e temperatura do ar próximo à superfície, simuladas para o clima observado (ou clima presente) no período 1900-2005, e projetadas para o clima futuro: 2006-2100. Essas simulações e projeções climáticas são provenientes de 31 MCGs integrantes do CMIP5 (TAYLOR; STOUFFER; MEEHL, 2012), fornecidos pelo *Program for Climate Model Diagnosis and Intercomparison* (PCMDI) e disponibilizado pelo *Earth System Grid data portal* (Tabela 1).

Tabela 1 – Lista de modelos, resolução espacial aproximada e área do pixel relativo a cada um deles e simulações do clima presente (Historical, 1900 - 2005) e projeções futuras (2006 - 2100) em diferentes cenários forçantes (RCPs 2.6, 4.5, 6.0, e 8.5) advindas do conjunto CMIP5 utilizados. Em azul são apresentados os 9 modelos com menores áreas do pixel; em preto, os 11 de áreas intermediárias e em vermelho, os 11 modelos de menor área.

MODELOS	RESOLUÇÃO (LAT/LON)	ÁREA DO PIXEL (Km ²)	HISTORICAL	RCP			
				2.6	4.5	6.0	8.5
CMCC-CESM	3.8 ° x 3.8 °	177.915,24	X				X
FGOALS-g2	3.1 ° x 2.8 °	106.946,28	X	X	X		X
BCC-CSM1-1	2.8 ° x 2.8 °	96.596,64	X	X	X	X	X
BNU-ESM	2.8 ° x 2.8 °	96.596,64	X		X		X
CanESM2	2.8 ° x 2.8 °	96.596,64	X	X	X		X
MIROC-ESM	2.8 ° x 2.8 °	96.596,64	X	X	X	X	X
MIROC-ESM-CHEM	2.8 ° x 2.8 °	96.596,64	X	X	X	X	X
IPSL-CM5B-LR	1.9 ° x 3.8 °	88.957,62	X		X		X
IPSL-CM5A-LR	1.9 ° x 3.8 °	88.957,62	X	X	X	X	X
GFDL-CM3	2.0 ° x 2.5 °	61.605	X	X		X	X
GFDL-ESM2G	2.0 ° x 2.5 °	61.605	X	X	X	X	X
Giss-E2-R	2.0 ° x 2.5 °	61.605	X		X		
GFDL-ESM2M	2.0 ° x 2.5 °	61.605	X	X	X	X	X
FGOALS-s2	1.7 ° x 2.8 °	58.647,96	X	X	X	X	X
NorESM1-M	1.9 ° x 2.5 °	58.524,75	X	X	X	X	X
CMCC-CMS	1.9 ° x 1.9 °	44.478,81	X		X		X
CSIRO-Mk3-6-0	1.9 ° x 1.9 °	44.478,81	X	X	X	X	X
MPI-ESM-LR	1.9 ° x 1.9 °	44.478,81	X	X	X		X
MPI-ESM-MR	1.9 ° x 1.9 °	44.478,81	X	X	X		X
IPSL-CM5A-MR	1.3 ° x 2.5 °	40.043,25	X	X		X	X
INMCM4	1.5 ° x 2.0 °	36.963	X		X		X
HadGEM2-CC	1.3 ° x 1.9 °	30.432,87	X		X		X
HadGEM2-ES	1.3 ° x 1.9 °	30.432,87	X	X	X	X	X
ACCESS1.0	1.3 ° x 1.9 °	30.432,87	X	X	X		X
CNRM-CM5	1,4 ° x 1,4 °	24.149,16	X	X	X		X
MIROC5	1.4 ° x 1.4 °	24.149,16	X	X	X	X	X
EC-EARTH	1.1 ° x 1.1 °	14.908,41	X		X		
MRI-CGCM3	1.1 ° x 1.1 °	14.908,41	X	X	X	X	X
BCC-CSM1-1-m	1.1 ° x 1.1 °	14.908,41	X	X	X	X	X
CCSM4	0.9 ° x 1.3 °	14.415,57	X	X	X	X	X
CMCC-CM	0.8 ° x 0.8 °	7.885,44	X		X		X

O CMIP é um Projeto de Intercomparação de Modelos Acoplados, no qual há uma análise conjunta de diversos modelos, a fim de gerar projeções climáticas de centenas de variáveis meteorológicas sobre todo o globo. As versões mais recentes desse projeto são CMIP3 e CMIP5, relativos, respectivamente, ao Quarto (AR4) e Quinto (AR5) Relatório de Avaliação do IPCC. Comparativamente, o CMIP5 é composto por uma maior quantidade de modelos, os quais são mais avançados em relação aos do CMIP3, possuem resoluções espaciais mais refinadas e incluem experimentos para avaliar a previsibilidade climática na escala decenal, permitindo, assim, uma melhor abordagem de questões científicas (TAYLOR; STOUFFER; MEEHL, 2012). Houve diversos aperfeiçoamentos nas equações que representam as diferentes partes do sistema climático dentro dos MCGs do CMIP5. Algumas dessas mudanças são a inclusão dos ciclos biogeoquímicos, representação da criosfera e da microfísica de nuvens, aprimoramento no acoplamento dos oceanos e na interação oceano-atmosfera e, dentre outras, a utilização de uma modelagem mais acurada dos efeitos indiretos dos aerossóis e a inserção de séries históricas das atividades vulcânica e solar em grande parte dos modelos, possibilitando a utilização de forçantes radiativas mais completas nos dados gerados (TAYLOR; STOUFFER; MEEHL, 2012; SILLMANN et al., 2013a).

Nas simulações referentes ao clima do século XX, caracterizadas como experimentos de controle, são identificadas as forçantes climáticas que poderiam impactar o clima observado, além de serem incluídas nas integrações dos MCGs séries históricas dessas forçantes. No CMIP3, essas simulações são chamadas de “20C3M”, enquanto no CMIP5 recebem o nome “historical”. Já as projeções de mudanças climáticas para o século XXI são obtidas através de cenários de emissões, os quais descrevem parâmetros como futuros lançamentos de GEEs, aerossóis e outros poluentes na atmosfera, e acompanhado de informações de uso e cobertura do solo, servem de condições de entrada para os modelos.

Tais cenários, no projeto CMIP3, são narrativas baseadas em diferentes hipóteses sobre o crescimento populacional, uso de energia, globalização e desenvolvimento econômico, todos sem a intervenção governamental. Essas “*Storylines*” fazem parte do *Special Report on Emission Scenarios – SRES* (IPCC, 2008) e são chamadas B1, B2, A1 e A2. Na versão mais recente, CMIP5, os cenários são baseados na sintetização de todos os parâmetros anteriormente citados em forçante radiativa, considerando que haverá um determinado aumento de energia (dada em Wm^{-2}) armazenada no sistema climático em cada cenário e quantificando as implicações que isso pode trazer na temperatura, precipitação e outras variáveis. Os RCPs,

Representative Concentration Pathways como são chamados, representam um aumento relativo às condições pré-industriais de $2,6 \text{ Wm}^{-2}$ (RCP2.6), $4,5 \text{ Wm}^{-2}$ (RCP4.5), $6,0 \text{ Wm}^{-2}$ (RCP6.0) e $8,5 \text{ Wm}^{-2}$ (RCP8.5) de energia armazenada no sistema climático e correspondem aos cenários de mitigação, intermediários e de alta emissão de GEEs, respectivamente (MOSS et al., 2010).

Para fins comparativos, a Figura 3 representa as trajetórias das emissões de CO_2 , CH_4 , e N_2O para os cenários RCPs (2.6, 4.5, 6.0, 8.5), mostrando também as projeções de inúmeros cenários já publicados na literatura, em especial os pertencentes ao SRES (B1, B2, A1, A2). Pode-se observar que os cenários RCPs possuem magnitudes de emissão mais abrangentes quando comparados aos cenários SRES, englobando quase a totalidade de trajetórias publicadas na literatura à respeito da concentração dos gases CO_2 e CH_4 , e uma grande maioria das projeções para o N_2O . Maiores detalhes sobre os cenários do CMIP3 e CMIP5 podem ser encontrados, por exemplo, em IPCC (2008), Moss et al. (2010), e van Vuuren et al. (2011).




Figura 4 - Trajetórias das emissões de CO_2 (a), CH_4 (b), e N_2O (c) referentes aos quatro cenários RCPs (2.6, 4.5, 6.0, 8.5). As áreas em cinza representam os percentis 98° (cinza claro) e 90° (cinza escuro) encontrados na literatura. As linhas tracejadas indicam quatro dos cenários SRES (A2, A1b, B2, e B1).
Fonte: van Vuuren et al. (2011).

3.2 Métodos

Primeiramente, para fins comparativos, fez-se necessário uma interpolação bilinear dos modelos do CMIP5, uma vez que suas resoluções horizontais variam em torno de 1 a 4 graus de latitude/longitude (Tabela 1). Esta interpolação servirá para transformar a resolução espacial original de cada variável e modelo em $2,5^\circ \times 2,5^\circ$ de latitude/longitude, a mesma grade dos dados observados. A interpolação bilinear é dada pela média ponderada dos pontos de grade originais que rodeiam o novo *pixel*, sendo determinado para cada ponto um peso: quanto mais

distante o *pixel* interpolado estiver de seu ponto vizinho, menor será a influência sofrida e, portanto, menor o fator atribuído a ele (PEDRINI; SCHWARTZ, 2007).

No tópico 3.2.1 são apresentados os índices extremos de precipitação e temperatura utilizados no estudo, os quais, após os ajustes de interpolação, seguiram as etapas: i) análise das simulações e projeções dos índices e ii) avaliação das incertezas via Inferência Bayesiana.

3.2.1 Índices Extremos

Para quantificar e qualificar os eventos extremos climáticos, existem alguns índices (Tabela 2). No presente estudo foram utilizados índices extremos anuais de temperatura e precipitação, calculados a partir de dados de precipitação e temperatura diárias provenientes de 31 MCGs do conjunto CMIP5. Para as reanálises, tidas como observações, o período foi 1948-2011, para as simulações, utilizou-se o período 1900-2005 e para as projeções, o período 2006-2100, tomando-se como referência 1961-1990. Estes índices (Tabela 2) foram também utilizados por Frich et al. (2002), Sillmann et al. (2013 a, b), Natividade, Garcia e Torres (2017), e estão disponíveis através do endereço eletrônico <ftp://ftp.cccma.ec.gc.ca/data/climdex>.

Tabela 2 - Índices de extremos de precipitação e temperatura utilizados com suas respectivas descrições.

ÍNDICE (unidade)	DESCRIÇÃO
CDD (dias) <i>Dias secos consecutivos</i>	Número máximo de dias consecutivos do ano com precipitação diária inferior a 1 mm
R10mm (dias) <i>Dias de precipitação intensa</i>	Número de dias no ano em que a precipitação diária foi superior a 10 mm
R95p (mm) <i>Dias muito úmidos</i>	Precipitação anual total acima do 95º percentil da distribuição no período 1961-1990
Rx5Day (mm) <i>Máximo de precipitação em 5 dias</i>	Precipitação total máxima acumulada em 5 dias consecutivos
TN10p (%) <i>Noites muito frias</i>	Porcentagem de dias no ano em que a temperatura mínima está abaixo do 10º percentil da distribuição de temperatura diária do período 1961-1990
TN90p (%) <i>Noites muito quentes</i>	Porcentagem de dias no ano em que a temperatura mínima está acima do 90º percentil da distribuição de temperatura diária do período 1961-1990
TX10p (%) <i>Dias muito frios</i>	Porcentagem de dias no ano em que a temperatura máxima está abaixo do 10º percentil da distribuição de temperatura diária do período 1961-1990
TX90p (%) <i>Dias muito quentes</i>	Porcentagem de dias no ano em que a temperatura máxima está acima do 90º percentil da distribuição de temperatura diária do período 1961-1990

3.2.2 Análise das simulações e projeções de mudança nos índices de extremos

Com os índices de extremos climáticos interpolados, foi feita uma comparação do padrão espacial entre os dados observados e as simulações dos diversos modelos e cenários para todo o continente Sul-Americano, ambos para o período 1961-1990, verificando a consistência dos índices. Para obter a acurácia dos modelos em simular os extremos de temperatura e precipitação, realizou-se alguns indicadores estatísticos, como o viés (simulação menos observação), correlação de Pearson, erro quadrático médio e desvio padrão. Estes três últimos tiveram suas informações sintetizadas por meio do Diagrama de Taylor (TAYLOR, 2001), a fim de melhorar a visualização do desempenho dos modelos em representar os padrões médios climatológicos em cada uma das quatro sub-regiões. Nesse diagrama, os modelos foram utilizados com suas resoluções espaciais originais (Tabela 1), visando observar se existe relação entre a área do pixel com a acurácia em simular as reanálises. E, com base no Erro Quadrático Médio (EQM) e no Erro Potencial (PE), calculou-se o Índice de Concordância de Willmott d_w (WILLMOTT, 1981, 1982), dado pela equação (1):

$$d_w = 1 - \frac{\sum_{i=1}^n (X_0 - X_i)^2}{\sum_{i=1}^n (|X_i - \bar{O}| + |X_0 - \bar{O}|)^2} = 1 - n \frac{MSE}{PE} \quad (1)$$

Em que i corresponde a cada um dos modelos, n é o número total de modelos e \bar{O} a média das observações. Esse índice de concordância varia entre 0 e 1, com valores próximos a 1 indicando que os dados simulados X_i têm melhor concordância com os dados observados X_0 .

Ademais, agrupou-se as simulações climáticas do século XX para o período 1961-1990 e as projeções para o final do século XXI no período 2071-2100. A mudança esperada da variável climática é resultante da diferença entre os valores médios do futuro (v) e do presente (μ), dada por $\Delta\xi = v - \mu$. Assim, as projeções de mudanças nos índices extremos de cada modelo foram analisadas e comparadas às estimativas de mudanças dos extremos anuais após a aplicação do método de Inferência Bayesiana, descrito no item 3.2.3, possibilitando averiguar as regiões de maior ou menor concordância entre ambas, e avaliando as incertezas quanto aos cenários de emissões e as estruturas dos modelos.

3.2.3 Avaliação das incertezas via Inferência Bayesiana

As incertezas nas projeções de mudanças de eventos extremos de temperatura e precipitação foram investigadas mais profundamente ao utilizarmos a metodologia de

Inferência Bayesiana aplicada aos dados de modelos climáticos. A seguir é apresentada a forma analítica desse método estatístico desenvolvido por Tebaldi et al. (2005).

Primeiramente são listadas as hipóteses de distribuição para os dados utilizados, depois as funções prévias para todos os parâmetros envolvidos no método. Utilizando a Inferência Bayesiana, as quantidades “incertas” de interesse tornam-se parâmetros de um modelo estatístico e são tratados como variáveis aleatórias. Uma distribuição de probabilidade prévia para estes parâmetros é especificada independentemente dos dados em mãos. A componente da probabilidade condicional do modelo estatístico especifica a distribuição condicional dos dados, dado os parâmetros do modelo. Através do teorema de Bayes, distribuições prévias e condicionais são combinadas em uma distribuição posterior dos parâmetros, uma vez fornecido os dados. Assim, esse teorema estabelece que:

$$p(\theta|D) \propto p(\theta) \times p(D|\theta) \quad (2)$$

em que $p(\theta|D)$ é a distribuição posterior dos parâmetros e forma a base de qualquer inferência estatística formal sobre eles, $p(\theta)$ é a distribuição prévia e $p(D|\theta)$ corresponde a probabilidade condicional dos dados (D). Como a complexidade de $p(\theta|D)$ impede uma solução de forma fechada, uma estimativa empírica da distribuição pode ser obtida através de simulações MCMC (*Markov Chain Monte Carlo*⁵), as quais são formas eficientes de simular amostras de distribuições posteriores, contornando a necessidade de resolvê-las analiticamente.

Nas formulações a seguir, X_i e Y_i denotarão, respectivamente, um dado índice de evento climático extremo para o clima presente e projetado para o clima futuro pelo modelo i , mediados anualmente e agregados a cada 30 anos (e.g. 1961-1990 e 2071-2100).

Em primeiro lugar, são assumidas distribuições gaussianas para X_i e Y_i :

$$X_i \sim N(\mu, \lambda_i^{-1}), \quad (3)$$

$$Y_i \sim N(v, (\theta \lambda_i)^{-1}), \quad (4)$$

⁵ *Markov Chain Monte Carlo* é um algoritmo computacional utilizado para a determinação da probabilidade aproximada de um evento específico resultante de uma série de processos estocásticos. Consiste na geração de novas amostras a partir do elemento atual da cadeia, com uma dada probabilidade e geradas de forma aleatória.

em que a notação $X_i \sim N(\mu, \lambda_i^{-1})$ indica uma distribuição gaussiana (Figura 5a) com média μ e variância λ_i^{-1} . O parâmetro λ_i , recíproco da variância, é referido como a precisão da distribuição de X_i . Para permitir que Y_i tenha uma precisão diferente de X_i , sua distribuição é definida como o produto $\theta\lambda_i$, onde θ é um parâmetro adicional, que será comum a todos os modelos climáticos, diferindo apenas entre regiões ou pontos de grade. A hipótese implícita nas Equações (3) e (4) é que as respostas dos modelos climáticos possuem uma distribuição simétrica, cujo valor central é o “valor verdadeiro” da variável de interesse, mas com uma variabilidade natural, a ser relacionada como uma medida de quão bem cada MCG se aproxima da resposta do clima a um dado conjunto de forçantes naturais e antropogênicas.

A distribuição relacionada às observações da variável supracitada no clima presente é definida como:

$$X_o \sim N(\mu, \lambda_o^{-1}). \quad (5)$$

O parâmetro μ é o mesmo inserido na Equação (3), mas λ_o é de uma natureza diferente de $\lambda_1, \dots, \lambda_n$, onde n , nesse caso, diz respeito ao número de modelos utilizados. Enquanto que $\lambda_1, \dots, \lambda_n$ são medidas da precisão dos modelos em específico e dependem das aproximações numéricas, parametrizações, resoluções de grade, λ_o é uma função da variabilidade natural específica de cada região e é determinado como o recíproco da variabilidade natural ao quadrado ($\lambda_o = 1/\varepsilon^2$). Assim como Giorgi e Mearns (2002), Tebaldi et al. (2005), e Xu, Xuejie e Giorgi (2010), a variabilidade natural (ε) é estimada para cada ponto de grade tomando-se a diferença entre o maior e o menor valor da série temporal observada (1948-2011), após remover-se a tendência linear dos dados, e aplicar-se um filtro média-móvel para eliminar flutuações com período inferior a 30 anos em cada ponto de grade ($\varepsilon = X_{o_max} - X_{o_min}$).

O modelo descrito pelas equações 3 - 5 é formulado como uma função dos parâmetros $\mu, \nu, \theta, \lambda_1, \dots, \lambda_n$, e segue os seguintes critérios:

- Os parâmetros de precisão λ_i possuem densidades prévias Gamma [indicado por $Ga(a, b)$], representado na forma

$$\frac{b^a}{\Gamma(a)} \lambda_i^{a-1} e^{-b\lambda_i} \quad (6)$$

onde a, b são conhecidos e escolhidos de tal forma que a distribuição tenha uma grande variância no domínio real positivo. Similarmente, $\theta \sim Ga(c, d)$, com c, d conhecidos. Estas são escolhas prévias padrão para os parâmetros de precisão das distribuições Gaussianas. Como escolhido por Tebaldi et al. (2005), será utilizado $a = b = c = d = 0,001$, o que implica média 1 e variância 1000 para a distribuição Gamma (Figura 5b), a qual é dispersiva para garantir que informações *a priori* do modelo que possam enviar sua distribuição não sejam consideradas. Por ser extremamente difusa, as distribuições têm uma qualidade não-informativa que requeremos nas análises;

- As médias μ e ν possuem densidades prévias uniformes no domínio real. Mesmo se as densidades forem impróprias, a forma do modelo de probabilidade assegura que a função posterior é uma função densidade apropriada.

Aplicando o teorema de Bayes nas equações mencionadas acima, o resultado conjunto da densidade posterior para os parâmetros $\mu, \nu, \theta, \lambda_1, \dots, \lambda_n$ é dado, a menos de uma constante de normalização, por

$$\prod_{i=1}^n \lambda_i^{a-1} e^{-b\lambda_i} \times \lambda_i \theta^{1/2} \exp\left\{-\frac{\lambda_i}{2} [(X_i - \mu)^2 + \theta(Y_i - \nu)^2]\right\} \times \theta^{c-1} e^{-d\theta} \quad (7)$$

$$\times \exp\left\{-\frac{\lambda_o}{2} (X_o - \mu)^2\right\}$$

A distribuição da equação 7 não pertence a nenhuma família paramétrica conhecida e, portanto, não pode ser resolvida de forma analítica. O mesmo é verdade para as distribuições posteriores dos parâmetros individuais. Portanto, um algoritmo utilizando amostragem de Gibbs, que é um caso particular de um algoritmo MCMC, é utilizado para gerar números de valores amostrais para todos os parâmetros, assim como descrito em Tebaldi et al. (2005). Nas análises desse estudo foram gerados 10.000 valores amostrais a partir de 550.000 iterações de MCMC, com um descarte inicial (*burn in*) de 50.000 iterações e sendo salvos valores a cada 50 iterações.

Para determinar as estimativas centrais das mudanças, apresentar os padrões espaciais das projeções climáticas e identificar o nível de convergência dos dados, os seguintes procedimentos foram realizados: i) PDFs são estimadas para cada ponto de grade fazendo-se uso do método *Kernel Density Estimation*⁶ aplicado aos 10.000 valores amostrais mencionados anteriormente, ii) o valor de mudança relacionado ao pico da PDF é encontrado, e atribuído ao ponto de grade, e iii) o mesmo procedimento é repetido para todos os pontos de grade continentais.

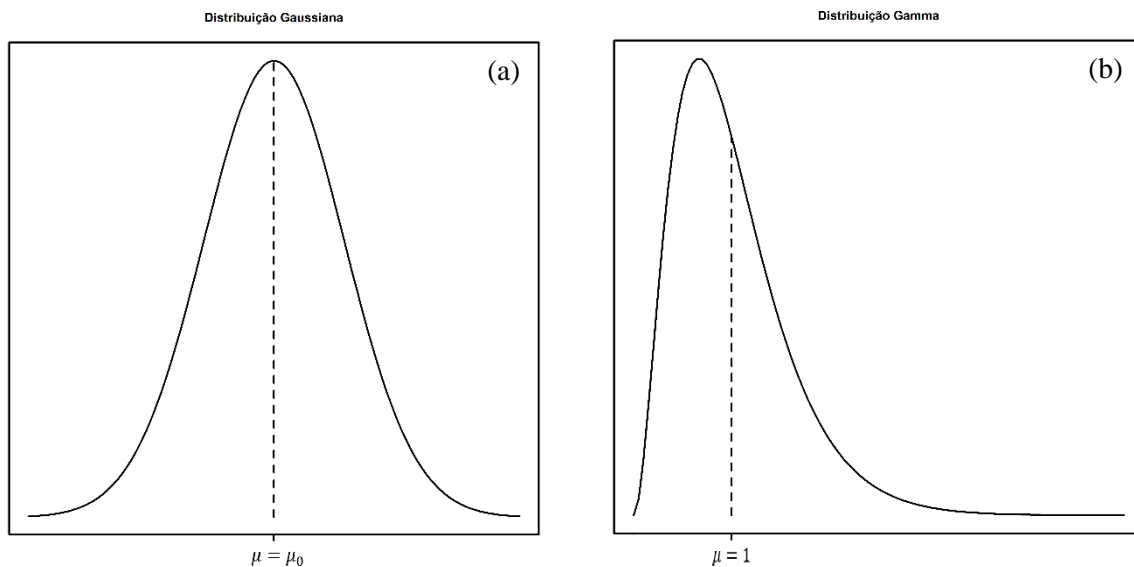


Figura 5 – Distribuição Normal ou Gaussiana (a) e Distribuição Gamma (b).

No modelo estatístico Bayesiano, as médias das distribuições condicionais de μ e ν dependem dos dados e são aleatórias, fazendo com que as incertezas em suas estimativas sejam consideradas no cálculo. Tal incerteza aumentará a largura da distribuição posterior de μ e ν , e, conseqüentemente, de $\Delta\xi$. Uma aproximação da média da distribuição posterior dos λ_i 's para $i = 1, \dots, n$, é:

$$E(\lambda_i | \{X_0, \dots, X_n, Y_1, \dots, Y_n\}) \approx \frac{a+1}{b + \frac{1}{2}[(X_i - \bar{\mu})^2 + \theta(Y_i - \bar{\nu})^2]} \quad (8)$$

Avaliando a equação 8 constatamos que λ_i é grande uma vez que $|X_i - \bar{\mu}|$ e $|Y_i - \bar{\nu}|$ sejam pequenos. Estas duas quantidades correspondem aos critérios de viés e convergência,

⁶ *Kernel Density Estimation* é um método não-paramétrico utilizado para estimar a função densidade de probabilidade (PDF) de uma variável aleatória, objetivando a suavização dos dados e um prognóstico probabilístico.

respectivamente. Aqui, $|Y_i - \bar{v}|$ mede a distância da projeção futura do *i-ésimo* modelo à projeção média do conjunto, e dessa forma possui características similares à medida de convergência adotada em Giorgi e Mearns (2002). Também, no limite quando $\lambda_o \rightarrow \infty$, a média da variável verdadeira no presente tende a ser uma estimativa extremamente precisa da observação ($\bar{\mu} \rightarrow X_o$), e o termo de viés se torna no limite $|X_i - X_o|$, ou seja, quanto maior λ_i , melhor a capacidade do modelo em simular a variável observada. Por fim, gerou-se gráficos com a distribuição posterior dos parâmetros de precisão específicos de cada MCG (λ_i) referentes ao cenário RCP 4.5 de todos os índices extremos, a fim de ranquear os melhores e piores modelos para cada uma das sub-regiões.

4 RESULTADOS E DISCUSSÃO

4.1 Avaliação dos MCGs

Primeiramente, todos os MCGs foram avaliados quanto ao seu desempenho em simular a climatologia observada, representada pela reanálise NCEP para o período 1961-1990, referente aos índices extremos de precipitação e temperatura sobre a América do Sul.

Para o índice de precipitação dias secos consecutivos (Figura 6a), os maiores valores foram observados sobre a região central da Cordilheira dos Andes (≈ 150 a 180 dias), chegando em até 210 dias de estiagem em algumas localidades do Chile e Peru, o que é esperado, uma vez que encontra-se na região do deserto. No território central da Argentina, no Centro-Oeste e parte do Sudeste do Brasil e no semiárido nordestino, observou-se também grandes valores de CDD, entre 90 e 120 dias, enquanto os menores (< 30 dias) foram encontrados no sul da Patagônia, Uruguai, países do norte da América do Sul, oeste da Amazônia e Sul do Brasil. O Centro-Oeste e Sudeste do Brasil estão sob influência do SMAS, caracterizado por verões chuvosos e invernos secos (ZHOU; LAU, 1998; GAN; KOUSKY; ROPELEWSKI, 2004; GRIMM; VERA; MECHOSO, 2005; GARCIA; KAYANO, 2009). Assim, as observações de CDD podem estar associadas com as características que esse sistema determina nessas regiões, concentrando alto número de CDD no inverno austral (estação seca). Porém, uma análise sazonal de precipitação precisaria ser realizada para que possa ser verificado tal comportamento. Em relação ao semiárido nordestino, este já é caracterizado por um clima seco (MARENGO; TORRES; ALVES, 2017), assim como a região central da Argentina (GRIMM; BARROS; DOYLE, 2000). Analisando as simulações (Figura 6e), nota-se que, no geral, os padrões espaciais de altos valores de CDD possuem magnitude superior à observada, e a área que estes maiores valores abrangem é mais extensa. Desse modo, os vieses (Figura 6i) positivos são encontrados em todo o território brasileiro e países do norte do continente, sendo a superestimativa de 45 a 75 dias secos consecutivos em grande parte do Norte, no Nordeste, Guiana, Suriname, Guiana Francesa e norte da Colômbia e Venezuela, sendo mais pronunciada (> 105 dias) no extremo norte destes dois últimos países e na faixa norte nordestina. Por fim, as subestimativas foram observadas sob a extensão central dos Andes e a porção oeste da Argentina, chegando a uma diferença de aproximadamente 100 dias de estiagem contínua no norte do Chile e da Argentina e no Peru, sempre em áreas adjacentes à cordilheira.

Para o índice dias de precipitação intensa (R10mm), as observações (Figura 6b) mostram altos valores na faixa norte do Brasil, na Colômbia e na Venezuela (≈ 120 a 150 dias).

O pico desse índice (> 180 dias) encontra-se entre o Pará e o Maranhão e no leste da Colômbia. Esses valores podem estar relacionados com a Zona de Convergência Intertropical (ZCIT), caracterizada por uma banda de nuvens convectivas na faixa equatorial causada pela convergência dos ventos alísios e pela TSM elevada nas regiões oceânicas adjacentes, sendo considerado um importante gerador de precipitação nesta faixa latitudinal (UVO, 1989); além das Linhas de Instabilidade (LI), as quais transportam umidade do oceano Atlântico para o interior do continente (COHEN, 1989). Um número intermediário de R10mm (≈ 60 a 90 dias) foi observado no Sul do Brasil e a leste da cordilheira dos Andes no Peru, Bolívia e Argentina, podendo ser consequência dos Jatos de Baixos Níveis. Esses jatos são fluxos de ar oriundos dos ventos alísios que adentram ao continente e, ao passar pela floresta Amazônica, adquirem maior umidade (BONNER, 1968; WHITEMAN; BIAN; ZHONG, 1997). Quando eles convergem com a Cordilheira dos Andes, sofrem aceleração e são canalizados em direção ao sul do Brasil e norte da Argentina, podendo contribuir, principalmente no verão (alísios mais intensos), na variabilidade da precipitação sobre essas regiões (MARENGO et al., 2004). Já os menores valores (< 30 dias) encontram-se no semiárido nordestino, concordando com as observações de CDD e com a característica climática da região. Quando analisadas as simulações e vieses associados (Figuras 6f e 6j), nota-se que há uma subestimativa geral sobre todo o continente, sendo mais pronunciada (≈ 75 a 125 dias) no norte do Amazonas, na região entre Maranhão, Pará e Tocantins e no leste da Colômbia e da Venezuela. Além disso, observa-se menor superestimativa (≈ 25 a 75 dias) dos modelos quanto ao R10mm no Peru e no Equador, mas, ainda assim, é relativamente alta.

Avaliando o índice dias muito úmidos (R95p), as observações (Figura 6c) mostram altos valores (≈ 355 a 420 mm) na região equatorial, leste da região central Andina, sul do Chile e Sul do Brasil, e os menores valores (≈ 95 a 160 mm) encontram-se novamente no semiárido nordestino e na Argentina, corroborando com R10mm. Essa alta quantidade de precipitação anual no sul do Chile pode ser explicada pelo transporte de umidade, proveniente do Oceano Pacífico, que, ao encontrar a Cordilheira dos Andes como barreira, causa precipitação na região. Já no Sul do Brasil, os sistemas frontais, mais frequentes durante o inverno, podem ser os responsáveis por esses números, uma vez que causam precipitação durante sua passagem (REBOITA; AMBRIZZI; DA ROCHA, 2009; SATYAMURTY; MATTOS, 1989). As simulações de R95p (Figura 6g) mostram uma área mais abrangente de totais de precipitação anual, encontrando-se vieses positivos sobre todo o continente (Figura 6k), exceto leste da Colômbia (≈ 150 a 250 mm a menos) e norte do Pará (≈ 50 a 150 mm a menos). As

superestimativas foram, na maioria do território, entre 50 e 150 mm, chegando a 150-250 mm sob o norte da Bolívia e Peru, e entre 250-350 mm no litoral do Peru e Equador.

Quanto ao índice precipitação máxima em 5 dias (Rx5Day), os dados observados (Figura 6d) mostram os menores valores (entre 20 e 60 mm) no sul da Argentina, nordeste da Bolívia e centro do Mato Grosso. Os totais de precipitação maiores (\approx 100 a 120 mm) são encontrados sob a maior parte do território sul-americano, evidenciando as regiões Sul, Sudeste e parte do Nordeste brasileiro, Uruguai, parte da Venezuela e da Bolívia e centro da Argentina, sendo mais pronunciados no noroeste da Colômbia (\approx 180 a 200 mm) e sul da Bolívia (\approx 140 a 160 mm). Essa grande quantidade de precipitação acumulada nas regiões Sudeste e Sul do Brasil podem estar associadas à Zona de Convergência do Atlântico Sul (ZCAS), caracterizada por um corredor de nebulosidade que se estende da Amazônia até o Sudeste, é resultante do escoamento de umidade do Oceano Atlântico equatorial e da região amazônica que, ao encontrar os Andes como barreira, é redirecionado no sentido noroeste-sudeste, e ocasiona nessa faixa chuvas no verão, podendo muitas vezes ser responsável pela ocorrência de precipitação severa e supersaturação do solo, com consequentes alagamentos e deslizamentos de terra (QUADRO, 1994; ALVARENGA, 2012). Na análise da média dos modelos (Figura 6h), nota-se que valores das simulações em torno de 120 - 140 mm abrangem quase todo o continente, encontrando-se majoritariamente superestimativas sob a área (Figura 6l), exceto para o centro da Argentina (subestima entre 15 e 45 mm) e noroeste da Colômbia (subestima entre 45 e 75 mm). Tais vieses positivos apresentaram-se em torno de 45 a 75 mm na área que compreende Colômbia, Equador, Peru, Bolívia, Centro-oeste e parte do Sudeste do Brasil.

Observa-se que, o viés de CDD é positivo em algumas localidades, indicando que os modelos simulam escassez de chuva, porém apresentam vieses também positivos de R95p e Rx5Day na mesma região. Esse comportamento mostra que os modelos iniciam e terminam o período de chuvas rapidamente, indicando que não possuem considerável habilidade em representar o ciclo diário de precipitação nessas áreas.

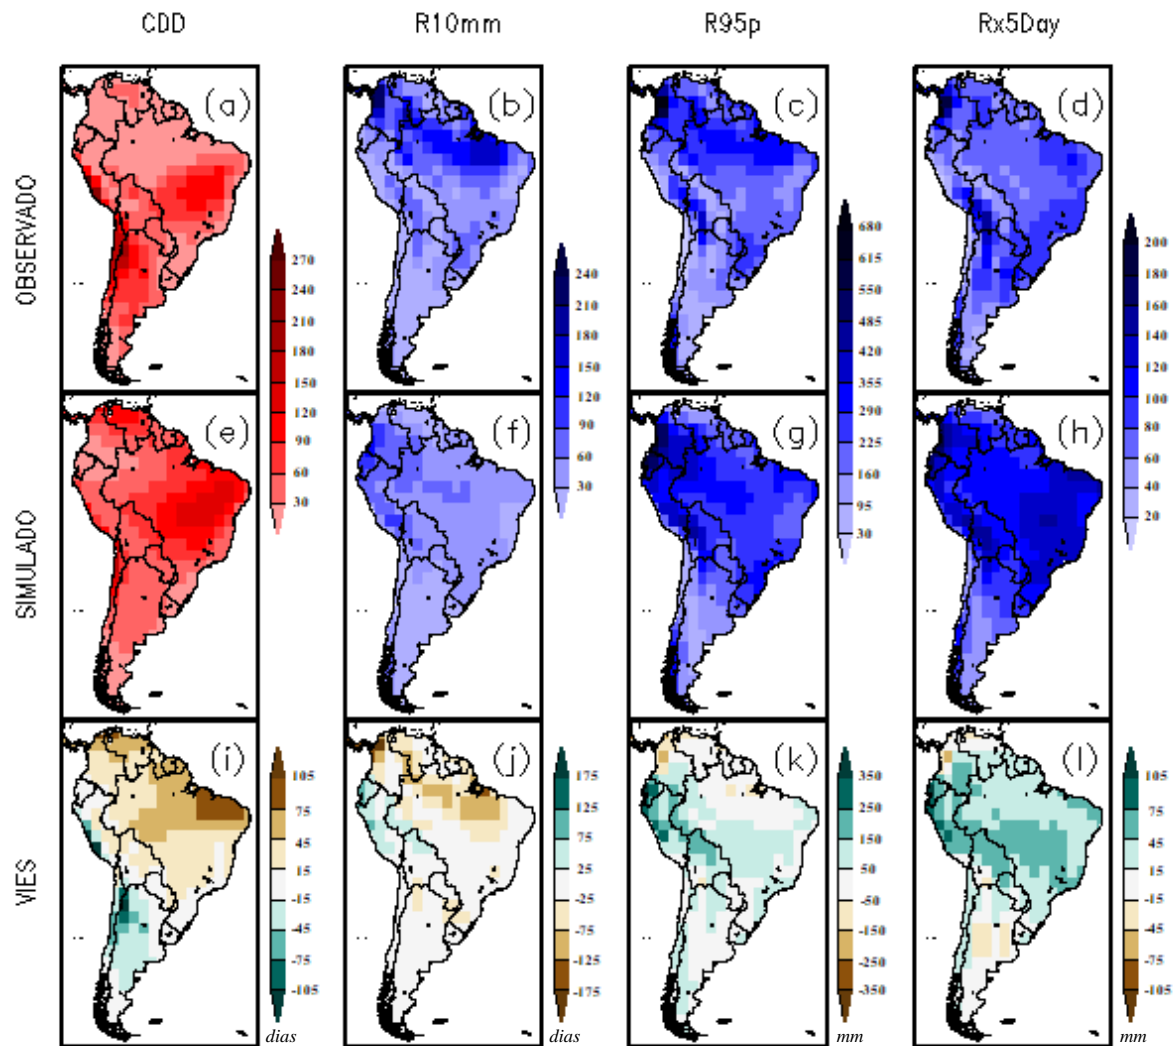


Figura 6 – Climatologia média anual observada (superior), simulada (central) e viés associado (inferior) dos índices extremos de precipitação, resultantes, respectivamente, dos dados de reanálises do NCEP, da média de todos os modelos do CMIP5 e da diferença entre ambos (simulado menos observado), utilizados para o período de 1961 a 1990. As unidades estão em *dias* para os índices CDD (*a*, *e* e *i*) e R10mm (*b*, *f* e *j*), e em *mm* para os índices R95p (*c*, *g* e *k*) e Rx5Day (*d*, *h* e *l*).

Assim como para os índices de extremos de precipitação, é possível observar que todos os índices de temperatura (Figura 7) possuem pequena variação, em torno de 2%, em todo o continente sul-americano. Especificamente, para o índice noites muito frias (TN10p), observa-se (Figura 7a) as menores porcentagens ($\approx 9,4\%$ a 10%) na faixa equatorial, crescendo gradativamente na direção das latitudes mais altas, e tendo uma ligeira diminuição (diferença de $0,2\%$) na porção centro-sul argentino. A região de máximos valores, em torno de $10,4\%$ a $10,6\%$, compreende o Paraguai, sul da Bolívia, norte da Argentina e parte das regiões Centro-oeste, Sudeste e Sul do Brasil. Esse gradiente norte/sul de TN10p, o qual foi identificado, pode ser associado à quantidade de radiação incidente em cada região e a nebulosidade, indicando

uma faixa latitudinal mais quente nos trópicos, o que acarreta em um menor número de noites muito frias, e uma faixa subtropical mais fria, favorecendo a ocorrência de noites mais frias em baixas latitudes. As simulações (Figura 7e) mostram valores de TN10p entre 10,4% e 10,6% para quase toda a América do Sul, exceto por uma estreita faixa litorânea, pelo Sudeste e parte do Centro-oeste e do Paraguai, nos quais a porcentagem varia entre 10,6% e 10,8%. Mesmo com os maiores valores simulados para essas áreas, os mais altos vieses (Figura 7i) podem ser verificados no norte do continente, variando entre 0,4% e 1%, principalmente na região entre o Pará e o Amazonas, onde a superestimativa foi a mais pronunciada. Tal superestimativa pode ser transmitida para as projeções, indicando uma quantidade superior de noites muito frias no futuro, divergindo da possível realidade.

Avaliando o índice noites muito quentes (TN90p), as observações (Figura 7b) mostram que os menores valores encontram-se sob o norte do Amazonas, Roraima, leste da Venezuela, Guiana, Suriname ($\approx 9,6\%$ a $9,8\%$) e litoral leste do Rio Grande do Norte, Paraíba e Pernambuco ($< 9,4\%$). Este percentual vai aumentando do Nordeste em direção ao Sudeste e sul do continente, atingindo seus maiores valores na região central da Argentina ($\approx 10,4\%$ a $10,6\%$). As simulações (Figura 7f) para TN90p mostram uma uniformidade dos valores, em torno de 10,2% a 10,4%, sobre todo o continente, sendo o número de noites quentes considerado ligeiramente maior ($\approx 10,4\%$ a $10,6\%$) no litoral do Nordeste e extremo norte do país, abrangendo parte do Amazonas, Pará, Amapá, Roraima e Guiana Francesa, Suriname, Guiana. Assim, os maiores vieses (Figura 7j), com valores entre 0,8% e 1,2%, são encontrados nesta região norte da América do Sul, valores intermediários ($\approx 0,4\%$ a $0,8\%$) na área central do Brasil e as menores porcentagens dessa diferença sobre o Sudeste e Sul do Brasil, Paraguai, Chile, Uruguai e Argentina ($< 0,4\%$).

Para o índice dias muito frios (TX10p), nota-se que as observações têm comportamentos semelhantes ao índice TN10p, com menores valores sobre a região equatorial, aumentando gradativamente com as altas latitudes (Figura 7c). A diferença está no Sudeste e Sul do Brasil, onde TX10p encontra-se entre 10,2% e 10,4% como a maioria do país, e não um pouco maior como em TN10p. As simulações dos modelos (Figura 7g) mostram valor mínimo entre 10,4% e 10,6% sobre todo o território, sendo parte do Nordeste, Centro-Oeste e Sudeste do Brasil, Pará, Amapá e norte da Venezuela e da Colômbia as regiões com simulados de TX10p mais altos ($\approx 10,6\%$ a $10,8\%$). Assim como TN10p, existe superestimativa em toda a América do Sul, podendo ser encontrados os maiores vieses na região equatorial do continente, variando entre 0,6 e 1,2% (Figura 7k).

Finalmente, para o índice dias muito quentes (TX90p), observa-se que os valores são superiores a 10% sobre toda a América do Sul, sendo os maiores índices ($\approx 10,4\%$ a $10,6\%$) observados no semiárido nordestino, Sudeste, parte do Centro-Oeste e do Sul do Brasil, Paraguai, Uruguai, leste da Bolívia e Argentina (Figura 7d). O semiárido do Nordeste apresenta geralmente altas temperaturas durante todo o ano, já as regiões Centro-Oeste e Sudeste estão sob influência do SMAS, o qual é caracterizado por verões quentes, podendo justificar as observações mais elevadas desse índice (ZHOU; LAU, 1998; GARCIA; KAYANO, 2009). Quando analisadas as simulações, nota-se uniformidade dos maiores valores ($\approx 10,6\%$ a $10,8\%$) sobre países ao norte do Brasil e em todo o território brasileiro, exceto na região Sul (Figura 7h). A região Sul, juntamente com os demais países da América do Sul apresentam o índice um pouco menor, entre $10,4\%$ e $10,6\%$. Porém, no geral, os vieses em todo o continente mantiveram-se abaixo dos $0,4\%$, sendo ligeiramente maiores no sul do Peru ($\approx 0,4\%$ a $0,6\%$) e litoral nordeste da América do Sul, onde as superestimativas chegaram a 1% em algumas localidades (Figura 7l).

De maneira geral, nota-se que os índices de temperatura têm os menores vieses quando comparados aos de precipitação, concordando com Natividade (2015) e Natividade, Garcia e Torres (2017). Essa diferença pode estar relacionada à problemas nas simulações dos extremos de precipitação, à utilização de reanálises tidas como observações, ou, até mesmo, à interpolação utilizada. Na região equatorial, os modelos tendem a superestimar esses índices, diferentemente dos índices de precipitação, os quais possuem heterogeneidade na distribuição de seus vieses: negativos sobre os Andes (CDD) e positivos sobre a bacia amazônica (exceto R10mm) e, para todos os índices de precipitação, sobre noroeste da América do Sul, NEB, Centro-oeste e Sudeste (CHOU et al., 2014). Essas regiões, exceto pelo Centro-oeste e Sudeste, se assemelham às áreas enviesadas encontradas por Torres (2014), o qual analisou a média anual e sazonal de temperatura e precipitação.

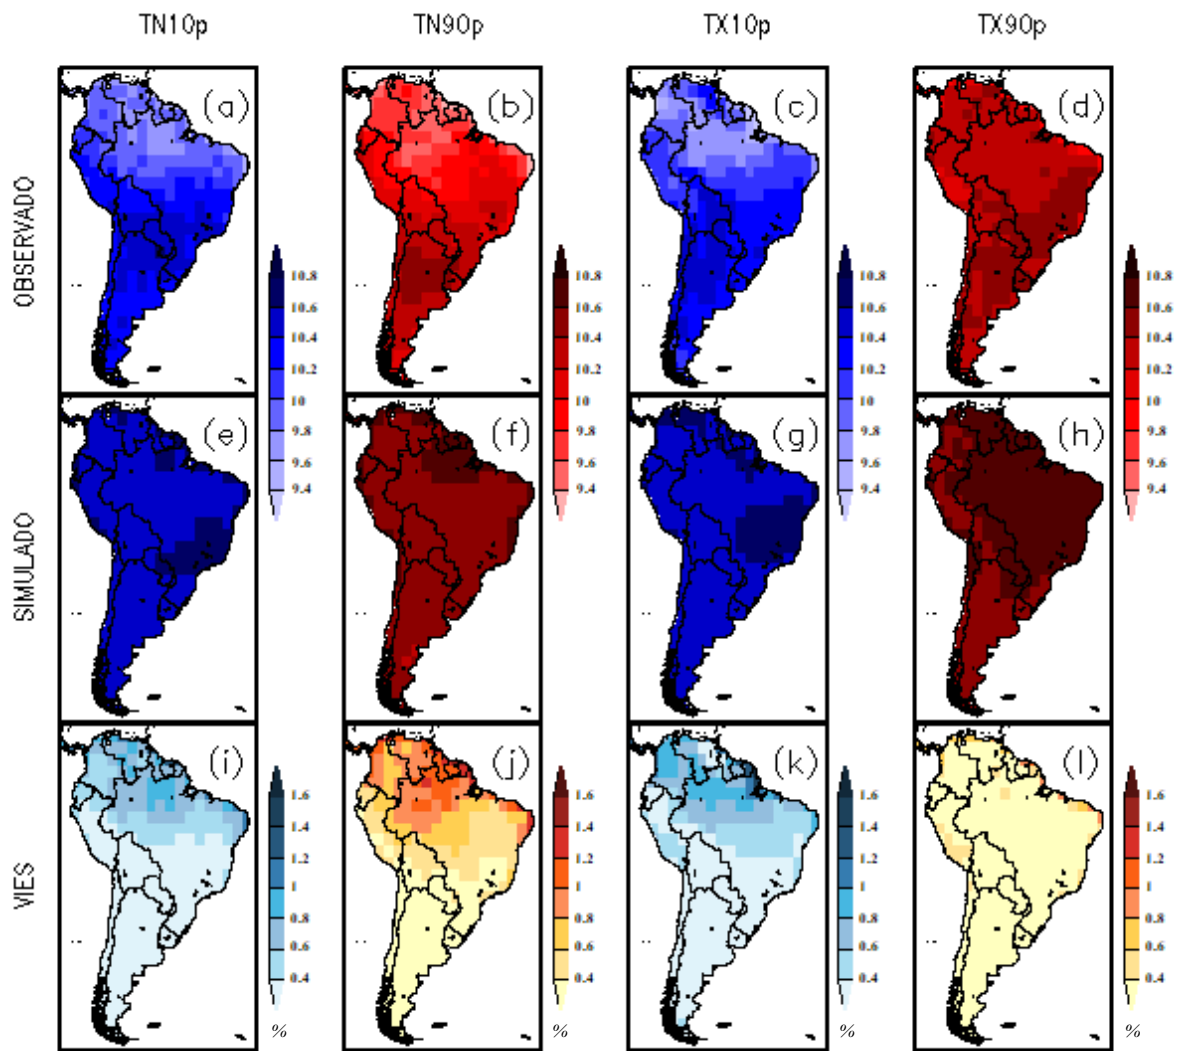


Figura 7 – Climatologia média anual observada (superior), simulada (central) e viés associado (inferior) dos índices extremos de temperatura, resultantes, respectivamente, dos dados de reanálises do NCEP, da média de todos os modelos do CMIP5 e da diferença entre ambos (simulado menos observado), utilizados para o período de 1961 a 1990. As unidades estão em % para os índices TN10p (a, e e i), TN90p (b, f e j), TX10p (c, g e k) e TX90p (d, h e l).

Para analisar a acurácia dos modelos em simular os padrões médios dos extremos de precipitação e temperatura para cada uma das 4 sub-regiões, gerou-se o Diagrama de Taylor, com base na correlação de Pearson (linhas pretas), erro quadrático médio (linhas circulares verdes) e desvio padrão (linhas circulares azuis), em que os dois últimos encontram-se normalizados. O quadrado verde na abscissa do gráfico representa a média da reanálise (considerada como observação) e os círculos denotam os 31 MCGs do CMIP5, classificados por suas resoluções espaciais com base na área do pixel (Tabela 1). Tanto as observações quanto as simulações foram avaliadas neste diagrama para o período 1961-1990, após utilizar um filtro

média móvel nessas séries para filtrar somente aquelas variabilidades com período superior a 30 anos.

As correlações referentes ao CDD (Figura 8) são majoritariamente negativas em todas as sub-regiões de estudo. Nota-se que as simulações estão concentradas ao redor do desvio nulo e as correlações são, em sua maioria, inferiores a -0,6 no EAMZ (Figura 8a) e NEB (Figura 8c), mas como demonstram comportamento inverso (correlação negativa) aos dados observados e os modelos encontram-se mais afastados das observações, estes têm baixa acurácia na modelagem de CDD. Já no WAMZ (Figura 8b) e LPB (Figura 8d), tanto correlações positivas quanto negativas foram observadas e os resultados são ligeiramente melhores, porém são poucos os modelos os quais apresentam simulações mais próximas às observações, podendo serem identificados pelas maiores correlações positivas, menores EQM e desvios padrão mais próximos às observações. Assim, apesar do melhor desempenho nas regiões WAMZ e LPB, as simulações nas quatro sub-regiões ainda são deficientes em representar as observações do índice CDD.

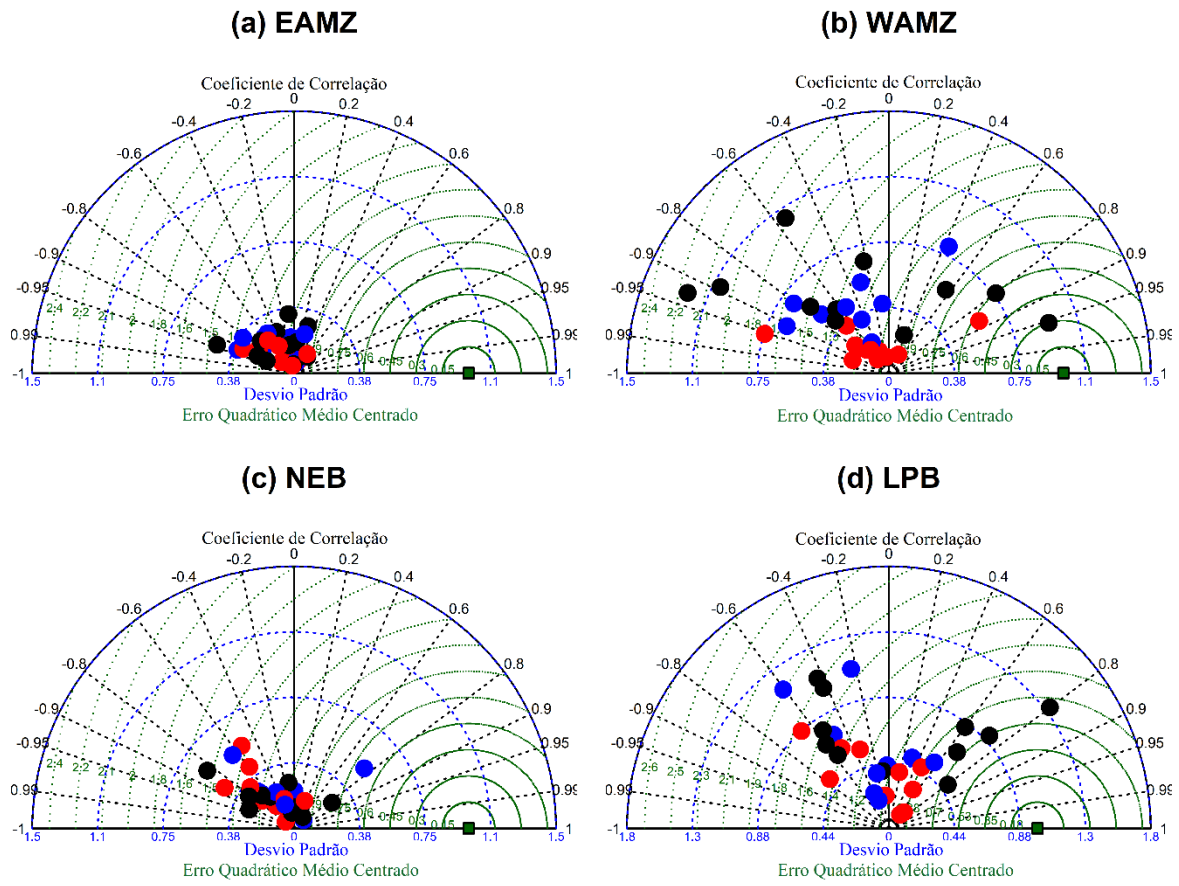


Figura 8 – Diagramas de Taylor para as simulações de Dias Secos Consecutivos (CDD) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990.

Os diagramas de Taylor para as simulações dos índices R10mm e R95p (Figuras 9 e 10) mostram comportamentos semelhantes, indicando convergência das simulações em torno do eixo de desvio nulo. Apesar dos valores altos em alguns casos, as correlações são negativas e positivas, e acompanhado da pouca aproximação do desvio padrão observado e elevado EQM, os modelos demonstram pouca destreza em simular as observações dos índices R10mm e R95p.

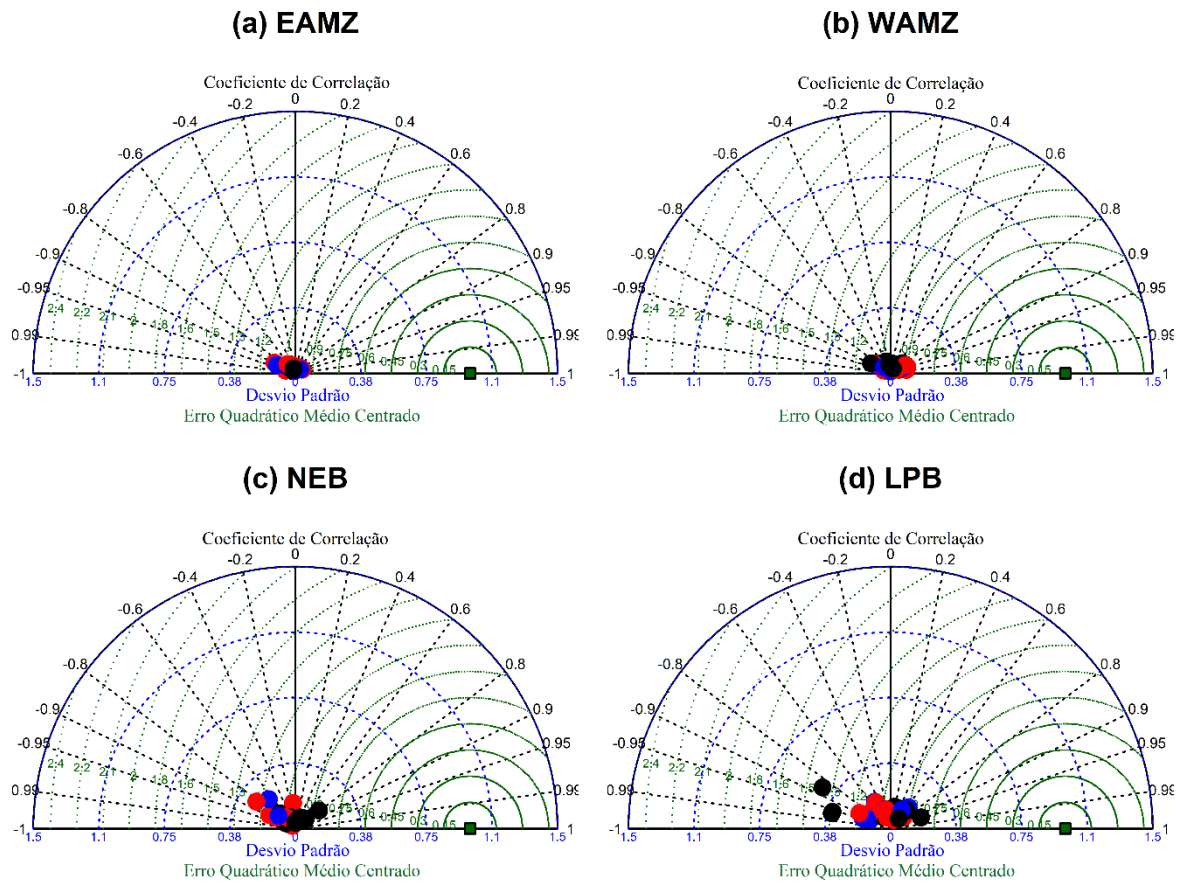


Figura 9 – Diagramas de Taylor para as simulações de Dias de Precipitação Intensa (R10mm) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990.

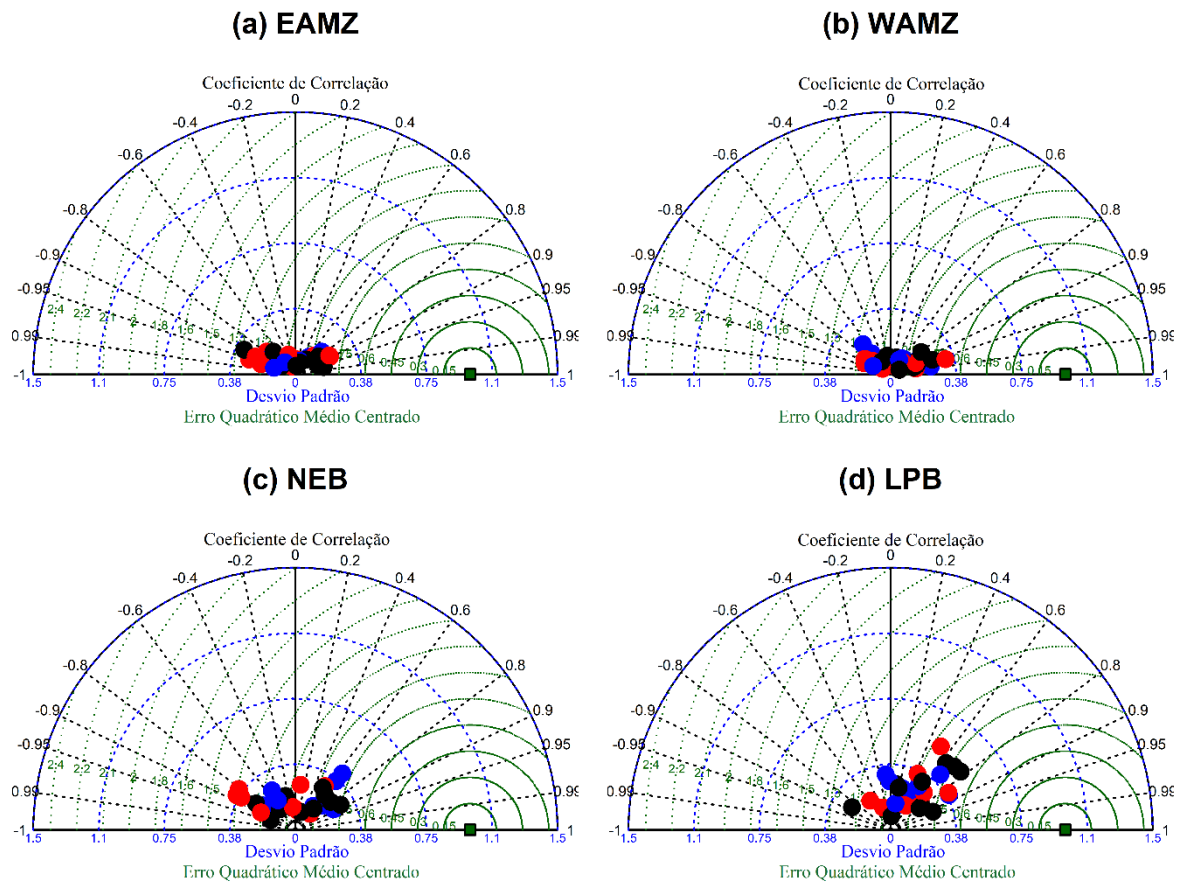


Figura 10 – Diagramas de Taylor para as simulações de Dias Muito Úmidos (R95p) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990.

Já para o diagrama do índice Rx5Day (Figura 11), pode-se observar, de modo geral, que os modelos possuem maior dispersão, principalmente no NEB (Figura 11c), e as correlações são negativas e positivas, significando que os modelos não possuem uma representação fidedigna, uma vez que denotam comportamento muitas vezes inverso ao observado. Para EAMZ (Figura 11a), WAMZ (Figura 11b), e LPB (Figura 11d), as simulações encontram-se ao redor do desvio padrão nulo, mas ainda são poucos os modelos que possuem desvios próximos ao observado e EQM pequenos.

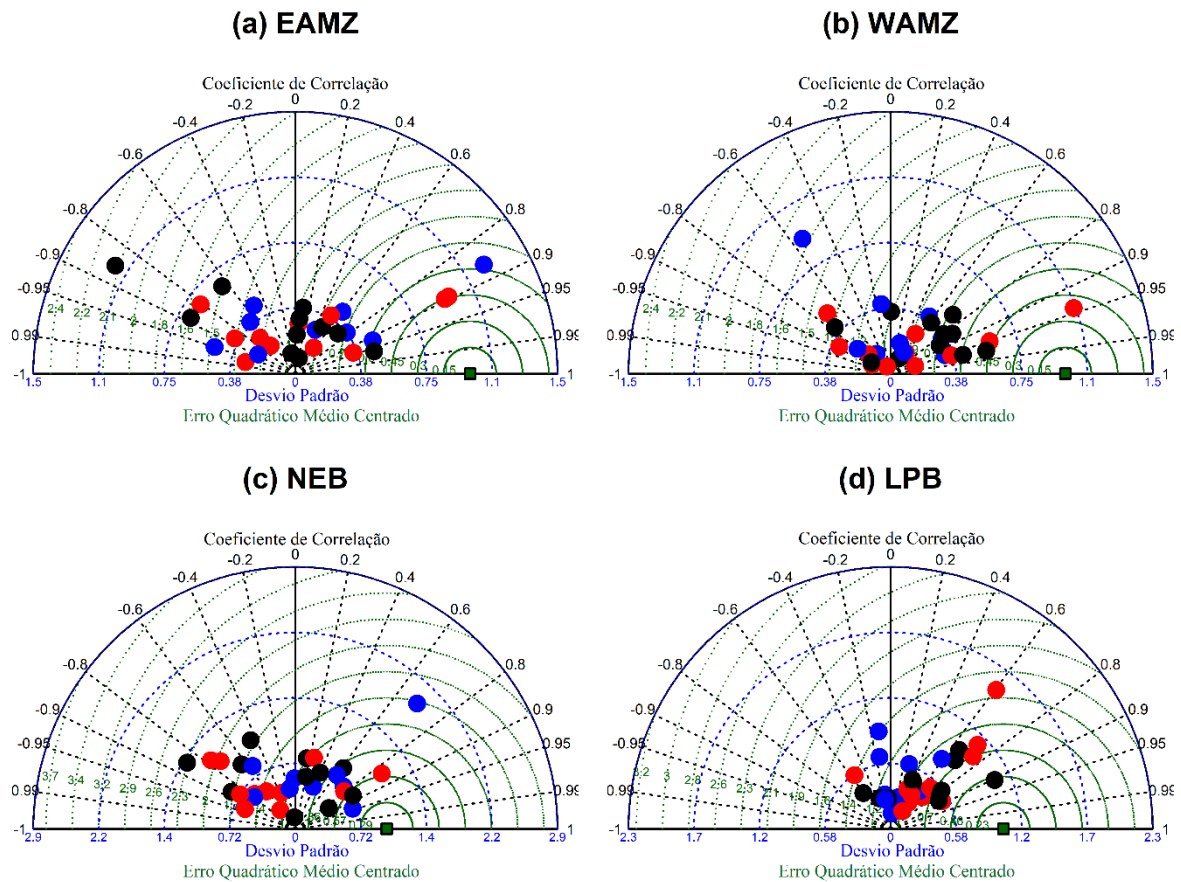


Figura 11 – Diagramas de Taylor para as simulações de Máximo de Precipitação em 5 dias (Rx5Day) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990.

Quando analisados os diagramas de Taylor referentes aos extremos climáticos de temperatura, as correlações positivas são parcialmente unânimes para os quatro índices (TN10p, TN90p, TX10p, TX90p). Especificamente, os diagramas para TN10p (Figura 12) e TN90p (Figura 13) mostram correlações entre 0,8 e 0,99, desvios padrão próximos do observado e EQM pequenos, o que demonstra a alta capacidade dos modelos em simular as observações dos índices TN10p e TN90p para as quatro regiões, com menor acurácia no NEB. Nota-se ainda que tal destreza é maior para TN90p em relação à TN10p, uma vez que a quantidade de modelos com erros pequenos e próximos ao referencial é mais alta.

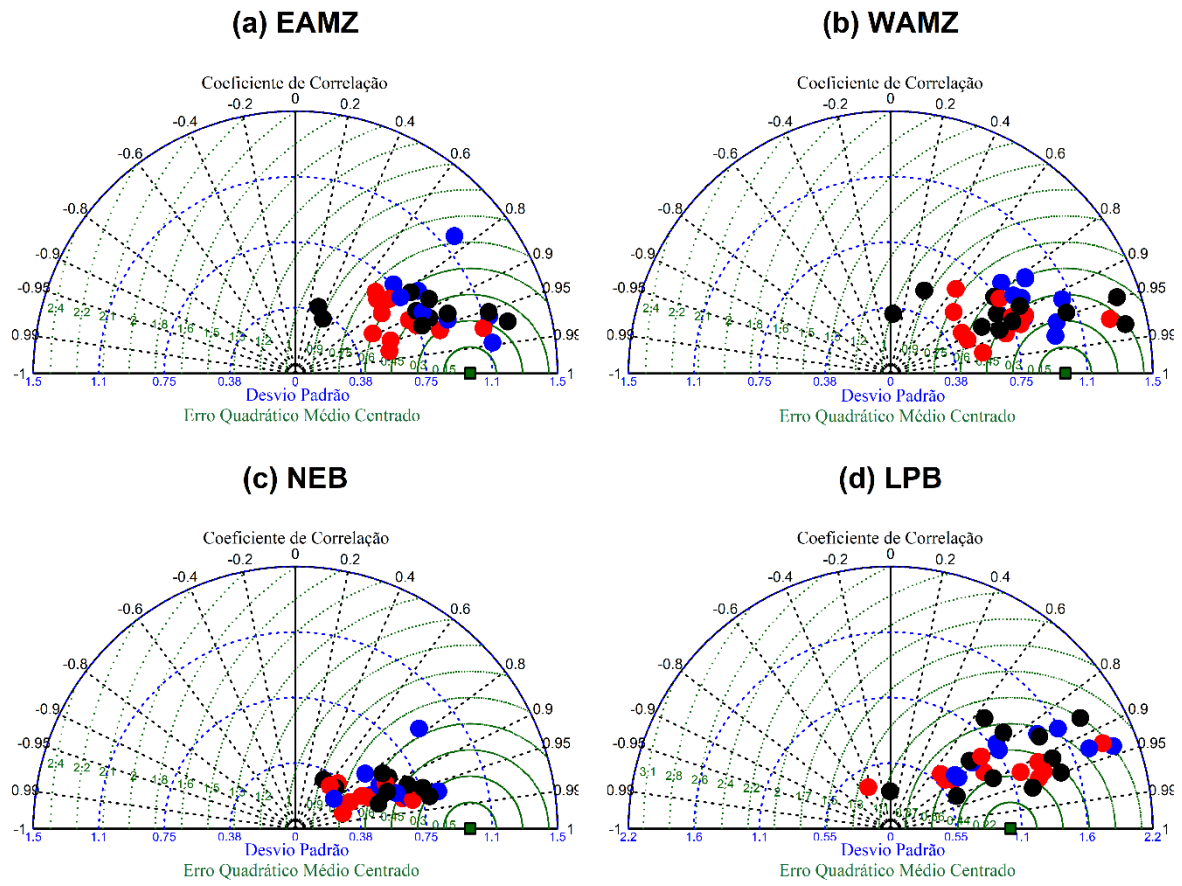


Figura 12 – Diagramas de Taylor para as simulações de Noites Muito Frias (TN10p) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990.

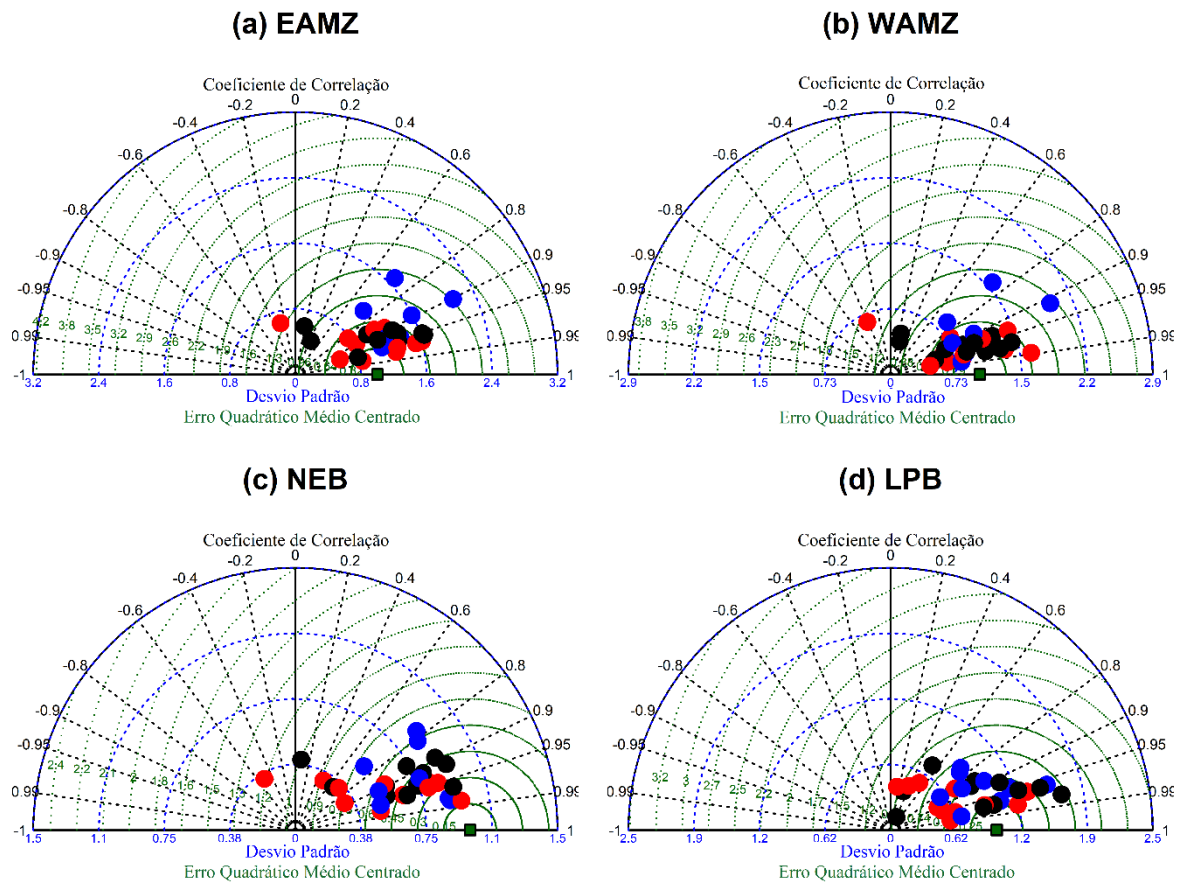


Figura 13 – Diagramas de Taylor para as simulações de Noites Muito Quentes (TN90p) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990.

Para o índice TX10p (Figura 14), o diagrama mostra correlações concentradas entre 0,2 e 0,8 no WAMZ, entre 0,4 e 0,9 no EAMZ, entre 0,2 e 0,95 no LPB e acima de 0,6 no NEB, no qual alguns modelos alcançam até 99% de correlação. Apesar disso, no WAMZ (Figura 14b) e LPB (Figura 14d), as simulações estão mais espalhadas e afastadas do referencial. Já no EAMZ (Figura 14a) e NEB (Figura 14c), os modelos são mais convergentes e possuem menores EQM e desvios padrão próximos ao observado, sendo no NEB a maior acurácia em simular as observações de TX10p.

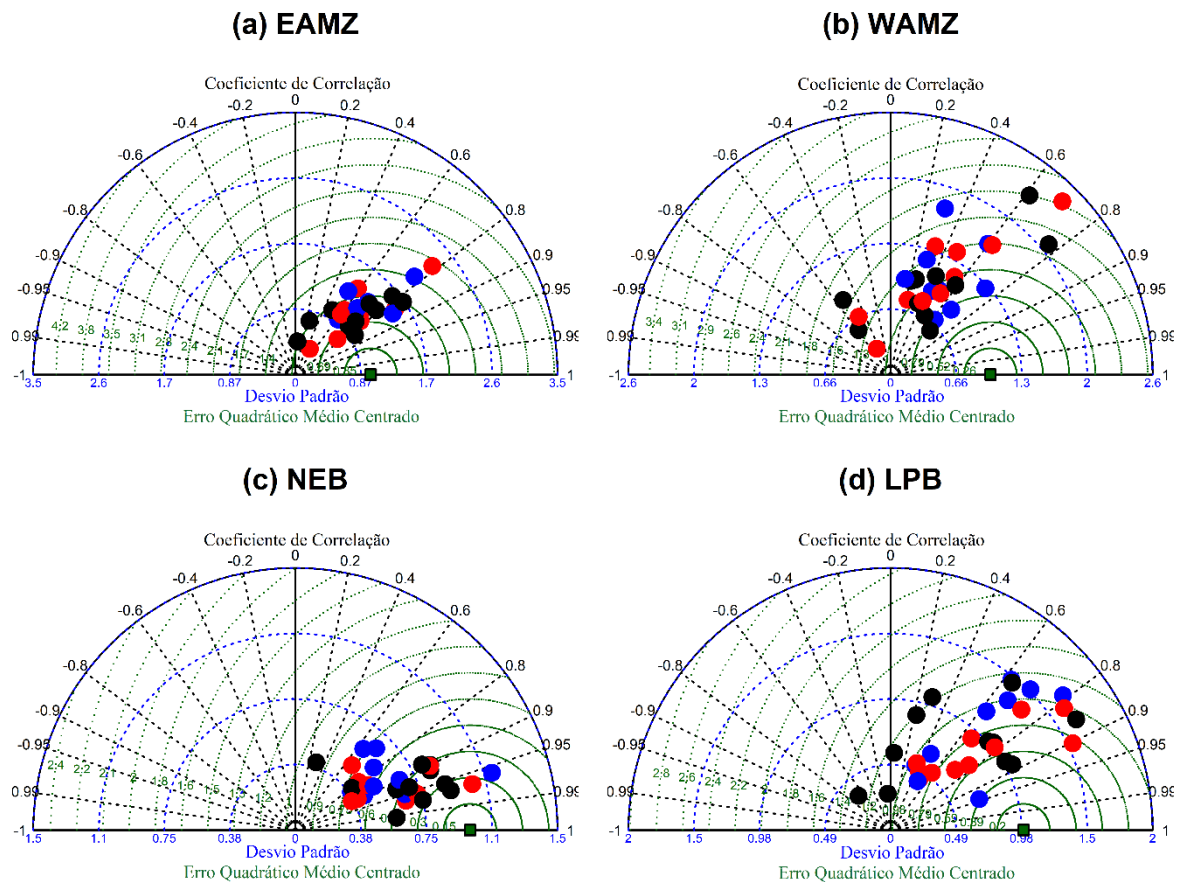


Figura 14 – Diagramas de Taylor para as simulações de Dias Muito Frios (TX10p) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990.

Finalmente, para o índice TX90p (Figura 15), nota-se que os modelos possuem correlações de até 80% na região Amazônica (Figuras 15a e 15b), até 95% no LPB (Figura 15d) e concentram-se sua grande maioria entre 90% e 99% de correlação no NEB (Figura 15c). Assim, em conjunto com os menores EQM e desvios próximos ao observado, o desempenho dos modelos é maior na LPB e NEB.

Ressalta-se que, apesar de haver modelos de altas resoluções espaciais (áreas do pixel pequenas, representadas pelos círculos vermelhos) com relativa destreza em simular as observações de TX10p no NEB e LPB, não se pode afirmar que existe uma relação direta entre a acurácia dos modelos e seu refinamento espacial, uma vez que esse comportamento não foi observado nas outras regiões e índices.

Comparativamente, os índices extremos de temperatura apresentaram melhor desempenho em simular as observações do que os índices de precipitação, nos quais a

deficiência foi bastante pronunciada. Também, TN90p foi o índice de maior acurácia para todas as sub-regiões dentre os índices de temperatura, uma vez que as correlações são altas e os desvios próximos ao observado, indicando que as projeções podem ser mais consistentes e confiáveis. Essa menor habilidade em simular os índices de precipitação deve-se à maior dificuldade em representar suas parametrizações, além da precipitação não ser utilizada como variável de entrada do modelo quando geradas as reanálises, aumento, assim, as incertezas associadas (KALNAY et al., 1996).

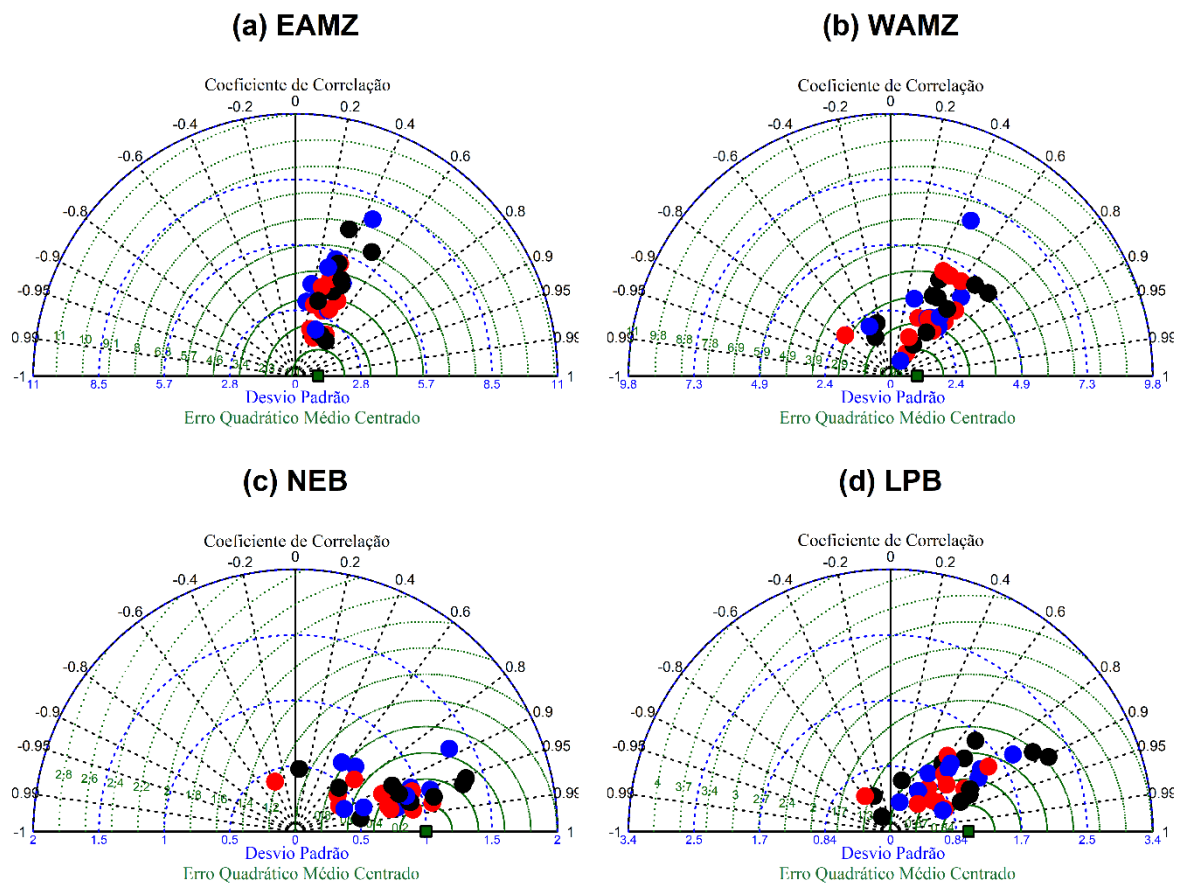


Figura 15 – Diagramas de Taylor para as simulações de Dias Muito Quentes (TX90p) nas 4 sub-regiões de estudo para todos os MCGs do CMIP5. Em vermelho são representados os 11 modelos com altas resoluções, em preto, os 10 com médias resoluções e, em azul, os 10 com baixas resoluções. O quadrado verde na abscissa representa as observações e o período utilizado das séries de dados foi 1961-1990.

Por fim, para avaliar a concordância entre os dados observados e simulados pelos modelos, calculou-se o Índice de Concordância de Willmott (Figura 16). Este índice varia entre 0 e 1, com valores próximos a 1 indicando que as simulações representam bem as observações.

Quando analisados os índices extremos de precipitação, observa-se que as concordâncias (d_w) entre os modelos e as observações são inferiores a 0,5. Especificamente, para CDD (Figura 16a), nota-se as menores d_w ($< 0,1$) na porção norte do continente, a qual abrange Colômbia, Venezuela, Guiana, Suriname, Guiana Francesa e grande parte do oeste da Amazônia. Na região Andina do Peru e da Bolívia, na faixa litorânea do Brasil e na região Sul, as concordâncias variam entre 0,2 e 0,3. Já na área central brasileira (regiões Sudeste e Centro-Oeste; e semiárido nordestino), Paraguai, Chile e Argentina, a d_w está entre 0,3 e 0,5. Em relação ao índice R10mm (Figura 16b), as simulações possuem baixa concordância ($< 0,1$) na área que abrange toda a Cordilheira dos Andes. No restante do continente, a concordância dos modelos varia entre 0,3 e 0,4, sendo os maiores valores (0,5) sobre o leste da Amazônia e região central da Argentina. Para R95p (Figura 16c), as concordâncias estão entre 0,3 e 0,4 em praticamente todo o continente, sendo ligeiramente maiores (0,4 - 0,5) em poucos pontos de grade específicos, e menores (0,2 - 0,3) na região Andina, norte da Bolívia, leste do Paraguai e parte das regiões Nordeste e Centro-oeste do Brasil. Já para Rx5Day (Figura 16d), as simulações apresentam baixas concordâncias ($< 0,2$) com as observações na maior parte da América do Sul, sendo ligeiramente melhores (0,3 - 0,4) a modelagem de máximo de precipitação em 5 dias no sul da Bolívia, Sul do Brasil, Uruguai e Argentina. Na Cordilheira dos Andes, as concordâncias foram ínfimas para os quatro índices extremos de precipitação, podendo ser decorrente da resolução espacial grosseira dos MCGs, dificultando um detalhamento mais refinado da topografia local complexa, assim como também foi enfatizado por Minvielle, Garreaud (2011) e Torres (2014).

Por fim, em relação aos índices extremos de temperatura, nota-se concordâncias de até 0,7 em algumas localidades. Para TN10p (Figura 16e), observou-se as menores concordâncias (0,3 - 0,4) no sul da Patagônia, área entre Bolívia e Paraguai e extremos norte dos países acima da Linha do Equador. Já, concordâncias de 0,5 - 0,6 ocorreram nas regiões Norte, Nordeste e partes do Sudeste e Centro-Oeste brasileiro, Peru, Equador, Colômbia, Venezuela e sul da Guiana, chegando até 0,7 a concordância entre modelos e observações em áreas da Colômbia, Amazonas, Pará e Nordeste brasileiro. No restante do continente, d_w permaneceu entre 0,4 e 0,5. As concordâncias para TN90p (Figura 16f) predominam entre 0,4 e 0,5, sendo superiores (0,5 - 0,6) em partes do Amazonas, da Bahia, do Sudeste e do Centro-Oeste, leste da Patagônia, norte do Peru, Colômbia e oeste da Venezuela. Nas adjacências do Amapá, no Paraná, no Paraguai e em partes da Bolívia e da Argentina, esse índice diminui para 0,3 e 0,4. Para TX10p (Figura 16g), nota-se concordâncias de até 0,5 apenas numa área entre o Amazonas, Colômbia

e Venezuela, e no sul do Peru. Na região central do Brasil, esse índice permanece entre 0,3 e 0,4, sendo mais baixo (0,2 - 0,3) numa faixa da região Norte. Finalmente, para TX90p (Figura 16h), as concordâncias são menores (0,1 - 0,3) na região equatorial, aumentando (entre 0,3 e 0,5) em direção ao sul do continente, e alcançam valores de até 0,6 em localidades no leste da Patagônia argentina.

De maneira geral, para todo o território sul-americano, a concordância dos modelos com as observações é maior nos extremos de temperatura (destaque para TN10p e TN90p) quando comparados aos de precipitação, como foi observado nas análises dos Diagramas de Taylor para as 4 sub-regiões. Isso também pode estar relacionado aos dados, por ter sido utilizados dados de reanálise como observações, as quais carregam maiores incertezas no cálculo dos índices de precipitação quando comparados aos de temperatura (KALNAY et al., 1996). Além disso, esses índices são derivados das variáveis precipitação e temperatura e suas simulações possuem qualidade inferior às variáveis em si. Devido à sua resolução finita e ainda relativamente grosseira, não se espera que MCGs representem eventos climáticos extremos com a mesma intensidade e frequência como em dados observados, particularmente para eventos relacionados à precipitação (KIKTEV et al., 2003).

No presente estudo, o índice R10mm foi o que apresentou maior valor de d_w e, portanto, maior concordância com as observações, sendo o extremo de precipitação melhor representado pelos modelos. Isso difere de Rusticuci et al. (2010), no qual R95t (correspondente à R95p dividido pelo total de precipitação anual) possui melhor desempenho. Essa divergência pode estar ligada aos dados e à análise utilizada por Rusticucci et al. (2010), os quais compararam simulações de 9 MCGs com observações provenientes de 90 estações meteorológicas na Argentina, Uruguai, Paraguai, Chile, Brazil, Bolívia, Peru e Equador. Essas estações estavam mais concentradas na Argentina e como não havia dados para a maior parte do território brasileiro e norte da América do Sul, os menores vieses para R95t foram encontrados pontualmente, onde estavam localizadas as estações, não abrangendo, assim, o continente sul-americano como um todo.

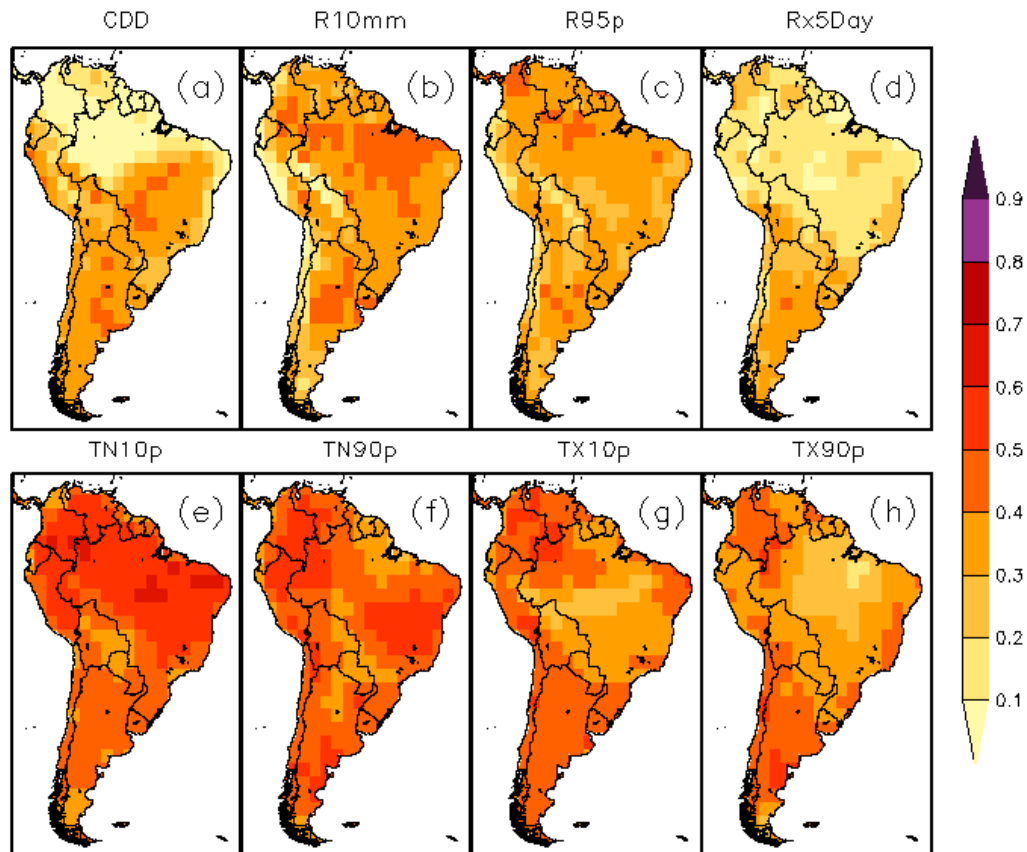


Figura 16 – Índice de Concordância de Willmott para os índices extremos de precipitação (CDD, R10mm, R95p, Rx5Day) e temperatura (TN10p, TN90p, TX10p, TX90p). Esse índice varia entre 0 e 1, com valores próximos a 1 indicando maior concordância entre os modelos e valores próximos a 0, menor concordância das simulações numa dada área.

4.2 Projeções Climáticas e Incertezas associadas

Após a avaliação dos modelos em simular as observações, optou-se por analisar a média das projeções para os índices extremos de precipitação e temperatura de todos os modelos avaliados, comparando-se com as projeções de mudanças utilizando o método de Inferência Bayesiana, proposto por Tebaldi et al. (2005). Esse método trata de forma aleatória os dados utilizados e os parâmetros envolvidos são dispostos através de curvas de densidade de probabilidade, fazendo com que a subjetividade das escolhas na fase de ponderamento sejam reduzidas.

As Figuras 17 a 24 apresentam a mudança anual de cada índice extremo climático projetada para o final do século (2071-2100) nos cenários forçantes RCP2.6, RCP4.5, RCP6.0 e RCP8.5, provenientes da média dos MCGs e a média aplicando-se a Inferência Bayesiana. A mudança em questão é resultante da diferença entre as projeções (2071-2100) e as simulações

(1961-1990), mostrando que mudanças positivas indicam um aumento dos valores do índice no futuro em relação ao presente e valores negativos mostram uma diminuição do índice em questão.

Nota-se que as projeções para o cenário RCP2.6 (Figura 17a) indicam aumento do número de CDD em grande parte do continente, abrangendo Guiana Francesa, Suriname, Guiana, Venezuela, norte da Colômbia, leste do Peru, Bolívia, Paraguai, norte da Argentina e Brasil (exceto região Sul), sendo os maiores valores da mudança (≈ 15 a 25 dias) sob o interior do Brasil. No cenário RCP4.5 (Figura 17b), a área de mudança positiva diminui, acompanhado da magnitude (decrece ≈ 10 dias), podendo ser resultante especificamente das características desse cenário, o qual é intermediário e ainda considera que haja uma pequena intervenção para diminuir as emissões de GEEs. Porém, nos cenários forçantes mais pessimistas (Figuras 17c e 17d), a extensão territorial da mudança das projeções aumenta gradativamente acompanhada de sua magnitude, que pode variar de 25 a 35 dias secos consecutivos no Centro-Oeste e Sudeste (RCP6.0) e no Nordeste (RCP8.5), alcançando valores entre 35 e 45 dias em Goiás (RCP6.0) e norte da Venezuela (ambos os cenários). Utilizando a Inferência Bayesiana, a área e as magnitudes das mudanças decrescem (≈ 10 dias) em quase todo o continente sul-americano quando comparada à média simples dos MCGs, concentrando os maiores valores (crescentes com o aumento da forçante radiativa dos cenários) no norte da Argentina, nas regiões Centro-Oeste, Sudeste e Nordeste, principalmente no semiárido nordestino (≈ 25 a 35 dias no RCP8.5), o qual já é caracterizado por longos períodos de estiagem. Essa tendência de aumento de CDD no Nordeste como um todo também foi observada por Marengo, Torres e Alves (2017), os quais analisaram 3 períodos futuros, sendo mais pronunciada para 2071-2100, porém ainda existentes quando verificados o futuro próximo (2011-2040) e futuro intermediário (2041-2070).

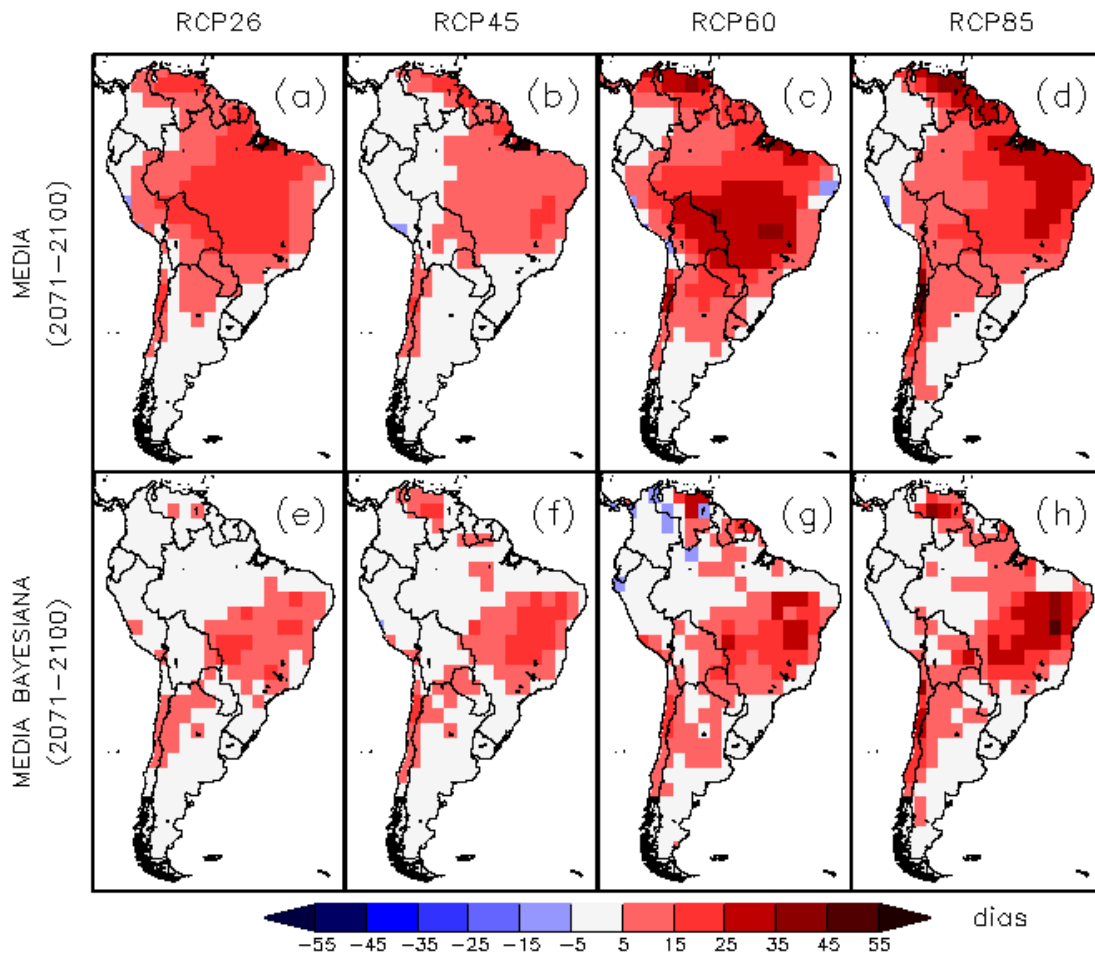


Figura 17 – Mudança anual do índice extremo Dias Secos Consecutivos (CDD) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.

Com relação ao índice R10mm (Figura 18), há mudanças positivas e negativas sobre o continente. As projeções para o cenário RCP2.6 (Figura 18a) indicam diminuição (≈ 6 a 10 dias) de dias de grande precipitação para o sul do Chile, parte do Centro-Oeste e Sudeste brasileiro, Nordeste e Norte do Brasil e áreas de países adjacentes, sendo mais pronunciada na região equatorial, principalmente sobre Guiana, Suriname e Guiana Francesa (redução de 14 a 18 dias). O aumento de R10mm (≈ 2 a 10 dias) é apenas observado no leste da Bolívia e sul do Peru. Para os outros cenários forçantes (Figuras 18b, 18c, 18d), a área de mudança positiva expandiu, abrangendo toda a faixa litorânea da Colômbia, Equador e Peru e a região Sul do Brasil (RCP4.5 e RCP8.5). Essa projeção de aumento de R10mm na região Sul do Brasil pode estar relacionada à maior frequência de sistemas frontais que atingirão a região no futuro (IPCC, 2014b). No geral, apesar da magnitude ter sido mantida, a área de mudança negativa para esses três últimos cenários contraiu, sendo observada no leste da Amazônia (RCP4.5), Bolívia,

Paraguai, nordeste da América do Sul (RCP6.0 e RCP8.5) e Chile (todos os cenários). Quando calculada a mudança de R10mm com o método bayesiano, as magnitudes decrescem (≈ 4 dias a menos), principalmente no cenário RCP2.6 (Figura 18e), e o sinal da mudança encontra-se menos uniforme sobre o continente. Porém, em concordância com a média simples dos modelos, ainda pode-se observar áreas de diminuição de R10mm no Chile, Bolívia, Centro-Oeste e Nordeste do Brasil (RCP2.6, RCP6.0 e RCP8.5) e norte da América do Sul (RCP4.5 e RCP8.5), e áreas de aumento da precipitação no leste da região equatorial (todos os cenários) e Sul do Brasil (RCP6.0 e RCP8.5).

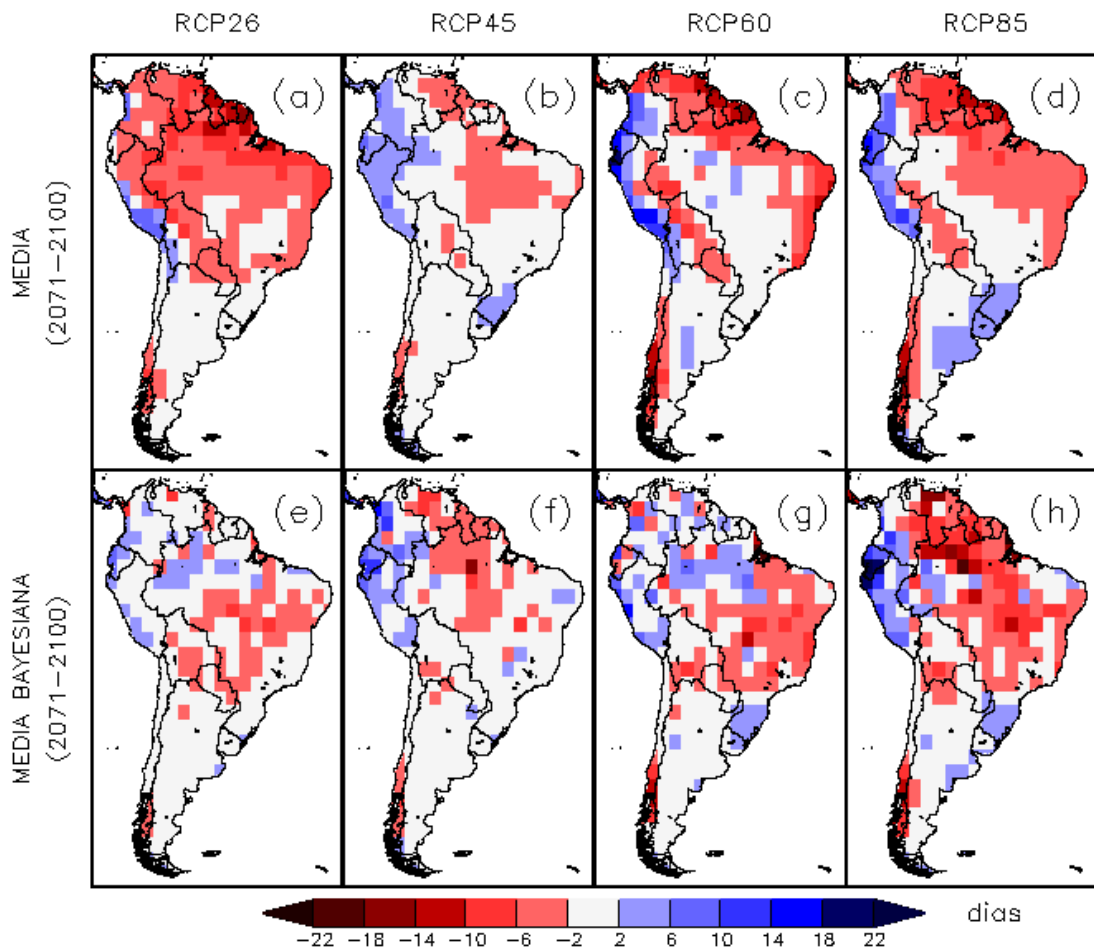


Figura 18 – Mudança anual do índice extremo Dias de Precipitação Intensa (R10mm) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em dias e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.

Os resultados para o índice dias muito úmidos - R95p (Figura 19) mostram mudanças negativas (≈ 75 a 125 mm) no extremo norte do continente e no sul do Chile nos cenários de forçantes 6.0 e 8.5 Wm^{-2} , porém o predomínio é de mudança positiva na faixa subtropical da América do Sul. A área em questão aumenta com os cenários, assim como a magnitude dos valores positivos de R95p. Deste modo, a precipitação acima do 95° percentil pode variar de 75-125 mm para RCP2.6 e RCP4.5 no Brasil, entre 125-175 mm na região equatorial para RCP6.0 e, no geral, valores acima de 125 mm para RCP8.5. Neste último cenário, o mais pessimista dos quatro, destaca-se a projeção de maior aumento de R95p no leste da Colômbia, Equador, Peru e Bolívia e no Sul do Brasil (concordando com R10mm), superando os 275 mm de precipitação.

Essas projeções de aumento na frequência de R95p em praticamente todo o continente e, principalmente, no sudeste da América do Sul e para o cenário mais pessimista de mudanças climáticas no final do século XXI, foi também observado por Natividade (2015). Esse aumento possivelmente será causado pela intensificação dos JBN a leste dos Andes que transportarão maior umidade da Amazônia para essas áreas (MARENGO et al., 2009; SOARES; MARENGO, 2009). Como o aumento desse índice acompanhado de R10mm e Rx5Day estão relacionados com alta umidade, episódios intensos de precipitação e grandes acumulados de chuva, poderão favorecer a ocorrência de enchentes, deslizamentos e desastres naturais de grandes proporções (IPCC, 2012), já que essa área é a mais populosa do continente sul-americano, e abrange a área de maior vulnerabilidade às mudanças climáticas (Centro-oeste e Sudeste brasileiros), como mostrado por Torres (2014), Torres; Marengo (2014) e Debortoli et al. (2017). As mudanças de R95p utilizando a Inferência Bayesiana apresentam comportamento espacial semelhante quanto aos cenários, mas suas magnitudes decrescem (≈ 50 mm) em quase todo o continente comparando-se com a média simples dos modelos.

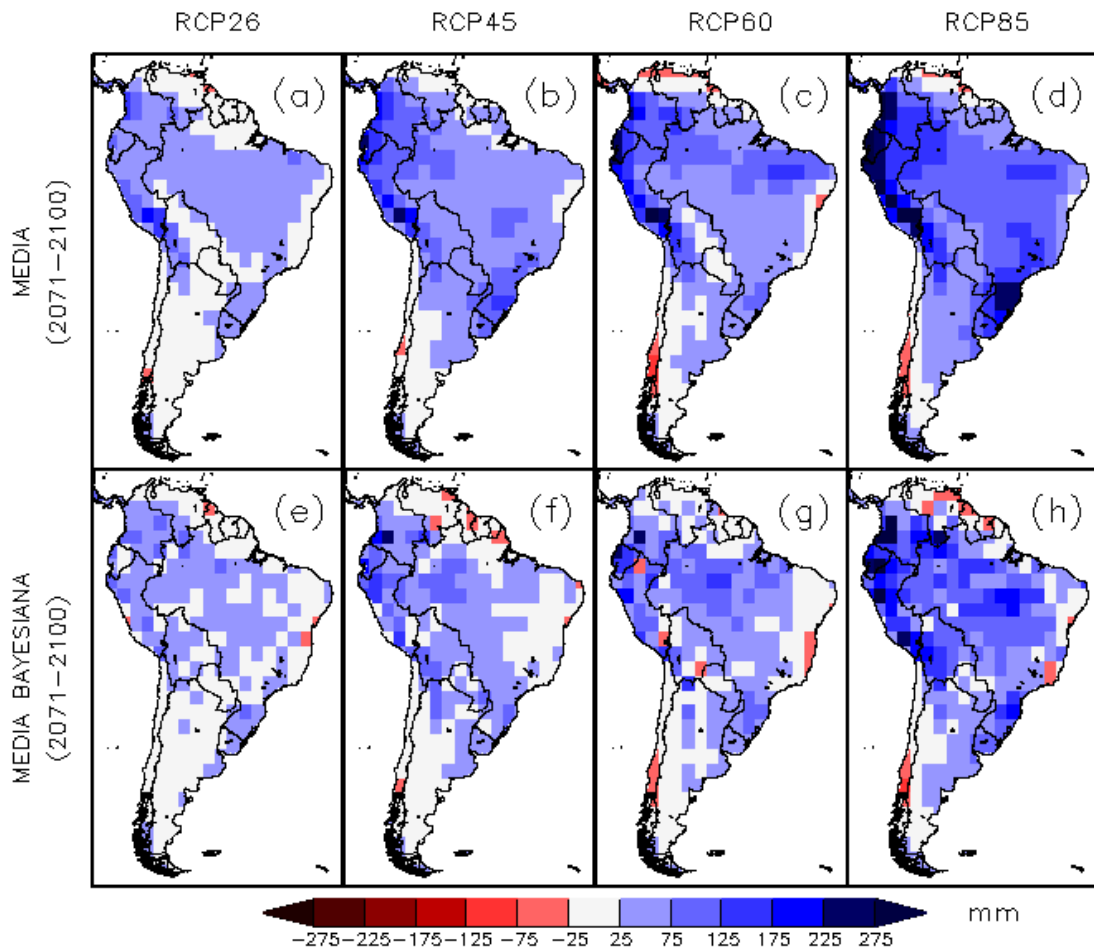


Figura 19 – Mudança anual do índice extremo Dias Muito Úmidos (R95p) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em mm e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.

Quanto ao índice Rx5Day, estes sofrerão mudanças predominantemente positivas (≈ 15 a 35 mm) em toda a América do Sul quando analisados a média simples dos MCGs, exceto Chile e extremo norte do continente, nos quais pode haver diminuição (≈ 5 a 25 mm) de Rx5Day (Figura 20). Há um aumento gradativo de Rx5Day a medida em que a forçante radiativa aumenta nos cenários, atingindo as maiores mudanças (≈ 35 a 45 mm) no Piauí, Ceará, Rio Grande do Norte e Paraíba (RCP6.0) e faixa central do Nordeste, Sudeste e Sul do Brasil (RCP8.5), além da porção leste da Colômbia, Equador, Peru e Bolívia (cenários mais pessimistas). Quanto à média dos modelos utilizando o método bayesiano (Figuras 20e-h), pode-se observar uma considerável diminuição de extensão territorial das mudanças sob a região central do Brasil. Além disso, a amplitude dos valores diminuiu em aproximadamente 10 mm nos cenários mais otimistas (RCP2.6 e RCP4.5), e no cenário de maior forçante

(RCP8.5), apesar de mais amenas (≈ 15 a 25 mm), as mudanças para Rx5Day são mais pronunciadas em parte do Nordeste, no Sul do Brasil e no Uruguai.

Resumidamente, as projeções de extremos de precipitação mostram, no geral, um aumento na frequência de chuvas no oeste da Amazônia e sudeste da América do Sul (Figuras 18, 19), pouca quantidade de eventos no leste da Amazônia e Nordeste do Brasil (Figura 17), e aumento de CDD no Altiplano chileno e no Platô brasileiro (Figura 17), assim como foram retratados no relatório sobre extremos climáticos do IPCC (2012) e por diversos outros trabalhos, tais como: MARENGO et al. (2009), SOARES; MARENGO (2009), KITO, KUSUNOKI; NAKAEGAWA (2011). O aumento de um índice que indique escassez de chuva não impede o aumento de um índice de precipitação intensa numa mesma região, uma vez que eles são independentes e podem ocorrer em épocas distintas. Com a utilização da Inferência Bayesiana, notou-se que as mudanças foram suavizadas, diminuindo em magnitude e extensão, o que significa que aos modelos cujas projeções de mudanças eram mais elevadas (tanto positivas quanto negativas, dependendo do índice) foram atribuídos menores pesos. Dessa maneira, as projeções para esses índices parecem mais próximas à possível realidade, uma vez que esse método diminui os valores nos cenários otimistas e se aproxima de algo aceitável no cenário mais pessimista, removendo, assim, as superestimativas dos modelos em relação às observações encontradas em algumas regiões. Então, a média utilizando o método bayesiano seria mais vantajosa nas projeções de extremos de precipitação do que a média simples dos modelos.

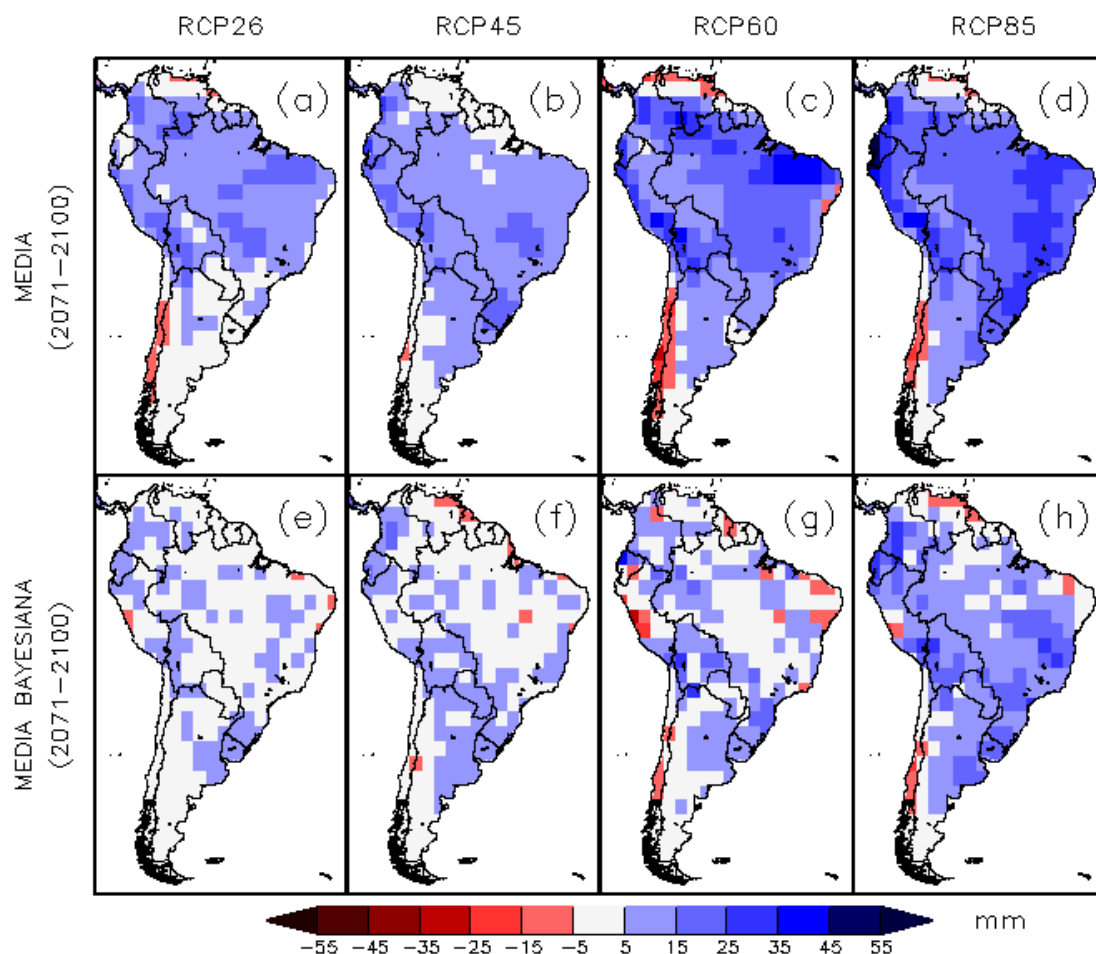


Figura 20 – Mudança anual do índice extremo de Máximo de Precipitação em 5 dias (Rx5Day) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em mm e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.

Com relação a análise dos índices extremos climáticos de temperatura, as projeções mostram que o número de dias e noites muito frios diminuirá e os dias e noites muito quentes sofrerão aumento significativo no final do século XXI, concordando com os resultados retratados pelo IPCC (2012).

Especificamente, para noites muito frias (TN10p – Figura 21), nota-se um gradiente norte-sul nos valores negativos, sendo as maiores porcentagens de diminuição (9% - 11%) na região subtropical, decrescendo em direção às latitudes mais altas, podendo chegar entre 3% e 5% a diminuição de TN10p na Argentina, Uruguai e Rio Grande do Sul para o cenário RCP2.6. A área referente a esse máximo de diminuição (9% - 11%) se expande para o sul com o aumento da forçante radiativa nos cenários, chegando a quase total domínio sobre o continente sul-americano no RCP8.5, exceto pela Argentina, na qual pode apresentar valores entre 7% e 9% de diminuição. Quando observadas as mudanças aplicando-se a Inferência Bayesiana, o mesmo

comportamento da média simples dos modelos é encontrado, não havendo nem mesmo variação nas magnitudes do índice.

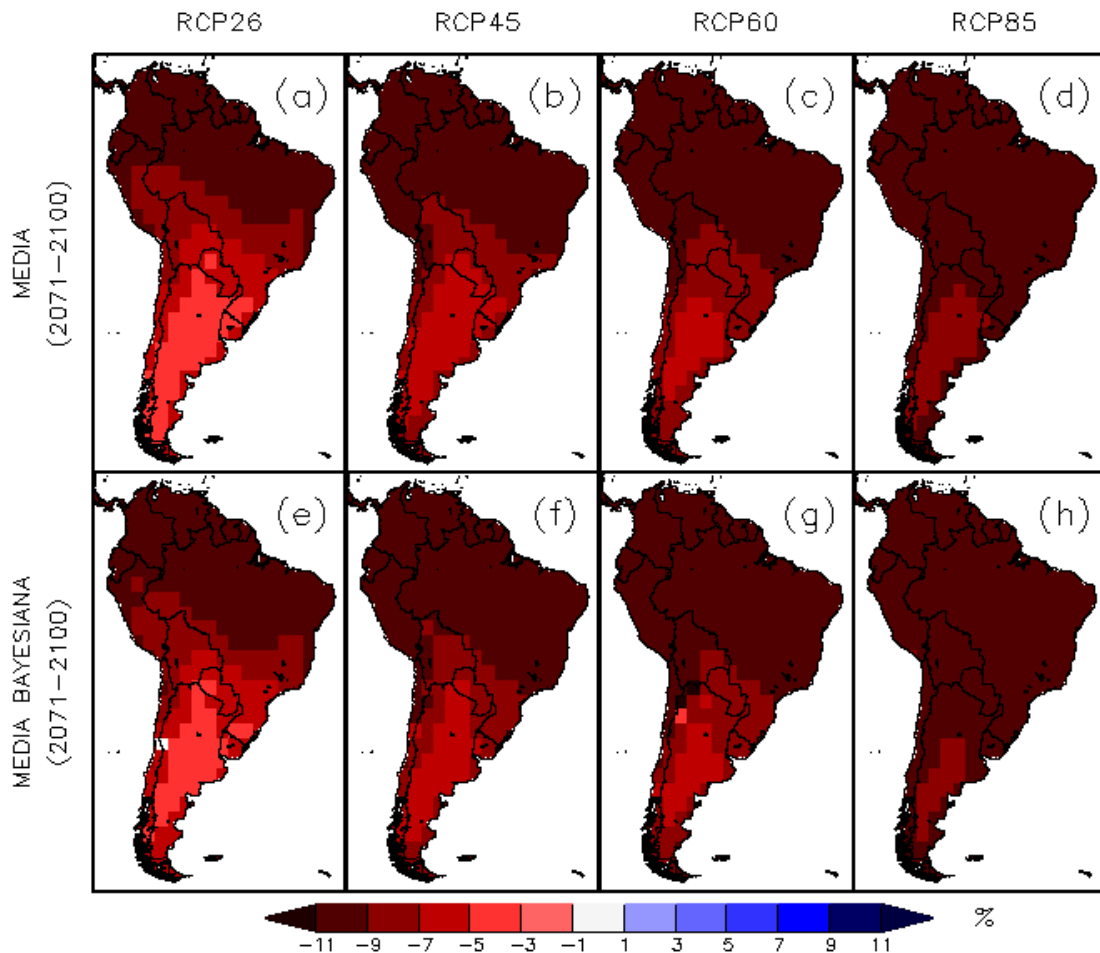


Figura 21 – Mudança anual do índice extremo de Noites Muito Frias (TN10p) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em % e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.

Complementar ao índice TN10p, para as noites muito quentes (TN90p - Figura 22), a média dos modelos evidencia faixas latitudinais de mudanças positivas que diminuem sua magnitude em direção aos polos, sendo o aumento de TN90p no cenário RCP2.6 (Figura 22a) entre 40% e 56% na região equatorial; entre 24% e 40% na área que compreende sul do Peru, norte do Chile, Bolívia, Centro-Oeste, Sudeste e semiárido nordestino; e entre 8% e 24% no Chile, norte da Argentina, Paraguai, Uruguai e Sul do Brasil. Os valores neutros de mudanças foram observados na Patagônia argentina para esse cenário mais otimista, tendo sua magnitude elevada em até 48% na região quando comparado ao cenário RCP8.5 (Figura 22 d). Como já

esperado, os intervalos de mudanças aumentam com os cenários forçantes e a área abrangida pelos maiores valores sofre expansão, uma vez que um maior aquecimento ocorrerá não somente na região equatorial, como também na faixa subtropical, aumentando a possibilidade de incidência de TN90p. Quando comparado à média bayesiana, o comportamento encontrado mostra-se semelhante em área e magnitude, apenas apresentando uma intensificação ($\approx 6\%$) de mudança positiva nos países ao norte da linha do Equador, faixa norte da região Amazônica e do Nordeste brasileiro nos cenários RCP4.5 (Figura 22f) e RCP8.5 (Figura 22h).

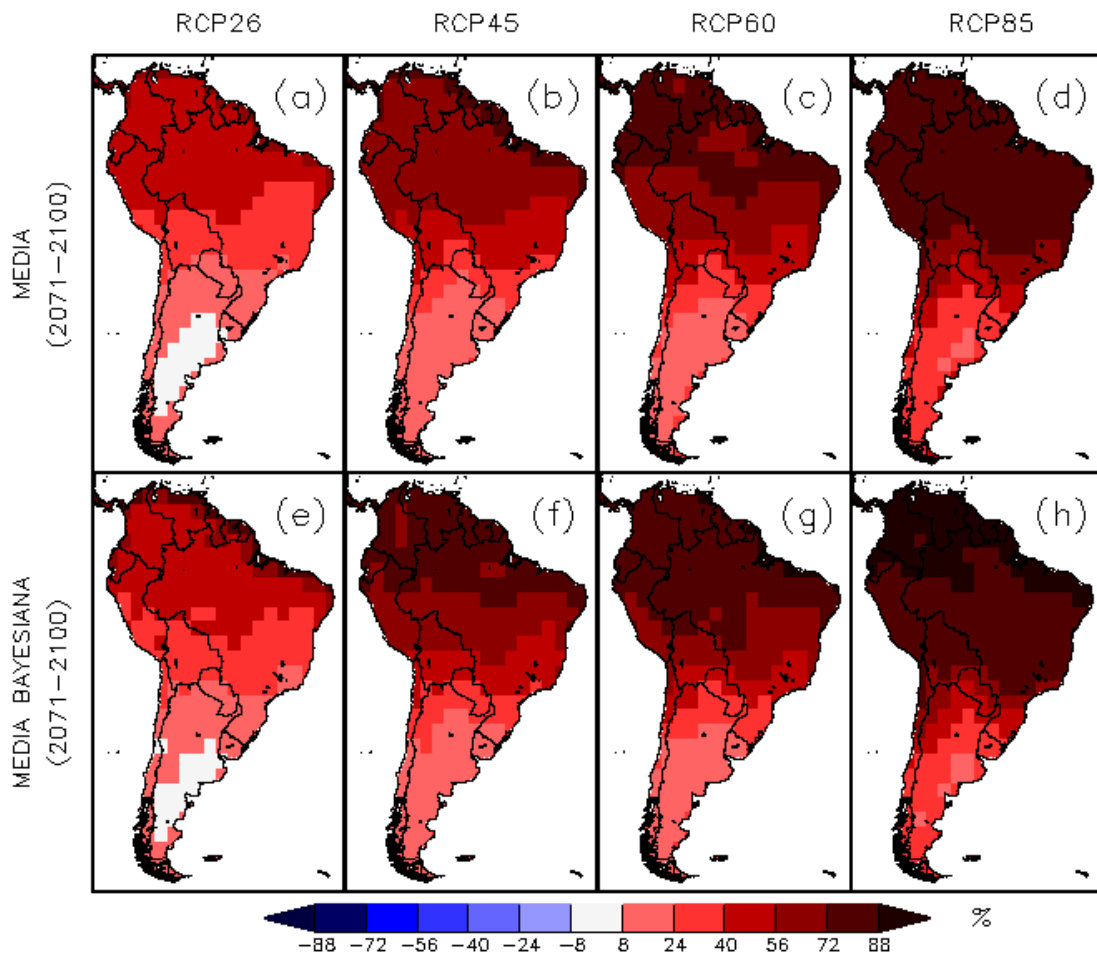


Figura 22 – Mudança anual do índice extremo de Noites Muito Quentes (TN90p) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em % e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.

A média dos modelos apontam uma queda representativa no número de dias frios (TX10p – Figura 23) em todo território, o que é indicado pelos valores negativos de porcentagem da diferença entre os períodos 2071-2100 (clima futuro) e 1961-1990 (clima presente). Semelhante aos resultados encontrados para TN10p, os valores das mudanças

negativas mostram-se maiores nos subtropicais e menores nas latitudes mais altas, havendo também uma expansão da área com valores máximos de mudança em direção ao sul do continente nos diferentes cenários de emissão. Esse comportamento deve-se ao aquecimento nas regiões tropicais e subtropicais, o qual limita a quantidade de dias muito frios durante o ano, sendo esse índice inversamente proporcional ao aumento da forçante radiativa. Para a média utilizando o método bayesiano, não houve variação no comportamento desse índice em comparação com a média simples dos MCGs, observando-se apenas para dois pontos específicos no Chile um anômalo aumento de TX10p no cenário RCP2.6.

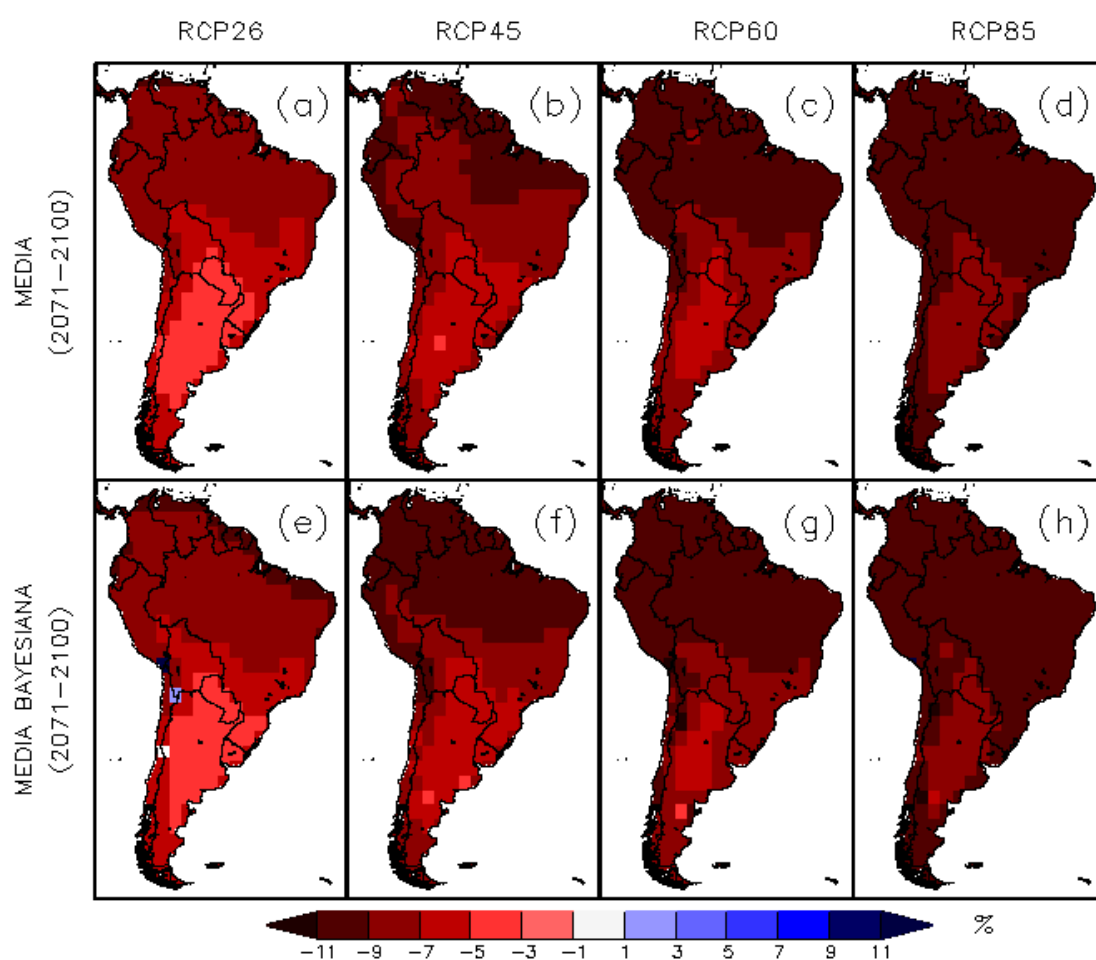


Figura 23 – Mudança anual do índice extremo de Dias Muito Frios (TX10p) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em % e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.

Finalmente, para o índice dias muito quentes (TX90p - Figura 24), nota-se que a média dos modelos aponta para um considerável aumento e sua distribuição também se dá em faixas latitudinais, assim como observado para TN90p. Os valores das mudanças aumentam a medida

em que a forçante radiativa cresce, abrangendo valores entre 56% e 72% na região subtropical, chegando em 72% a 88% de aumento de TX90p no litoral sudeste da América do Sul para o cenário RCP8.5 (Figura 24d). Quando comparado com a média utilizando Inferência Bayesiana, os resultados são coincidentes com a média simples dos modelos, aumentando a magnitude da mudança em $\approx 16\%$ na região Amazônica e no Nordeste do Brasil no cenário mais pessimista (Figura 24h).

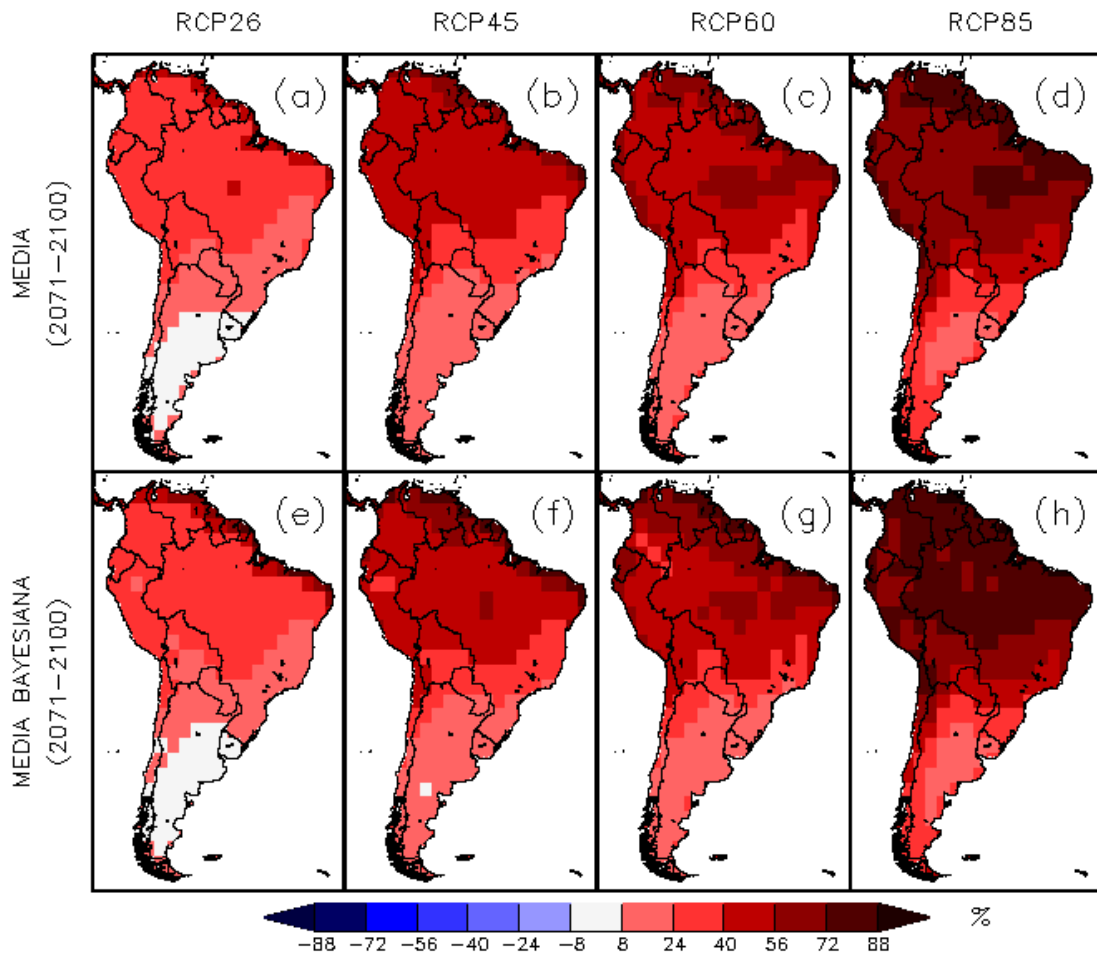


Figura 24 – Mudança anual do índice extremo de Dias Muito Quentes (TX90p) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a, e), RCP4.5 (b, f), RCP6.0 (c, g), e RCP8.5 (d, h), provenientes da média do conjunto CMIP5 (superior) e a média aplicando-se a Inferência Bayesiana (inferior). As unidades estão em % e as mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.

Segundo o relatório do IPCC (2014a) e Torres (2014), a probabilidade da temperatura exceder 2°C nos cenários mais pessimistas chega a 90% na América do Sul, sendo 50% provável que esse aumento supere os 4°C na faixa equatorial (entre 10°N e 25°S). O aquecimento da atmosfera torna a amplitude térmica menor durante o dia, diminuindo os episódios frios e aumentando os quentes. Assim, é consistente observar uma tendência de

diminuição das noites e dias muito frios (TN10p e TX10p, respectivamente) e aumento das noites e dias muito quentes (TN90p e TX90p, respectivamente) para toda a América do Sul, concordando com estudos anteriores, tais como Marengo et al. (2009), IPCC (2012), Natividade (2015), Natividade, Garcia, Torres (2017). Contudo, essa mudança é mais pronunciada e abrange área ligeiramente maior para TN10p e TN90p; ou seja, as projeções indicam que, para final do século (2071-2100), o número de noites muito frias (TN10p) será menor que os dias muito frios (TX10p) na região subtropical, assim como a frequência de noites muito quentes (TN90p) se apresentará superior aos dias muito quentes (TX90p), principalmente na região equatorial. Para esses índices, a utilização do método de Inferência Bayesiana não apresentou variação significativa nas projeções de mudanças dos extremos, apenas indicando um pequeno aumento em relação à média simples dos MCGs para a região equatorial, o que difere de Torres (2014), o qual observou diminuição da mudança de projeções de temperatura para a América do Sul quando utilizado esse método bayesiano. Assim, no caso dos índices de temperatura, a utilização da média simples dos MCGs mostrou-se mais vantajosa nas projeções em relação a média utilização a Inferência Bayesiana.

Posteriormente, a fim de analisar as incertezas entre os cenários forçantes e os modelos, criou-se as PDFs de mudanças anuais dos índices extremos de precipitação e temperatura para o período 2071-2100 nos diversos cenários RCPs e para as quatro sub-regiões de estudo, obtidas aplicando-se o método de Inferência Bayesiana ao conjunto CMIP5. As distribuições das PDFs geradas por esse método são caracterizadas por serem concentradas para as regiões em que os modelos apresentam desempenho satisfatório com relação às simulações e cujas projeções são coerentes com os outros modelos do conjunto. Assim, curvas unimodais são estimadas em regiões onde há um grande consenso entre os MCGs, ou onde os modelos com valores atípicos têm pesos menores atribuídos a eles, devido a apresentarem grandes vieses. Em contraste, regiões nas quais os modelos projetam valores discrepantes dos índices, e que não são descontadas com base nos seus vieses, são representadas por curvas multimodais. As linhas representam os cenários forçantes RCP2.6 (azul marinho), RCP4.5 (azul ciano), RCP6.0 (laranja) e RCP8.5 (vermelho).

Pode-se observar que as distribuições de PDFs referentes às mudanças projetadas dos índices extremos de precipitação (Figura 25) em cada uma das quatro sub-regiões de estudo são predominantemente multimodais e, no geral, as larguras das PDFs apresentam-se grandes, o que implica em intervalos de incerteza maiores sobre esses índices e regiões. Também, não há uma clara relação entre a intensificação da forçante radiativa e um aumento ou decréscimo das

mudanças nos índices de precipitação nas sub-regiões avaliadas, assim como observado por Torres (2014) referente à precipitação média.

Especificamente, as PDFs indicam um aumento de CDD para todas as regiões, sendo o intervalo de mudanças 0 - 20 dias, exceto para WAMZ (Figura 25e), onde as distribuições são unimodais e variam em ≈ 10 dias. Para R10mm, as mudanças indicam uma diminuição de ≈ 10 dias no EAMZ e NEB, e as distribuições para WAMZ e LPB estão em torno do eixo zero, indicando mudanças tanto positivas quanto negativas em ambas as regiões. As projeções indicam um aumento generalizado de R95p, variando de 0 a 190 mm nas regiões EAMZ e WAMZ, e de 0 a 100 mm no LPB, exceto para NEB (Figura 25k), onde pode ocorrer diminuição de dias muito úmidos nos cenários mais otimistas e aumento de precipitação em até 50 mm nos cenários pessimistas. Já para Rx5Day, as mudanças mostram-se predominantemente positivas no WAMZ, LPB e cenário RCP8.5 no EAMZ, alcançando total de 25 mm de precipitação. Para os cenários RCP2.6, RCP4.5 e RCP6.0 na região EAMZ (Figura 25d), os valores estão em torno do eixo de mudança nula, enquanto para o NEB há uma projeção de diminuição de Rx5Day em ≈ 10 mm.

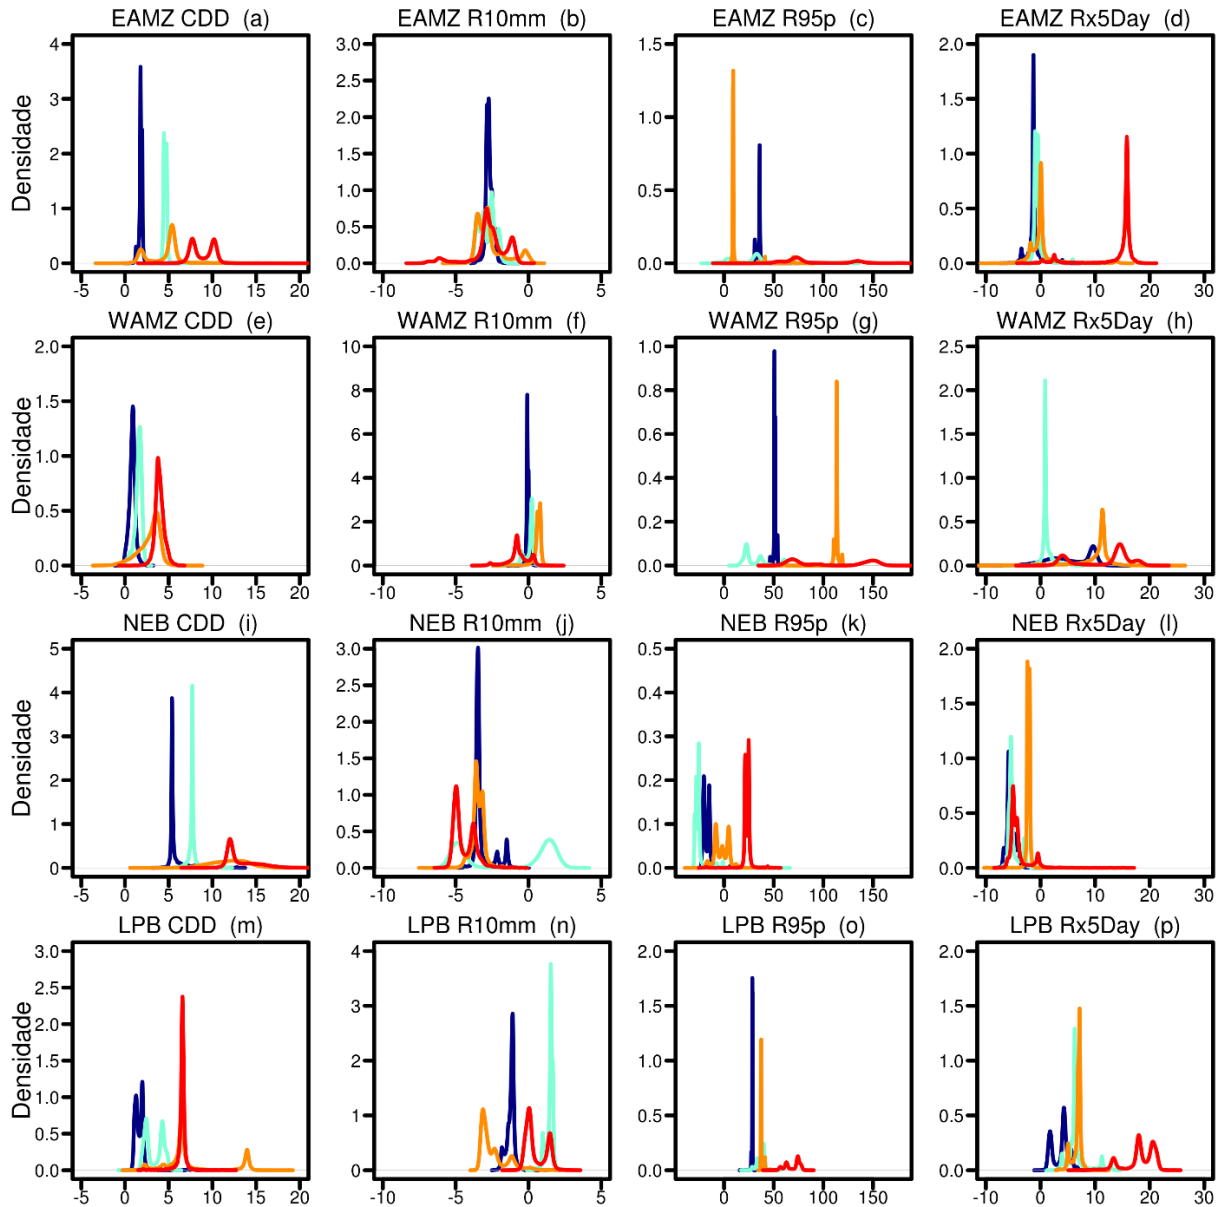


Figura 25 – Funções Densidade de Probabilidade para as mudanças anuais dos índices extremos de precipitação (CDD, R10mm, R95p, Rx5Day) para o final do século XXI nas regiões EAMZ (*a - d*), WAMZ (*e - h*), NEB (*i - l*) e LPB (*m - p*). As PDFs foram obtidas através do método de Inferência Bayesiana aplicado ao conjunto de modelos do CMIP5 e as linhas referem-se aos cenários RCP2.6 (azul-marinho), RCP4.5 (azul ciano), RCP6.0 (laranja) e RCP8.5 (vermelho). As unidades de medida de CDD e R10mm é em dias do ano, enquanto R95p e RxDay são dados em milímetros (mm) por ano.

As distribuições de PDFs para os índices extremos climáticos de temperatura (Figura 26) são unanimemente unimodais e concentradas no entorno de um valor específico, no qual a largura da distribuição não é muito extensa, em sua maioria. Assim, curvas mais estreitas caracterizam boa concordância entre os modelos quanto às projeções de mudanças do índice, aumentando o intervalo de incertezas na região com a largura da curva. Também, observou-se

uma relação direta entre a intensificação da forçante climática e a redução ou aumento do índice de temperatura nas quatro sub-regiões.

Individualmente, as projeções mostram uma diminuição de $\approx 10\%$ em TN10p, não excedendo 1% a largura das distribuições para os cenários RCP4.5, RCP6.0 e RCP8.5, as quais praticamente se sobrepuseram umas as outras nas regiões EAMZ, WAMZ e NEB. Exceção pode ser vista em LPB (Figura 26m), onde a distribuição das mudanças de acordo com os cenários mostra-se mais espaçada. Para TN90p, as mudanças indicam um aumento de 20% a 100% para EAMZ, WAMZ e NEB, com distribuições muito semelhantes entre essas regiões; e para LPB, as projeções indicam ampliação de 1% a 80% na frequência de noites muito quentes, levando-se em consideração os diferentes cenários. Já o índice TX10p possui tendência de diminuição concentrada entre 9% e 11% para toda a região Amazônica e NEB, exceto no cenário RCP2.6 ($\approx 4\%$ a 11%); para LPB, esse intervalo é um pouco menor, variando entre 4% e 10%. Por fim, as projeções mostram aumento de TX90p para todas as sub-regiões, sendo entre 20% e 90% para EAMZ, WAMZ e NEB, e entre 1% e 60% na LPB, além da largura das curvas permanecerem em torno de 20%. Assim, analisando-se a largura das curvas em todos os índices extremos de temperatura, no geral, a correlação entre os modelos mostrou-se superior nas distribuições para o cenário RCP8.5 (curvas mais estreitas), enquanto para RCP2.6 e RCP4.5, a concordância entre os modelos quanto às mudanças apresentou-se um pouco menor (curvas mais largas).

Tebaldi et al. (2005), quando apresentou o método de Inferência Bayesiana, analisou projeções ao redor de todo o globo, identificando distribuições estreitas no sul da América do Sul, o que demonstra relativa certeza nas projeções de aquecimento para essa região. Adicionalmente, Torres (2014), em seu estudo sobre incertezas nas projeções médias de temperatura e precipitação, observou também predomínio de curvas multimodais e maiores incertezas dos modelos para precipitação, e predomínio de curvas unimodais, com larguras de distribuição estreitas, mostrando boa concordância entre os modelos para as mesmas 4 sub-regiões em questão. Dessa maneira, além dos valores médios de temperatura, os extremos também seguem os mesmos padrões, o que já era esperado, porém não havia sido mostrado ainda.

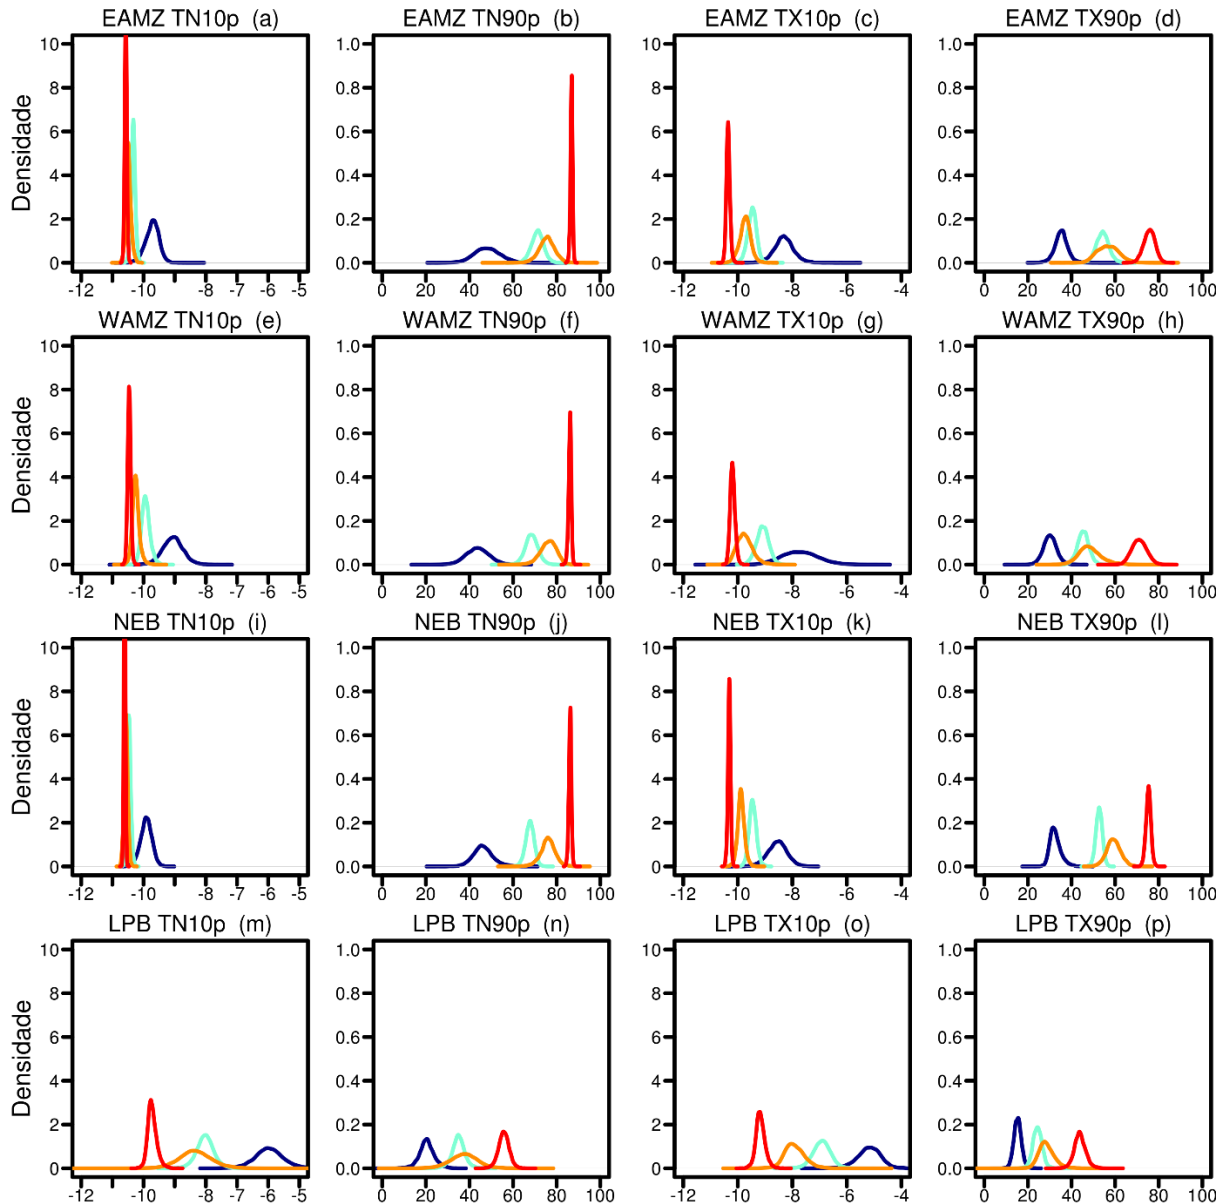


Figura 26 – Funções Densidade de Probabilidade (PDF) para as mudanças anuais dos índices extremos de temperatura (TN10p, TN90p, TX10p, TX90p) para o final do século XXI nas regiões EAMZ (a - d), WAMZ (e - h), NEB (i - l) e LPB (m - p). As PDFs foram obtidas através do método de Inferência Bayesiana aplicado ao conjunto de modelos do CMIP5 e as linhas referem-se aos cenários RCP2.6 (azul-marinho), RCP4.5 (azul ciano), RCP6.0 (laranja) e RCP8.5 (vermelho). A unidade de medida desses índices é dada em porcentagem (%) de dias do ano.

As distribuições posteriores dos parâmetros de precisão (λ_i) de cada modelo i relativos aos índices extremos climáticos de precipitação e temperatura, correspondentes ao cenário RCP4.5, podem ser vistas nas Figuras 27 e 28. Esse λ_i é entendido como um parâmetro de desempenho ou credibilidade de um modelo para uma determinada região, ou seja, modelos com menores pesos atribuídos à média final são representados por valores baixos de λ_i e modelos com maiores pesos atribuídos podem ser identificados através de altas mediadas de λ_i .

Assim, os λ_i 's foram ranqueados de forma decrescente, de acordo com o valor de suas medianas. Os 3 modelos com as maiores medianas dos parâmetros de precisão (maior desempenho) e os 3 com os menores λ_i (maiores incertezas) para cada uma das 4 sub-regiões foram organizados em Tabelas, para sua melhor identificação. Estes *rankings* estão dispostos nas Tabelas 3 e 4, as quais correspondem aos índices extremos de precipitação e temperatura, respectivamente. Os nomes de modelos em vermelho identificam os de menor área do pixel, em preto, os de áreas intermediárias, e em azul, os de maior área do pixel dentre os MCGs avaliados no cenário RCP4.5. Este cenário foi escolhido por se tratar de uma forçante intermediária, onde seria possível verificar o comportamento dos modelos em uma condição climática com maior probabilidade de ocorrência.

Para os índices extremos de precipitação (Figura 27, Tabela 3), a distribuição dos parâmetros de precisão mostra que, em relação à CDD, os modelos com melhores desempenhos foram CNRM-CM5 e BCC-CSM1-1, principalmente para EAMZ e NEB; já os piores foram IPSL-CM5A-LR, CSIRO-Mk3-6-0 e FGOALS-s2. Para R10mm, o melhor modelo foi MIROC-E-C (exceto em LPB, onde foi intermediário), e o pior foi INMCM4 (exceto em WAMZ, onde foi sétimo melhor). Para R95p, os parâmetros indicam que o modelo BCC-CSM1-1 é um dos mais deficientes em simular a climatologia observada nas regiões Amazônicas e NEB, porém, quando analisada LPB, esse modelo tem desempenho intermediário. Já os melhores a simular esse índice são NorESM1-M e GFDL-ESM2G. Por fim, para Rx5Day, o modelo INMCM4 possui os maiores parâmetros no EAMZ e WAMZ, e o modelo NorESM1 tem melhor desempenho nas regiões NEB e LPB. Em contrapartida, o modelo MRI-CGCM3 apresentou-se entre os três mais deficientes em todas as regiões, exceto LPB.

Analisando-se os índices extremos de temperatura (Figura 28, Tabela 4), observa-se que o *ranking* dos parâmetros λ_i possui menos variação, não sendo tão discrepantes os valores dos modelos com melhor desempenho. Para TN10p, nota-se INMCM4 e FGOALS-g2 como os modelos mais deficientes, em contraste com MPI-ESM-LR, o qual apresentou-se com melhor desempenho em todas as regiões, exceto LPB (modelo intermediário). Para TN90p, o modelo CanESM2 foi o de maior desempenho na região Amazônica e Nordeste do Brasil, sendo um dos 6 melhores também no LPB, além de CCSM4, o qual está entre os 3 melhores em todas as sub-regiões (exceto NEB). O índice TX10p teve seus valores mais baixos do parâmetro de precisão apresentados pelos modelos FGOALS-g2 e FGOALS-s2, em todas as sub-regiões. Já

para TX90p, GFDL-2G é um dos mais eficientes em simular a climatologia observada no EAMZ e WAMZ, enquanto o modelo EC-EARTH representa melhor para NEB e LPB.

Assim, pode-se notar que cada MCGs é ponderado de maneira diferente para as sub-regiões e índices extremos, evidenciando diferentes capacidades em simular a climatologia observada na área e graus de concordâncias entre os modelos para as mudanças nos índices. Essas diferenças entre os modelos podem estar relacionadas às suas características, como, por exemplo, representação dos processos físicos e químicos, condições de entrada, resolução espacial, as quais são distintas para cada modelo, uma vez que são desenvolvidos por instituições diversas pelo mundo (SILVEIRA et al., 2013). Também, não pode-se observar uma relação direta entre a área do pixel (resolução espacial) e a maior ou menor credibilidade dos modelos em projetar os índices de ambas as variáveis.

De maneira geral, como pode ser visto mais claramente na Tabela 4, o modelo de maior credibilidade foi MPI-ESM-MR e o mais deficiente foi FGOALS-g2 para os índices extremos de temperatura. No caso dos índices de precipitação (Tabela 3), CanESM2 apresentou o menor desempenho entre os 28 MCGs analisados para o cenário 4.5, e não houve um modelo o qual pudesse ser associado alta credibilidade de projeções nas 4 sub-regiões. Ressalta-se que não se deve atribuir a baixa eficiência das projeções exclusivamente às configurações dos modelos, uma vez que pode também estar associada à interpolação utilizada (aumento e diminuição da resolução espacial dos modelos), aos dados de reanálises (carregam grandes incertezas e não têm a precipitação como dado de entrada do modelo que as geram) e ao cálculo dos índices extremos (complexidade estatística).

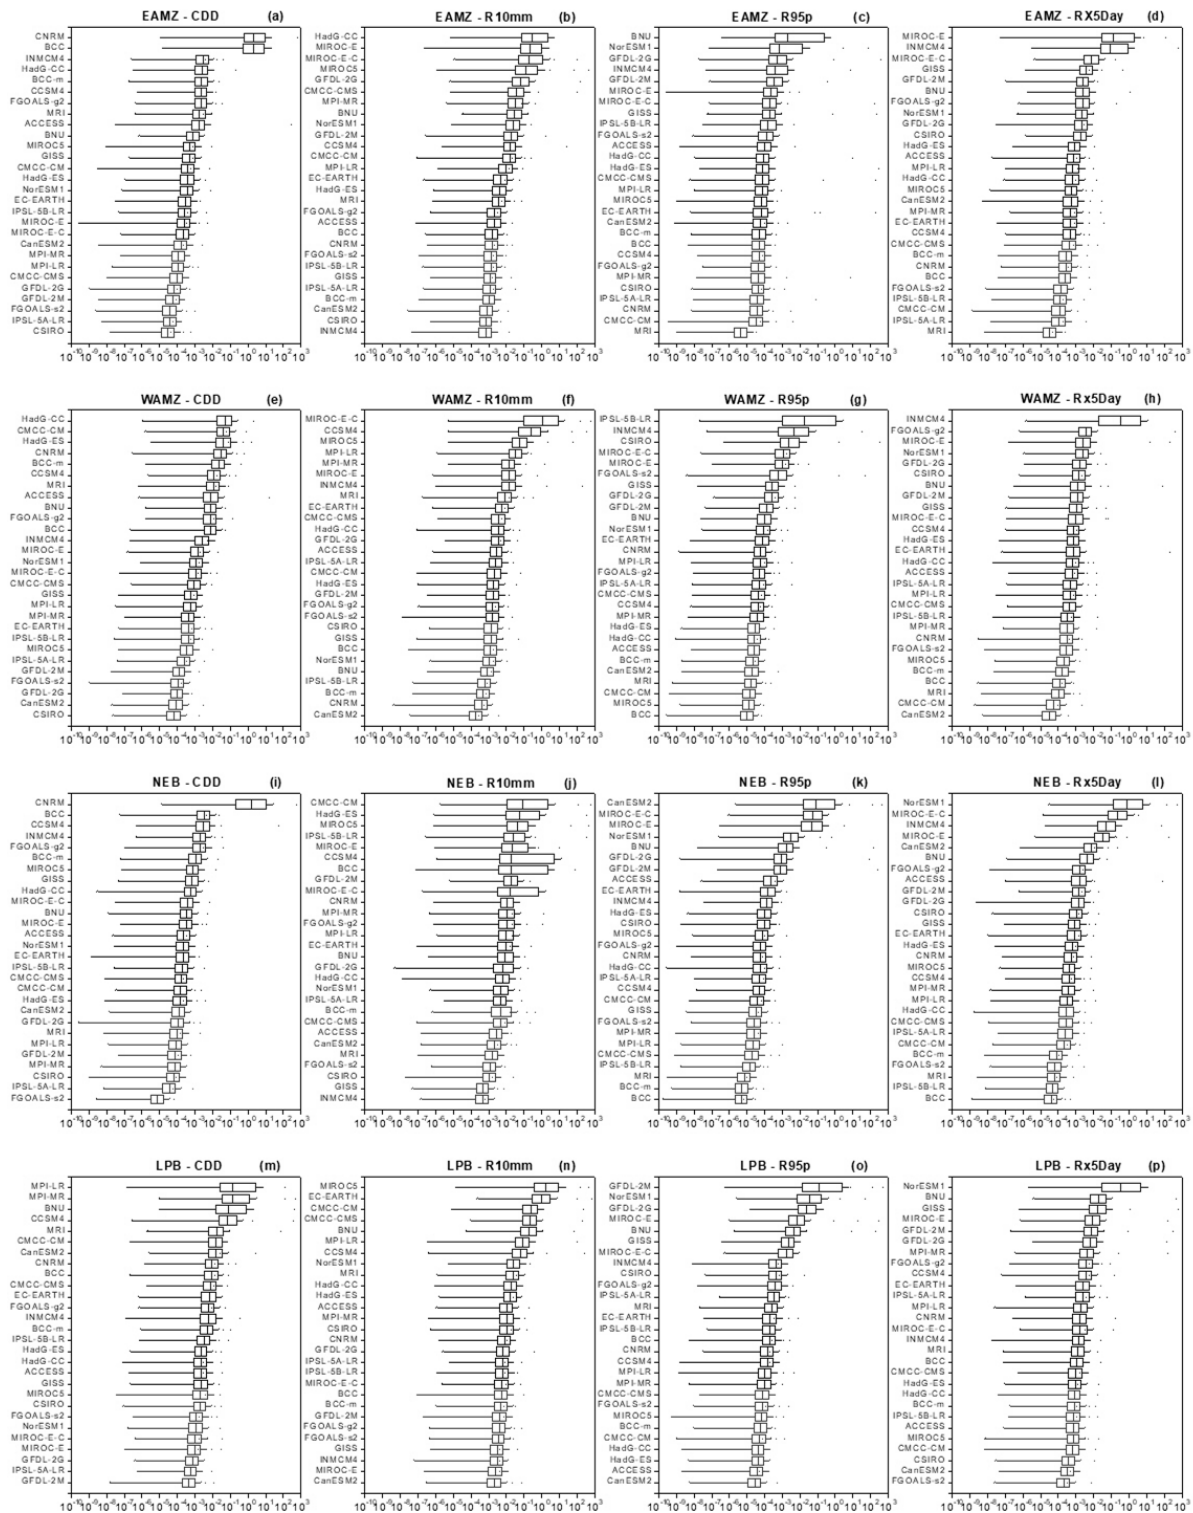


Figura 27 – Distribuição posterior dos parâmetros de precisão específicos de cada MCG (λ_i) pertencentes ao CMIP5 e relativos aos índices extremos de precipitação CDD, R10mm, R95p e Rx5Day referentes ao cenário RCP 4.5, para cada uma das quatro sub-regiões de estudo analisadas, ordenadas por sua mediana. As caixas azuis indicam os dez primeiros MCGs, as pretas os nove intermediários, e as vermelhas os nove últimos.

Tabela 3 – Modelos com as maiores e menores medianas dos parâmetros de precisão (λ_i) para os índices extremos de precipitação CDD, R10mm, R95p e Rx5Day em cada sub-região. O valor da mediana de λ_i é apresentado entre parênteses. Em vermelho são representados os modelos com menores áreas do pixel, em preto, com as áreas intermediárias, e em azul, os modelos com maiores áreas.

	λ_i	EAMZ	WAMZ	NEB	LPB
CDD	MAIOR	CNRM-CM5 (2,1497)	HadGEM2-CC (0,0510)	CNRM-CM5 (1,5808)	MPI-ESM-LR (0,1308)
		BCC-CSM1-1 (1,9404)	CMCC-CM (0,0409)	BCC-CSM1-1 (0,0033)	MPI-ESM-MR (0,1291)
		INMCM4 (0,0028)	HadGEM2-ES (0,0401)	CCSM4 (0,0029)	BNU-ESM (0,0745)
	MENOR	FGOALS-s2 (3,85.E-5)	GFDL-ESM2G (0,0001)	CSIRO-Mk3-6-0 (6,46.E-5)	GFDL-ESM2G (0,0008)
		IPSL-CM5A-LR (3,76.E-5)	CanESM2 (8,58.E-5)	IPSL-CM5A-LR (3,67.E-5)	IPSL-CM5A-LR (0,0006)
		CSIRO-Mk3-6-0 (3,06.E-5)	CSIRO-Mk3-6-0 (6,56.E-5)	FGOALS-s2 (7,54.E-6)	GFDL-ESM2M (0,0005)
R10mm	MAIOR	HadGEM2-CC (0,2686)	MIROC-ESM-CHEM (1,0733)	CMCC-CM (0,0823)	MIROC5 (1,7588)
		MIROC-ESM (0,2089)	CCSM4 (0,2385)	HadGEM2-ES (0,0525)	EC-EARTH (0,9144)
		MIROC-ESM-CHEM (0,1795)	MIROC5 (0,0565)	MIROC5 (0,0396)	CMCC-CM (0,2327)
	MENOR	CanESM2 (0,0008)	BCC-CSM1-1-m (0,0005)	CSIRO-Mk3-6-0 (0,0011)	INMCM4 (0,0031)
		CSIRO-Mk3-6-0 (0,0007)	CNRM-CM5 (0,0004)	GISS-E2-R (0,0005)	MIROC-ESM (0,0025)
		INMCM4 (0,0006)	CanESM2 (0,0002)	INMCM4 (0,0004)	CanESM2 (0,0022)
R95p	MAIOR	BNU-ESM (0,0019)	IPSL-CM5B-LR (0,0192)	CanESM2 (0,0812)	GFDL-ESM2M (0,1185)
		NorESM1-M (0,0007)	INMCM4 (0,0044)	MIROC-ESM-CHEM (0,0542)	NorESM1-M (0,0361)
		GFDL-ESM2G (0,0005)	CSIRO-Mk3-6-0 (0,0024)	MIROC-ESM (0,0449)	GFDL-ESM2G (0,0244)
	MENOR	CNRM-CM5 (3,82.E-5)	CMCC-CM (1,4.E-5)	MRI-CGCM3 (7,41.E-6)	HadGEM2-ES (4,44.E-5)
		CMCC-CM (3,19.E-5)	MIROC5 (1,31.E-5)	BCC-CSM1-1-m (5,36.E-6)	ACCESS1-0 (3,67.E-5)
		MRI-CGCM3 (4,61.E-6)	BCC-CSM1-1 (1,06.E-5)	BCC-CSM1-1 (5,01.E-6)	CanESM2 (2,85.E-5)
Rx5Day	MAIOR	MIROC-ESM (0,1238)	INMCM4 (0,3223)	NorESM1-M (0,7427)	NorESM1-M (0,3249)
		INMCM4 (0,0923)	FGOALS-g2 (0,0036)	MIROC-ESM-CHEM (0,2381)	BNU-ESM (0,0198)
		MIROC-ESM-CHEM (0,0079)	MIROC-ESM (0,0026)	INMCM4 (0,0527)	GISS-E2-R (0,169)
	MENOR	CMCC-CM (0,00012)	MRI-CGCM3 (0,0001)	MRI-CGCM3 (5,96.E-5)	CSIRO-Mk3-6-0 (0,0004)
		IPSL-CM5A-LR (0,00011)	CMCC-CM (5,68.E-5)	IPSL-CM5B-LR (5,02.E-5)	CanESM2 (0,0003)
		MRI-CGCM3 (3,33.E-5)	CanESM2 (3,0.E-5)	BCC-CSM1-1 (3,94.E-5)	FGOALS-s2 (0,0002)

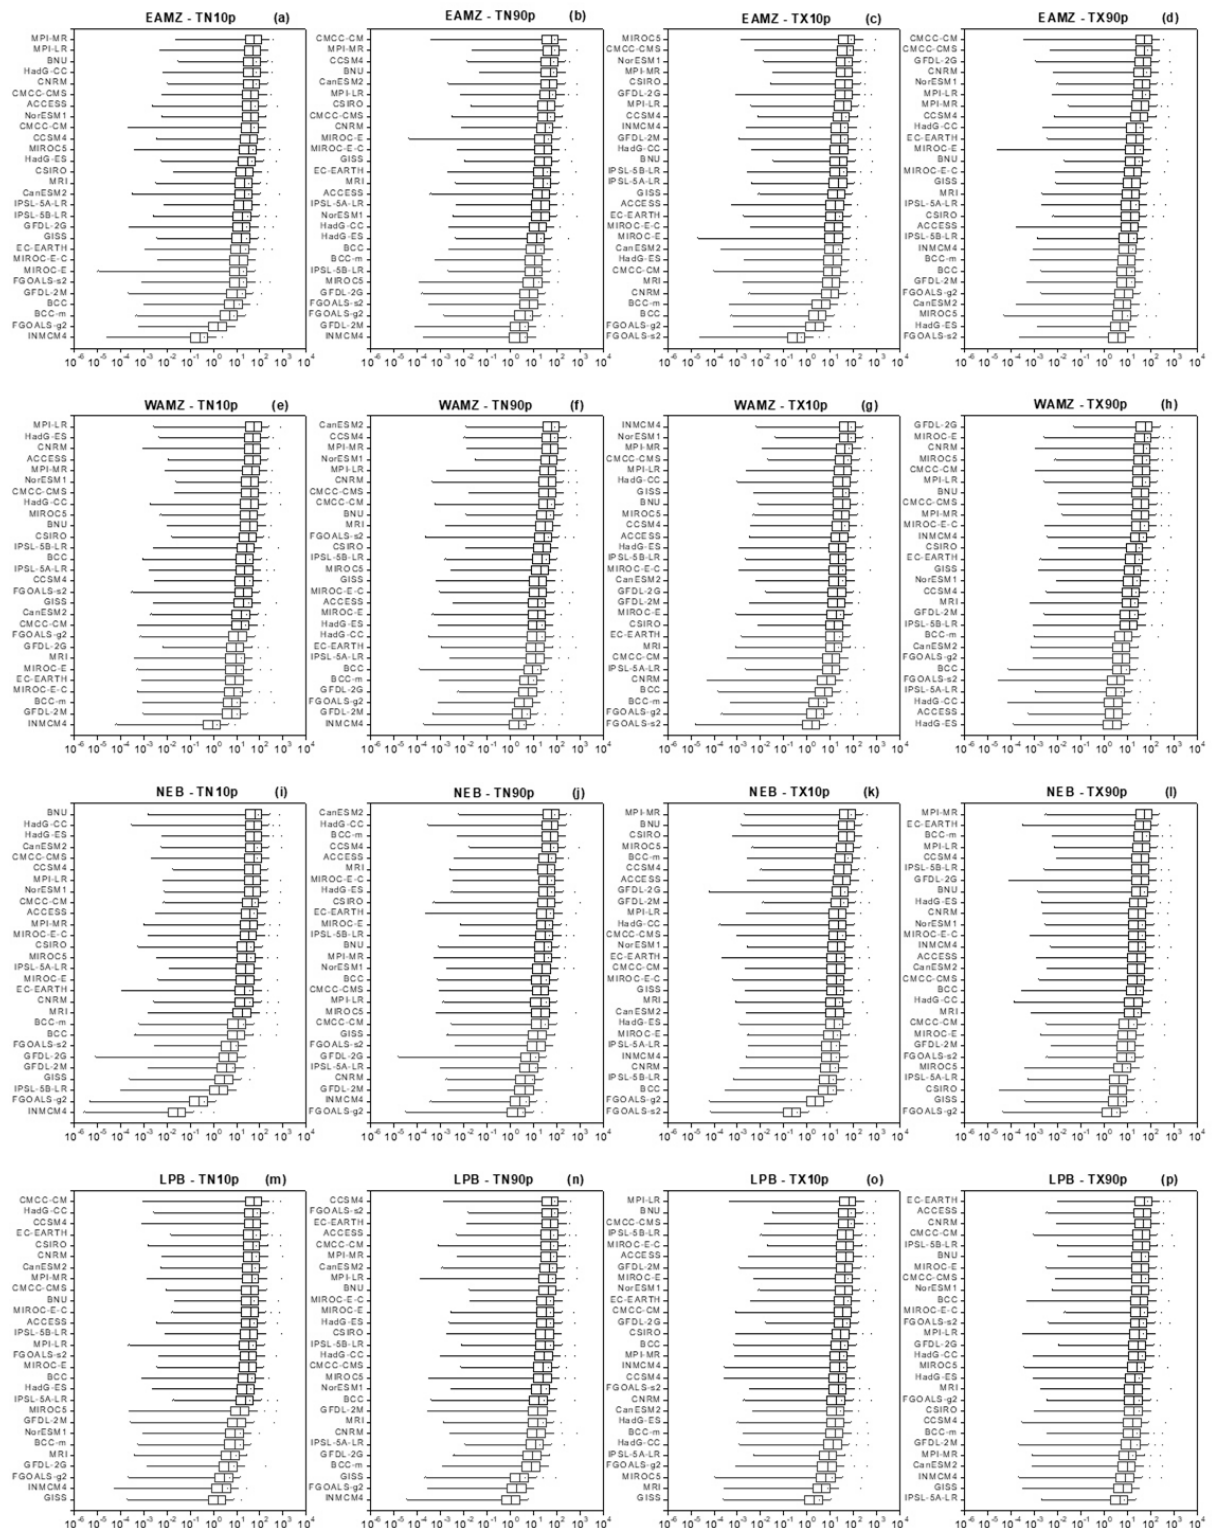


Figura 28 – Distribuição posterior dos parâmetros de precisão específicos de cada MCG (λ_i) pertencentes ao CMP5 e relativos aos índices extremos de temperatura TN10p, TN90p, TX10p e TX90p referentes ao cenário RCP 4.5, para cada uma das quatro sub-regiões de estudo analisadas, ordenados por sua mediana. As caixas azuis indicam os dez primeiros MCGs, as pretas os nove intermediários, e as vermelhas os nove últimos.

Tabela 4 – Modelos com as maiores e menores medianas dos parâmetros de precisão (λ_i) para os índices extremos de temperatura TN10p, TN90p, TX10p e TX90p em cada sub-região. O valor da mediana de λ_i é apresentado entre parênteses. Em vermelho são representados os modelos com menores áreas do pixel, em preto, com as áreas intermediárias, e em azul, os modelos com maiores áreas.

	λ_i	EAMZ	WAMZ	NEB	LPB
TN10p	MAIOR	MPI-ESM-MR (57,8598)	MPI-ESM-LR (58,2267)	BNU-ESM (62,2821)	CMCC-CM (56,4779)
		MPI-ESM-LR (51,4551)	HadGEM2-ES (53,2089)	HadGEM2-CC (57,5159)	HadGEM2-CC (53,1355)
		BNU-ESM (48,5293)	CNRM-CM5 (51,9578)	HadGEM2-ES (57,4515)	CCSM4 (52,4509)
	MENOR	BCC-CSM1-1-m (4,9117)	BCC-CSM1-1-m (6,4898)	IPSL-CM5B-LR (1,8557)	FGOALS-g2 (2,9742)
		FGOALS-g2 (1,6318)	GFDL-ESM2M (6,4704)	FGOALS-g2 (0,2468)	INMCM4 (2,3424)
		INMCM4 (0,2558)	INMCM4 (0,9145)	INMCM4 (0,0286)	GISS-E2-R (1,5529)
TN90p	MAIOR	CMCC-CM (58,7697)	CanESM2 (59,7597)	CanESM2 (59,7672)	CCSM4 (57,3085)
		MPI-ESM-MR (57,8918)	CCSM4 (56,1479)	HadGEM2-CC (56,7644)	FGOALS-s2 (57,0803)
		CCSM4 (52,5999)	MPI-ESM-MR (55,7581)	BCC-CSM1-1-m (54,5694)	EC-EARTH (56,0801)
	MENOR	FGOALS-g2 (4,0997)	FGOALS-g2 (3,7384)	GFDL-ESM2M (4,2824)	GISS-E2-R (2,5534)
		GFDL-ESM2M (2,5073)	GFDL-ESM2M (3,2979)	INMCM4 (2,6445)	FGOALS-g2 (1,9251)
		INMCM4 (2,4913)	INMCM4 (2,2837)	FGOALS-g2 (1,9829)	INMCM4 (1,1353)
TX10p	MAIOR	MIROC5 (56,4057)	INMCM4 (58,5486)	MPI-ESM-MR (57,1401)	MPI-ESM-LR (61,1873)
		CMCC-CMS (50,1585)	NorESM1-M (57,8042)	BNU-ESM (54,6681)	BNU-ESM (57,4231)
		NorESM1-M (43,8621)	MPI-ESM-MR (44,3663)	CSIRO-Mk3-6-0 (52,9655)	CMCC-CMS (55,7656)
	MENOR	BCC-CSM1-1 (2,9787)	BCC-CSM1-1-m (3,1193)	BCC-CSM1-1 (8,1192)	MIROC5 (6,6641)
		FGOALS-g2 (2,2703)	FGOALS-g2 (2,4533)	FGOALS-g2 (2,3332)	MRI-CGCM3 (4,4156)
		FGOALS-s2 (0,3625)	FGOALS-s2 (1,5802)	FGOALS-s2 (0,2332)	GISS-E2-R (2,0820)
TX90p	MAIOR	CMCC-CM (57,3299)	GFDL-ESM2G (58,2922)	MPI-ESM-MR (55,1006)	EC-EARTH (54,6397)
		CMCC-CMS (54,5294)	MIROC-ESM (53,1545)	EC-EARTH (49,4947)	ACCESS1-0 (50,3246)
		GFDL-ESM2G (50,6199)	CNRM-CM5 (46,9275)	BCC-CSM1-1-m (46,2744)	CNRM-CM5 (49,9449)
	MENOR	MIROC5 (6,2899)	HadGEM2-CC (2,7216)	CSIRO-Mk3-6-0 (4,1294)	INMCM4 (8,7235)
		HadGEM2-ES (4,9767)	ACCESS1-0 (2,7152)	GISS-E2-R (3,9143)	GISS-E2-R (6,9338)
		FGOALS-s2 (4,0301)	HadGEM2-ES (2,3465)	FGOALS-g2 (2,1487)	IPSL-CM5A-LR (4,7881)

5 CONCLUSÕES

As projeções climáticas indicam considerável mudança no clima da América do Sul para o século XXI. Devido às deficiências sociais, econômicas e ambientais, essa região encontra-se despreparada para enfrentar possíveis intensificações de eventos climáticos extremos. Como são poucos os estudos que analisam as projeções desses índices especificamente para o continente sul-americano utilizando amplas informações, e nenhum aborda as incertezas envolvidas, um maior conhecimento acerca desses eventos são de suma importância para a sociedade.

Assim, o estudo teve por objetivo verificar a consistência dos índices de extremos climáticos para as variáveis precipitação e temperatura, por meio da comparação entre os dados observados e as simulações dos MCGs em seus diferentes cenários de emissões, além de obter estatisticamente a acurácia dos modelos em simular tais índices para a América do Sul. Também, analisar as projeções de mudanças desses índices extremos e suas incertezas associadas, identificando a confiabilidade dos modelos em cada região.

Dessa maneira, os resultados mostram uma subestimativa de CDD para a região Andina e uma superestimativa para o norte da América do Sul. Para o índice R10mm, as subestimativas ocorrem no EAMZ e WAMZ, já as superestimativas são encontradas no Equador, Peru e norte da Bolívia. Já os índices R95p e Rx5Day possuem comportamento semelhante, identificando que os modelos simulam valores maiores que os observados para todo o continente. Quando analisado os índices extremos de temperatura, nota-se uma superestimativa das médias para todo o continente, sendo para TN10p, TN90p e TX10p mais pronunciada na região equatorial; já para TX90p, os vieses não superam 0,4% sobre toda a América do Sul.

Adicionalmente, a fim de analisar a acurácia dos modelos em simular as observações em cada uma das 4 sub-regiões, observou-se nos Diagramas de Taylor que, para CDD, as correlações são majoritariamente negativas; para R10mm e R95p, as correlações estão concentradas no eixo de desvio nulo e são tanto positivas quanto negativas; para Rx5Day, os modelos estão mais dispersos entre si, com ambas as correlações. Mesmo os que apresentaram correlações positivas podem ser considerados deficientes na simulação desses 4 índices de precipitação, uma vez que muitos modelos possuem EQM grandes e desvios padrão afastados das observações. Já, os índices TN10p e TN90p apresentaram alta capacidade de simulação para todas as regiões; as melhores representações de TX10p foram identificadas no EAMZ e

NEB; e para TX90p, o desempenho dos modelos apresentou-se superior no NEB e LPB. Assim, os índices extremos de temperatura apresentaram melhor desempenho em relação aos de precipitação, sendo TN90p o índice de maior acurácia dentre todos para as 4 sub-regiões. Ressalta-se que não foi possível observar uma relação direta entre a acurácia dos modelos e sua resolução espacial em nenhum dos 8 índices.

As simulações e observações em cada sub-região, representadas através do Índice de Concordância de Willmott, apresentou maior convergência nos índices de temperatura em relação aos de precipitação, assim como nos Diagramas de Taylor. Destaque positivo (maiores concordâncias, entre 0,5 e 0,6) pode ser observado para noites muito frias (TN10p) e noites muito quentes (TN90p), enquanto os menores valores de concordância ($< 0,1$) foram encontrados para máximo de precipitação em 5 dias (Rx5Day) e dias secos consecutivos (CDD).

Através da análise conjunta do viés, do Diagrama de Taylor e do Índice de concordância de Willmott, fica evidente que as observações são melhores representadas pelos MCGs para os índices extremos de temperatura em relação aos de precipitação. Isso pode ser decorrente dos dados de reanálise, os quais podem não representar fidedignamente as observações e possuir maiores incertezas, principalmente para precipitação. Também, a modelagem de índices extremos possui qualidade inferior às variáveis como temperatura, precipitação, umidade, uma vez que são derivados destas por meio de estatísticas. Além disso, os MCGs podem estar mal configurados para representar as propriedades físicas, químicas e biológicas as quais o Sistema Climático possui.

Posteriormente, as projeções de mudanças para o final do século XXI evidenciam um aumento de CDD, principalmente no Centro-oeste (RCP6.0) e Nordeste (RCP8.5), enquanto o índice R10mm apresenta mudanças tanto positivas (maior parte do Brasil) quanto negativas (Equador, Peru e Sul do Brasil). Os dias muito úmidos (R95p) sofrerão aumento em todo o continente, sendo mais evidente no extremo leste da região equatorial e no Sul do Brasil. Já Rx5Day apresenta projeções positivas sobre toda a América do Sul, exceto sul do Chile. A média desses índices extremos de precipitação utilizando o método de Inferência Bayesiana diminuiu ligeiramente em relação à média simples dos MCGs, suavizando em extensão e magnitude as projeções sobre o continente, o que significa que aos modelos com mudanças mais discrepantes foram atribuídos menores pesos. O aumento dos índices extremos R10mm, R95p e Rx5Day está relacionado à uma alta na umidade, episódios intensos de precipitação e

grandes acumulados de chuva, o que poderão favorecer um crescimento na ocorrência de enchentes, deslizamentos de terra e desastres naturais de grandes proporções, principalmente nas regiões Centro-Oeste e Sudeste, as quais já apresentam grande vulnerabilidade climáticas.

Para as projeções dos índices de temperatura, notou-se uma distribuição em faixas latitudinais, as quais possuíam os maiores valores de mudança na região equatorial, diminuindo em relação às latitudes mais elevadas. No geral, pode-se observar uma diminuição de TN10p e TX10p, e um aumento de TN90p e TX90p, porém as projeções indicam que o número de noites muito frias será menor que os dias muito frios na região subtropical, assim como a frequência de noites muito quentes (TN90p) se apresentará superior aos dias muito quentes, principalmente na região equatorial. Aplicando-se a Inferência Bayesiana sobre a média das projeções, não notou-se diferenças substanciais em relação à média simples dos MCGs para todo o continente, exceto suave aumento das mudanças na região equatorial.

As Funções Densidades de Probabilidade (PDFs) também foram analisadas, a fim de observar a concordância entre os modelos e cenários (incertezas quanto aos cenários RCPs). Os resultados mostram que, para os índices de precipitação, predominou-se curvas multimodais, com grandes larguras de distribuição, evidenciando maiores incertezas dos modelos nas projeções. Contrariamente, para os índices extremos de temperatura, as curvas foram unanimemente unimodais, com larguras da distribuição relativamente pequenas, mostrando boa concordância entre os modelos quanto às projeções de mudanças. Também, para esses índices, pode-se observar uma relação de intensificação da forçante radiativa e do aumento ou redução do índice nas sub-regiões de estudo, além de concluir que as menores incertezas foram encontradas para projeções do cenário RCP8.5 (curvas mais estreitas) e as maiores incertezas para os cenários mais otimistas RCP2.5 e RCP4.5.

Por fim, quando avaliadas as distribuições posteriores dos parâmetros de precisão λ_i e estudadas as incertezas inter-modelos, observou-se que os MCGs possuem diferentes ponderamentos nas sub-regiões e índices extremos, evidenciando diferentes concordâncias entre os modelos e destrezas variadas em simular as observações. Para os índices extremos de precipitação, notou-se que a distribuição dos parâmetros possuía modelos destaques, sendo CanESM2 o modelo mais deficiente e não havendo um modelo que tivesse alta credibilidade de projeções em todas as regiões. Enquanto para os índices de temperatura, esse *ranking* apresentou menor variação, não possuindo valores discrepantes consideráveis, e, de maneira geral, o modelo de maior credibilidade foi MPI-ESM-MR e o que apresentou maiores incertezas

foi FGOALS-g2. É importante salientar que, a deficiência desses modelos pode estar associada à má configuração dos parâmetros dentro da rotina computacional, à interpolação utilizada para equiparar a resolução espacial dos dados, à utilização de reanálises, as quais carregam maiores incertezas em relação ao dado propriamente observado, além da maior complexidade estatística no cálculo dos índices extremos climáticos, principalmente os de precipitação.

Portanto, com esses resultados, pretende-se colaborar com estudos sobre a temática de mudanças climáticas e melhorar os conhecimentos a respeito das incertezas existentes nas projeções desses índices extremos de precipitação e temperatura, auxiliando numa futura análise mais fidedigna de vulnerabilidade na América do Sul, principalmente nas 4 sub-regiões estudadas.

5.1 Sugestões de trabalhos futuros

Como sugestão para trabalhos futuros, pode-se indicar:

- Utilização de uma base de dados observados a qual não seja composta por reanálises, a fim de diminuir as incertezas associadas na comparação com as simulações;
- Cálculo do Índice de Mudança Climática Regional para os extremos climáticos de temperatura e precipitação, assim como estudado por Torres (2014) para as variáveis médias de temperatura e precipitação, objetivando obter quais áreas da América do Sul possuem maior vulnerabilidade quanto às projeções desses índices extremos;
- Investigar a acurácia do novo Modelo Brasileiro do Sistema Terrestre (BESM), primeiro a ser criado recentemente pelo Brasil para compor o conjunto de modelos do CMIP6 que subsidiarão as avaliações apresentadas no próximo relatório do IPCC. Como tal modelo possui características do sistema com uma perspectiva brasileira, talvez as projeções para o Brasil e adjacências sejam mais adequadas.

6 REFERÊNCIAS

- ALEXANDER, M. Extratropical Air-Sea Interaction, Sea Surface Temperature Variability, and the Pacific Decadal Oscillation. In: SUN, D.-Z.; BRYAN, F. **Climate Dynamics: Why Does Climate Vary?**. Washington: American Geophysical Union, 2010. p. 123-149.
- ALVES, M. P. A.; SILVEIRA, R. B.; BITENCOURT, D. P.; FRANKE, A. E. Onda de frio? Análise de diferentes métodos de identificação. **Revista Brasileira de Climatologia**, v. 21, p. 295-312, 2017.
- ALVARENGA, L. A. Precipitação no sudeste brasileiro e sua relação com a Zona de Convergência do Atlântico Sul. **Revista Agrogeoambiental**, v. 2, n. 2, p. 1-7, 2012.
- AMBRIZZI, T.; SOUZA, E. B.; PULWARTY, R. S. The Hadley and Walker regional circulations and associated ENSO impacts on South American seasonal rainfall. In: **The Hadley circulation: present, past, and future**. Springer Netherlands, 2004. p. 203-235.
- ARTAXO, P.; OLIVEIRA, P. H.; LARA, L. L.; PAULIQUEVIS, T. M.; RIZZO, L. V.; JUNIOR, C. P.; PAIXÃO, M. A.; LONGO, K. M.; FREITAS, S.; CORREIA, A. L. Efeitos climáticos de partículas de aerossóis biogênicos e emitidos em queimadas na Amazônia. **Revista Brasileira de Meteorologia**, Edição Especial LBA, v. 21, n. 3a, p. 168-189, 2006.
- BANCO MUNDIAL. **Avaliação de Perdas e Danos: Inundações e Deslizamentos na Região Serrana do Rio de Janeiro - Janeiro de 2011**. Relatório elaborado pelo Banco Mundial com apoio do Governo do Estado do Rio de Janeiro. [TORO, J. (Coord.)]. Editora Executiva, Brasília, GO, 2012. 63 p.
- BARROS, V.; CLARKE, R.; DIAS, P. S. (Ed.). **Climate change in the La Plata Basin**. Inter American Institute on Global Change. Buenos Aires, Argentina, 2006. 221 p.
- BIDEGAIN, M. E RENON, M. Temperaturas extremas y amplitudes diárias en Uruguay condicionadas según el fenomeno ENOS. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 12, 2002, Foz do Iguaçu. **Anais...** Foz do Iguaçu: SBMET, 2002.
- BJERKNES, J. Atmospheric teleconnections from the equatorial Pacific. **Monthly Weather Review**, v. 97, p. 163–172, 1969.
- BLÁZQUES, J.; NUÑEZ, M. N. Analysis of uncertainties in future climate projections for South America: comparison of WCRP-CMIP3 and WCRP-CMIP5 models. **Climate Dynamics**, v. 41, p. 1039–1056, 2013.
- BONNER, W. D. Climatology of the low level jet. **Monthly Weather Review**, v. 96, p. 833–850, 1968.
- BRITISH BROADCASTING CORPORATION – BBC BRASIL. Onda de frio castiga América do Sul e mata dezenas. **BBC Brasil**, São Paulo, 21 jul. 2010. Disponível em: <http://www.bbc.com/portuguese/noticias/2010/07/100721_frio_argentina_rc>. Acesso em: 13 dez. 2017.

CHOU, S. C.; LYRA, A.; MOURÃO, C.; DERECZYNSKI, C.; PILOTTO, I.; GOMES, J.; BUSTAMANTE, J.; TAVARES, P.; SILVA, A.; RODRIGUES, D.; CAMPOS, D.; CHAGAS, D.; SUEIRO, G.; SIQUEIRA, G.; NOBRE, P.; MARENGO, J. Evaluation of the Eta Simulations Nested in Three Global Climate Models. **American Journal of Climate Change**, v. 3, p. 438-454, 2014.

CLIMATEMPO. Nova Onda de frio no Sul. **Climateempo**, São Paulo, 17 jun. 2017. Disponível em: <<https://www.climateempo.com.br/noticia/2017/06/17/nova-onda-de-frio-no-sul-4933>>. Acesso em: 22 fev. 2018.

COELHO, C. A. S.; CARDOSO, D. H. F.; FIRPO, M. A. F. Precipitation diagnostics of an exceptionally dry event in São Paulo, Brazil. **Theoretical and Applied Climatology**, v. 125, n. 3-4, p. 769-784, 2016.

COELHO, C. A. S.; OLIVEIRA, C. P.; AMBRIZZI, T.; REBOITA, M. S.; CARPENEDO, C. B.; CAMPOS, J. L. P. S.; TOMAZIELLO, A. C. N.; PAMPUCH, L. A.; CUSTÓDIO, M. S.; DUTRA, L. M. D.; DA ROCHA, R. P.; REHBEIN, A. The 2014 southeast Brazil austral summer drought: regional scale mechanisms and teleconnections. **Climate Dynamics**, v. 46, n. 11-12, p. 3737-3752, 2016.

COHEN, J. C. P. **Um Estudo observacional de Linhas de Instabilidade na Amazônia**. 1989. 160 f. Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, 1989.

COLLINS, M. Ensembles and probabilities: a new era in the prediction of climate change. **Philosophical Transactions of the Royal Society A**, v. 365, p. 1957-1970, 2007.

COLLINS, M.; AN, S.-I.; CAI, W.; GANACHAUD, A.; GUILYARDI, E.; JIN, F.-F.; JOCHUM, M.; LENGAINNE, M.; POWER, S.; TIMMERMANN, A.; VECCHI, G.; WITTENBERG, A. The impact of global warming on the tropical Pacific Ocean and El Niño. **Nature Geoscience**, v. 3, p. 391-397, 2010.

DEBORTOLI, N. S.; CAMARINHA, P. I. M.; MARENGO, J. A.; RODRIGUES, R. R. An index of Brazil's vulnerability to expected increases in natural flash flooding and landslide disasters in the context of climate change. **Nat Hazards**, v. 86, p. 557-582, 2017.

DOURADO, F.; ARRAES, T. C.; SILVA, M. F. O Megadesastre da Região Serrana do Rio de Janeiro – as Causas do Evento, os Mecanismos dos Movimentos de Massa e a Distribuição Espacial dos Investimentos de Reconstrução no Pós-Desastre. **Anuário do Instituto de Geociências – UFRJ**, v. 35, p. 43-54, 2012.

EBERT, E. E. Ability of a poor man's ensemble to predict the probability and distribution of precipitation. **Monthly Weather Review**, v. 129, p. 2461-2480, 2001.

EGLER, C. A. G.; GUSMÃO, P. P. Gestão costeira e adaptação às mudanças climáticas: o caso da Região Metropolitana do Rio de Janeiro, Brasil. **Revista da Gestão Costeira Integrada**, v. 14, n. 1, p. 65-80, 2014.

ESCOBAR, G. C. J. Padrões sinóticos associados a ondas de frio na cidade de São Paulo. **Revista Brasileira de Meteorologia**, v. 22, n. 2, p. 241-254, 2007.

EXTRA. Bolívia declara estado de emergência devido à seca e escassez de água. **Extra**, Rio de Janeiro, 21 nov. 2016. Disponível em: <<https://extra.globo.com/noticias/mundo/bolivia-declara-estado-de-emergencia-devido-seca-escassez-de-agua-20510853.html>>. Acesso em: 12 jan. 2018.

FEDOROVA, N.; CARVALHO, M.H. Processos sinóticos em anos de La Niña e de El Niño. Parte II: Zonas Frontais. **Revista Brasileira de Meteorologia**, v. 15, p. 57-72, 2000.

FIRPO, M. A. F.; SANSIGOLO, C. A.; ASSIS, S. V. Climatologia e variabilidade sazonal do número de ondas de calor e de frio no Rio Grande do Sul associadas ao ENOS. **Revista Brasileira de Meteorologia**, v.27, n.1, p. 95-106, 2012.

FOLHA DE SÃO PAULO. Enchentes forçam remoção de mais de 150 mil pessoas na América do Sul. **Folha de São Paulo**, São Paulo, 25 dez. 2015. Disponível em: <<http://www1.folha.uol.com.br/mundo/2015/12/1723104-enchentes-forcam-remocao-de-150-mil-no-paraguai-argentina-e-uruguai.shtml>>. Acesso em: 11 jan. 2018.

FRICH, P.; ALEXANDER, L. V.; DELLA-MARTA, P.; GLEASON, B.; HAYLOCK, M.; TANK, A. M. G. K.; PETERSON, T. Observed coherent changes in climatic extremes during the second half of the twentieth century. **Climate Research**, v. 19, p. 193–212, 2002.

GAN, M. A.; KOUSKY, V. E.; ROPELEWSKI, C. F. The South America monsoon circulation and its relationship to rainfall over West-Central Brazil. **Journal of Climate**, v. 17, n. 1, p. 47-66, 2004.

GARCIA, S. R.; KAYANO, M. T. Some evidence on the relationship between the South American monsoon and the Atlantic ITCZ. **Theoretical and Applied Climatology**, v. 99, n. 1-2, p. 29-38, 2010.

GARTLAND, L. **Ilhas de calor**: Como mitigar zonas de calor em áreas urbanas. Tradução Sílvia Helena Gonçalves. São Paulo: Oficina de Textos, 2010. 28 p.

GASQUES, J. G.; BASTOS, E. T.; VALDES, C.; BACCHI, M. R. P. Produtividade da Agricultura: Resultados para o Brasil e estados selecionados. **Revista de Política Agrícola**. Ano XXIII, n. 3, jul./ago./set. 2014.

GIORGI, F.; MEARNNS, L. O. Calculation of average, uncertainty range, and reliability of regional climate changes from AOGCM simulations via the “Reliability Ensemble Averaging” (REA) method. **Journal of Climate**, v. 15, p. 1141-1158, 2002.

GIORGI, F. Climate Change Prediction. **Climatic Change**, v. 73, p. 239-265, 2005.

GRIMM, A. M.; BARROS, V. R.; DOYLE, M. E. Climate Variability in Southern South America Associated with El Niño and La Niña Events. **Journal of Climate**, v. 13, p. 35-58, 2000.

GLOBO. Frio provoca 80 mortes em 5 países da América do Sul. **Globo**, Rio de Janeiro, 19 jul. 2010. Disponível em: <<http://g1.globo.com/mundo/noticia/2010/07/frio-provoca-80-mortes-em-cinco-paises-da-america-do-sul.html>>. Acesso em: 13 dez. 2017.

GLOBO. Paraguai, Argentina, Uruguai e Brasil somam mais de 160 mil deslocados por cheias. **Globo**, São Paulo, 26 dez. 2015. Disponível em: <<http://g1.globo.com/mundo/noticia/2015/12/paraguai-argentina-uruguai-e-brasil-somam-160-mil-deslocados-por-cheias.html>>. Acesso em: 11 jan. 2018.

GRIMM, A. M. The El Niño Impact on the Summer Monsoon in Brazil: Regional Processes versus Remote Influences. **Journal of Climate**, v. 16, p. 263-280, 2003.

GRIMM, A.M. How do La Niña events disturb the summer monsoon system in Brazil?. **Climate Dynamics**, v. 22, p. 123-138, 2004.

GRIMM, A.M.; TOGATLIAN, I.M. Relação entre eventos El Niño /La Niña e frequência de extremos frios e quentes de temperatura no Cone Sul da América do Sul. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 12, 2002, Foz do Iguaçu. **Anais...** Foz do Iguaçu: SBMET, 2002.

GRIMM, A. M.; VERA, C. S.; MECHOSO, C. R. The South American Monsoon System. In: CHANG, C.-P.; WANG, B.; LAU, N.-C. G. **The Global Monsoon System: research and forecast**, p. 219-238, 2005.

GROTCH, S. L.; MACCRACKEN, M. The Use of General Circulation Models to Predict Regional Climatic Change. **Journal of Climate**, v. 4, p. 286-303, 1991.

HARTMANN, D. L. **Global Physical Climatology**. San Diego: Academic Press, 1994. v. 56. 411 p.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. **Climate Change 2001: the Scientific Basis. Summary for Policymakers**. Cambridge University Press, Cambridge, UK, 2001. 20 p.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. Summary for Policymakers. In: **Climate Change 2007: the Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change** [SOLOMON, S.; QIN, D.; MAMMING, M.; CHEN, Z.; MARQUIS, M.; AVERYT, K. B.; TIGNOR, M.; MILLER, H. L. (Ed.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2007. 1007 p.

INTERGOVERNMENTAL PANEL IN CLIMATE CHANGE - IPCC. **Climate Change and Water**. Technical Paper of the Intergovernmental Panel on Climate Change. [BATES, B.C.; KUNDZEWICZ, Z. W.; WU, S.; PALUTIKOF, J. P. (Ed.)]. IPCC Secretariat, Geneva, 2008. 210 p.

INTERGOVERNMENTAL PANEL IN CLIMATE CHANGE – IPCC. **Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation**. A Special Report of Working Groups I and II of the Intergovernmental Panel on Climate Change [FIELD, C. B.; BARROS, V. R.; STOCKER, T. F.; QIN, D.; DOKKEN, D. J.; EBI, K. L.; MAstrandrea, M. D.; MACH, K. J.; PLATTNER, G. –K.; ALLEN, S. K.; TIGNOR, M.; MIDGLEY, P. M. (Ed.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2012. 582 p.

INTERGOVERNMENTAL PANEL IN CLIMATE CHANGE - IPCC. **Climate Change 2013: The Physical Science Basis. Summary for Policymakers.** Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [STOCKER, T.F.; QIN, D.; PLATTNER, G. –K.; TIGNOR, M.; ALLEN, S. K.; BOSCHUNG, J.; NAUELS, A.; XIA, Y.; BEX, V.; MIDGLEY, P. M. (Ed.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2013. 28 p.

INTERGOVERNMENTAL PANEL IN CLIMATE CHANGE - IPCC. **Climate Change 2014: Impacts, Adaptation, and Vulnerability. Summary for Policymakers.** Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [FIELD, C. B.; BARROS, V. R.; DOKKEN, D. J.; MACH, K. J.; MASTRANDREA, M. D.; BILIR, T. E.; CHATTERJEE, M.; EBI, K. L.; ESTRADA, Y. O.; GENOVA, R. C.; GIRMA, B.; KISSEL, E. S.; LEVY, A. N.; MACCRACKEN, S.; MASTRANDREA, P. R.; WHITE, L. L. (Ed.)]. Cambridge University Press, Cambridge, United Kingdom e New York, NY, USA, 2014a. 32 p.

INTERGOVERNMENTAL PANEL IN CLIMATE CHANGE - IPCC. **Climate Change 2014: Synthesis Report.** Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [TEAM, C. W; PACHAURI, R.K.; MEYER, L.A. (Ed.)]. IPCC, Geneva, Switzerland, 2014b. 151 p.

JOETZJER, E.; DOUVILLE, H.; DELIRE, C.; CIAIS, P. Present-day and future Amazonian precipitation in global climate models: CMIP5 versus CMIP3. **Climate Dynamics**, v. 41, n. 11, p. 2921-2936, 2013.

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

KALNAY, E.; KANAMITSU, M.; KISTLER, R.; COLLINS, W.; DEAVEN, D.; GANDIN, L.; IREDELL, M.; SAHA, S.; WHITE, G.; WOOLEN, J.; ZHU, Y.; CHELLIAH, M.; EBISUZAKI, W.; HIGGINS, W.; JANOWIAK, J.; MO, K. C.; ROPELEWSKI, C.; WANG, J.; LEETMAA, A.; REYNOLDS, R.; JENNE, R.; JOSEPH, D. The NCEP/NCAR 40-year Reanalysis Project. **Bulletin of the American Meteorological Society**, v. 77, n.3, p. 437-471, 1996.

KIKTEV, D.; SEXTON, D. M. H.; ALEXANDER, L.; FOLLAND, C. K. Comparison of modeled and observed trends in indices of daily climate extremes. **Journal of Climate**, v. 16, p. 3560–3571, 2003.

KISTLER, R.; KALNAY, E.; COLLINS, W.; SAHA, S.; WHITE, G.; WOOLEN, J.; CHELLIAH, M.; EBISUZAKI, W.; KANAMITSU, M.; KOUSKY, V.; VAN DEN DOOL, H.; JENNE, R.; FIORINO, M. The NCEP–NCAR 50-Year Reanalysis: Monthly Means CD-ROM and Documentation. **Bulletin of the American Meteorological Society**, v. 82, n. 2, p. 247-268, 2001.

KITOH, A.; KUSUNOKI, S.; NAKAEGAWA, N. D. T. Climate change projections over South America in the late 21st century with the 20 and 60 km mesh. Meteorological Research Institute Atmospheric General Circulation Model (MRIAGCM). **Journal of Geophysical Research – Atmospheres**, v. 116, 2011.

KNUTTI, R. Should we believe model predictions of future climate change?. **Philosophical Transactions of the Royal Society A**, v. 366, p. 4647-4664, 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, p. 2739-2758, 2010.

KOUSKY, V. E.; CAVALCANTI, I. F. A. Eventos Oscilação Sul/El Nino. Características, evolução e anomalias de precipitação. **Ciência e Cultura**, v. 36, p. 1888-1899, 1984.

MANTUA, N. J.; HARE, S. R.; ZHANG, Y.; WALLACE, J. M.; FRANCIS, R. C. A Pacific Interdecadal Climate Oscillation with impacts on salmon production. **Bulletin of the American Meteorological Society**, v. 78, n. 6, p. 1069-1079, 1997.

MARENGO, J. A.; ALVES, L. M. Crise hídrica em São Paulo em 2014: seca e desmatamento. **GEOUSP – Espaço e Tempo (Online)**, v. 19, n. 3, p. 485-494, 2016.

MARENGO, J. A.; ALVES, L. M.; SOARES, W. R.; RODRIGUEZ, D. A.; CAMARGO, H.; RIVEROS, M. P.; PABLÓ, A. D. Two contrasting seasonal extremes in tropical South America in 2012: flood in Amazonia and drought in Northeast Brazil. **Journal of Climate**, v. 26, n. 22, p. 9137-9154, 2013.

MARENGO, J. A.; ALVES, L. M.; ALVALA, R. C. S.; CUNHA, A. P.; BRITO, S.; MORAES, O. L. L. Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**, p. 1-13, 2017.

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

MARENGO, J. A.; NOBRE, C. A.; SELUCHI, M. E.; CUARTAS, A.; ALVES, L. M.; MENDIONDO, E. M.; OBREGÓN, G.; SAMPAIO, G. A seca e a crise hídrica de 2014-2015 em São Paulo. **Revista USP**, São Paulo, n. 106, p. 31-44, 2015.

MARENGO, J. A.; RUSTICUCCI, M.; PENALBA, O.; RENOM, M. An intercomparison of observed and simulated extreme rainfall and temperature events during the last half of the twentieth century. Part 2: historical trends. **Climatic Change**, v. 98, p. 509-529, 2010a.

MARENGO, J. A.; AMBRIZZI, T.; ROCHA, R. P.; ALVES, L. M.; CUADRA, S. V.; VALVERDE, M.; FERRAZ, S. E. T.; TORRES, R. R.; SANTOS, D. C. Future change of climate in South America in the late XXI century: intercomparison of scenarios from three regional climate models. **Climate Dynamics**, v. 35, p. 1073-1097, 2010b.

MARENGO, J. A.; SOARES, W. R.; SAULO, C.; NICOLINI, M. Climatology of Low-Level Jet East of the Andes as Derived from the NCEP-NCAR Reanalyses: Characteristics and Temporal Variability. **Journal of Climate**, v. 17, n. 12, p. 2261 – 2280, 2004.

MARENGO, J. A.; TOMASELLA, J.; ALVES, L. M.; SOARES, W. R.; RODRIGUEZ, D. A. The drought of 2010 in the context of historical droughts in the Amazon region. **Geophysical Research Letters**, v. 38, L12703, p. 1-5, 2011.

MARENGO, J. A., TORRES, R. R.; ALVES, L. M. Drought in Northeast Brazil – past, presente, and future. **Theoretical and Applied Climatology**, v. 129, p. 1189-1200, 2017.

MARENGO, J.A.; VALVERDE, M. C.; OBREGON, G.O. Observed and projected changes in rainfall extremes in the Metropolitan Area of São Paulo. **Climate Research**, v. 57, p. 61-72, 2013.

MEARNS, L. O.; HULME, M.; CARTER, T. R.; LEEMANS, R., LAL, M.; WHETTON, P. H. Climate Scenario Development. In: HOUGHTON, J. T.; DING, Y.; GRIGGS, D. J.; NOGUER, M., VAN DER LINDEN, P. J.; XIAOXU, D. (Ed.). **Climate Change 2001: The Scientific Basis. Contribution of Working Group I to the Third Assessment Report of the Intergovernmental Panel on Climate Change (IPCC)**. Cambridge: Cambridge University Press, 2001. cap. 13.

MEEHL, G. A.; STOCKER, T. F.; COLLINS, W. D.; FRIESLINGSTEIN, P.; GAYE, A. T.; GREGORY, J. M.; KITO, A.; KNUTTI, R.; MURPHY, J. M.; NODA, A.; RAPER, S. C. B.; WATTERSON, I. G.; WEAVER, A. J.; ZHAO, Z-C. Global Climate Projections. In: SOLOMON, S.; QIN, D.; MAMMING, M.; CHEN, Z.; MARQUIS, M.; AVERYT, K. B.; TIGNOR, M.; MILLER, H. L. (Ed.), **Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change**. Cambridge and New York: Cambridge University Press, 2007.

MINISTÉRIO DE MINAS E ENERGIA - MME. **Balanco energético nacional 2015 – Ano base 2014: Síntese do relatório final**. Rio de Janeiro: EPE, 2015.

MINVIELLE, M.; GARREAUD, R. D. Projecting rainfall changes over South American altiplano. **Journal of Climate**, v. 24, p. 4577–4583, 2011.

MOSS, R. H.; EDMONDS, J. A.; HIBBARD, K. A.; MANNING, M. R.; ROSE, S. K.; VAN VUUREN, D. P.; CARTER, T. R.; EMORI, S.; KAINUMA, M.; KRAM, T.; MEEHL, G. A.; MITCHELL, J. F. B.; NAKICENOVIC, N.; RIAHI, K.; SMITH, S. J.; STOUFFER, R. J.; THOMSON, A. M.; WEYANT, J. P.; WILLBANKS, T. J. The next generation of scenarios for climate change research and assessment. **Nature**, v. 463, p. 747-756, 2010.

NATIVIDADE, U. A. **Observação e projeção de eventos climáticos extremos sobre o Brasil e identificação de possíveis vulnerabilidades sobre Minas Gerais**. 2015. 98 f. Dissertação (Mestrado em Meio Ambiente e Recursos Hídricos) - Universidade Federal de Itajubá (UNIFEI), Itajubá, MG, 2015.

NATIVIDADE, U. A.; GARCIA, S. R.; TORRES, R. R. Tendências dos Índices de Extremos Climáticos Observados e Projetados no Estado de Minas Gerais. **Revista Brasileira de Meteorologia**, v. 32, n. 4, p. 600-614, 2017.

NOBRE, P.; MARENGO, J. A.; CAVALCANTI, I. F. A.; OBREGON, G. Seasonal to

decadal predictability and prediction of South American climate. **Journal of Climate**, v. 19, p. 5988–6004, 2006.

NOBRE, C. A.; MARENGO, J. A.; SELUCHI, M. E.; CUARTAS, L. A.; ALVES, L. M. Some Characteristics and Impacts of the Drought and Water Crisis in Southeast Brazil during 2014 and 2015. **Journal of Water Resource and Protection**, v. 8, p. 252-262, 2016.

OLIVEIRA, M. J.; VECCHIA, F. A. S. Mudanças Climáticas. In: CALIJURI, M. C.; CUNHA, D. G. F. (Org.). **Engenharia Ambiental: Conceitos, Tecnologias e Gestão**. Rio de Janeiro: Elsevier, 2013. cap. 16.

PAINEL BRASILEIRO DE MUDANÇAS CLIMÁTICAS – PBMC. **Base científica das mudanças climáticas**. Contribuição do Grupo de Trabalho 1 do Painel Brasileiro de Mudanças Climáticas ao Primeiro Relatório da Avaliação Nacional sobre Mudanças Climáticas [AMBRIZZI, T., ARAUJO, M. (Ed.)]. COPPE. Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil, 2014. 464 p.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**. 1. ed. São Paulo: Thomson Learning Edições, 2007. v. 1. 508p.

PINHEIRO, H.; ANDRADE, K.; MOURA, C. **A maior catástrofe climática do Brasil sob a visão operacional do CPTEC/INPE**. Centro de Previsão do Tempo e Estudos Climáticos – CPTEC/INPE, Cachoeira Paulista, SP, 2011.

QUADRO, M. F. L. **Estudo de episódios de Zona de Convergência do Atlântico Sul (ZCAS) sobre a América do Sul**. 1994. 123 f. Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, 1994.

REBOITA, M. S.; AMBRIZZI, T.; DA ROCHA, R. P. Relationship between the Southern Annular Mode and Southern Hemisphere Atmospheric Systems. **Revista Brasileira de Meteorologia**, v. 24, n. 1, p. 48-55, 2009.

REBOITA, M. S.; KRUSCHE, N.; AMBRIZZI, T.; DA ROCHA, R. P. Entendendo o Tempo e o Clima na América do Sul. **Terrae Didática**, v. 8, n. 1, p. 34-50, 2012.

RODRIGUES, R. R.; MCPHADEN, M. J. Why did the 2011-2012 La Niña cause a severe drought in the Brazilian Northeast?. **Geophysical Research Letters**, v. 4, p. 1012-1018, 2014.

RUSTICUCI, M.; MARENGO, J. A.; PENALBA, O.; RENOM, M. An intercomparison of observed and simulated extreme rainfall and temperature events during the last half of the twentieth century. Part 1: mean values and variability. **Climatic Change**, v. 98, p. 493-508, 2010.

SANTOS, E.; MATOS, H.; ALVARENGA, J.; SALES, M. C. L. A seca no nordeste no ano de 2012: relato sobre a estiagem na região e o exemplo de prática de convivência com o semiárido no distrito de Iguaçú/Canindé-CE. **Revista Geonorte**, Edição Especial 2, v. 1, n. 5, p. 819-830, 2012.

SANTOS, T. S. **Cálculo das incertezas climáticas sobre América do Sul utilizando modelos do CMIP5: Aferição através das Redes Neurais Artificiais**. 2015. 94 f. Tese

(Doutorado em Ciências Climáticas) – Universidade Federal do Rio Grande do Norte (UFRN), Natal, RN, 2015.

SARTORI, M.G.B. A dinâmica do clima do Rio Grande do Sul: indução empírica e conhecimento científico. **Revista Terra Livre**, v. 1, n. 20, p. 27-49, 2003.

SATYAMURTY, P.; MATTOS, L. F. Climatological lower tropospheric frontogenesis in the midlatitudes due to horizontal deformation and divergence. **Monthly Weather Review**, v. 117, n. 6, p. 1355-1364, 1989.

SHI, L.; ESCOBAR, M.; JOYCE, B.; KOSTARAS, J. Ordenamiento territorial estratégico teniendo en cuenta la escasez de agua debido al cambio climático en El Alto, Bolivia. **Lincoln Institute of Land Policy**, p. 1-57, 2013.

SHIMIZU, M. H.; AMBRIZZI, T.; LIEBMANN, B. Extreme precipitation events and their relationship with ENSO and MJO phases over northern South America. **International Journal of Climatology**, v. 37, p. 2977-2989, 2017.

SILLMANN, J.; KHARIN, V. V.; ZHANG, X.; ZWIERS, F. W.; BRONAUGH, D. Climate extremes indices in the CMIP5 multimodel ensemble: Part 1. Model evaluation in the present climate. **Journal of Geophysical Research**, v. 118, p. 1-18, 2013a.

SILLMANN, J.; KHARIN, V. V.; ZWIERS, F. W.; ZHANG, X.; BRONAUGH, D. Climate extremes indices in the CMIP5 multimodel ensemble: Part 2. Future climate projections. **Journal of Geophysical Research**, v. 118, p. 2473–2493, 2013b.

SILVA, W.L.; DEREZYNSKI, C.; CHOU, S.C.; CAVALCANTI, I. Future Changes in Temperature and Precipitation Extremes in the State of Rio de Janeiro (Brazil). **American Journal of Climate Change**, v. 3, n. 4, p. 353, 2014.

SILVA, W.L.; DEREZYNSKI, C.; CHANG, M.; FREITAS, M.; MACHADO, B.J.; TRISTÃO, L.; RUGGERI, J. Tendências observadas em indicadores de extremos climáticos de temperatura e precipitação no estado do Paraná. **Revista Brasileira de Meteorologia**, v. 30, n. 2, p. 181-194, 2015.

SILVA, W. L.; NASCIMENTO, M. X.; MENEZES, W. F. Atmospheric Blocking in the South Atlantic during the Summer 2014: A Synoptic Analysis of the Phenomenon. **Atmospheric and Climate Sciences**, v. 5, p. 386- 393, 2015.

SILVEIRA, C. S.; FILHO, F. A. S.; COSTA, A. A.; CABRAL, S. L. Avaliação de desempenho dos modelos do CMIP5 quanto à representação dos padrões de variação da precipitação no século XX sobre a região Nordeste do Brasil, Amazônia e Bacia do Prata e análise das projeções para o cenário RCP8.5. **Revista Brasileira de Meteorologia**, v. 28, n. 3, p. 317-330, 2013.

SILVEIRA, C. S.; FILHO, F. A. S.; MARTINS, E. S. P. R.; OLIVEIRA, J. L.; COSTA, A. C.; NOBREGA, M. T.; SOUZA, S. A.; SILVA, R. F. V. Mudanças climáticas na bacia do rio São Francisco: Uma análise para precipitação e temperatura. **Revista Brasileira de Recursos Hídricos**, v. 21, n. 2, p. 416-428, 2016.

- SOARES, W.R.; MARENGO, J. A. Assessments of moisture fluxes east of the Andes in South America in a global warming scenario. **International Journal of Climatology**, v. 29, n. 10, p. 1395-1414, 2009.
- STOTT, P. A.; KETTLEBOROUGH, J. A. Origins and estimates of uncertainty in predictions of twenty-first century temperature rise. **Nature**, v. 416, p. 723-726, 2002.
- TAYLOR, K. E. Summarizing multiple aspects of model performance in a single diagram. **Journal of Geophysical Research: Atmospheres**, v. 106, p. 7183-7192, 2001.
- TAYLOR, K. E.; STOUFFER, R. J.; MEEHL, G. A. An overview of CMIP5 and the experiment design. **Bulletin of the American Meteorological Society**, v. 93, p. 485-498, 2012.
- TEBALDI, C.; SMITH, R. L.; NYCHKA, D.; MEARNNS, L. O. Quantifying uncertainty in projections of regional climate change: a bayesian approach to the analysis of multimodel ensembles. **Journal of Climate**, v. 18, p. 1524-1540, 2005.
- TEBALDI, C.; HAYHOE, K.; ARBLASTER, J. M.; MEEHL, G. A. Going to the extremes. **Climatic Change**, v. 79, p. 185-211, 2006.
- TORRES, R. R. **Análise de incertezas em projeções de mudanças climáticas na América do Sul**. 2014. 271 f. Tese (Doutorado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, 2014.
- TORRES, R. R.; MARENGO, J. A. Climate change hotspots over South America: from CMIP3 to CMIP5 multi-model datasets. **Theoretical and Applied Climatology**, v. 117, p. 579-587, 2014.
- UVO, C. R. B. **A Zona de Convergência Intertropical (ZCIT) e sua relação com a precipitação da Região Norte do Nordeste Brasileiro**. 1989. 81 f. Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, 1989.
- VALVERDE, M.C.; MARENGO, J.A. Extreme Rainfall Indices in the Hydrographic Basins of Brazil. **Open Journal of Modern Hydrology**, v. 4, n. 1, p. 10, 2014.
- VAN VUUREN, D. P.; EDMONDS, J.; KAINUMA, M.; RIAHI, K.; THOMSON, A.; HIBBARD, K.; HURTT, G. C.; KRAM, T.; KREY, V.; LAMARQUE, J. F.; MASUI, T.; MEINSHAUSEN, M.; NAKICENOVIC, N.; SMITH, S. J.; ROSE, S. K. The representative concentration pathways: an overview. **Climatic Change**, v. 109, p. 5-31, 2011.
- TRENBERTH, K. E. The Definition of El Niño. **Bulletin of the American Meteorological Society**, v. 78, n. 12, 1997.
- WANG, C.; DESER, C.; YU, J.-Y.; DINEZIO, P.; CLEMENT, A. El Niño-Southern Oscillation (ENSO): A review. In: GLYMN, P.; MANZELLO, D.; ENOCHS, I. (Ed.). **Coral Reefs of the Eastern Pacific**. Dordrecht: Springer Science Publisher, 2016. cap. 4, p. 85-106.

WHITEMAN, C.; BIAN, X.; ZHONG, S. Low-level jet climatology from enhanced rawinsonde observations at a site in the southern Great Plains. **Journal of Applied Meteorology**, v. 36, p. 1363–1375, 1997.

WILBY, R. L.; WIGLEY, T. M. L. Downscaling general circulation model output: a review of methods and limitations. **Progress in Physical Geography**, v. 21, n. 4, p. 530-548, 1997.

WILLMOTT, C. J. On the validation of models. **Physical Geography**, v. 2, p. 184-194, 1981.

WILLMOTT, C. J. Some Comments on the Evaluation of Model Performance. **Bulletin American Meteorological Society**, v. 63, n. 11, p. 1309-1313, 1982.

WORLD METEOROLOGICAL ORGANIZATION – WMO. **Greenhouse Gas Bulletin**. The State of Greenhouse Gases in the Atmosphere Based on Global Observations through 2015. Atmospheric Environment Research Division, Research Department, Geneva, 8 p. 2016.

XU, Y.; XUEJIE, G.; GIORGI, F. Upgrades to the reliability ensemble averaging method for producing probabilistic climate change projections. **Climate Research**, v. 41, p. 61–81, 2010.

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. Advanced Review. **Climate Change**, p. 1-20, 2011.

ZHOU, J.; LAU, K.-M. Does a Monsoon Climate Exist over South America?. **Journal of Climate**, v. 11, p. 1020-1040, 1998.