



Ministério da
**Ciência, Tecnologia
e Inovação**



sid.inpe.br/mtc-m19/2014/01.13.12.37-TDI

ANÁLISE DE INCERTEZAS EM PROJEÇÕES DE MUDANÇAS CLIMÁTICAS NA AMÉRICA DO SUL

Roger Rodrigues Torres

Tese de Doutorado do Curso de Pós-Graduação em Meteorologia, orientada pelo Dr. José Antonio Marengo Orsini, aprovada em 03 de fevereiro de 2014.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3FHR358>>

INPE
São José dos Campos
2014

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@sid.inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE (RE/DIR-204):

Presidente:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Membros:

Dr. Antonio Fernando Bertachini de Almeida Prado - Coordenação Engenharia e Tecnologia Espacial (ETE)

Dr^a Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Dr. Germano de Souza Kienbaum - Centro de Tecnologias Especiais (CTE)

Dr. Manoel Alonso Gan - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr^a Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Maria Tereza Smith de Brito - Serviço de Informação e Documentação (SID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)



Ministério da
**Ciência, Tecnologia
e Inovação**



sid.inpe.br/mtc-m19/2014/01.13.12.37-TDI

ANÁLISE DE INCERTEZAS EM PROJEÇÕES DE MUDANÇAS CLIMÁTICAS NA AMÉRICA DO SUL

Roger Rodrigues Torres

Tese de Doutorado do Curso de
Pós-Graduação em Meteorologia,
orientada pelo Dr. José Antonio
Marengo Orsini, aprovada em 03 de
fevereiro de 2014.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3FHR358>>

INPE
São José dos Campos
2014

Dados Internacionais de Catalogação na Publicação (CIP)

Torres, Roger Rodrigues.

T636a Análise de incertezas em projeções de mudanças climáticas na América do Sul / Roger Rodrigues Torres. – São José dos Campos : INPE, 2014.

xxx + 239 p. ; (sid.inpe.br/mtc-m19/2014/01.13.12.37-TDI)

Tese (Doutorado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014.

Orientador : Dr. José Antonio Marengo Orsini.

1. climatologia. 2. mudanças climáticas. 3. modelos climáticos.
4. projeções climáticas. 5. incertezas. 6. América do Sul. I.Título.

CDU 551.583(8)

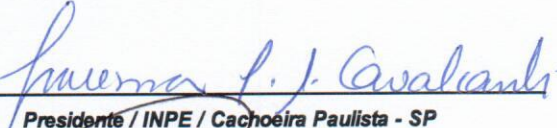


Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).


Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de **Doutor(a)** em
Meteorologia

Dra. Iracema Fonseca de Albuquerque
Cavalcanti



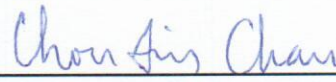
Presidente / INPE / Cachoeira Paulista - SP

Dr. José Antonio Marengo Orsini



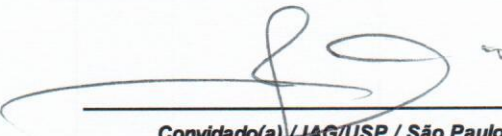
Orientador(a) / INPE / Cachoeira Paulista - SP

Dra. Chou Sin Chan



Membro da Banca / INPE / Cachoeira Paulista - SP

Dr. Tércio Ambrizzi



Convidado(a) / IAG/USP / São Paulo - SP

Dr. Paulo Sérgio Lúcio



Convidado(a) / UFRN / Rio Grande do Norte - RN

Este trabalho foi aprovado por:

() maioria simples

unanimidade

Aluno (a): **Roger Rodrigues Torres**

São José dos Campos, 03 de Fevereiro de 2014

“Há um tempo em que é preciso abandonar as roupas usadas, que já tem a forma do nosso corpo, e esquecer os nossos caminhos, que nos levam sempre aos mesmos lugares. É o tempo da travessia: e, se não ousarmos fazê-la, teremos ficado, para sempre, à margem de nós mesmos.”

Fernando Pessoa

A meus pais
Reinaldo Rodrigues Torres
&
Lázara Aparecida da Silva Torres

AGRADECIMENTOS

A meus pais, irmãos e sobrinhos pelo amplo apoio e orações dedicadas a mim durante toda a minha vida.

A minha esposa Nancy Rios pelo companheirismo e apoio, o qual foi fundamental na conclusão de mais essa etapa acadêmica.

Ao Dr. José Marengo pela orientação e apoio na realização deste trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo auxílio financeiro.

Ao Instituto Nacional de Pesquisas Espaciais (INPE) pela utilização de equipamentos e instalações.

Aos amigos do curso de Pós-Graduação em Meteorologia do INPE e do curso de Ciências Atmosféricas da Universidade Federal de Itajubá (Unifei), muito obrigado pelos momentos vividos e pelas trocas de experiência compartilhadas.

A todos os amigos que estiveram a meu lado durante a realização deste trabalho, em especial a Alan, Alex, Cristiano, Cristina, David Lapola, David Mendes, Elder, Enrique, Fabrina, Helber, Marcelo, Renato, Ridenia, Sâmia, Vanessa, e Weber, cuja amizade e companheirismo foram fundamentais nesses últimos anos.

RESUMO

Este estudo avaliou as incertezas envolvidas nas projeções de mudanças de temperatura e precipitação na América do Sul, geradas por inúmeros Modelos de Circulação Geral (MCGs) pertencentes ao CMIP3 e CMIP5 (*Coupled Model Intercomparison Project Phase 3 e Phase 5*, respectivamente), no intuito de identificar como essas incertezas distribuem-se geograficamente e fornecer informações mais confiáveis, sintéticas, e probabilísticas. Sete diferentes cenários forçantes foram avaliados: SRES B1, A1B, e A2; e RCP 2.6, 4.5, 6.0, e 8.5. Especial atenção foi dada nas projeções para 2071-2100, com relação ao período de 1961-1990. Três métodos foram usados para avaliar as incertezas: REA (*Reliability Ensemble Averaging*) e REA modificado, e inferência bayesiana. As simulações dos MCGs do CMIP3 e CMIP5 demonstraram-se capazes de representar bem os aspectos climatológicos básicos observados das variáveis analisadas, tais como média sazonal e ciclo anual, apesar de alguns vieses serem identificados, principalmente sobre os Andes, noroeste da América do Sul, bacia Amazônica, e Nordeste brasileiro. Entretanto, os MCGs do CMIP5 apresentaram simulações mais próximas das observações comparadas ao CMIP3. Levando em consideração o desempenho de cada MCG em representar o clima observado e a convergência de sua projeção com relação à média dos conjuntos CMIP3 ou CMIP5, como proposto explicitamente pelo método REA e intrinsecamente pela inferência bayesiana, notou-se que, em geral, a média das projeções de mudança de temperatura decresce ligeiramente ($\sim 0,5^{\circ}\text{C} - 1^{\circ}\text{C}$) sobre toda região, comparado à média aritmética simples dos MCGs. Em todas as análises constatou-se que as mudanças de temperatura são maiores do que os intervalos de incerteza associados para toda América do Sul e nos diversos períodos, conjuntos de MCGs, e cenários forçantes, indicando uma alta confiabilidade nas projeções. Nos cenários de forçantes mais intensas (SRES A2 e RCP 8.5), a probabilidade de um aumento de temperatura exceder 2°C em 2071-2100 é extremamente alta ($> 90\%$) para toda América do Sul. Quanto à precipitação, os métodos não resultaram em padrões de mudanças substancialmente diferentes daqueles obtidos com uma média aritmética simples dos MCGs, tanto para o CMIP3 quanto para o CMIP5. Os intervalos de incerteza apresentaram magnitudes iguais ou maiores do que a das mudanças projetadas. Portanto, concluiu-se que existe uma alta confiabilidade de uma projeção de mudanças pequena ou inexistente na precipitação sazonal e anual sobre a América do Sul. Por fim, os resultados advindos da utilização do *Regional Climate Change Index* (RCCI) sobre a América do Sul ressaltam que o sul da Amazônia, a região Centro-Oeste e a porção oeste do estado de Minas Gerais são persistentes *hotspots* de mudanças climáticas nos diferentes cenários forçantes e conjuntos de MCGs. Em geral, na medida em que os cenários variam do mais baixo ao mais alto nível de forçante, as áreas de altos valores de RCCI aumentam e a magnitude intensifica-se do centro-oeste e sudeste do Brasil em direção ao noroeste da América do Sul.

UNCERTAINTY ANALYSIS OF CLIMATE CHANGE PROJECTIONS OVER SOUTH AMERICA

ABSTRACT

This study evaluated the uncertainties involved in projections of surface air temperature and precipitation in South America generated by numerous General Circulation Models (GCMs) belonging to CMIP3 and CMIP5 dataset (Coupled Model Intercomparison Project Phases 3 and 5, respectively), in order to identify how these uncertainties are distributed geographically and provide informations more reliable, summarized, and probabilistic. Seven different forcing scenarios were evaluated: SRES B1, A1B, and A2; and RCP 2.6, 4.5, 6.0, and 8.5. Special attention was given to the projections for 2071-2100 with respect to 1961-1990. Three methods have been used to evaluate uncertainties: REA (Reliability Ensemble Averaging) and REA modified, and Bayesian inference. GCMs simulations from CMIP3 and CMIP5 were able to well represent the basic climatological features of the observed variables, such as seasonal mean and annual cycle, although some bias were identified, mainly over the Andes, northwestern South America, Amazon basin, and Northeast Brazil. On the other hand, GCMs from CMIP5 showed simulations closer to observations when compared to CMIP3. Taking into account the performance of each GCM in representing the observed climate and the convergence of its projection with respect to the average of CMIP3 or CMIP5 datasets, as proposed explicitly by the REA method and intrinsically by Bayesian inference, it was noted that, in general, the average projections of temperature change decreases slightly ($\sim 0.5^{\circ}\text{C} - 1^{\circ}\text{C}$) over the entire region, compared to the simple average of GCMs. In all analyzes, it was found that the temperature changes are larger than the associated uncertainty intervals throughout South America and in different periods, sets of GCMs and forcing scenarios, indicating a high reliability in these projections. In the scenarios of most intense forcings (SRES A2 and RCP 8.5), the probability of a temperature change exceeding 2°C in 2071-2100 is extremely high ($> 90\%$) throughout South America. Regarding to precipitation, and for both CMIP3 and CMIP5, the methods did not result in patterns substantially different from those obtained from a simple average of GCMs. The ranges of uncertainty presented magnitudes equal to or larger than the projected changes. Therefore, it is concluded that there is a high reliability of a projection of small or no changes in seasonal and annual precipitation over South America. Finally, the results of application of the Regional Climate Change Index (RCCI) over South America show that southern Amazonia and the central-western region and western portion of Minas Gerais state are persistent climate change hotspots through different forcing scenarios and GCM datasets. In general, as the scenarios vary from low- to high-level forcing, the area of high values of RCCI increase and the magnitude intensify from central-western and southeast Brazil to northwest South America.

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Principais processos naturais e antropogênicos influenciando o comportamento do sistema climático.....	8
2.2 Cascata de incertezas em uma projeção de mudanças climáticas. A linha tracejada engloba o segmento de simulação climática da cascata. A sigla AOGCMs significa <i>atmosphere – ocean general circulation models</i>	11
2.3 Segmento da simulação climática da cascata de incertezas representada na Figura 2.1.	12
3.1 Trajetórias das emissões de CO ₂ (direita), CH ₄ (centro), e N ₂ O (esquerda) referentes à seis cenários representativos do SRES (A1B, A1T, A1FI, A2, B1, B2), e o cenário IS92a.	26
3.2 Trajetórias das emissões de CO ₂ (direita), CH ₄ (centro), e N ₂ O (esquerda) 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)	27
3.3 Mudança de temperatura global (média e um desvio padrão, indicado com o sombreado) relativo a 1986-2005, projetada pelos MCGs do CMIP3 utilizando os cenários SRES (esquerda), e pelos MCGs do CMIP5 utilizando os RCPs (direita). O número de MCGs utilizados para cada cenário estão indicados entre parênteses.....	28
3.4 Domínio de estudo. Os retângulos indicam as sub-regiões utilizadas nas análises: leste e oeste da Amazônia (EAMZ e WAMZ, respectivamente), Nordeste do Brasil (NEB), e Bacia do Prata (LPB).	32
4.1 Climatologia média sazonal e anual de precipitação (superior), e viés associado (inferior), resultante da média do conjunto de 24 modelos do CMIP3 utilizados para o período de 1961 a 1990. As unidades estão em mm dia ⁻¹	50
4.2 Climatologia média sazonal e anual de temperatura do ar próximo à superfície (superior), e viés associado (inferior), resultante da média do conjunto de 24 modelos do CMIP3 utilizados para o período de 1961 a 1990. As unidades estão °C.....	51
4.3 Climatologia média sazonal e anual de precipitação (esquerda), e viés associado (direita), simulada pelos modelos do CMIP3 para o período de 1961 a 1990. As climatologias foram obtidas depois do agrupamento dos modelos em três subconjuntos diferentes de acordo com sua resolução horizontal: LOW-RES (superior), MED-RES (central), HIGH-RES	

	(inferior), referentes às resoluções (em graus de latitude/longitude) de 5° x 4°, 2,8° x 2,8°, e 1,9° x 1,9°, respectivamente. As unidades estão mm dia ⁻¹	54
4.4	Climatologia média sazonal e anual de temperatura do ar próximo à superfície (esquerda), e viés associado (direita), simulada pelos modelos do CMIP3 para o período de 1961 a 1990. As climatologias foram obtidas depois do agrupamento dos modelos em três subconjuntos diferentes de acordo com sua resolução horizontal: LOW-RES (superior), MED-RES (central), HIGH-RES (inferior), referentes às resoluções (em graus de latitude/longitude) de 5° x 4°, 2,8° x 2,8°, e 1,9° x 1,9°, respectivamente. As unidades estão °C.	55
4.5	Ciclo anual de precipitação observada (azul, CRU TS 3.0) e simulada (cinza) pelos 24 modelos do CMIP3 analisados nas sub-regiões de estudo: leste e oeste da Amazônia (EAMZ e WAMZ, respectivamente), nordeste do Brasil (NEB), e bacia do Prata (LPB). A linha em negrito representa a média de todos os modelos. A média do erro quadrático médio (RMSE) de todos os modelos é indicada na figura.	56
4.6	Mesmo que Figura 4.5, exceto para temperatura do ar próximo a superfície. A temperatura observada é indicada em vermelho.	58
4.7	Correlação temporal entre a série de temperatura simulada pelos MCGs do CMIP3 (indicada na esquerda de cada mapa) e a série observada (CRU TS 3.0) para o período de 1901 a 1998. Um filtro média móvel foi aplicado a série para reter somente aquela variabilidade com período maior do que 30 anos. O resultado para a média do conjunto (ENS) é indicado no mapa inferior direito.	59
4.8	Mesmo que Figura 4.7, exceto para a variável precipitação.	60
4.9	Climatologia média sazonal e anual de precipitação (superior), e viés associado (inferior), resultante da média do conjunto de todos os modelos do CMIP5 utilizados para o período de 1961 a 1990. As unidades estão mm dia ⁻¹	62
4.10	Climatologia média sazonal e anual de temperatura do ar próximo à superfície (superior), e viés associado (inferior), resultante da média do conjunto de todos os modelos do CMIP5 utilizados para o período de 1961 a 1990. As unidades estão °C.	63
4.11	Ciclo anual de precipitação observada (azul, CRU TS 3.0) e simulada (cinza) pelos 24 modelos do CMIP5 analisados nas sub-regiões de estudo: leste e oeste da Amazônia (EAMZ e WAMZ, respectivamente), nordeste do Brasil (NEB), e bacia do Prata (LPB). A linha em negrito representa a média de todos os modelos. A média do erro quadrático médio (RMSE) de todos os modelos é indicada na figura.	64

4.12	Mesmo que Figura 4.11, exceto para temperatura do ar próximo a superfície. A temperatura observada é indicada em vermelho.	65
4.13	Correlação temporal entre a série de temperatura simulada pelos MCGs do CMIP5 (indicada na esquerda dos mapas) e a série observada (CRU TS 3.0) para o período de 1901 a 1998. Um filtro média móvel foi aplicado a série para reter somente aquela variabilidade com período maior do que 30 anos. O resultado para a média do conjunto (ENS) é indicado no mapa inferior direito.	67
4.14	Mesmo que Figura 4.13, exceto para a variável precipitação.	68
4.15	Série temporal de temperatura simulada e projetada no cenário forçante RCP4.5, provenientes de alguns modelos do CMIP5 (GFDL-ESM2G, GFDL-ESM2M, HadGEM2-CC, e HadGEM2-ES) para duas localidades na América do Sul (as coordenadas são indicadas no canto superior esquerdo das imagens). A série observada (CRU TS 3.0) para o período presente está destacada em negrito. Um filtro média móvel foi aplicado às séries para reter somente aquela variabilidade com período maior do que 30 anos.	69
4.16	Diagramas de Taylor para as simulações de temperatura nas sub-regiões avaliadas neste estudo para todos os MCGs do CMIP3 (círculos vermelhos) e CMIP5 (círculos azuis), relativos ao período de 1901 a 1998. As observações são indicadas como pequenos quadrados verdes na abcissa.....	70
4.17	Mesmo que Figura 4.16, exceto para a variável precipitação.	71
5.1	Mudanças sazonal e anual de temperatura do ar próximo à superfície (°C) projetadas para o final do século (2071-2100) nos cenários de emissões SRES A2 (a-e), A1B (f-j), e B1 (k-o), provenientes do conjunto CMIP3. As mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.	74
5.2	Desvio padrão entre os diversos MCGs do CMIP3, relativo às mudanças sazonal e anual de temperatura do ar próximo à superfície (°C) apresentadas na Figura 5.1.	75
5.3	O mesmo que na Figura 5.1, exceto para mudança sazonal e anual de precipitação (mm.dia ⁻¹).	76
5.4	Concordância (%) no sinal projetado de mudança sazonal e anual de precipitação sobre a América do Sul para o final do século (2071-2100), nos cenários SRES A2 (a-e), A1B (f-j), e B1 (k-o), provenientes do conjunto CMIP3. Os tons verdes (marrons) indicam a porcentagem de MCGs que projetam aumento (diminuição) de precipitação sobre a região. O número de modelos utilizados em cada cenário é indicado entre parênteses na esquerda.	77
5.5	Mudanças sazonal e anual de temperatura do ar próximo à superfície (°C) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a-e), RCP4.5 (f-j), RCP6.0 (k-o), e RCP8.5 (p-t), provenientes do	

	conjunto CMIP5. As mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.....	79
5.6	Desvio padrão entre os diversos MCGs do CMIP5, relativo às mudanças sazonal e anual de temperatura do ar próximo à superfície (°C) apresentadas na Figura 5.5.	80
5.7	O mesmo que na Figura 5.5, exceto para mudança sazonal e anual de precipitação (mm.dia ⁻¹).	81
5.8	Concordância (%) no sinal projetado de mudança sazonal e anual de precipitação sobre a América do Sul para o final do século (2071-2100), nos cenários RCP2.6 (a-e), RCP4.5 (f-j), RCP6.0 (k-o), e RCP8.5 (p-t), provenientes do conjunto CMIP5. Os tons verdes (marrons) indicam a porcentagem de MCGs que projetam aumento (diminuição) de precipitação sobre a região. O número de modelos utilizados em cada cenário é indicado entre parênteses na esquerda.	82
5.9	Média REA para mudanças sazonal e anual de temperatura do ar próximo à superfície (°C) utilizando as projeções dos MCGs do CMIP3 para 2071-2100 nos cenários SRES A2 (a-e), A1B (f-j), e B1 (k-o).	87
5.10	Variabilidade natural observada de temperatura (ϵT , a-e) calculada para o período de 1901 a 2000, e intervalo de incerteza ($\delta\Delta T$, f-j), confiabilidade no conjunto ($\rho\Delta T$, k-o), e média dos parâmetros de desempenho (RB, p-t) e convergência (RD, u-z) do método REA para as mudanças sazonal e anual de temperatura utilizando as projeções dos MCGs do CMIP3 para 2071-2100 no cenário SRES A2. As unidades de ϵT e $\delta\Delta T$ estão em °C, e os demais parâmetros são adimensionais.	89
5.11	Média REA para mudanças sazonal e anual de precipitação (mm.dia ⁻¹) utilizando as projeções dos MCGs do CMIP3 para 2071-2100 nos cenários SRES A2 (a-e), A1B (f-j), e B1 (k-o).	90
5.12	Variabilidade natural observada de precipitação (ϵP , a-e) calculada para o período de 1901 a 2000, e intervalo de incerteza ($\delta\Delta P$, f-j), confiabilidade no conjunto ($\rho\Delta P$, k-o), e média dos parâmetros de desempenho (RB, p-t) e convergência (RD, u-z) do método REA para as mudanças sazonal e anual de precipitação utilizando as projeções dos MCGs do CMIP3 para 2071-2100 no cenário SRES A2. As unidades de ϵP e $\delta\Delta P$ estão em mm.dia ⁻¹ , e os demais parâmetros são adimensionais.....	92
5.13	Probabilidades sazonais das mudanças de temperatura excederem determinados limiares (2°, 3°, 4°, e 5°C), obtidas através das projeções dos modelos do CMIP3 para 2071-2100 no cenário SRES A2.....	93
5.14	Funções distribuição acumulada de mudança de temperatura (°C) para os modelos do CMIP3 processados pelo método REA nos cenários A2 (esquerda), A1B (centro), e B1 (direita), e projetadas para as regiões leste e	

oeste da Amazônia (a-c e d-f, respectivamente), Nordeste do Brasil (g-i), e bacia do Prata (j-l). As linhas pretas representam o período de 2041 a 2070, e as linhas cinza o período de 2071-2100. Círculos preenchidos indicam DJF e círculos vazios JJA.	95
5.15 Mesmo que Figura 5.14, exceto para precipitação (mm.dia^{-1}).....	96
5.16 Média REA para mudanças sazonal e anual de temperatura do ar próximo à superfície ($^{\circ}\text{C}$) utilizando as projeções dos MCGs do CMIP5 para 2071-2100 nos cenários RCP 2.6 (a-e), RCP 4.5 (f-j), RCP 6.0 (k-o), e RCP 8.5 (p-t).....	98
5.17 Variabilidade natural observada de temperatura (ϵT , a-e) calculada para o período de 1901 a 2000, e intervalo de incerteza ($\delta\Delta T$, f-j), confiabilidade no conjunto ($\rho\Delta T$, k-o), e média dos parâmetros de desempenho (RB, p-t) e convergência (RD, u-z) do método REA para as mudanças sazonal e anual de temperatura utilizando as projeções dos MCGs do CMIP5 para 2071-2100 no cenário RCP 8.5. As unidades de ϵT e $\delta\Delta T$ estão em $^{\circ}\text{C}$, e os demais parâmetros são adimensionais.	99
5.18 Probabilidades sazonais das mudanças de temperatura excederem determinados limiares (2° , 3° , 4° , e 5°C), obtidas através das projeções dos modelos do CMIP5 para 2071-2100 no cenário RCP 8.5.....	100
5.19 Funções distribuição acumulada de mudança de temperatura ($^{\circ}\text{C}$) para os modelos do CMIP5 processados pelo método REA nos cenários RCP 2.6, RCP 4.5, RCP 6.0, e RCP 8.5, e projetadas para as regiões leste e oeste da Amazônia (a-c e d-f, respectivamente), Nordeste do Brasil (g-i), e bacia do Prata (j-l). As linhas pretas representam o período de 2041 a 2070, e as linhas cinza o período de 2071-2100. Círculos preenchidos indicam DJF e círculos vazios JJA.....	102
5.20 Mesmo que Figura 5.19, exceto para precipitação (mm.dia^{-1}).....	103
5.21 Média REA modificado para mudanças sazonal e anual de temperatura do ar próximo à superfície ($^{\circ}\text{C}$) utilizando as projeções dos MCGs do CMIP3 para 2071-2100 nos cenários SRES A2 (a-e), A1B (f-j), e B1 (k-o).	105
5.22 Intervalo de incerteza para precipitação ($\delta\Delta P$, a-e) e temperatura ($\delta\Delta T$, f-j), e confiabilidade no conjunto (ρ , k-o), derivado do método REA modificado, para as mudanças sazonal e anual utilizando as projeções dos MCGs do CMIP3 para 2071-2100 no cenário SRES A2. As unidades de $\delta\Delta P$ e $\delta\Delta T$ são mm.dia^{-1} e $^{\circ}\text{C}$, respectivamente, e ρ é adimensional.	106
5.23 Média REA modificado para mudanças sazonal e anual de temperatura do ar próximo à superfície ($^{\circ}\text{C}$) utilizando as projeções dos MCGs do CMIP5 para 2071-2100 nos cenários RCP 2.6 (a-e), RCP 4.5 (f-j), RCP 6.0 (k-o), e RCP 8.5 (p-t).....	108

5.24	Intervalo de incerteza para precipitação ($\delta\Delta P$, a-e) e temperatura ($\delta\Delta T$, f-j), e confiabilidade no conjunto (ρ , k-o), derivado do método REA modificado, para as mudanças sazonal e anual utilizando as projeções dos MCGs do CMIP5 para 2071-2100 no cenário RCP 8.5. As unidades de $\delta\Delta P$ e $\delta\Delta T$ são mm.dia^{-1} e $^{\circ}\text{C}$, respectivamente, e ρ é adimensional.....	109
5.25	Contribuição sazonal e anual das 5 funções peso (a-z) da Equação 3.8, assim como o referido peso total (aa-ae), mediado sobre as 4 sub-regiões de estudo para os modelos do CMIP3.	111
5.26	Estimativa central das mudanças sazonal e anual de temperatura ($^{\circ}\text{C}$) após a aplicação do método de inferência bayesiana, utilizando as projeções dos MCGs do CMIP3 para 2071-2100 nos cenários SRES A2 (a-e), A1B (f-j), e B1 (k-o).....	117
5.27	Estimativa central das mudanças sazonal e anual de temperatura ($^{\circ}\text{C}$) após a aplicação do método de inferência bayesiana, utilizando as projeções dos MCGs do CMIP5 para 2071-2100 nos cenários RCP 2.6 (a-e), RCP 4.5 (f-j), RCP 6.0 (k-o), e RCP 8.5 (p-t).....	118
5.28	Funções densidade de probabilidade para mudanças sazonal e anual de temperatura ($^{\circ}\text{C}$) para 2071-2100 nos cenários SRES B1 (azul), A1B (verde), e A2 (vermelho), obtidas com o método de inferência bayesiana aplicado ao conjunto CMIP3.....	119
5.29	Mesmo que Figura 5.28, exceto para precipitação (mm.dia^{-1}).....	120
5.30	Funções densidade de probabilidade para mudanças sazonal e anual de temperatura ($^{\circ}\text{C}$) para 2071-2100 nos cenários RCP 2.6 (azul escuro), RCP 4.5 (azul claro), RCP 6.0 (laranja) e RCP 8.5 (vermelho), obtidas com o método de inferência bayesiana aplicado ao conjunto CMIP5.....	121
5.31	Mesmo que Figura 5.30, exceto para precipitação (mm.dia^{-1}).....	122
5.32	Distribuição posterior dos parâmetros de precisão de cada MCG (λ_i) pertencentes ao CMIP3 e relativos à variável temperatura e o cenário SRES A1B, para cada uma das quatro sub-regiões de estudo analisadas, ordenados por sua mediana. As caixas azuis indicam os oito primeiros MCGs, as pretas os oito intermediários, e as vermelhas os oito últimos.....	127
5.33	Mesmo que Figura 5.32, exceto para precipitação.....	128
5.34	Distribuição posterior dos parâmetros de precisão específicos de cada MCG (λ_i) pertencentes ao CMIP5 e relativos à variável temperatura e o cenário RCP 4.5, para cada uma das quatro sub-regiões de estudo analisadas, ordenados por sua mediana. As caixas azuis indicam os oito primeiros MCGs, as pretas os oito intermediários, e as vermelhas os oito últimos.....	129
5.35	Mesmo que Figura 5.34, exceto para precipitação.....	130

6.1	<i>Regional Climate Change Index (RCCI)</i> para a América do Sul, utilizando as projeções climáticas dos MCGs dos conjuntos CMIP3 (a) e CMIP5 (b) para o final do século XXI. As unidades são adimensionais.	132
6.2	As quatro componentes de mudanças climáticas utilizadas no cálculo do <i>RCCI</i> para as projeções advindas do conjunto CMIP3 para o final do século XXI: <i>Regional Warming Amplification Factor (RWF)</i> , adimensional), mudança na precipitação sazonal média (ΔP , %), e mudança na variabilidade interanual de temperatura ($\Delta\sigma T$, %) e precipitação ($\Delta\sigma P$, %). Os resultados são apresentados para o verão e inverno austral (DJF e JJA, respectivamente). As porcentagens são relacionadas aos valores médios climatológicos de 1961-1990 tomados como referência.....	133
6.3	Mesmo que Figura 6.4, exceto para o conjunto CMIP5.	135
6.4	<i>RCCI</i> calculado para a América do Sul, discriminando cada cenário forçante separadamente. Na parte superior encontram-se os mapas de <i>RCCI</i> computado para os cenários SRES A2 (a), A1B (b), e B1 (c) advindos do CMIP3, e na parte inferior, o <i>RCCI</i> para os cenários RCP 8.5 (d), 6.0 (e), 4.5 (f), e 2.6 (g) advindos do CMIP5. As unidades são adimensionais.	137

LISTA DE TABELAS

	<u>Pág.</u>
3.1 Lista de modelos do conjunto CMIP3 utilizado neste estudo, contendo as resoluções horizontais aproximadas (latitude/longitude), cenários de emissões, e o número de rodadas. Os modelos estão organizados na tabela de acordo com sua resolução horizontal. Os modelos integrantes dos grupos LOW-RES, MED-RES, e HIGH-RES são indicados com as cores vermelho, verde e azul, respectivamente.	30
3.2 Lista de modelos do conjunto CMIP5 utilizados neste estudo, com a descrição das resoluções horizontais aproximadas, e número de rodadas das simulações futuras (RCPs 2.6, 4.5, 6.0, 8.5) e históricas (historical). Assim como na Tabela 3.1, os modelos estão organizados de acordo com a sua resolução horizontal.	31
3.3 Valores dos fatores n usados na determinação do $RCCI$	46
5.1 Média aritmética simples do conjunto (ΔT_{ENS} , °C), média REA (ΔT_{REA} , °C), intervalo de incerteza (δ , °C), confiabilidade no conjunto (ρ , adimensional), e média do critério de convergência (R_d , adimensional), relativos à mudança de temperatura para o verão e inverno projetado pelos modelos do CMIP3 para 2071-2100 nos cenários SRES A2, A1B, e B1. Os valores entre parênteses indicam os resultados obtidos pelo REA modificado.	112
5.2 O mesmo que na Tabela 5.1, exceto para precipitação (mm.dia ⁻¹).	113
5.3 Média aritmética simples do conjunto (ΔT_{ENS} , °C), média REA (ΔT_{REA} , °C), intervalo de incerteza (δ , °C), confiabilidade no conjunto (ρ , adimensional), e média do critério de convergência (R_d , adimensional), relativos à mudança de temperatura para o verão e inverno projetado pelos modelos do CMIP5 para 2071-2100 nos cenários RCP 2.6, 4.5, 6.0 e 8.5. Os valores entre parênteses indicam os resultados obtidos pelo REA modificado.	114
5.4 O mesmo que a Tabela 5.3, exceto para precipitação (mm.dia ⁻¹).	115
5.5 Percentis das PDFs estimadas para mudanças de temperatura (°C) no verão e inverno austral para 2071-2100 nos cenários SRES A2, A1B, e B1, obtidas com o método de inferência bayesiana aplicado ao conjunto CMIP3.	125
5.6 Percentis das PDFs estimadas para mudanças de temperatura (°C) no verão e inverno austral para 2071-2100 nos cenários RCP 2.6, 4.5, 6.0, e 8.5, obtidas com o método de inferência bayesiana aplicado ao conjunto CMIP5.	126

LISTA DE ABREVIATURAS E SIGLAS

CMIP3	- <i>Coupled Model Intercomparison Project Phase 3</i>
CMIP5	- <i>Coupled Model Intercomparison Project Phase 5</i>
CRU	- <i>Climate Research Unit</i>
EAMZ	- Região leste da Amazônia
ENOS	- El Niño Oscilação Sul
GEEs	- Gases de Efeito Estufa
GPCP	- <i>Global Precipitation Climatology Project</i>
IPCC	- <i>Intergovernmental Panel on Climate Change</i>
IPCC AR4	- <i>IPCC Fourth Assessment Report</i>
LPB	- Região da Bacia do Prata
MCGs	- Modelos de Circulação Geral
NEB	- Região Nordeste do Brasil
PCMDI	- <i>Program for Climate Model Diagnosis and Intercomparison</i>
PDF	- <i>Probability Distribution Function</i>
PNM	- Pressão ao Nível Médio do Mar
REA	- <i>Reliability Ensemble Averaging</i>
RCCI	- <i>Regional Climate Change Index</i>
RCPs	- <i>Representative Concentration Pathways</i>
RWAF	- <i>Regional Warming Amplification Factor</i>
SMAS	- Sistema de Monções na América do Sul
SRES	- <i>Special Report on Emission Scenarios</i>
WAMZ	- Região oeste da Amazônia
ZCAS	- Zonal de Convergência do Atlântico Sul
ZCIT	- Zona de Convergência Intertropical

LISTA DE SÍMBOLOS

- $B_{\xi,i}$ - Viés apresentado pelo modelo i na simulação da variável climática ζ
- CV - Coeficiente de variação
- $D_{\xi,i}$ - Distância entre a projeção produzida pelo modelo i na variável climática ζ e a projeção média do conjunto
- N - Número total de modelos
- N_{ef} - Número efetivo de modelos
- P_{m_i} - Probabilidade associada a uma dada mudança $\Delta\xi_i$ produzida pelo modelo i
- R_i - Fator de confiabilidade atribuída a um dado modelo i
- $R_{B,i}$ - Fator de confiabilidade atribuída ao modelo i em função do seu viés $B_{\xi,i}$
- $R_{D,i}$ - Fator de confiabilidade atribuída ao modelo i em função da distância $D_{\xi,i}$
- STD - Desvio padrão interanual
- X_i - Variável climática ζ . simulada para o clima presente pelo modelo i
- X_o - Variável climática ζ . observada
- Y_i - Variável climática ζ . simulada para o clima futuro pelo modelo i
- $\Delta\xi_i$ - Mudança projetada em uma variável climática ζ . por um dado modelo i
- $\tilde{\Delta}\xi$ - Mudança esperada em uma variável ζ
- ΔP - Mudança na precipitação média
- $\Delta\sigma_P$ - Mudança na variabilidade interanual da precipitação
- $\Delta\sigma_T$ - Mudança na variabilidade interanual da temperatura
- ε_ξ - variabilidade natural apresentada pela variável climática ζ
- $\pm\tilde{\delta}_{\Delta\xi}$ - Intervalo de incerteza entorno da mudança $\tilde{\Delta}\xi$
- ρ - Parâmetro de confiabilidade no conjunto
- μ - Valor médio da variável climática ζ no clima presente
- ν - Valor médio da variável climática ζ no clima futuro
- λ_i - Recíproco da variância referido como precisão da distribuição de X_i
- θ - Parâmetro adicional multiplicando λ_i para constituir a precisão da distribuição de Y_i

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
2 REVISÃO BIBLIOGRÁFICA	7
2.1. Confiabilidades e incertezas em projeções de mudanças climáticas	7
2.2. Projeções de mudanças climáticas na América do Sul e incertezas relacionadas.....	16
3 DADOS E MÉTODOS	25
3.1. Descrição dos dados e região de estudo.....	25
3.2. Métodos.....	32
3.2.1. Reliability Ensemble Averaging (REA)	33
3.2.2. Inferência Bayesiana	39
3.2.3. Índice de Mudança Climática Regional (RCCI)	44
4 SIMULAÇÕES DOS PADRÕES CLIMÁTICOS OBSERVADOS.....	49
4.1. Modelos do CMIP3	49
4.2. Modelos do CMIP5	61
5 PROJEÇÕES DE MUDANÇAS CLIMÁTICAS NA AMÉRICA DO SUL: QUANTIFICAÇÃO DE INCERTEZAS E PROBABILIDADES.....	73
5.1. Resultados obtidos a partir do método REA	85
5.2. Resultados obtidos a partir da inferência bayesiana	116
6 IDENTIFICAÇÃO DE HOTSPOTS NA AMÉRICA DO SUL.....	131
7 CONSIDERAÇÕES FINAIS	141
7.1. Conclusões	141
7.2. Sugestões para trabalhos futuros.....	145
REFERÊNCIAS BIBLIOGRÁFICAS	147

APÊNDICE A – SIMULAÇÕES INDIVIDUAIS DOS MODELOS	157
APÊNDICE B – PROJEÇÕES INDIVIDUAIS DOS MODELOS	179
ANEXO A – PRIMEIRO ARTIGO PUBLICADO NO PERIÓDICO	
<i>THEORETICAL AND APPLIED CLIMATOLOGY</i>	191
ANEXO B – SEGUNDO ARTIGO PUBLICADO NO PERIÓDICO	
<i>CLIMATIC CHANGE</i>	213
ANEXO C – TERCEIRO ARTIGO PUBLICADO NO PERIÓDICO	
<i>THEORETICAL AND APPLIED CLIMATOLOGY</i>	229

1 INTRODUÇÃO

Apesar dos enormes avanços científicos e computacionais das últimas décadas terem possibilitado um melhor entendimento da dinâmica do sistema climático global e contribuído consideravelmente para as análises das possíveis causas e futuros impactos das mudanças climáticas, as incertezas nas projeções climáticas baseadas nos modelos numéricos continuam a ser altas, principalmente na escala regional. As incertezas nas projeções futuras de mudanças climáticas advêm de diversas fontes, e são introduzidas na sequência de etapas envolvidas no processo de modelagem climática, o que acaba produzindo uma cascata de incertezas (KNUTTI et al., 2010; GIORGI, 2005).

Vários fatores contribuem para as incertezas nas simulações ou projeções¹ climáticas, tais como: comportamento estocástico e não linear dos processos inerentes ao sistema climático (o que inclui as variações naturais do clima ou variabilidade interna), aspectos aleatórios das forçantes radiativas² naturais e antropogênicas (e.g., erupções vulcânicas e emissões antrópicas de gases de efeito estufa e aerossóis), *feedback*³ do sistema climático às forçantes, conhecimento insuficiente das condições iniciais e de fronteira do sistema climático como um todo, e incertezas inerentes aos modelos climáticos. Adicionalmente, as incertezas inerentes aos modelos climáticos são comumente subdivididas em: incertezas nas parametrizações físicas (parâmetros que controlam os processos físicos que ocorrem na escala sub-grade dos modelos, tais como convecção cúmulus e mistura turbulenta na camada limite planetária), e incertezas estruturais advindas das esco-

¹ Doravante, o termo “**simulação**” irá referir-se preferencialmente àqueles experimentos numéricos com modelos climáticos realizados para períodos de clima observado (e.g., 1901 a 2010), e o termo “**projeção**” irá referir-se àqueles experimentos para períodos futuros (e.g., 2020 a 2100) realizados mediante uma dada forçante climática.

² **Forçante radiativa** ou **forçante climática** refere-se à mudança no saldo de irradiância (descendente menos ascendente) no topo da tropopausa devido a uma alteração em um agente externo de mudança climática, tais como, por exemplo, uma mudança na concentração de dióxido de carbono ou na irradiância solar.

³ **Feedback** ou **retroalimentação**, mas especificamente como tratado aqui, *feedback* climático, é um mecanismo de interação entre processos no sistema climático, no qual o resultado de um processo inicial dispara mudanças em um segundo processo, que em contrapartida influencia o processo anterior (e.g., *feedback* gelo/albedo, *feedback* de nuvens, etc.). Um *feedback* positivo intensifica o processo original, enquanto que um *feedback* negativo o atenua.

lhas feitas durante a codificação dos processos resolvidos pela grade do modelo (GIORGI, 2005; COLLINS, 2007; TEBALDI; KNUTTI, 2007; KNUTTI et al., 2010).

Na tentativa de avaliar a ampla gama de incertezas supracitadas, duas abordagens são geralmente empregadas: o uso de conjuntos de simulações realizadas por vários modelos com diferentes condições iniciais e de fronteira (COLLINS, 2007; TEBALDI; KNUTTI, 2007), e o uso de conjuntos de simulações geradas por perturbação física de um mesmo modelo (MURPHY et al., 2007). Adicionalmente, esses conjuntos podem utilizar vários cenários de emissões de gases de efeito estufa (GEEs) e aerossóis, tais como aqueles desenvolvidos no Relatório Especial sobre Cenários de Emissões (do acrônimo em inglês, SRES) do Painel Intergovernamental de Mudanças Climáticas (do acrônimo em inglês, IPCC), que se baseiam em quatro grupos de cenários, os quais tentam, essencialmente, cobrir a diversa gama de possíveis emissões futuras sob diferentes cenários de não intervenção governamental (NAKICENOVIC et al., 2000).

Uma vez que as projeções de mudanças climáticas possuem um intrínseco nível de incerteza (GIORGI, 2005), considerações probabilísticas devem ser levadas em conta ao analisarmos os resultados sobre o clima futuro. Por outro lado, o grau de incerteza depende profundamente das variáveis analisadas, assim como, das escalas espaciais e temporais investigadas. Muitas das componentes do sistema climático são caóticas (e.g., aquelas referentes à variabilidade climática interna), mas acredita-se ser previsível em grandes escalas espaciais, e em escalas temporais decenais ou mais longas (KNUTTI, 2008).

Diversos estudos têm identificado a América do Sul como uma das regiões no mundo que podem ser profundamente impactadas caso as atuais projeções de mudanças climáticas se concretizem, principalmente na região tropical do seu continente (BAETTIG et al., 2007; IPCC, 2007; MEEHL, 2007a; DIFFENBAUGH; GIORGI, 2012; TORRES et al., 2012; IPCC, 2013; SILLMANN et al., 2013a, b). Esta região é vulnerável às variabilidades e extremos climáticos atuais (especialmente aqueles relacionados a enchentes, enxurradas, e secas), e pode ser afetada principalmente na forma de extremos climáticos mais frequentes na iminência de um planeta mais quente (MARENGO et al., 2010a, b,

2011; RUSTICUCCI et al., 2010; DONAT et al., 2013; SILLMANN et al., 2013a, b). Com uma economia notadamente baseada na produção agrícola, altamente dependente da geração hidroelétrica, e sujeito a inúmeros problemas sociais e ambientais associados aos padrões de desenvolvimento e urbanização, o continente sul-americano sofre constantemente com extremos de temperatura e precipitação que causam enormes danos econômicos e sociais, tais como perdas humanas e em safras agrícolas.

Nos últimos anos, inúmeros estudos têm analisado as projeções de mudanças climáticas na América do Sul (BOULANGER et al., 2006, 2007; VERA et al., 2006; VERA; SILVESTRI, 2009; BOMBARDI; CARVALHO, 2009; SETH et al., 2010; JUNQUAS et al., 2012; IPCC, 2012), baseando-se principalmente nos modelos de circulação geral (MCGs) provenientes do *Coupled Model Intercomparison Project Phase 3* (CMIP3; MEEHL et al., 2007b), e mais recentemente, baseando-se na nova geração de MCGs (IPCC, 2013; BLÁZQUEZ; NUÑEZ, 2013; JOETZJER et al., 2013; JONES; CARVALHO, 2013) integrantes do *Coupled Model Intercomparison Project Phase 5* (CMIP5; TAYLOR et al., 2012). Vários estudos também analisaram as projeções climáticas nessa região utilizando alguns métodos de *downscaling* dos resultados dos MCGs (NUÑEZ et al., 2008; URRUTIA; VUILLE, 2009; BOULANGER et al., 2010; MARENGO et al. 2009, 2010b, 2012; BIDEGAIN et al., 2012; CHOU et al., 2012). Entretanto, entre estes estudos, nenhum dos modelos apresentou um desempenho superior em representar o clima observado. O desempenho dos modelos variou de acordo com a região, escala temporal, e variáveis analisadas. Além disso, poucos desses estudos analisaram as incertezas nas projeções de mudanças climáticas sobre a América do Sul de uma forma sistemática e probabilística, e na maioria dos casos, utilizou somente um pequeno subconjunto de MCGs disponíveis no CMIP3 e CMIP5.

Um método comumente aplicado para sintetizar os resultados de uma previsão (ou projeção)⁴ por conjunto é calcular uma média aritmética simples dos seus membros, no

⁴ O termo “previsão ou projeção por conjunto” refere-se aqui à inúmeros experimentos realizados com diversos MCGs, podendo também ser denominados como previsão (ou projeção) por conjunto multimodelos (*multimodel ensemble prediction*).

qual para cada membro é atribuído igual probabilidade de ocorrência. Esta abordagem tem-se mostrado útil em produzir resultados mais próximos das observações, que são melhores do que qualquer membro individual pertencente ao conjunto de modelos (EBERT, 2001). Outras técnicas propostas para lidar com as diferentes projeções climáticas são: selecionar um subconjunto de modelos com os melhores desempenhos sobre uma região (e conseqüentemente descartar aqueles modelos com os piores desempenhos), ponderar os resultados de todos os modelos do conjunto (e.g., atribuir diferentes pesos aos modelos de acordo com seu desempenho em simular o clima atual), e utilizar uma abordagem probabilística, no qual os resultados de vários modelos são empregados para produzir uma função densidade de probabilidade (do acrônimo em inglês, PDF) para as variáveis projetadas (GIORGI, 2005; COLLINS, 2007). Adicionalmente, com relação à abordagem probabilística, diversas metodologias têm sido propostas para gerar estas PDFs através de processamentos estatísticos de conjuntos médios ou grandes de simulações realizadas com modelos de variada complexidade (WIGLEY; RAPER, 2001; GIORGI; MEARNS, 2002, 2003; GREENE et al., 2006; MURPHY et al., 2007; TEBALDI et al., 2005; TEBALDI; KNUTTI, 2007; XU et al., 2010; e citações inclusas).

Portanto, baseado na complexidade dos problemas supracitados e da necessidade remanescente de informações detalhadas sobre as incertezas envolvidas nas projeções de mudanças climáticas na América do Sul, este estudo considerará as seguintes questões: **Os modelos climáticos atuais podem projetar, de maneira confiável, o clima futuro da América do Sul? Como podemos estimar as incertezas nas projeções de clima futuro, de forma que esta informação possa ser usada em estudos de impacto, adaptação, e vulnerabilidade?** Dessa forma, o objetivo geral desse estudo será avaliar as principais incertezas envolvidas nas projeções de mudanças climáticas na América do Sul geradas por MCGs, assim como, identificar como essas 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 das variáveis precipitação e temperatura do ar próximo à superfície⁵ na América do Sul pelos inúmeros modelos integrantes do conjunto CMIP3, assim como, do recém-disponibilizado conjunto CMIP5;
- Identificar as incertezas envolvidas nas projeções climáticas para a região de estudo em diferentes períodos do século XXI, focando-se principalmente naquelas incertezas relacionadas às variabilidades intermodelos e devido a diferentes cenários de emissões de GEEs e aerossóis;
- Produzir projeções climáticas médias e probabilísticas das variáveis precipitação e temperatura para toda América do Sul, levando-se em consideração as incertezas envolvidas;
- E finalmente, produzir para todo o continente sul-americano um índice de mudanças climáticas, no intuito de identificar aquelas áreas que possivelmente podem ser mais impactadas (*hotspots*⁶), mediante às projeções climáticas atuais.

Este trabalho está organizado em 7 capítulos. No capítulo 2, faz-se uma breve revisão bibliográfica sobre as incertezas envolvidas em projeções de mudanças climáticas, assim como, sobre as projeções de mudanças climáticas na América do Sul e incertezas relacionadas. Os dados e metodologias que serão empregados estão descritos no capítulo 3. No capítulo 4, são apresentadas as simulações dos padrões climáticos observados no continente sul-americano provenientes dos conjuntos CMIP3 e CMIP5. As projeções climáticas e a quantificação de incertezas e probabilidades estão inseridas no capítulo 5, e a identificação dos *hotspots* climáticos na América do Sul é apresentada no capítulo 6. Finalmente, no capítulo 7, estão contidas as considerações finais e sugestões para trabalhos futuros.

⁵ Doravante, a variável temperatura do ar próximo à superfície será denominada apenas de temperatura.

⁶ A palavra “*hotspots*” será utilizada em todo manuscrito para referir-se às áreas cujas mudanças climáticas regionais projetadas são grandes, e nas quais um possível impacto pode ser mais exacerbado.

2 REVISÃO BIBLIOGRÁFICA

2.1. Confiabilidades e incertezas em projeções de mudanças climáticas

O sistema climático consiste de cinco componentes principais que interagem entre si: a atmosfera, a hidrosfera, a criosfera, a litosfera, e a biosfera. Este sistema modifica-se com o tempo pela influência de sua própria dinâmica interna e por causa de forçantes externas naturais e antropogênicas (Figura 2.1; MOSS et al., 2010). Nesse sentido, o termo “mudança climática” refere-se a uma variação no estado do clima de uma região ou do planeta como um todo, decorrente de uma perturbação no sistema climático. Uma mudança climática pode ser identificada como alterações no valor médio do clima e/ou na variabilidade de seus elementos (e.g., precipitação, temperatura, vento, etc.), e que persiste por um período longo, tipicamente acima de várias décadas. As mudanças climáticas podem ser atribuídas tanto à variabilidade interna natural do sistema climático quanto à forçantes externas atuando sob este sistema (IPCC, 2007; HEGERL et al., 2007).

Desde a sua formação, há cerca de 4,6 bilhões de anos, a Terra sofreu inúmeras mudanças em seu clima devido à variabilidade natural do sistema climático. Essas mudanças naturais ocorreram principalmente devido às seguintes forçantes externas:

- Variações na estrutura e composição da atmosfera terrestre durante a sua formação;
- Deriva dos continentes;
- Variações nos parâmetros orbitais, como por exemplo, na inclinação do eixo de rotação e/ou características da órbita que a Terra faz ao redor do Sol;
- E erupções vulcânicas, devido ao lançamento de partículas na atmosfera, que podem ficar suspensas por até vários meses em altos níveis da atmosfera.

Tais fatores, cíclicos na maioria dos casos, alteram o balanço de radiação no sistema climático e causam grandes mudanças na temperatura do planeta. No entanto, exceto para as erupções vulcânicas, estas mudanças ocorrem na escala de milhares de anos, ou seja, muito lentas para serem percebidas durante a vida dos seres humanos. Por essa razão, as mudanças climáticas que os cientistas vêm observando nas últimas décadas

são mais intensas e rápidas do que aquelas observadas por algum fator natural conhecido. Por outro lado, outras forçantes externas que também podem contribuir significativamente para uma mudança no clima são aquelas originadas pelas atividades humanas, tais como mudança na composição da atmosfera e mudança no uso do solo, e que ocorrem em escalas de tempo compatíveis com aquelas variações abruptas observadas no clima da Terra nas últimas décadas (MEEHL, 2007a).

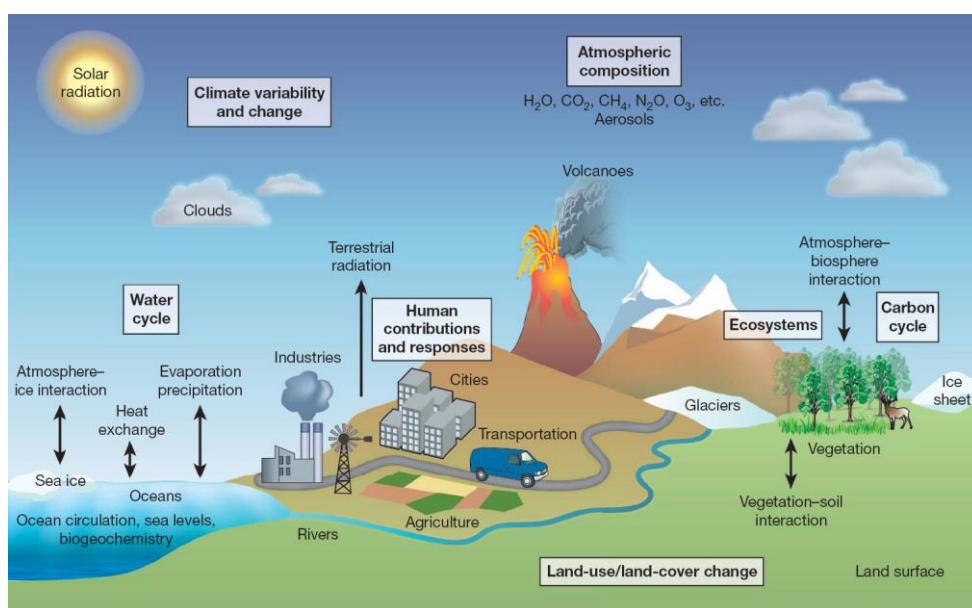


Figura 2.1 - Principais processos naturais e antropogênicos influenciando o comportamento sistema climático.

Fonte: Moss et al. (2010).

A distinção entre os efeitos causados pelas diversas forçantes externas e pela variabilidade natural do sistema climático requer uma comparação cautelosa entre as mudanças observadas e aquelas esperadas como resultado de determinadas forçantes. Os estudos que tratam desse tema são conhecidos como estudos de detecção e atribuição de mudanças climáticas, e baseiam-se no entendimento físico aprofundado dos mecanismos e *feedbacks* que regem o sistema climático, e utilizam um tratamento estatístico bastante complexo e cauteloso nos dados observados (HEGERL et al., 2007; STOTT et al., 2010).

Uma vez que os processos que ocorrem no sistema climático não podem ser reproduzidos em sua totalidade em um experimento laboratorial, os cientistas utilizam certos modelos numéricos, tais como os modelos climáticos, ou modelos do sistema climático, para compreender as possíveis respostas e comportamentos desse sistema quando da atuação de determinadas forçantes, assim como para projetar o clima do planeta nas próximas décadas e séculos. Um modelo climático consiste de um sistema de equações diferenciais discretizadas de alta complexidade (transformadas em um código computacional contendo milhares de linhas de comando) que representam as leis físicas, químicas, e biológicas que regem o comportamento das componentes do sistema climático e suas interações. Por ser o sistema climático altamente complexo, por conter inúmeros processos não-lineares e estocásticos, e inúmeros processos ainda desconhecidos ou pouco entendidos pelos cientistas, os modelos climáticos são representações aproximadas desse sistema, que vão evoluindo com o surgimento de novas descobertas científicas e novas metodologias de análise e de medições. No entanto, à medida que um modelo é capaz de reproduzir as características principais do sistema climático e suas variações, aumenta-se sua credibilidade para simular mudanças no clima. Além disso, apesar da complexidade envolvida na simulação do sistema climático, em grandes escalas espaciais, e em escalas temporais decenais ou mais longas, estima-se ser possível simular o clima de forma razoável e com certa confiabilidade (KNUTTI, 2008).

Portanto, as projeções de mudanças climáticas atuais baseiam-se exclusivamente no uso de modelos climáticos, tais como os MCGs que serão tratados neste estudo. Apesar do contínuo aprimoramento desses modelos e o enorme crescimento do poder computacional nas últimas décadas, possibilitando aos cientistas a inclusão de inúmeros processos físicos e dinâmicos e um aumento da resolução espacial e temporal com a qual eles são configurados, eles ainda continuam a ser processados com baixa resolução espacial (da ordem de centenas de quilômetros) e parametrizações físicas inadequadas (em parte devido à dificuldade da representação de alguns processos físicos e dinâmicos numa escala espacial menos refinada (ou mais grosseira), e em outra, devido ao ainda pouco conhecimento sobre todos os processos envolvidos) (GIORGI, 2005; COLLINS, 2007;

RÄISÄNEN, 2007; TEBALDI; KNUTTI, 2007; ANNAN; HARGREAVES, 2010; KNUTTI et al., 2010). Dessa forma, os MCGs não possuem uma perfeita representação do clima atual e não possibilitam um detalhamento mais regional das mudanças climáticas, imprescindíveis nos estudos de adaptação, impacto e vulnerabilidade. Por isso, faz-se ainda necessário a utilização de técnicas de regionalização (conhecidas como *downscaling*) para traduzir as informações fornecidas por esses modelos numa escala espacial mais refinada. Entre as técnicas comumente utilizadas podemos citar o uso de modelos regionais climáticos (*downscaling* dinâmico), e o uso de técnicas de *downscaling* estatístico, tais como funções ortogonais empíricas, redes neurais, e funções de transferência (HEWITSON; CRANE, 2006; BOULANGER et al., 2006, 2007, 2010; CHRISTENSEN et al., 2007a,b; GIORGI 2008; MARENGO et al. 2009, 2010b, 2012).

No entanto, muitas vezes, utilizando o mesmo período e o mesmo cenário de emissões ou forçantes, diferentes MCGs e/ou técnicas de regionalização fornecem resultados divergentes, devido à ampla gama de incertezas inseridas nas diversas etapas inerentes à produção de uma projeção, o que impede uma afirmação mais contundente sobre os padrões apresentados. Por outro lado, vale ressaltar que incerteza não é o mesmo que erro, uma vez que se tivéssemos um perfeito modelo do sistema climático, uma perfeita rede de observações, e um perfeito conhecimento do comportamento das forçantes externas agindo sobre o sistema, parte das incertezas adicionadas ao processo de projeção climática seria eliminada, mas remanesceriam aquelas incertezas associadas à natureza estocástica e não linear das projeções de mudanças climáticas (GIORGI, 2005).

De uma forma mais ampla, a sequência de etapas envolvidas em uma projeção de mudanças climáticas permeiam inúmeras áreas do conhecimento científico e diversos setores da sociedade, e com isso, as incertezas inerentes ao processo de projeção não se restringem somente ao processo de simulação climática. Dentre as etapas necessárias ou intrínsecas a um processo de projeção climática, podemos destacar: i) adoção de hipóteses socioeconômicas, ii) produção de cenários de emissões de GEE e aerossóis, 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 regio-

nais de mudanças climáticas utilizando técnicas de *downscaling*, e finalmente vi) avaliação dos possíveis impactos na sociedade e na biodiversidade do planeta, geralmente utilizando também modelos numéricos designados para esse fim. Além disso, diversas considerações adicionais devem ser avaliadas durante os procedimentos anteriores, tais como: respostas políticas às projeções de mudanças climáticas na forma de adaptação e mitigação, interações e *feedbacks* entre as inúmeras componentes do sistema climático, atuação de forçantes naturais, e mudanças no uso da terra (Figura 2.2).

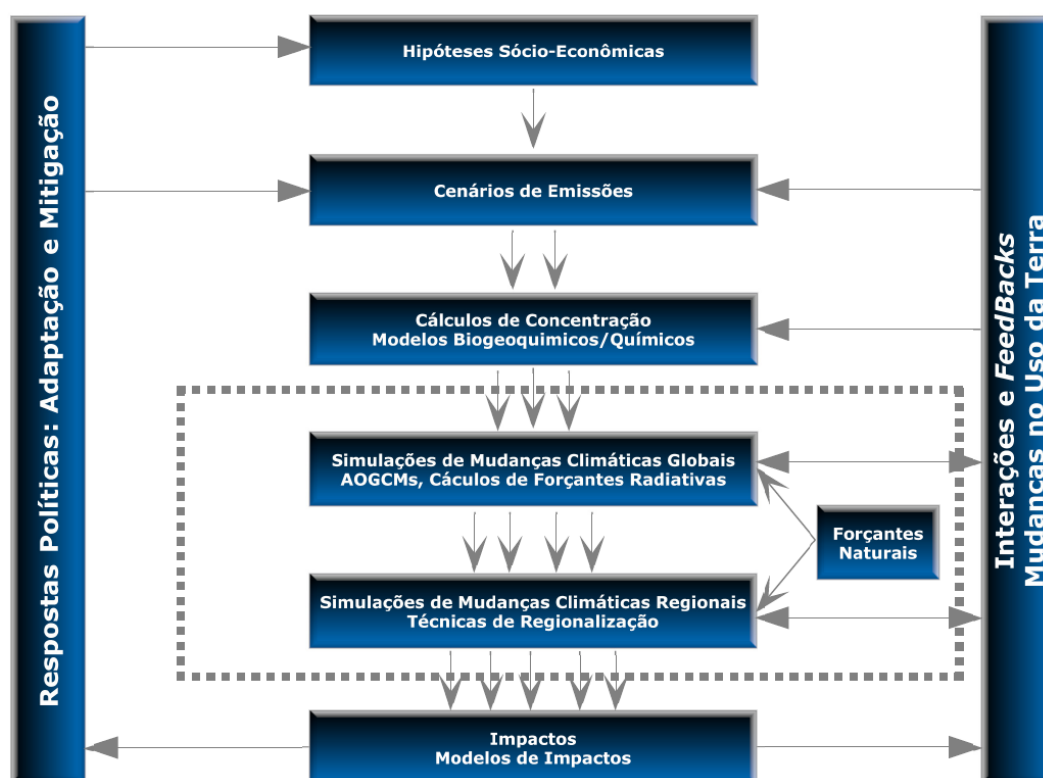


Figura 2.2 - Cascata de incertezas em uma projeção de mudanças climáticas. A linha tracejada engloba o segmento de simulação climática da cascata. A sigla AOGCMs significa *atmosphere – ocean general circulation models*.

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

Cada etapa citada anteriormente é caracterizada por uma incerteza que é transmitida para a próxima etapa em um processo de cascata (Figura 2.2), que ao final determina a incerteza total da projeção (Mearns et al., 2001; Giorgi, 2005). Neste estudo focaremos principalmente naquelas incertezas relacionadas às etapas de simulação climática, espe-

cificamente às variabilidades intermodelos (MCGs), e naquelas incertezas relacionadas a diferentes cenários de emissões de GEEs e aerossóis. Os elementos que contribuem para as incertezas no segmento das simulações e projeções climáticas são representados esquematicamente na Figura 2.3. Nas projeções climáticas com MCGs as incertezas podem ser divididas em três fatores principais: i) incertezas nas configurações dos modelos, ii) incertezas devido a variabilidade interna do modelo, e iii) incertezas associadas à natureza estocástica das forçantes naturais futuras.

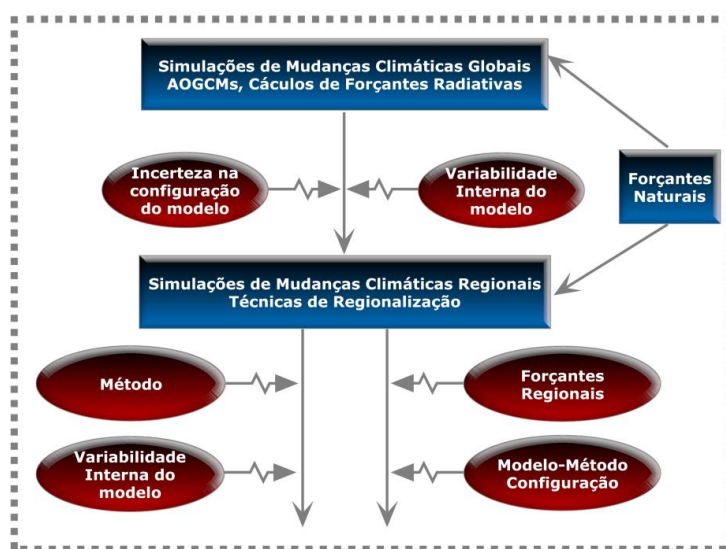


Figura 2.3 - Segmento da simulação climática da cascata de incertezas representada na Figura 2.1.

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

As incertezas advindas da configuração dos modelos fornecem uma contribuição dominante para a cascata de incertezas (IPCC, 2001; Giorgi, 2005). Elas relacionam-se com a escolha de uma dada configuração do modelo (e.g., resolução horizontal e vertical), esquemas de parametrização física (e.g., parametrização de cúmulos, de superfície), valores de certos parâmetros dentro do modelo, e algoritmos numéricos. A escolha de certa configuração é geralmente baseada em considerações físicas e computacionais, que diferem entre os vários modelos de um conjunto, tal como os do CMIP3 e CMIP5. Com isso, diferentes modelos podem simular respostas climáticas bastante diferentes para uma mesma forçante climática (IPCC 2001, 2007). Estas mesmas diferenças po-

dem ser também encontradas quando são usadas diferentes parametrizações físicas e/ ou parâmetros dentro de um modelo individual (GIORGI, 2005; MURPHY et al., 2007). Além disso, as incertezas devido à configuração dos modelos aumentam quando analisamos a escala regional.

A contribuição da variabilidade interna dos modelos para as incertezas é atribuída à dependência que as simulações climáticas apresentam com relação à variabilidade não forçada do sistema (e.g., o El Niño Oscilação Sul é o modo de variabilidade não forçada mais bem conhecido), e com relação às condições iniciais dos estados dos oceanos e superfícies. Entretanto, quando avaliando as mudanças em médias decenais, a incerteza associada com a variabilidade interna dos modelos aparenta ser muito menor do que aquela relacionada à configuração dos modelos (GIORGI; FRANCISCO, 2000). Finalmente, a terceira fonte de incertezas está associada com a natureza estocástica das forçantes naturais futuras. No entanto, estimativas dessa fonte de incertezas mostram que ela pode ser expressiva, embora menos importante do que as incertezas relacionadas com as forçantes antropogênicas (STOTT; KETTLEBOROUGH, 2002; GIORGI, 2005).

Quando as projeções climáticas dos MCGs são traduzidas para a escala regional via métodos de regionalização ou *downcalling*, incertezas adicionais são agregadas às projeções (Figura 2.3). A principal delas diz respeito a escolha de um específico MCG para fornecer as condições iniciais e de fronteira para alimentar o processo de *downscalling*. Além disso, as forçantes subgrade dos MCGs, tais como complexa topografia e linha costeira, podem afetar profundamente o padrão de mudanças climáticas local, tanto no sinal quanto na magnitude. Ademais, a escolha dos diferentes métodos de regionalização pode afetar a simulação climática. Adicionalmente, as técnicas de regionalização também são caracterizadas por incertezas na configuração e por incertezas relacionadas com a variabilidade interna (GIORGI, 2005).

Tendo em vista às inúmeras etapas necessárias para a produção de uma projeção climática, e as inúmeras incertezas supracitadas associadas a cada uma dessas etapas, duas metodologias são geralmente empregadas nas simulações com MCGs para extrair-se um

amplo intervalo plausível de possibilidades e aumentar a confiabilidade nas projeções: o uso de conjuntos de simulações/projeções realizadas por vários modelos com diferentes condições iniciais e de fronteira (COLLINS, 2007; TEBALDI; KNUTTI, 2007), e o uso de conjuntos de simulações/projeções geradas por perturbação física de um mesmo modelo (MURPHY et al., 2007). Além disso, esses experimentos numéricos podem utilizar vários cenários de emissões de GEEs e aerossóis para tentar levar em consideração as possíveis emissões futuras. Por outro lado, dada uma extensa variedade de experimentos, conjuntos de MCGs, e cenários de emissões, surge a difícil tarefa de sintetizar todas essas informações, atribuir uma incerteza relacionada aos resultados, e transmitir esses resultados para outras áreas do conhecimento científico, assim como, para políticos e tomadores de decisão.

Nesse sentido, uma forma comumente empregada para sintetizar os resultados de uma previsão por conjunto é a produção de uma média aritmética simples, onde para cada membro é atribuído igual probabilidade de ocorrência. Esta metodologia tem-se demonstrado hábil em produzir resultados mais próximos aos observados do que qualquer membro isolado do conjunto (EBERT, 2001). Outra técnica para lidar com as diferentes projeções climáticas é a utilização de aproximações probabilísticas, na qual os resultados de diferentes MCGs ou integrações de um mesmo modelo são utilizados para a produção de uma PDF (GIORGI, 2005; COLLINS, 2007). A largura ou espalhamento da PDF representa uma medida da incerteza na projeção, e a integral entre dois limiares estabelecidos indicam a probabilidade de sua ocorrência. Nos últimos anos várias metodologias têm sido propostas para a produção dessas funções baseadas em processamentos estatísticos de grandes ou médios conjuntos de simulações realizadas com modelos de variada complexidade (WIGLEY; RAPER, 2001; GIORGI; MEARNNS, 2002, 2003; GREENE et al., 2006; MURPHY et al., 2007; TEBALDI et al., 2005, 2007; XU et al. 2010; e citações inclusas).

Giorgi e Mearns (2002, 2003) propuseram a aplicação de um método baseado na média ponderada de diferentes MCGs que levam em consideração a “confiabilidade” de cada modelo, denominado *Reliability Ensemble Averaging* (REA). No método REA esta confiabilidade leva em consideração a destreza de cada modelo em simular o clima obser-

vado (viés) e o grau de convergência de sua projeção de mudanças climáticas com relação aos outros modelos do conjunto. Este método também possibilita uma avaliação da credibilidade da média ponderada das projeções, o cálculo de um intervalo de incerteza e a produção de resultados probabilísticos. Por seus vários tipos de informações geradas e a simplicidade de sua aplicação, o método REA é considerado uma ferramenta flexível que pode ser aplicado tanto na escala global quanto regional, e tem sido amplamente utilizado na literatura (XU et al., 2010; MOISE; HUDSON, 2008; OSORIO; GALIANO, 2011, 2013; WEILAND et al., 2012). Adicionalmente, Xu et al. (2010), avaliando este método para o leste da Ásia, propuseram a exclusão do parâmetro de convergência e a inclusão de múltiplas variáveis e estatísticas no cálculo do peso atribuído a cada modelo baseado em seu desempenho com relação ao clima observado.

Telbaldi et al. (2005) propôs um modelo estatístico bayesiano, no qual informações provenientes de vários MCGs e observações podem ser combinados para determinar distribuições de probabilidade de mudanças futuras de uma determinada variável climática numa escala regional. As distribuições derivadas de hipóteses estatísticas incluem o critério de viés e convergência nos pesos relativos implicitamente incorporados aos membros do conjunto de MCGs. Esta aproximação pode ser considerada como uma extensão e elaboração do método REA. Para ilustração do método bayesiano, os autores utilizaram a variável temperatura média em superfície de nove MCGs simulados no cenário SRES A2 para o inverno e verão boreal, agregados sobre 22 regiões continentais definidas em Giorgi e Mearns (2002) e em duas médias de 30 anos representativas das condições do clima presente e futuro. Os formatos das funções densidade de probabilidade das mudanças de temperatura variaram amplamente sobre as diversas regiões, desde curvas unimodais para regiões onde os resultados dos modelos convergem (ou projeções muito distantes da média são descartadas) até curvas multimodais onde os modelos que não puderam ser descartados no critério do viés fornecem projeções divergentes. Os resultados sugeriram que uma aproximação probabilística, particularmente na forma de um modelo bayesiano, é uma ferramenta útil a partir da qual podemos sintetizar a informação proveniente de um conjunto de simulações. As distribuições de probabilidade

de mudanças de temperatura revelaram características tais como multimodalidade e longas caudas que não podem ser de outro modo facilmente discernido.

2.2. Projeções de mudanças climáticas na América do Sul e incertezas relacionadas

As projeções climáticas para a América do Sul apresentadas no IPCC AR4 indicam um aumento de temperatura média para toda região de até 1°C nas próximas décadas. Para o final do século XXI, este aumento poderá chegar a aproximadamente 3°C em um cenário otimista de baixas emissões (SRES B1) e de até 5°C em um cenário pessimista de altas emissões (SRES A2) (a especificação dos cenários utilizados no CMIP3 e CMIP5 serão descritos na Seção 3.1), em que a magnitude das maiores mudanças estão localizadas na porção tropical do continente sul americano (CHRISTENSEN et al., 2007b; MEEHL et al., 2007a). Apesar das enormes incertezas relacionadas aos padrões de mudança no regime de precipitação apresentados, os resultados indicam para o período de 2090-2099 (em um cenário intermediário de emissões – SRES A1B) um aumento de precipitação no verão austral entre 10 e 20% no oeste da Amazônia, Peru, Equador, Colômbia, sul do Brasil e norte da Argentina, e um decréscimo durante o inverno austral de mais de 20% no leste da Amazônia e Nordeste do Brasil, quando comparado a 1980-1999 (CHRISTENSEN et al., 2007b; IPCC, 2007; MARENGO et al., 2010b). Com relação aos índices extremos de precipitação e temperatura para esse mesmo período e cenário, os resultados indicam um aumento na intensidade de eventos de precipitação em quase todo o continente, sendo mais acentuado no oeste da Amazônia, Peru, Equador, Colômbia e sul do Brasil, Uruguai e norte da Argentina, e aumento no número de dias secos consecutivos no leste da Amazônia, nordeste brasileiro e Chile (TEBALDI et al., 2006).

Apesar do conjunto robusto de MCGs reunidos no CMIP3 e utilizados no IPCC AR4 terem contribuído muito para o conhecimento atual do clima e das mudanças climáticas, os resultados apresentados para algumas variáveis e regiões possuem enormes incertezas, principalmente devido à baixa qualidade da representação do clima presente e resultados divergentes nas projeções futuras para um mesmo cenário de emissões. Especi-

ficamente sobre a América do Sul, vários estudos avaliaram as simulações e projeções do CMIP3 (BOULANGER et al., 2006, 2007; VERA et al., 2006; VERA; SILVESTRE, 2009; BOMBARDI; CARVALHO, 2009; SETH et al. 2010; MINVIELLE; GARREAUD, 2011; JUNQUAS et al. 2012), e alguns já estão sendo publicados na literatura com o novo conjunto CMIP5, que está sendo utilizado no IPCC AR5 (BLÁZQUEZ; NUÑEZ, 2013; IPCC, 2013; JOETZJER et al., 2013; JONES; CARVALHO, 2013). Segundo esses estudos, nenhum modelo tem um desempenho superior em representar o clima observado. O desempenho dos MCGs varia de acordo com a região, a escala temporal e espacial, e variáveis analisadas, o que dificulta a sintetização dos resultados e sua divulgação para um público leigo. Além disso, poucos estudos supracitados analisaram as incertezas nas projeções de mudanças climáticas na América do Sul de forma quantitativa e probabilística, e vários usaram apenas um pequeno subconjunto de MCGs disponíveis no CMIP3 e CMIP5, e/ou avaliaram apenas uma região específica do continente.

Vera et al. (2006) avaliou a precipitação simulada sobre a América do Sul usando 7 MCGs do CMIP3 no período de 1970 a 1999, assim como as mudanças projetadas nessa variável para 2070-2099 no cenário SRES A1B. Segundo esses autores, a maior parte dos modelos é capaz de reproduzir as características básicas do ciclo sazonal de precipitação na região, como a sua migração noroeste-sudeste na parte tropical do continente, e o máximo de precipitação observado no sul dos Andes. Todavia, observaram-se grandes discrepâncias nestes modelos em simular a intensidade, localização e evolução sazonal da Zona de Convergência do Atlântico Sul (ZCAS), assim como a reprodução da precipitação durante o inverno sobre o sudeste da América do Sul. Além disso, esses autores identificaram que o conjunto de modelos analisados possuem problemas na representação quantitativa e acurada da precipitação sazonal sobre as principais bacias do continente, como a bacia amazônica e a da Prata. Vera et al. (2006) também enfatizou o efeito da baixa resolução espacial para descrever a topografia, resultando em uma má representação da localização e intensidade da precipitação sobre a Cordilheira dos Andes, assim como enfatizado posteriormente por Minvielle e Garreaud (2011). Com relação aos cenários futuros, Vera et al. (2006) identificaram um aumento na precipitação de

verão sobre o norte dos Andes e sudeste da América do Sul, um decréscimo da precipitação durante o inverno sobre a maior parte do continente, assim como uma redução de precipitação na porção sul dos Andes em todas as estações.

Boulangier et al. (2006, 2007) analisaram os padrões espaciais climatológicos e o ciclo sazonal de temperatura e precipitação na América do Sul simulados por 7 MCGs do CMIP3 na última metade do século XX, assim como as projeções desses mesmos modelos para o século XXI nos cenários de emissões SRES A2, A1B e B1, utilizando redes neurais e inferência bayesiana para combinar e avaliar o desempenho dos resultados dos modelos. Eles constataram que as regiões com os piores desempenhos dos modelos na representação da climatologia observada de temperatura estão localizadas no extremo sul da América do Sul e ao longo de praticamente toda a costa oeste sul-americana. Para o final do século XXI, no cenário SRES A2, os resultados projetam um aumento de temperatura média anual de até 4°C na porção tropical da região, e entre 2 a 3°C no sul do continente, quando comparado ao período de 1976 a 2000. Além disso, os autores encontraram uma tendência de aumento da amplitude do ciclo sazonal de temperatura no sul da América do Sul, e uma tendência de atenuação dessa amplitude no norte do continente, indicando a possibilidade de invernos muito mais amenos. Com relação à precipitação, os MCGs apresentaram baixo desempenho em simular os padrões espaciais dessa variável na região. Entretanto, para o final do século e no cenário SRES A2, os resultados obtidos projetam um aumento na precipitação sobre a bacia do Prata coerente com a projeção média de todo o conjunto, e um decréscimo de precipitação sobre a bacia amazônica, apesar de grande divergência entre os modelos. No extremo sul do continente, os modelos também representam muito mal o clima observado, no entanto, eles apresentam boa concordância com relação a um moderado aumento de precipitação para o final do século ao sul de 45°S e um decréscimo no Chile, entre 20 e 45°S. Tanto para precipitação quanto para temperatura, todos os cenários de emissões indicaram padrões espaciais de projeções similares, diferindo apenas na amplitude das tendências projetadas.

Núñez et al. (2008) analisaram os padrões de mudanças climáticas sobre o sul da América do Sul projetados pelo modelo regional MM5. As simulações foram realizadas em

dois períodos de 10 anos representando o clima presente (1981-1990) e os cenários SRES A2 e B2 para o período de 2081-2090. Segundo os autores, poucas diferenças nos padrões projetados foram encontradas entre os diferentes cenários de emissões analisados, apesar das amplitudes das mudanças serem maiores no cenário A2. As projeções indicaram um aumento de temperatura mais acentuado no sul do Brasil, Paraguai, Bolívia e nordeste da Argentina, e um decréscimo na precipitação sobre a costa oeste da América do Sul. Sobre o norte e centro da Argentina foi projetado um aumento na precipitação no verão e outono, e um decréscimo no inverno e primavera. Para o sul do Brasil, as projeções apontaram para um aumento na precipitação durante a estação de outono.

Vera e Silvestri (2009), utilizando os mesmos MCGs que Vera et al. (2006), analisaram o desempenho dos modelos em reproduzir a variabilidade interanual da precipitação na América do Sul, assim como a influência da Oscilação Antártica e do El Niño Oscilação Sul (ENOS) em tal variabilidade. Segundo os autores, os modelos são capazes de reproduzir a migração norte – sul da variabilidade do máximo de precipitação sobre a região, assim como a alta variabilidade no sul do Chile. Entretanto, a maioria dos MCGs não representa apropriadamente a variabilidade associada com a ZCAS durante o verão, e o típico máximo de variabilidade de precipitação na porção subtropical do continente durante o outono e inverno. O padrão anular da influência da Oscilação Antártica na circulação do hemisfério sul é razoavelmente bem simulado por todos os modelos, mas com sérias deficiências na representação da relação observada entre a Oscilação Antártica e as anomalias de precipitação e circulação na América do Sul. Além disso, grande parte dos modelos não é capaz de reproduzir o típico trem de onda observado nas anomalias de circulação no hemisfério Sul associado com o ENOS. Apenas poucos modelos, previamente identificados como aqueles com razoável representação do ENOS no Pacífico equatorial mostraram evidências de tais trens de onda, sendo estes aqueles que melhor representaram o sinal do ENOS na precipitação da região. Vera e Silvestri concluíram que era preciso uma considerável melhora dos modelos na representação da variabilidade climática na região e nas teleconexões de grande escala associadas, e que os resulta-

dos encontrados inviabilizam os estudos sobre mudanças futuras de tais padrões em decorrência de um aquecimento global.

Bombardi e Carvalho (2009) analisaram a variabilidade do Sistema de Monções na América do Sul (SMAS) através dos dados de precipitação do *Global Precipitation Climatology Project* (GPCP; ADLER et al., 2003) e de dez MCGs do conjunto CMIP3 no período de 1979 a 2006, assim como as projeções dos modelos para 2081-2100 no cenário SRES A1B. Eles concluíram que a maioria dos modelos é deficiente em representar a Zona de Convergência Intertropical (ZCIT) e o ciclo anual de precipitação sobre a Amazônia e o noroeste da América do Sul. Com relação à representação da ZCAS, que é uma das principais características do SMAS, com exceção do modelo ECHAM5, todos os MCGs representaram satisfatoriamente esse sistema. MIROC3.2(hires) foi o modelo que simulou mais realisticamente a precipitação durante o verão em associação com a ZCAS, enquanto que FGOALS e ECHAM5 apresentaram os piores desempenhos. As simulações do início e fim da estação chuvosa e do total de precipitação sazonal divergiram entre os modelos, apresentando resultados não realísticos sobre o norte e noroeste da Amazônia para a maioria deles. Todavia, Bombardi e Carvalho classificaram como boa a perspectiva de se usar os modelos do CMIP3 para entender e prever futuras mudanças climáticas no SMAS, devido a grande maioria dos modelos simularem razoavelmente bem as características médias e o ciclo anual de precipitação sobre o centro da América do Sul no clima presente. Dessa forma, os autores verificaram que no cenário SRES A1B, a característica mais coerente mostrada em seis dos dez modelos analisados foi um decréscimo do total de precipitação monçônica sobre o centro - leste da América do Sul, que coincidiu com a região onde os modelos apresentaram um melhor desempenho em simular as características da SMAS no clima presente.

Urrutia e Vuille (2009) utilizaram o modelo regional HadRM3P para analisar as projeções climáticas na parte tropical dos Andes para o final do século (2071-2100) nos cenários SRES A2 e B2. As projeções indicaram um significativo aquecimento sobre a região de estudo, mais proeminente sobre as elevações mais altas, e amplificado na troposfera média e alta. As mudanças de temperatura foram espacialmente similares em ambos os cenários, mas com maior amplitude no A2. As mudanças indicadas para a variá-

vel precipitação foram espacialmente muito menos coerentes, com tendências alternadas de aumento ou decréscimo ao longo dos Andes.

Marengo et al. (2010b) utilizou três modelos regionais (HadRM3P, Eta CCS e RegCM3) para analisar as projeções de mudanças climáticas na América do Sul para o final do século XXI, como parte do projeto intitulado CREAS (Cenários Regionalizados de Clima Futuro da América do Sul). As simulações abrangeram períodos de 30 anos representando o clima presente (1961-1990) e projeções futuras (2071-2100) para o cenário SRES A2, com resolução espacial de 50 km. Os resultados indicaram que regiões como o Nordeste brasileiro e leste e sul da Amazônia poderão sofrer deficiência hídrica no futuro, enquanto que aumento de precipitação foi projetado para a costa Noroeste do Peru, Equador, sul do Brasil e norte da Argentina. Os três modelos simularam maior aquecimento na região tropical em todas as estações, sendo mais proeminente durante o inverno austral, onde são projetados aumentos de temperatura de até 6 a 8°C comparado ao clima presente. No sul da América do Sul o aquecimento no verão variou entre 2 e 4°C e no inverno entre 3 e 6°C. Apesar do detalhamento regional das projeções de mudanças climáticas naquele estudo, as incertezas constatadas nas simulações dos modelos regionais ainda continuaram grandes, como por exemplo, a localização da região de máximo aumento de temperatura para o final do século. Enquanto dois modelos simularam esse máximo aumento de temperatura no leste da Amazônia, o terceiro modelo simulou no oeste dessa mesma região.

Seth et al. (2010) utilizou nove modelos do conjunto CMIP3 para examinar as mudanças projetadas no ciclo anual do SMAS para o final do século XXI (2071-2100) no cenário SRES A2, em comparação com o período de 1971 a 2000. As análises realizadas neste estudo foram focalizadas em três regiões principais: uma região no SMAS (50-60°W, 10-20°S), a sua extensão sudeste (40-50°W, 15-25°S) e o sudeste da América do Sul (50-60°W, 23-35°S). Os resultados obtidos reafirmaram estudos anteriores (VERA et al., 2006; IPCC, 2007; BOMBARDI; CARVALHO, 2009) que indicam um provável aumento de precipitação no verão austral na região sudeste da América do Sul para o final do século. Embora na região da monção os resultados apresentaram grande divergência entre os modelos, a média do conjunto indica uma primavera austral mais seca.

Estas mudanças na precipitação foram acompanhadas por um deslocamento mais para o sul do máximo de precipitação na ZCAS e da Alta subtropical do Atlântico Sul. Os resultados também sugerem um aumento no transporte de umidade para o sul, associado com uma intensificação do fluxo de baixos níveis a leste dos Andes durante a primavera. Os cálculos da divergência do fluxo de umidade não apresentaram mudanças significativas na região da monção, enquanto que um significativo aumento na convergência foi simulado no sudeste da América do Sul durante todo o verão. Os resultados encontrados por Seth et al. (2010) sugerem que na região do SMAS poderá ocorrer uma primavera mais quente e seca no final do século, corroborando os resultados encontrados por Bombardi e Carvalho (2009).

Junquas et al. (2012) utilizou 18 MCGs do conjunto CMIP3 para avaliar a variabilidade da precipitação de verão no sudeste da América do Sul utilizando simulações do clima presente (1979 - 1999) e projeções futuras (2001 - 2098) no cenário SRES A1B. Os autores identificaram que o aumento projetado de precipitação de verão no sudeste da América do Sul, assim como identificado anteriormente por Vera et al. (2006), está associado com a intensificação e predominância da fase positiva de uma estrutura tipo-dipolo (DOYLE; BARROS, 2002) com centros de ação no sudeste da América do Sul e na região da ZCAS (na fase positiva (negativa) desse dipolo há um favorecimento de precipitação acima (abaixo) da média climatológica no sudeste da América do Sul, e precipitação abaixo da média (acima) na região da ZCAS).

Blázquez e Nuñez (2013), utilizando 8 MCGs do conjunto CMIP3 e CMIP5, avaliaram duas fontes de incertezas nas projeções de temperatura e precipitação sobre a América do Sul nos cenários SRES A1B e RCP 4.5 (cenário intermediário de forçante no CMIP5), respectivamente: variabilidade interna e variabilidade inter-modelos. Eles identificaram alguns melhoramentos no novo conjunto de modelos, como por exemplo, uma redução na variabilidade inter-modelos da temperatura de verão projetada para o final do século XXI sobre o nordeste da Argentina, Paraguai, e norte do Brasil. A confiabilidade das projeções de temperatura para ambos os conjuntos é alta, com razões de sinal-ruído maior do que 1 sobre a maior parte do continente sul-americano. Com relação à precipitação, a confiabilidade apresentou-se baixa em ambos os conjuntos, embora

que no CMIP5 a variabilidade inter-modelos é menor sobre o norte e leste do Brasil na estação de verão. Por outro lado, a relação sinal-ruído na nova geração de modelos é próxima de 1, e maior do que 1 sobre o leste da Argentina, Uruguai, e sul do Brasil em algumas estações.

Joetzjer et al. (2013) utilizou 13 MCGs que participaram tanto do CMIP3 quanto do CMIP5 para avaliar a precipitação simulada e projetada sobre a bacia Amazônica nos cenários forçantes SRES A2 e RCP 8.5 (cenário de maior forçante presente no CMIP5), respectivamente. Segundo esses autores, importantes melhoramentos ocorreram nas simulações de precipitação do CMIP5, comparado ao CMIP3. O viés negativo (ou seco) no ciclo anual foi consistentemente reduzido, a distribuição espacial e o ciclo sazonal de precipitação está melhor representado, e a variabilidade interanual também apresentou ligeira melhora na simulação das teleconexões referentes ao ENOS e às anomalias de temperatura da superfície do mar localizadas no Atlântico Tropical Norte. Todavia, segundo Joetzjer et al. (2013), as projeções para o século XXI permanecem bastante incertas. O único melhoramento aparente é o aumento no consenso da intensificação e prolongamento da estação seca, especialmente na parte leste da bacia Amazônica.

Jones e Carvalho (2013) utilizando 10 MCGs do CMIP5 avaliaram as características de grande escala do SMAS (início, fim, e duração da monção) para a simulação histórica (1951-2005) e projeções futuras (2006-2100) no cenário RCP 8.5. Comparações qualitativas com o estudo realizado por Bombardi e Carvalho (2009) indicam que alguns MCGs do CMIP5 apresentam expressiva melhora na representação da SMAS comparado às suas versões no conjunto CMIP3. Todavia, alguns MCGs persistem em exibir deficiências na simulação desse sistema meteorológico. A maioria das simulações e projeções apresentaram significantes aumentos na amplitude sazonal e duração da SMAS, consistentes com um progressivo adiantamento do início e retardamento do fim da monção. Adicionalmente, os autores identificaram uma falta de concordância dos MCGs quanto às projeções de mudanças no total de precipitação na estação chuvosa sobre a América do Sul para o final do século XXI. O padrão mais consistente refere-se a um aumento no total de precipitação monçônica sobre o sul do Brasil, Uruguai, e norte da Argentina, corroborando estudos anteriores realizados com o CMIP3 (VERA et al.,

2006; BOULANGER et al., 2007; SETH et al., 2010; JUNQUAS et al. 2012), e com alguns estudos já publicados com o CMIP5 (KNUTTI; SEDLÁČEK, 2012), e em concordância com as análises apresentadas preliminarmente no IPCC AR5 (IPCC, 2013).

3 DADOS E MÉTODOS

3.1. Descrição dos dados e região de estudo

As simulações e projeções climáticas analisadas neste estudo advêm dos conjuntos de MCGs integrantes do CMIP3 e CMIP5, fornecido pelo *Program for Climate Model Diagnosis and Intercomparison* (PCMDI) e disponibilizado pelo *Earth System Grid data portal*. As variáveis utilizadas são médias mensais de precipitação, temperatura do ar próximo à superfície, e pressão ao nível médio do mar (PNM) simuladas para o clima observado, denominado clima presente ou clima atual (1901 - 2000), e projetadas para o clima do século XXI (2011 - 2100), denominada clima futuro. Essas simulações e projeções são produzidas por 24 MCGs pertencentes ao CMIP3 (MEEHL et al., 2007) e 24 MCGs provenientes do CMIP5 (TAYLOR et al., 2012), totalizando aproximadamente 450 rodadas (Tabelas 3.1 e 3.2, respectivamente). Maiores detalhes acerca dos modelos e simulações podem ser encontrados em Randall et al. (2007), Meehl et al. (2007 a,b), e no sítio do PCMDI (http://www-pcmdi.llnl.gov/ipcc/about_ipcc.php).

As simulações do clima presente, referentes ao século XX, são caracterizadas como experimentos de controle para os quais as forçantes climáticas que poderiam impactar o clima observado são explicitamente identificadas, e séries históricas observadas dessas forçantes são incluídas nas integrações dos MCGs. Essas simulações são denominadas “20C3M” no conjunto CMIP3, e “historical” no conjunto CMIP5. Por outro lado, os cenários forçantes empregados nas projeções climáticas para o século XXI no CMIP3 são baseados em cenários de emissões de não intervenção governamental descritas por três narrativas B1, A1B, e A2 do *Special Report on Emission Scenarios – SRES* (NAKICENOVIC et al., 2000), que são baseadas em diferentes hipóteses acerca do crescimento populacional, desenvolvimento econômico, uso de energia, e globalização. Estes cenários correspondem a concentrações de CO₂ equivalente⁷ na atmosfera em 2100 de

⁷ CO₂ equivalente é uma terminologia usada para indicar a contribuição de um dado tipo de GEE para o aquecimento global, utilizando-se a concentração de CO₂ como referência. Neste contexto, surge a denominação de Potencial de Aquecimento Global (em inglês, *Global Warming Potential - GWP*), que é uma

aproximadamente 550 (B1), 700 (A1B), e 850 ppm (A2). Na Figura 3.1 são apresentadas as trajetórias de emissões dos três principais GEEs (CO_2 , CH_4 , e N_2O) para o século XXI, segundo seis cenários (ou narrativas) do SRES (A1B, A1T, A1FI, A2, B1, e B2), assim como o cenário IS92a utilizado nos relatórios do IPCC anteriores ao quarto relatório.

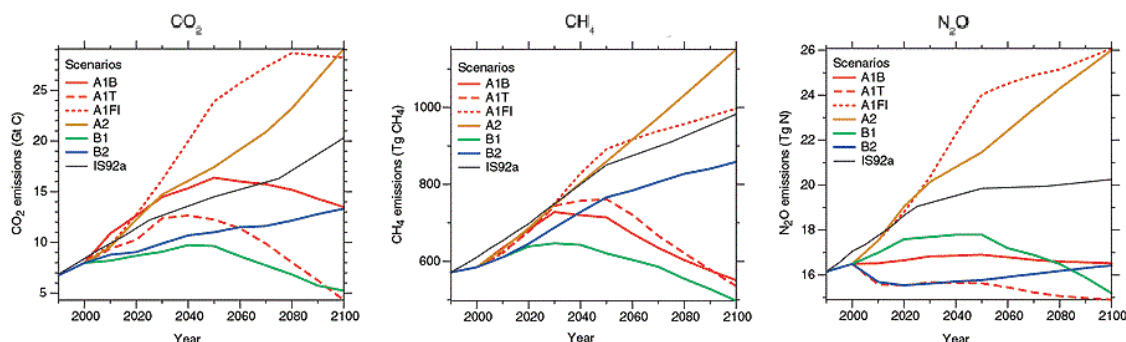


Figura 3.1 – Trajetórias das emissões de CO_2 (direita), CH_4 (centro), e N_2O (esquerda) referentes à seis cenários representativos do SRES (A1B, A1T, A1FI, A2, B1, B2), e o cenário IS92a.

Fonte: Adaptado de Nakicenovic et al. (2000).

Contudo, as projeções climáticas no CMIP5 são realizadas utilizando-se a nova geração de cenários forçantes intitulados *Representative Concentration Pathways* – RCPs (MOSS et al., 2010), e denominados como RCP 2.6, 4.5, 6.0, e 8.5, que correspondem a uma forçante radiativa aproximada no final do século XXI de 2.6, 4.5, 6.0, e 8.5 Wm^{-2} , respectivamente, relativo às condições pré-industriais (MOSS et al., 2010). Com relação às concentrações de CO_2 equivalente, os RCPs 2.6, 4.5, 6.0, e 8.5, correspondem aproximadamente a 490, 650, 850, e 1370 ppm, respectivamente, em 2100 (VAN VUUREN et al., 2011). A Figura 3.2 ilustra as trajetórias das emissões de CO_2 (esquerda), CH_4 (centro), e N_2O (direita) referentes aos quatro cenários RCPs (2.6, 4.5, 6.0, 8.5), situando esses cenários com relação aos inúmeros outros publicados na literatura, e em especial, com quatro cenários pertencentes ao SRES (A2, A1b, B2, e B1). Como podemos

medida de como uma dada quantidade de GEE contribui para o aquecimento global. Por exemplo, em um horizonte de 20 anos, o CO_2 tem um potencial de 1 (referência), o CH_4 de 62, e o N_2O de 275.

observar, os diferentes cenários RCPs são mais abrangentes com relação às magnitudes de emissão relativas aos SRES, e cobrem praticamente todo o intervalo de trajetórias publicadas na literatura para os gases CO_2 e CH_4 , e uma grande maioria para o N_2O (Figura 3.2). Maiores detalhes acerca dos cenários SRES e RCPs podem ser encontrados, por exemplo, em Nakicenovic et al. (2000), Moss et al. (2010), e van Vuuren et al. (2011).




Figura 3.2 - Trajetórias das emissões de CO_2 (direita), CH_4 (centro), e N_2O (esquerda) 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).

Comparando as projeções de aumento de temperatura média global advindas dos MCGs do CMIP3 (utilizando os cenários SRES) e CMIP5 (utilizando os cenários RCPs) (Figura 3.3), podemos constatar que a maior abrangência com relação às magnitudes de emissão dos diferentes GEEs nos cenários RCPs citado anteriormente, resulta também em um intervalo maior de possíveis mudanças na magnitude da temperatura média global. Por exemplo, para as projeções de mudança de temperatura em 2100 (relativo à 1986-2005) produzidas pelos modelos do CMIP3 com os cenários SRES A2, A1B, e B1, o intervalo de mudança projetada situa-se entre 1,3 - 3,8 °C. Por outro lado, para os modelos do CMIP5 utilizando os RCPs 2.6, 4.5, 6.0, e 8.5, este intervalo é de 0,5 - 4,9 °C (Figura 3.3).




Figura 3.3 – Mudança de temperatura global (média e um desvio padrão, indicado com o sombreado) relativo a 1986-2005, projetada pelos MCGs do CMIP3 utilizando os cenários SRES (esquerda), e pelos MCGs do CMIP5 utilizando os RCPs (direita). O número de MCGs utilizados para cada cenário estão indicados entre parênteses.

Fonte: Knutti e Sedláček (2013).

Ademais, comparativamente ao CMIP3, as resoluções horizontais dos MCGs pertencentes ao CMIP5 são ligeiramente mais altas e os experimentos delineados são mais abrangentes, por exemplo, com a inclusão de experimentos para avaliar a previsibilidade climática na escala decenal, o que possibilita aos cientistas explorar um amplo espectro de questões científicas (TAYLOR et al., 2012). Alguns dos principais aperfeiçoamentos nos MCGs do CMIP5 são um aprimoramento no acoplamento dos oceanos, a inclusão do ciclo de carbono, e a utilização de forçantes radiativas mais completas devido, entre outras coisas, a inserção de uma modelagem mais acurada dos efeitos indiretos dos aerossóis e o uso de séries temporais das forçantes vulcânica e solar na maioria dos modelos (TAYLOR et al., 2012; KNUTTI; SEDLÁČEK, 2013; SILLMANN et al., 2013a).

As resoluções horizontais dos MCGs do CMIP3 variam de aproximadamente 1 a 5 graus de latitude/longitude (Tabela 3.1), e aqueles provenientes do CMIP5 variam em torno de 1 a 3 graus (Tabela 3.2). Com o propósito de intercomparação, todas as variáveis utilizadas foram interpoladas para uma grade regular comum de 2,5° x 2,5° de lati-

tude/longitude utilizando uma interpolação bilinear. Seguindo um procedimento análogo ao utilizado por Kim et al. (2008), em algumas análises os MCGs do CMIP3 serão agrupados em três categorias de acordo com sua resolução espacial: LOW-RES ($5^\circ \times 4^\circ$ lat/lon), MED-RES ($2,8^\circ \times 2,8^\circ$ lat/lon), e HIGH-RES ($1,9^\circ \times 1,9^\circ$ lat/lon). Os modelos pertencentes a cada um desses grupos estão especificados na Tabela 3.1. Esta análise terá como objetivo avaliar a influência da resolução espacial no desempenho dos modelos em simular o clima presente, e verificar a possível necessidade de exclusão daqueles modelos com resolução espacial mais baixa.

Simulações climáticas para o século XX e projeções para o século XXI são agrupadas sazonalmente para os períodos de 1961-1990, 2041-2070, e 2071-2100. A partir daqui, o termo “mudanças” irá se referir a diferença entre os valores médios das variáveis climáticas projetadas (e.g., em 2071-2100) e o respectivo valor médio no período 1961-1990. Quando mais de uma rodada por experimento para um dado modelo estiver disponível, a média de todas as rodadas é utilizada. Isto é possível porque as médias temporais acima de 10 anos não diferem substancialmente para diferentes rodadas de um mesmo modelo (dentro de um mesmo experimento), e porque estas diferenças são muito menores quando comparadas com as diferenças entre modelos diferentes (GIORGI e FRANCISCO, 2000; KNUTTI, 2008).

Todas as simulações dos MCGs para o século XX serão comparadas com os dados observados de temperatura e precipitação provenientes do conjunto CRU TS 3.0 (HARRIS et al., 2013) produzidos pelo *Climate Research Unit – University of East Anglia* (CRU/UEA). Esses dados abrangem o período de 1901 a 2005, e possuem uma resolução espacial de $0,5^\circ \times 0,5^\circ$ de latitude/longitude. Por outro lado, os dados simulados de PNM serão comparados com aqueles dados observacionais provenientes do conjunto HadSLP2 (ALLAN e ANSELL, 2006) fornecido pelo *Met Office Hadley Centre*. Os dados observados de PNM encontram-se numa grade global com resolução de $5^\circ \times 5^\circ$ lat/lon, abrangendo tanto as superfícies continentais quanto as oceânicas no período de 1860 a 2004. Tanto os dados do CRU TS 3.0 quanto do HadSLP2 serão interpolados para uma grade regular de $2,5^\circ \times 2,5^\circ$ para ser contrastados com as simulações dos MCGs.

Tabela 3.1 - Lista de modelos do conjunto CMIP3 utilizado neste estudo, contendo as resoluções horizontais aproximadas (latitude/longitude), cenários de emissões, e o número de rodadas. Os modelos estão organizados na tabela de acordo com sua resolução horizontal. Os modelos integrantes dos grupos LOW-RES, MED-RES, e HIGH-RES são indicados com as cores vermelho, verde e azul, respectivamente.

Modelos	Resolução	20C3M	A2	A1B	B1
INM-CM3.0	5 ° x 4 °	1	1	1	1
GISS-EH	5 ° x 4 °	5	-	3	-
GISS-ER	5 ° x 4 °	9	1	2	1
GISS-AOM	4 ° x 3 °	2	-	2	2
CGCM3.1(T47)	3.8 ° x 3.8 °	5	5	5	5
MIUB-ECHO-G	3.8 ° x 3.8 °	5	3	3	3
UKMO-HadCM3	3.8 ° x 2.5 °	2	1	1	1
IPSL-CM4	3.8 ° x 2.5 °	1	1	1	1
FGOALS-g1.0	2.8 ° x 3 °	3	-	2	3
MRI-CGCM2.3.2	2.8 ° x 2.8 °	5	5	5	5
CGCM3.1(T63)	2.8 ° x 2.8 °	1	-	1	1
CNRM-CM3	2.8 ° x 2.8 °	1	1	1	1
MIROC3.2(medres)	2.8 ° x 2.8 °	2	3	3	3
PCM	2.8 ° x 2.8 °	4	4	4	2
GFDL-CM2.0	2.5 ° x 2 °	3	1	1	1
GFDL-CM2.1	2.5 ° x 2 °	3	1	1	1
BCCR-BCM2.0	1.9 ° x 1.9 °	1	1	1	1
CSIRO-MK3.0	1.9 ° x 1.9 °	3	1	1	1
CSIRO-MK3.5	1.9 ° x 1.9 °	3	1	1	1
ECHAM5	1.9 ° x 1.9 °	4	3	4	3
UKMO-HadGEM1	1.9 ° x 1.3 °	2	1	1	-
CCSM3	1.4 ° x 1.4 °	7	4	7	9
ECHAM4	1.1 ° x 1.1 °	1	1	1	-
MIROC3.2(hires)	1.1 ° x 1.1 °	1	-	1	1

Tabela 3.2 - Lista de modelos do conjunto CMIP5 utilizados neste estudo, com a descrição das resoluções horizontais aproximadas, e número de rodadas das simulações futuras (RCPs 2.6, 4.5, 6.0, 8.5) e históricas (historical). Assim como na Tabela 3.1, os modelos estão organizados de acordo com a sua resolução horizontal.

Modelos	Resolução (lat/lon)	Historical	RCP			
			2.6	4.5	6.0	8.5
FGOALS-g2	3.1 ° x 2.8 °	4	1	1	-	1
BCC-CSM1-1	2.8 ° x 2.8 °	3	1	1	1	1
CanESM2	2.8 ° x 2.8 °	5	5	5	-	5
MIROC-ESM	2.8 ° x 2.8 °	3	1	1	1	1
FIO-ESM	2.8 ° x 2.8 °	1	1	1	1	1
MIROC-ESM-CHEM	2.8 ° x 2.8 °	1	1	1	1	1
GFDL-CM3	2.0 ° x 2.5 °	5	1	1	1	1
GFDL-ESM2G	2.0 ° x 2.5 °	1	1	1	1	-
Giss-E2-R	2.0 ° x 2.5 °	5	1	5	1	1
GFDL-ESM2M	2.0 ° x 2.5 °	1	1	1	1	1
IPSL-CM5A-LR	1.9 ° x 3.8 °	4	1	3	1	3
NorESM1-M	1.9 ° x 2.5 °	3	1	1	1	1
CSIRO-Mk3-6-0	1.9 ° x 1.9 °	10	10	10	10	10
MPI-ESM-LR	1.9 ° x 1.9 °	3	3	3	-	3
INMCM4	1.5 ° x 2.0 °	1	-	1	-	1
CNRM-CM5	1,4 ° x 1,4 °	1	1	1	-	1
MIROC5	1.4 ° x 1.4 °	1	1	1	1	1
IPSL-CM5A-MR	1.3 ° x 2.5 °	1	1	1	-	1
HadGEM2-CC	1.3 ° x 1.9 °	1	-	1	-	1
HadGEM2-ES	1.3 ° x 1.9 °	4	1	1	1	4
ACCESS1.0	1.3 ° x 1.9 °	1	-	1	-	1
EC-EARTH	1.1 ° x 1.1 °	1	1	1	-	1
MRI-CGCM3	1.1 ° x 1.1 °	5	1	1	1	1
CCSM4	0.9 ° x 1.3 °	6	5	5	5	5

Em geral, todos os cálculos nesse estudo serão realizados utilizando-se todas as simulações e projeções para cada ponto continental na América do Sul. Entretanto, algumas médias espaciais dos resultados serão avaliadas para quatro regiões chave: leste e oeste

da Amazônia (EAMZ e WAMZ, respectivamente), Nordeste do Brasil (NEB), e bacia do Prata (LPB) (Figura 3.4). Estas regiões foram escolhidas porque apresentam condições climáticas anômalas diferentes durante eventos de El Niño e La Niña, assim como durante anomalias de temperatura da superfície do mar no Atlântico tropical (AMBRIZZI et al., 2004; NOBRE et al., 2006). Além disso, essas regiões apresentam diferentes sinais de mudança de precipitação para o final do século XXI projetadas por diversos modelos climáticos (MARENGO et al., 2010b; MEEHL et al., 2007a).




Figura 3.4 - Domínio de estudo. Os retângulos indicam as sub-regiões utilizadas nas análises: leste e oeste da Amazônia (EAMZ e WAMZ, respectivamente), Nordeste do Brasil (NEB), e Bacia do Prata (LPB).

3.2. Métodos

Primeiramente serão verificados de forma quantitativa e qualitativa a consistência entre os campos de precipitação e temperatura observados e simulados por cada MCG utilizado, em escala sazonal e anual para o período de 1901-1998 ou 1961-1990, dependendo da análise. Nesta etapa serão calculados viés (simulação menos observação), correlação

de Pearson, erro quadrático médio, desvio padrão, e ciclo sazonal. Adicionalmente, para uma melhor visualização do desempenho dos modelos em representar o clima presente, diagramas de Taylor (TAYLOR, 2001) serão produzidos para sintetizar as informações com relação ao erro quadrático médio, desvio padrão, e correlação.

Em seguida serão avaliadas as projeções de mudanças climáticas de cada MCG para os períodos de 2041-2070, e 2071-2100 nos diferentes cenários utilizados, com relação ao período de 1961-1990, averiguando-se as regiões de maior ou menor confiabilidade baseada na concordância entre eles. Posteriormente serão aplicadas as metodologias denominadas *Reliability Ensemble Averaging*, inferência bayesiana, e será produzido um índice de mudanças climáticas regional para sintetizar os resultados de todas as projeções avaliadas. Essas metodologias são descritas pormenorizadamente a seguir.

3.2.1. Reliability Ensemble Averaging (REA)

No método REA (GIORGI; MEARNES, 2002), o “consenso” sobre a mudança esperada em uma variável climática ξ ($\tilde{\Delta}\xi$) baseando-se em um conjunto de projeções de diferentes modelos é dada por uma combinação das mudanças projetadas por cada membro do conjunto ($\Delta\xi_i$) na forma

$$\tilde{\Delta}\xi = \frac{\sum_i R_i \Delta\xi_i}{\sum_i R_i}. \quad (3.1)$$

Na equação 3.1 R_i é o fator de “confiabilidade” de cada modelo definido por

$$R_i = [(R_{B,i})^m \times (R_{D,i})^n]^{1/(m \times n)} = \left\{ \left[\frac{\varepsilon_\xi}{\text{abs}(B_{\xi,i})} \right]^m \times \left[\frac{\varepsilon_\xi}{\text{abs}(D_{\xi,i})} \right]^n \right\}^{1/(m \times n)}, \quad (3.2)$$

em que: ε_ξ representa a variabilidade natural apresentada pela variável climática ξ , $B_{\xi,i}$ o viés apresentado pelo modelo i na simulação da variável ξ , $D_{\xi,i}$ a distância entre a projeção produzida pelo modelo i para a variável ξ e a projeção média do conjunto, $R_{B,i}$ e $R_{D,i}$ o fator de confiabilidade atribuída ao modelo i em função do seu viés ($B_{\xi,i}$) e distância ($D_{\xi,i}$), respectivamente, e finalmente, m e n são parâmetros introduzidos para ponderar diferentemente os critérios de desempenho e convergência.

O fator $R_{B,i}$ mede a confiabilidade do modelo i em função de seu viés ($B_{\xi,i}$) ao simular a variável ξ no clima atual, ou seja, quanto maior o viés, menor a confiabilidade do modelo i em projetar a variável ξ . Por outro lado, $R_{D,i}$ é um fator que avalia a confiabilidade do modelo i em termos da distância⁸ ($D_{\xi,i}$) entre a mudança na variável ξ projetada por este modelo e a mudança média REA ($\tilde{\Delta}\xi$) do conjunto, ou seja, para uma projeção atípica (*outlier*) de um dado modelo (i.e., que se afasta demais com relação aos outros membros do conjunto) atribui-se um peso menor. Em outras palavras, $R_{B,i}$ e $R_{D,i}$ representam um critério relativo ao desempenho e convergência, respectivamente. Dessa forma, as Equações (3.1) e (3.2) estabelecem que uma dada projeção de um modelo é dita confiável quando o viés do modelo em representar o clima presente e a distância de sua projeção à média REA estão dentro da variabilidade natural da variável analisada (ε_{ξ}), de tal forma que $R_B = R_D = 1$ (Giorgi e Mearns, 2002).

Para o cômputo de todos parâmetros inseridos nas Equações (3.1) e (3.2), 200 iterações foram realizadas. Este número de iterações foi determinado após testes de convergência dos valores dos parâmetros na segunda casa decimal.

Os parâmetros m e n são introduzidos para ponderar diferentemente os critérios de desempenho e convergência. Giorgi e Mearns (2002) investigaram a sensibilidade dos resultados do método REA aos parâmetros m e n , escolhendo diferentes valores para ambos, e, portanto, atribuindo mais “importância” ao critério de desempenho ou convergência. Em geral, os autores encontraram que a sensibilidade às mudanças nos parâmetros m e n foi menor do que 5 – 10%. Portanto, por simplicidade, e por acreditar que não exista nenhuma justificativa plausível para estabelecer um critério (desempenho ou convergência) como mais importante, assumiu-se que $m = n = 1$, assim como também adotado por Moise e Hudson (2008).

O critério de convergência é baseado na hipótese de que, para um dado cenário de forçante climática, se os sinais de mudanças climáticas produzidos por diferentes (e inde-

⁸ A distância referida no método REA é a diferença entre $\Delta\xi_i$ e $\tilde{\Delta}\xi$.

pendentes) modelos climáticos não forem tão sensitivos às diferenças entre os modelos, estes sinais são ditos mais confiáveis, e a média do conjunto de modelos poderia convergir para as condições climáticas futuras. Entretanto, como enfatizado por Giorgi e Mearns (2002), a distância à média REA é apenas uma estimativa do critério de convergência, uma vez que as condições futuras não são conhecidas. Além disso, através do cálculo da média REA, e ciente da complexidade e inúmeras incertezas inerentes às simulações do sistema climático, não se pretende obter a resposta climática real a uma dada forçante, mas sim, uma melhor estimativa do seu valor futuro.

Adicionalmente, assim como em Giorgi e Mearns (2002), Moise e Hudson (2008), e Xu et al. 2010, a variabilidade natural da temperatura e precipitação são estimadas para cada ponto de grade tomando-se a diferença entre o maior e o menor valor da série temporal observada (1901-2000), após remover-se a tendência linear dos dados, e aplicar-se um filtro média-móvel para eliminar flutuações com período menor do que 30 anos.

Por meio dos parâmetros supracitados, um intervalo de incerteza ($\tilde{\delta}_{\Delta\xi}$) no entorno da mudança média REA ($\tilde{\Delta\xi} \pm \tilde{\delta}_{\Delta\xi}$), e um parâmetro de confiabilidade do conjunto ($\tilde{\rho}$) podem ser estimados, respectivamente, por:

$$\tilde{\delta}_{\Delta\xi} = \left[\frac{\sum_i R_i (\Delta\xi_i - \tilde{\Delta\xi})^2}{\sum_i R_i} \right]^{1/2} \quad (3.3)$$

e

$$\tilde{\rho} = \frac{\sum_i R_i^2}{\sum_i R_i} \quad (3.4)$$

Além disso, os fatores de confiabilidade podem ser usados para se estimar a probabilidade das mudanças climáticas futuras projetadas pelo conjunto de MCGs (GIORGI; MEARNNS, 2003). Entretanto, enfatiza-se que a real probabilidade de ocorrência de certa mudança climática é desconhecida e, portanto, o desempenho dos modelos em prever mudanças climáticas não pode ser avaliado. Além disso, a PDF das mudanças simuladas também é desconhecida, uma vez que isso iria requerer um conjunto maior de simulações de cada um dos modelos. Portanto, algumas hipóteses precisam ser feitas durante a construção dessas funções, como por exemplo: i) assumir que os modelos podem proje-

tar o clima futuro, ii) que o conjunto disponível de resultados de modelos englobam o intervalo total de incerteza relacionada, e iii) que todos os modelos são independentes. Por outro lado, vale ressaltar que a hipótese de independência dos modelos em certos conjuntos, tais como o CMIP3 e CMIP5, é um dos principais pontos fracos de estudos envolvendo ponderamento de modelos, tais como o utilizado aqui. A maioria dos modelos exibem grandes semelhanças devido a diversos fatores, tais como: ter sido desenvolvido na mesma instituição, compartilhar versões das mesmas componentes atmosféricas e/ou oceânicas, serem sucessivas versões do mesmo modelo, entre outros (MASSON; KNUTTI, 2011; KNUTTI et al., 2013). Essa interdependência ou similaridade dos modelos reduzem o tamanho efetivo da amostra no processo de ponderamento do conjunto.

De acordo com Giorgi e Mearns (2003), a probabilidade de uma projeção de mudança em uma dada variável climática simulada por um modelo i (P_{m_i}) pode ser considerada proporcional ao parâmetro de confiabilidade definido na Equação (3.2) normalizado, ou seja,

$$P_{m_i} = \frac{R_i}{\sum_{i=1}^N R_i}, \quad (3.5)$$

em que N representa o número de diferentes MCGs utilizados na análise. Em outras palavras, assume-se que uma mudança climática projetada por um modelo com um parâmetro de confiabilidade maior possui uma maior probabilidade de ocorrência.

Com isso, dada as probabilidades calculadas pela Equação (3.5), pode-se construir uma PDF das projeções de mudanças em uma dada variável climática. Entretanto, a construção e validação de uma PDF estão longe de serem tarefas triviais. Primeiramente, para avaliar as PDFs geradas a partir de simulações do clima presente produzidas por um conjunto de modelos, uma distribuição observada e bem representativa da variabilidade climática da região de estudo deve ser criada, o que não é fácil de ser realizado devido a um problema comum de distribuição esparsa de dados observados e da falta de séries de dados climáticos observados contínuos e de longo prazo, principalmente na América do Sul. Devido a essa restrição primária, compromete-se a validação de qualquer PDF baseada em modelos, uma vez que a PDF real do clima presente não é conhecida. Em se-

gundo, uma boa PDF baseada em modelos climáticos deveria ser construída (idealmente) a partir de uma amostra bem grande de simulações em alta resolução espacial de diferentes modelos (*multi-model ensemble*), e com centenas de simulações do mesmo modelo obtidas por perturbações físicas (*perturbed physics ensemble*; MURPHY et al., 2007), o que é uma tarefa computacional bastante dispendiosa e praticamente não viável nos dias atuais.

Pelas problemáticas supracitadas, é difícil estabelecer uma metodologia para construir PDFs, ou para determinar aquelas metodologias mais apropriadas ou confiáveis. Dessa forma, todos os estudos (incluindo o presente estudo) estão limitados a um tamanho amostral relativamente pequeno de simulações e observações, e contendo metodologias contestáveis em certos pontos. Entretanto, apesar do REA ser uma metodologia bastante simples, as PDFs geradas por este método estão em concordância e são bastante comparáveis à PDFs obtidas com metodologias mais sofisticadas presentes na literatura (TEBALDI et al., 2005; GREENE et al., 2006; FURRER et al., 2007; TEBALDI; KNUTTI, 2007).

Dado algumas críticas ao método REA, principalmente com relação ao critério de convergência, Xu et al. (2010) propuseram melhoramentos que consistem na inclusão de mais de uma variável e estatística no cálculo do parâmetro de confiabilidade atribuída ao desempenho do modelo em representar o clima presente, assim como a exclusão do critério de convergência. Segundo os autores, a utilização de uma única variável fornece apenas uma medida relativamente fraca do desempenho do modelo, enquanto que o critério de convergência pode causar uma redução artificial no intervalo de incerteza, e mascarar importantes informações sobre projeções mais extremas (XU et al., 2010).

Uma das modificações de Xu et al. (2010) é que a incerteza calculada pela Equação 3.3 é substituída por

$$\bar{\delta}_{\Delta\xi} = \sqrt{\frac{N_{ef}}{N_{ef} - 1}} \times \tilde{\delta}_{\Delta\xi}, \quad (3.6)$$

em que N_{ef} é o número efetivo de modelos definido como

$$N_{ef} = \left(\sum_{i=1}^N P_i^2 \right)^{-1}. \quad (3.7)$$

Para pesos uniformes ($P_i = N^{-1}$ para todos os modelos) temos que N_{ef} é igual a N ; para pesos não uniformes $N_{ef} < N$. Esta revisão torna os limites de incerteza obtidos por diferentes opções de ponderamento mais diretamente comparáveis. Se assumirmos que as simulações dos modelos são provenientes de uma população na qual as projeções de mudanças climáticas e os pesos atribuídos aos modelos não são correlacionados, então o quadrado da equação 3.6 nos dará uma estimativa não enviesada da variância dentro desta população (XU et al., 2010).

A segunda e principal mudança no método REA é a exclusão do critério de convergência e a inclusão de mais de uma variável e estatística para avaliar o desempenho do modelo no clima presente. Na nova versão do método REA, o fator de confiabilidade do modelo é definido como:

$$R_i = [f_1(\bar{T})]^{m_1} \times [f_2(T_{var})]^{m_2} \times [f_3(\bar{P})]^{m_3} \times [f_4(P_{var})]^{m_4} \times [f_5(PNM_{corr})]^{m_5} \quad (3.8)$$

em que

$$f_1(\bar{T}) = \frac{\varepsilon_T}{abs(bias)}; f_2(T_{var}) = \frac{\varepsilon_{STD}}{abs(STD_{model} - STD_{obs})}; f_3(\bar{P}) = \frac{\varepsilon_P}{abs(bias)};$$

$$f_4(P_{var}) = \frac{\varepsilon_{CV}}{abs(CV_{model} - CV_{obs})}, f_5(PNM_{corr}) = corr(PNM_{model}, PNM_{obs}).$$

As funções f_1 e f_3 medem a habilidade do modelo em reproduzir a temperatura e precipitação média, respectivamente, enquanto que f_2 e f_4 medem a reprodutibilidade da variabilidade interanual observada dessas variáveis. Esta variabilidade é medida pelo desvio padrão interanual (STD) para temperatura e pelo coeficiente de variação interanual (CV , desvio padrão dividido pela média) para precipitação, onde STD e CV são calculados utilizando-se todo o período do século XX disponível de modo similar ao descrito no método REA original. A função f_5 é uma medida da correlação espacial entre o padrão de PNM simulado e observado numa extensa área abrangendo a região

de interesse e incluindo os pontos continentais e oceânicos do domínio, ou seja, uma medida do desempenho do modelo em reproduzir a circulação climatológica básica afetando a região. Neste estudo, para a avaliação deste último parâmetro, foi utilizado o domínio compreendido entre as longitudes de 120°W a 360°W e latitudes de 60°S a 30°N.

Em adição, os parâmetros m_1 a m_5 podem ser utilizados para ponderar cada função diferentemente. Entretanto, por simplicidade, e pelas mesmas considerações feitas ao método REA original, assumiremos que os m 's = 1, principalmente pela falta de justificativa plausível em estabelecer um fator mais importante do que outro.

3.2.2. Inferência Bayesiana

Nesta seção é apresentada a forma analítica advinda do método estatístico bayesiano de 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 (*prior probability distribution*) para estes parâmetros é especificada independentemente dos dados em mãos. A componente da probabilidade condicional, ou verossimilhança, 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.

Formalmente, sendo Θ o vetor dos parâmetros do modelo, e $p(\Theta)$ sua distribuição prévia. O dado D , sobre as hipóteses formuladas no modelo estatístico, possui uma probabilidade condicional $p(D|\Theta)$. Dessa forma, o teorema de Bayes estabelece que $p(\Theta|D) \propto p(\Theta) \times p(D|\Theta)$, em que $p(\Theta|D)$ é a distribuição posterior dos parâmetros e forma a base de qualquer inferência estatística formal sobre eles. Quando a complexidade de $p(\Theta|D)$ impede uma solução de forma fechada, que é o caso de nossa aplicação, uma estimativa empírica da distribuição pode ser obtida através de simulações MCMC (*Markov Chain Monte Carlo*). Técnicas MCMC são formas eficientes de simular amos-

tras de distribuições posteriores, contornando a necessidade de resolvê-las analiticamente.

Com isso, nas formulações a seguir, X_i e Y_i denotarão uma dada variável climática simulada para o clima presente e projetada para o clima futuro pelo modelo i , respectivamente, mediados sazonalmente 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 :

$$X_i \sim N(\mu, \lambda_i^{-1}) = (\lambda_i^{1/2} / \sqrt{2\pi}) \times e^{-\frac{\lambda_i(x_i - \mu)^2}{2}}, \quad (3.9)$$

$$Y_i \sim N(v, (\theta\lambda_i)^{-1}) = [(\theta\lambda_i)^{1/2} / \sqrt{2\pi}] \times e^{-\frac{\theta\lambda_i(y_i - v)^2}{2}}, \quad (3.10)$$

em que a notação $X_i \sim N(\mu, \lambda_i^{-1})$ indica uma distribuição gaussiana com média μ e variância λ_i^{-1} . Os parâmetros μ e v representam os valores “verdadeiros” da variável climática no presente e futuro, respectivamente, em uma da região (ou ponto de grade) e estação específica. Dessa forma, a mudança esperada da variável climática será dada por $\Delta\xi = v - \mu$. 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 (3.9) e (3.10) 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:

$$X_o \sim N(\mu, \lambda_o^{-1}) = (\lambda_o^{1/2} / \sqrt{2\pi}) \times e^{-\frac{\lambda_o(x_o - \mu)^2}{2}}. \quad (3.11)$$

O parâmetro μ é o mesmo inserido na equação (3.9), mas λ_0 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 etc., λ_0 é uma função da variabilidade natural específica de cada região e estação, e será determinado de forma análoga a ε no método REA ($\lambda_0 = 1/\varepsilon^2$).

O modelo descrito pelas equações 3.9-3.11 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

$$\frac{b^a}{\Gamma(a)} \lambda_i^{a-1} e^{-b\lambda_i} \quad (3.12)$$

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. Por ser extremamente difusa, as distribuições tem uma qualidade não-informativa que requeremos em nossas 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

$$\prod_{i=1}^N \lambda_i^{a-1} e^{-b\lambda_i} \times \lambda_i \theta^{1/2} \exp\left\{-\frac{\lambda_i}{2} [(X_i - \mu)^2 + \theta(Y_i - \nu)^2]\right\} \times \theta^{c-1} e^{-d\theta} \times \exp\left\{-\frac{\lambda_o}{2} (X_o - \mu)^2\right\}. \quad (3.13)$$

A distribuição da equação acima 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 um grande número 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 505.000 iterações de MCM, com um descarte inicial (*burn in*) de 5.000 iterações, e sendo salvo valores a cada 50 iterações.

Para determinar as estimativas centrais das mudanças e apresentar os padrões espaciais das projeções climáticas (veja, por exemplo, Figura 5.26), os seguintes procedimentos foram realizados: i) PDFs são estimadas para cada ponto de grade fazendo-se uso do método *Kernel Density Estimation*⁹ 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 ii) o mesmo procedimento é repetido para todos os pontos de grade continentais.

Avaliando a equação 3.13, podemos observar que a distribuição de μ fixando todos os outros parâmetros é uma distribuição Gaussiana com média

$$\bar{\mu} = \frac{\sum_{i=0}^N \lambda_i X_i}{\sum_{i=0}^N \lambda_i} \quad (3.14)$$

e variância

⁹ *Kernel Density Estimation* é uma forma não paramétrica comumente utilizada para estimar a função densidade de probabilidade de uma variável aleatória.

$$\left(\sum_{i=0}^N \lambda_i \right)^{-1} \quad (3.15)$$

De forma similar, a distribuição condicional de v é uma Gaussiana com média

$$\bar{v} = \frac{\sum_{i=1}^N \lambda_i Y_i}{\sum_{i=1}^N \lambda_i} \quad (3.16)$$

e variância

$$\left(\theta \sum_{i=1}^N \lambda_i \right)^{-1} \quad (3.17)$$

As equações 3.14 e 3.16 são análogas ao método REA (equação 3.1). Como no caso daquele método, estes pesos irão depender dos dados, mas uma fundamental diferença é que no modelo estatístico bayesiano essas quantidades são aleatórias, e com isso, as incertezas em suas estimativas são levadas em conta. Tal incerteza irá aumentar a largura da distribuição posterior de v , μ e conseqüentemente de $\Delta\xi$.

Uma aproximação da média da distribuição posterior dos λ_i 's para $i = 1, \dots, N$, é

$$E(\lambda_i | \{X_o, \dots, X_N, Y_1, \dots, Y_N\}) \approx \frac{a + 1}{b + \frac{1}{2} [(X_i - \bar{\mu})^2 + \theta(Y_i - \bar{v})^2]} \quad (3.18)$$

Avaliando a equação acima constatamos que λ_i é grande uma vez que $|X_i - \bar{\mu}|$ e $|Y_i - \bar{v}|$ sejam pequenos. Estas duas quantidades correspondem aos critérios de viés e convergência, 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). A importante diferença do método REA para este modelo é que a distância é baseada na projeção futura (Y_i) ao invés da mudança $Y_i - X_i$. Adicionalmente, no limite quando $\lambda_o \rightarrow \infty$ (ou seja, utilizando a observação X_o como uma estimativa extremamente precisa da variável verdadeira μ), $\bar{\mu} \rightarrow X_o$, e o termo de viés se torna no limite $|X_i - X_o|$, a mesma definição de viés utilizada na análise do REA.

3.2.3. Índice de Mudança Climática Regional (*RCCI*)

Nas últimas décadas tem-se tornado amplamente reconhecido pela comunidade científica que políticos e tomadores de decisão necessitam de informações confiáveis e ao mesmo tempo concisas sobre mudanças climáticas e seus possíveis impactos, juntamente com estimativas fidedignas das incertezas envolvidas. As projeções de mudanças climáticas são de uma natureza completamente diferente das previsões de tempo e clima, e é extremamente importante que o usuário final dessa informação esteja ciente de suas incertezas e limitações (GIORGI, 2005; KNUTTI, 2008; XU et al., 2009).

Uma possibilidade de atender essa necessidade de um breve panorama dos fatos científicos é a criação de índices de mudanças climáticas que agreguem diversas informações e estimativas de incertezas (GIORGI, 2006; BAETTIG et al., 2007; DIFFENBAUGH et al., 2007, 2008; XU et al. 2009; PRESTON et al., 2011; DIFFENBAUGH; GIORGI, 2012; TORRES et al., 2012). Entretanto, como enfatizado por Diffenbaugh e Giorgi (2012), os impactos das mudanças climáticas possivelmente serão determinados pelas características físicas, biológicas, e humanas locais. Por outro lado, a quantificação integrada de mudanças através de um conjunto de indicadores climáticos poderia ajudar na identificação de *hotspots* de mudanças climáticas para estudos de impacto, adaptação, e vulnerabilidade (DIFFENBAUGH; GIORGI, 2012; TORRES et al., 2012). Desta maneira, alguns índices de mudanças climáticas podem ser encontrados na literatura, tais como o Índice de Mudança Climática Regional (*Regional Climate Change Index – RCCI*; GIORGI, 2006), o *Climate Change Index* (BAETTIG et al., 2007), e o *Squared Chord Distance* e *Standard Euclidean Distance* (DIFFENBAUGH et al., 2008; DIFFENBAUGH; GIORGI, 2012).

Neste estudo o índice *RCCI* será aplicado sobre toda América do Sul, e a confiabilidade nos resultados será investigada utilizando-se diferentes projeções de mudanças climáticas como dados de entrada. Especificamente, o *RCCI* será computado para os 24 MCGs do CMIP3, e para os 24 MCGs do CMIP5. Portanto, as incertezas com relação ao uso de diferentes MCGs e cenários forçantes serão analisadas, e os principais *hotspots* climáticos sobre a América do Sul serão identificados.

O *RCCI* é um índice qualitativo proposto por Giorgi (2006), o qual é bem aceito na literatura como uma forma simples de identificar aquelas regiões aonde as mudanças climáticas podem ser, numa base relativa, mais pronunciada (XU et al., 2009; MAY, 2012; LI et al., 2013). Este índice é baseado em algumas quantidades de mudanças climáticas representativas: mudança de temperatura em uma dada região em específico relativo à mudança de temperatura média global (ou *regional warming amplification factor* – *RWAF*, adimensional), mudança na precipitação média (ΔP , % do valor do clima presente), e mudança na variabilidade interanual de temperatura ($\Delta\sigma_T$, % do valor do clima presente) e precipitação ($\Delta\sigma_P$, % do valor do clima presente). Todas as mudanças tratadas nesse estudo para o *RCCI* dizem respeito às projeções para o período de 2071-2100 com relação a 1961-1990. O *RCCI* possui uma natureza simplista e exploratória, permitindo a síntese de conjuntos de projeções climáticas constituídas de um grande número de modelos climáticos. No entanto, apesar dessa natureza simplista e exploratória, este índice pode ser útil para aprimorar o diálogo entre, por exemplo, cientistas climáticos e sociais, e para comunicar as projeções de mudanças climáticas para políticos e tomadores de decisão em uma forma mais concisa e socialmente relevante.

Originalmente, como proposto por Giorgi (2006), todas as quantidades mencionadas acima são calculadas separadamente para as estações seca e chuvosa. Entretanto, neste estudo, aquelas quantidades são calculadas para o verão (DJF) e inverno (JJA) austral, da mesma forma como calculado por Xu et al., (2009). Todavia, em quase toda América do Sul, as estações seca e chuvosa ocorrem durante as estações de inverno e verão austral, respectivamente, exceto para algumas localidades, tais como sobre o leste do Nordeste brasileiro, e no norte e noroeste da América do Sul (LIEBMANN; MARENGO, 2001; RAO et al., 1993). Portanto, o *RCCI* é finalmente definido como:

$$RCCI = [n(\Delta P) + n(\Delta\sigma_P) + n(RWAF) + n(\Delta\sigma_T)]_{DJF} + [n(\Delta P) + n(\Delta\sigma_P) + n(RWAF) + n(\Delta\sigma_T)]_{JJA} \quad (3.19)$$

em que n é um fator empírico que assume o valor de 0, 1, 2, ou 4, dependendo da magnitude da mudança envolvida (Tabela 3.3).

Por exemplo, assumindo uma localidade hipotética que apresenta para o verão austral $\Delta P = 2\%$, $\Delta\sigma_P = 18\%$, $RWAF = 1.2$, e $\Delta\sigma_T = 16\%$; e para o inverno austral $\Delta P = 14\%$, $\Delta\sigma_P = 8\%$, $RWAF = 1.4$, e $\Delta\sigma_T = -20\%$. Portanto, consultando a Tabela 3.3, o *RCCI* assume o valor:

$$RCCI = [0 + 2 + 1 + 4]_{DJF} + [2 + 1 + 2 + 4]_{JJA} = 16.$$

O mesmo procedimento é realizado sobre todas as localidades (ou pontos de grade) no domínio de estudo, e os valores do *RCCI* são comparados entre as localidades para identificar, de forma relativa, as regiões em que as mudanças climáticas podem ser mais proeminentes.

Tabela 3.3 - Valores dos fatores n usados na determinação do *RCCI*.

n	$ \Delta P $	$ \Delta\sigma_P $	$ RWAF $	$ \Delta\sigma_T $
0	<5%	<5%	<1.1	<5%
1	5 – 10%	5 – 10%	1.1 – 1.3	5 – 10%
2	10 – 15%	10 – 20%	1.3 – 1.5	10 – 15%
4	>15%	>20%	>1.5	>15%

O desvio padrão interanual de temperatura é utilizado como uma medida de σ_T , e o coeficiente de variação é utilizado como uma medida de σ_P . Tanto σ_T quanto σ_P são calculados para os períodos de 1961-1990 e 2071-2100 depois de retirada a tendência linear dos dados, para se obter uma estimativa não enviesada da variabilidade (GIORGI, 2006). O coeficiente de variação é usado como uma medida da variabilidade interanual de precipitação porque remove a dependência do desvio padrão com relação à média para variáveis delimitadas inferiormente por zero, tais como a precipitação (RÄISÄNEN, 2002; GIORGI, 2006).

Com o propósito de intercomparação e criar a possibilidade futura de relacionar o *RCCI* mais apropriadamente com dados de alta resolução espacial tais como dados sociais e econômicos (TORRES et al., 2012), todos os MCGs foram interpolados para uma grade regular comum de $1^\circ \times 1^\circ$ de latitude/longitude utilizando o esquema *conservative re-mapping* (JONES, 1999), de forma análoga à alguns autores na literatura (GIORGI; Bi, 2005; GIORGI, 2006; XU et al., 2009; DIFFENBAUGH; GIORGI, 2012).

Para o cálculo do *RCCI*, todas as estatísticas climáticas foram computadas como segue: 1) a mudança projetada foi calculada para cada rodada do modelo (2071-2100 menos 1961-1990); 2) quando disponível, tirou-se a média das diferentes rodadas do mesmo modelo; 3) os resultados foram interpolados para a resolução espacial de 1° de latitude/longitude; 4) a média do conjunto dos diferentes modelos disponíveis foi obtida; e 5) computou-se a média para os experimentos com diferentes cenários forçantes. Entretanto, quando analisando as incertezas com relação aos diferentes cenários forçantes, a etapa 5 foi excluída.

4 SIMULAÇÕES DOS PADRÕES CLIMÁTICOS OBSERVADOS

Antes de analisarmos as projeções de mudanças climáticas, todos os MCGs utilizados nesse estudo serão avaliados quanto ao seu desempenho em simular a climatologia observada (1961-1990) das variáveis temperatura do ar próximo à superfície e precipitação sobre a América do Sul, representada pela climatologia dos dados do CRU TS 3.0 (ver seção 3.1). Para uma melhor organização, as seções 4.1 e 4.2 foram criadas para separar os resultados dos modelos do CMIP3 e CMIP5, respectivamente.

4.1. Modelos do CMIP3

Na figura 4.1 é apresentada a climatologia média sazonal e anual de precipitação e viés associado, resultante da média do conjunto de todos os modelos do CMIP3 utilizados para o período de 1961 a 1990. Em geral, a média do conjunto de MCGs representa bem o sistema de monção na América do Sul e a associada Zona de Convergência do Atlântico Sul (ZCAS), caracterizadas pela migração noroeste/sudeste dos valores máximos de precipitação no decorrer das estações, desde a bacia Amazônica até o sudeste do Atlântico (Figura 4.1a-e). Entretanto, vieses consideráveis podem ser observados em algumas localidades quando comparado às observações. Por exemplo, superestimativas de precipitação são encontradas para quase todas as estações (exceto para JJA) e na média anual sobre a região central dos Andes/ altiplano andino (com valores de viés acima de 4 mm.dia⁻¹ em alguns lugares), assim como constatado por Seth et al. (2010) e Minvielle e Garreaud (2011), e superestimativas (~1-4 mm.dia⁻¹) sobre o Nordeste do Brasil durante o verão austral (Figura 4.1f-j). Subestimativas de precipitação são observadas na porção central da bacia do Prata para todas as estações (~ 1-4 mm.dia⁻¹), e em aproximadamente toda Amazônia, leste da Colômbia, Venezuela, Guiana, Guiana Francesa, e Suriname (~1-4 mm.dia⁻¹) (Figura 4.1f-j).

Com relação à simulação da climatologia de temperatura do ar próximo à superfície, a média do conjunto é bastante similar aos padrões observados, e o viés da temperatura não excede 1°C em grande parte do continente sul-americano (Figura 4.2). Todavia, temperaturas mais baixas do que as observadas são simuladas sobre o Nordeste e centro-oeste brasileiro (exceto em SON) e na região dos Andes, e temperaturas maiores do

que as observações são identificadas no nordeste da Argentina (exceto em JJA), sobre o Chile e oeste do Peru, e sobre a bacia Amazônica em SON (Figura 4.2f-j).

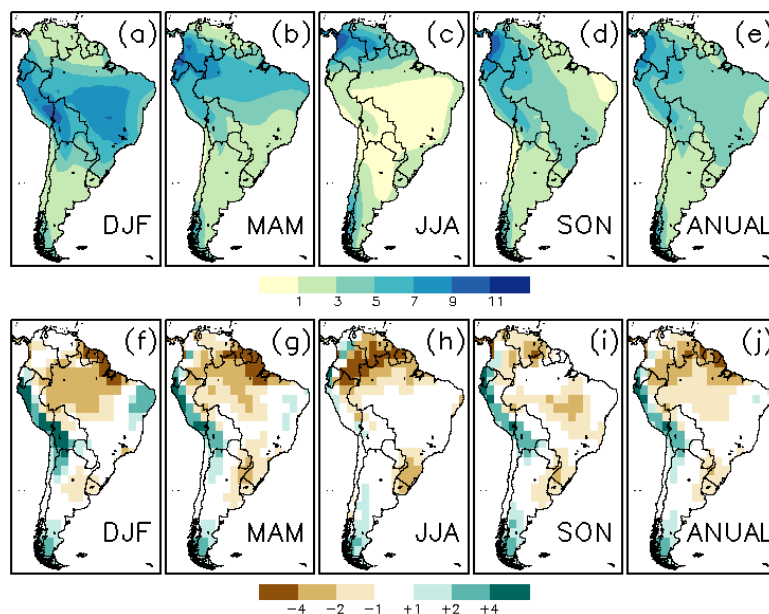


Figura 4.1 - Climatologia média sazonal e anual de precipitação (superior), e viés associado (inferior), resultante da média do conjunto de 24 modelos do CMIP3 utilizados para o período de 1961 a 1990. As unidades estão em mm dia⁻¹.

Avaliando individualmente as simulações de precipitação de todos os MCGs do CMIP3 (Figura A.1), podemos observar que existe certa similaridade entre os vieses de todos os modelos. De forma geral, eles superestimam a precipitação sobre a região dos Andes e a subestimam no norte/noroeste da América do Sul em todas as estações do ano. Adicionalmente, quase todos os MCGs subestimam a precipitação sobre a bacia Amazônica durante o verão austral, exceto UKMO-HADGEM1, MIROC3.2(hires), e MIROC3.2(medres). Notavelmente, CSIRO-MK3.0, CSIRO-MK3.5, INM-CM3, e IPSL-CM4 apresentam os piores desempenhos com relação à precipitação sobre a Amazônia, subestimando esta variável em todas as estações. Além disso, corroborando estudos anteriores (VERA et al., 2006; BOMBARDI; CARVALHO, 2009), nenhum modelo demonstra desempenho superior em simular a precipitação sobre a América do Sul como um todo, e em todas as estações. Mesmo aqueles MCGs com resolução horizontal mais baixa (e.g., GISS-EH, GISS-ER, e CGCM3.1-T47) apresentam resultados bastante

comparáveis àqueles com resolução mais alta. Além disso, observamos que os modelos CSIRO-MK3.0 e CSIRO-MK3.5 classificados como modelos de mais alta resolução no CMIP3 (Tabela 3.1) apresentaram os piores desempenhos em simular a precipitação sobre a região de estudo.

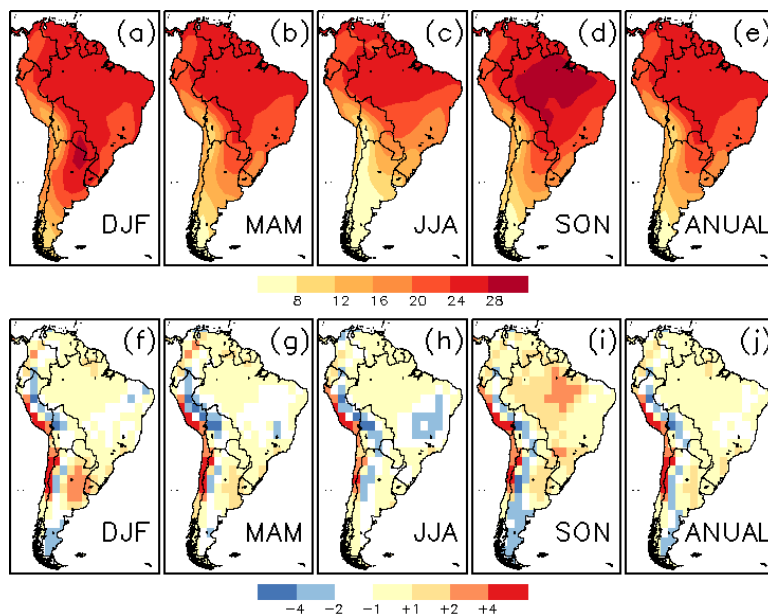


Figura 4.2 - Climatologia média sazonal e anual de temperatura do ar próximo à superfície (superior), e viés associado (inferior), resultante da média do conjunto de 24 modelos do CMIP3 utilizados para o período de 1961 a 1990. As unidades estão °C.

Diferentemente da precipitação, quando avaliando as simulações com relação à variável temperatura não identificamos uma similaridade bem definida entre os vieses dos diferentes MCGs do CMIP3 (Figura A.2). Notavelmente, apesar dos vieses não exceder $\pm 1^\circ\text{C}$ sobre boa parte do continente na média do conjunto, como mencionado anteriormente, alguns modelos apresentam magnitudes de vieses consideráveis, excedendo $\pm 4^\circ\text{C}$ em algumas partes da Amazônia e noroeste da América do Sul. Em geral, os modelos CCSM3, UKMO-HADGEM1, e MIROC3.2(hires) apresentam os menores vieses de temperatura sobre o continente sul-americano como um todo. Por outro lado, o modelo CSIRO-MK3.5 destaca-se como aquele com o pior desempenho entre todos os MCGs, superestimando a temperatura em quase todo o domínio de estudo, chegando a

valores acima de +4°C sobre toda a bacia Amazônica e noroeste da América do Sul. Assim como para a variável precipitação, praticamente todos os MCGs do CMIP3 apresentam baixo desempenho em simular a temperatura observada sobre os Andes e o extremo oeste do continente sul-americano, o que torna a confiabilidade das projeções sobre essa região bastante baixa.

O CSIRO-MK3.5 ilustra bem a problemática de se utilizar uma ampla gama de modelos para simulações e projeções de mudanças climáticas. Ao avaliarmos as variáveis precipitação e temperatura para todo o domínio de estudo constatamos que ele apresenta os vieses mais altos para ambas as variáveis. Nesse sentido pareceria óbvia a decisão de excluir esse modelo das análises, apesar dele possuir uma resolução alta ($\sim 1.9^\circ \times 1.9^\circ$) quando comparado aos outros MCGs do CMIP3 (Tabela 1). No entanto, se avaliarmos o CSIRO-MK3.5 somente sobre a Argentina, o classificariamos como aquele modelo com a melhor simulação das variáveis precipitação e temperatura sobre essa região. Além disso, se outras variáveis fossem incluídas nas análises, tais como PNM, umidade, vento, esse modelo pode demonstrar um resultado superior a certos membros do conjunto. Dessa forma, aquelas metodologias que atribuem diferentes pesos aos membros dos conjuntos multi-modelos para cada localidade analisada (tais como o método *REA* e a inferência bayesiana), levando-se em consideração certas características de avaliação como viés, parecem bastante razoáveis e promissoras para obter-se resultados mais confiáveis.

A má representação das condições climáticas (aqui representadas por precipitação e temperatura) sobre os Andes pode estar relacionada, entre outras coisas, à resolução horizontal grosseira dos MCGs que não permitem um detalhamento mais refinado da complexa topografia dessa região, assim como também enfatizado por Minvielle e Garreaud (2011). Deficiências nos esquemas de parametrização da convecção cúmulus sobre complexa topografia também pode ser um fator importante para explicar o viés de precipitação sobre a região andina. O viés seco sobre a bacia do Prata pode estar associado a deficiências dos MCGs em representar corretamente o transporte de vapor d'água e convergência de umidade sobre a região (SETH et al., 2010; GULIZIA et al., 2013). Sobre a bacia Amazônica, a sistemática subestimativa de precipitação pelos modelos

climáticos pode estar relacionada a inúmeros fatores, tais como má representação da convecção cúmulus, das interações biosfera-atmosfera na floresta tropical, da umidade no solo, e de outros processos na camada limite planetária. Por outro lado, existe uma grande deficiência na cobertura espacial e temporal de dados observados sobre a América do Sul, principalmente na bacia Amazônica e sobre os Andes nos quais poucas estações meteorológicas estão disponíveis, o que certamente deve influenciar um pouco a magnitude e localização dos padrões de viés, principalmente para precipitação.

Kim et al. (2008), ao avaliar a variabilidade espacial e temporal dos regimes de monção sobre o globo simulados pelos MCGs do CMIP3, agrupou os modelos em 3 subconjuntos de acordo com suas resoluções horizontais (grupos “low”, “medium” e “high”, correspondendo às resoluções de 4°-5°, 2°-3°, e menor do que 2° de latitude/longitude, respectivamente), na tentativa de analisar o impacto deste parâmetro na representação dos regimes de monção. Aqueles autores concluíram que, apesar de uma sutil melhora na simulação da precipitação sobre topografias elevadas apresentada pelo sub-conjunto de modelos de mais alta resolução, nenhum sub-conjunto apresentou um desempenho superior em representar as condições climáticas atuais como um todo. Mesmo o sub-conjunto de resolução horizontal mais grosseira exibem resultados comparáveis com aqueles modelos de resolução maior.

Com o objetivo de avaliar o impacto da resolução horizontal no desempenho dos modelos em simular os padrões observados de temperatura e precipitação na América do Sul, e verificar a viabilidade de exclusão daqueles modelos com resolução mais baixa, um procedimento análogo ao utilizado por Kim et al. (2008) foi aplicado neste estudo para os MCGs do CMIP3, agrupando-os em três categorias de acordo com sua resolução espacial: LOW-RES (5° x 4° lat/lon), MED-RES (2,8° x 2,8° lat/lon), e HIGH-RES (1,9° x 1,9° lat/lon). Os resultados obtidos para precipitação e temperatura são mostrados nas Figuras 4.3 e 4.4, respectivamente. Com relação à variável precipitação, de um modo geral, nenhuma redução expressiva do viés é observada com o aumento da resolução horizontal. Uma clara redução no viés com o aumento da resolução pode ser observada em DJF e MAM no sul da Amazônia, e centro-oeste e nordeste do Brasil, quando comparando os subconjuntos LOW-RES e MED-RES (Figura 4.3). Por outro lado, ao con-

trário de Kim et al. (2008), nenhuma melhora perceptível pode ser vista sobre a simulação da precipitação sobre a cordilheira dos Andes, o que sugere que aperfeiçoamentos nas parametrizações de convecção dos modelos podem ser um fator predominante na tentativa de reduzir o viés dessa variável, ao invés apenas do aumento da resolução. Com relação à variável temperatura, uma tênue redução de viés pode ser observada com o aumento da resolução entre os subconjuntos MED-RES e HIGH-RES. Entretanto, no nordeste da Argentina em DJF, o menor viés é apresentado pelo subconjunto MED-RES, e na Amazônia brasileira o aumento da resolução implica em um aumento das superestimativas dessa variável em SON.

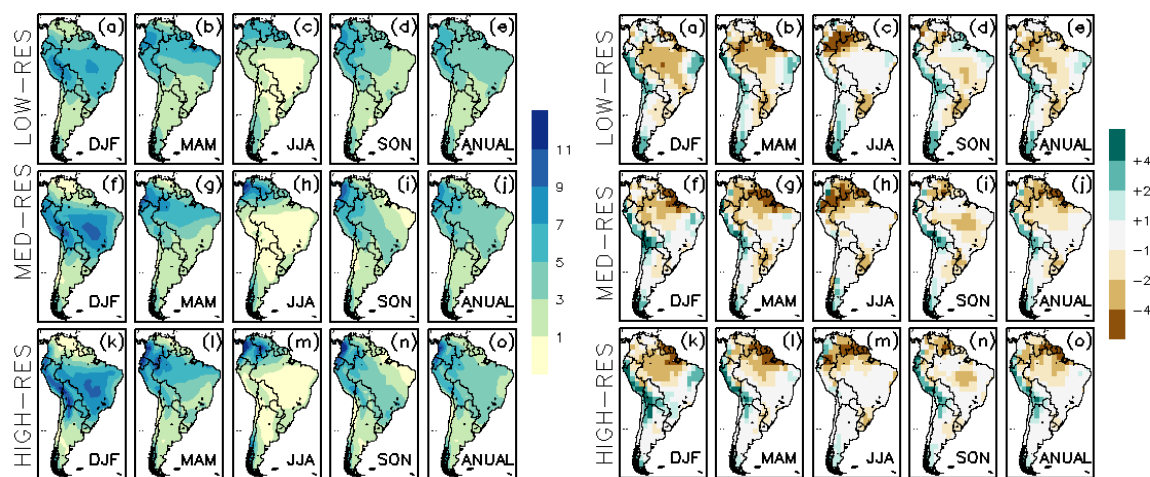


Figura 4.3 - Climatologia média sazonal e anual de precipitação (esquerda), e viés associado (direita), simulada pelos modelos do CMIP3 para o período de 1961 a 1990. As climatologias foram obtidas depois do agrupamento dos modelos em três subconjuntos diferentes de acordo com sua resolução horizontal: LOW-RES (superior), MED-RES (central), HIGH-RES (inferior), referentes às resoluções (em graus de latitude/longitude) de $5^{\circ} \times 4^{\circ}$, $2,8^{\circ} \times 2,8^{\circ}$, e $1,9^{\circ} \times 1,9^{\circ}$, respectivamente. As unidades estão mm dia^{-1} .

Dessa forma, constatamos que uma alta resolução horizontal é uma condição necessária e altamente desejável para fornecer informações com o maior detalhamento regional possível, mas não suficiente para uma boa simulação dos padrões climáticos de uma região. Portanto, uma vez que os vieses dos MCGs pertencentes ao subconjunto LOW-RES são comparáveis àqueles modelos de resolução horizontal mais alta, decidiu-se

utilizar daqui pra frente todos os MCGs disponíveis em nossas análises, ao invés de utilizarmos somente aqueles de resolução maior.

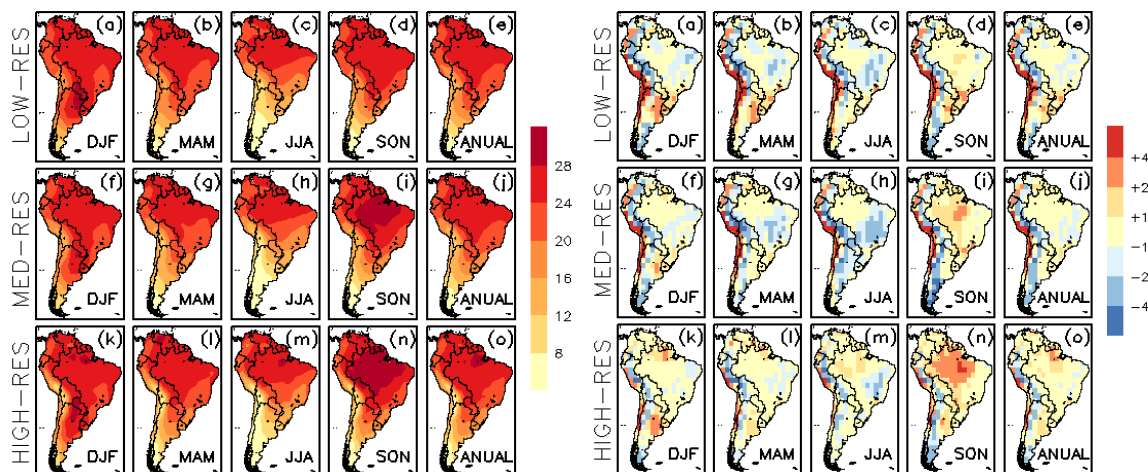


Figura 4.4 - Climatologia média sazonal e anual de temperatura do ar próximo à superfície (esquerda), e viés associado (direita), simulada pelos modelos do CMIP3 para o período de 1961 a 1990. As climatologias foram obtidas depois do agrupamento dos modelos em três subconjuntos diferentes de acordo com sua resolução horizontal: LOW-RES (superior), MED-RES (central), HIGH-RES (inferior), referentes às resoluções (em graus de latitude/longitude) de $5^\circ \times 4^\circ$, $2,8^\circ \times 2,8^\circ$, e $1,9^\circ \times 1,9^\circ$, respectivamente. As unidades estão $^\circ\text{C}$.

O ciclo anual observado e simulado das variáveis precipitação e temperatura é apresentado nas Figuras 4.5 e 4.6, respectivamente, para as quatro sub-regiões indicadas na Figura 3.1, sendo elas: leste da Amazônia (EAMZ), oeste da Amazônia (WAMZ), Nordeste do Brasil (NEB), e Bacia do Prata (BPT). A média do erro quadrático médio de todos os 24 MCGs (\overline{RMSE}) também é indicada nessas figuras. Para a variável precipitação, o ciclo anual é razoavelmente bem representado pela média dos modelos (indicada na Figura 4.5 como a linha em negrito) para as sub-regiões avaliadas. Entretanto, algumas deficiências podem ser facilmente constatadas, tais como o viés seco apresentado por quase todos os MCGs, exceto para a região NEB durante os meses de novembro a março. Dentre as sub-regiões, os MCGs apresentam os piores resultados para a Amazônia, no qual subestimam muito o período chuvoso no leste dessa região, e para o oeste

defasa o período seco entorno de 1 mês e simula um pico chuvoso secundário inexistente em novembro. Outra deficiência marcante é a defasagem de cerca de 1 mês do período chuvoso simulado no NEB. Além disso, um aspecto notável é que as 3 sub-regiões cujos domínios englobam a região equatorial (EAMZ, WAMZ, e NEB) obtiveram resultados inferiores aqueles da região da bacia do Prata. Um dos fatores que pode estar relacionado a isso é a má representação da localização e do ciclo anual da ZCIT pelos MCGs do CMIP3 (LIN, 2007; BOMBARDI; CARVALHO, 2009).




Figura 4.5 - Ciclo anual de precipitação observada (azul, CRU TS 3.0) e simulada (cinza) pelos 24 modelos do CMIP3 analisados nas sub-regiões de estudo: leste e oeste da Amazônia (EAMZ e WAMZ, respectivamente), nordeste do Brasil (NEB), e bacia do Prata (LPB). A linha em negrito representa a média de todos os modelos. A média do erro quadrático médio (\overline{RMSE}) de todos os modelos é indicada na figura.

A região EAMZ foi a que apresentou o maior \overline{RMSE} entre os membros do conjunto de simulações (2,52). Para esta região, o modelo UKMO-HadGEM1 foi aquele que apresentou o melhor desempenho ($RMSE = 1,31$), e em contrapartida, o modelo CSIRO-MK3.5, o pior desempenho ($RMSE = 4,03$). Apesar da região WAMZ apresentar uma

magnitude menor de \overline{RMSE} (1,98) entre os diversos MCGs comparado à EAMZ, os mesmo modelos (UKMO-HadGEM1 e CSIRO-MK3.5) foram aqueles que apresentaram o melhor ($RMSE = 0,75$) e pior desempenho ($RMSE = 3,19$) sobre a região. Na região NEB, o valor médio de $RMSE$ para todos os membros foi 1,47, dentre os quais o modelo MRI-CGCM2.3.2 destacou-se com o melhor resultado ($RMSE = 0,41$) e o modelo GISS-EH com o pior desempenho ($RMSE = 2,64$). Por fim, a sub-região da bacia do Prata foi aquela cujos MCGs apresentaram os resultados mais consistentes para o ciclo anual de precipitação, refletido em um valor relativamente baixo de $RMSE$ para a média do conjunto (1,01). Nesta região, a simulação mais próxima das observações foi produzida pelo CGCM3.1(T63), e a mais distante pelo IPSL-CM4, com valores de $RMSE$ de 0,33 e 2,07, respectivamente.

Com relação ao ciclo anual de temperatura (Figura 4.6), a média do conjunto de MCGs apresenta uma boa representação dos padrões observados, e uma razoável concordância entre todos os modelos analisados, apesar de uma amplitude de oscilação irrealista para as sub-regiões que incluem a bacia Amazônia. Assim como para a variável precipitação, as sub-regiões de maiores discrepâncias entre os membros do conjunto continuam sendo EAMZ e WAMZ ($\overline{RMSE} = 1,70$ e $1,83$, respectivamente). Para EAMZ, os modelos CSIRO-MK3.5 e GISS-ER foram aqueles que apresentaram o pior ($RMSE = 5,23$) e melhor ($RMSE = 0,39$) desempenho, respectivamente. Na sub-região WAMZ, como em EAMZ, o melhor desempenho foi obtido pelo modelo GISS-ER ($RMSE = 0,44$), e a representação mais deficiente foi apresentada pelo modelo CSIRO-MK3.5 ($RMSE = 5,84$). Vale a pena ressaltar que o modelo CSIRO-MK3.5 apresentou os piores desempenhos em representar tanto o ciclo anual de precipitação quanto o de temperatura na região Amazônica, e apresentou os maiores vieses das distribuições espaciais dessas variáveis sob essa região, como avaliado anteriormente. A região NEB foi aquela cujos MCGs apresentaram os resultados mais consistentes para o ciclo anual de temperatura ($\overline{RMSE} = 1,43$). Nesta região, a simulação mais próxima das observações foi produzida pelo modelo UKMO-HadCM3, e a mais distante pelo INM-CM3.0, com valores de $RMSE$ de 0,54 e 2,36, respectivamente. Por fim, na sub-região LPB o valor médio de $RMSE$ para todos os membros foi 1,52, dentre os quais o modelo MIROC3.2(hires) des-

tacou-se com o melhor resultado ($RMSE = 0,61$), e o modelo INM-CM3.0 com o pior desempenho ($RMSE = 3,22$).




Figura 4.6 - Mesmo que Figura 4.5, exceto para temperatura do ar próximo a superfície. A temperatura observada é indicada em vermelho.

No intuito de analisarmos mais detalhadamente o desempenho de todos os MCGs do CMIP3 sobre a América do Sul, as Figuras 4.7 e 4.8 apresentam a correlação temporal entre todos os modelos com as observações (CRU TS 3.0) para o período de 1901 a 1998, para as variáveis temperatura e precipitação. Uma vez que neste estudo estamos interessados em mudanças dos padrões climáticos que ocorrem em escalas decenais ou mais longas, um filtro média móvel foi aplicado a série para reter somente aquela variabilidade com período maior do que 30 anos.

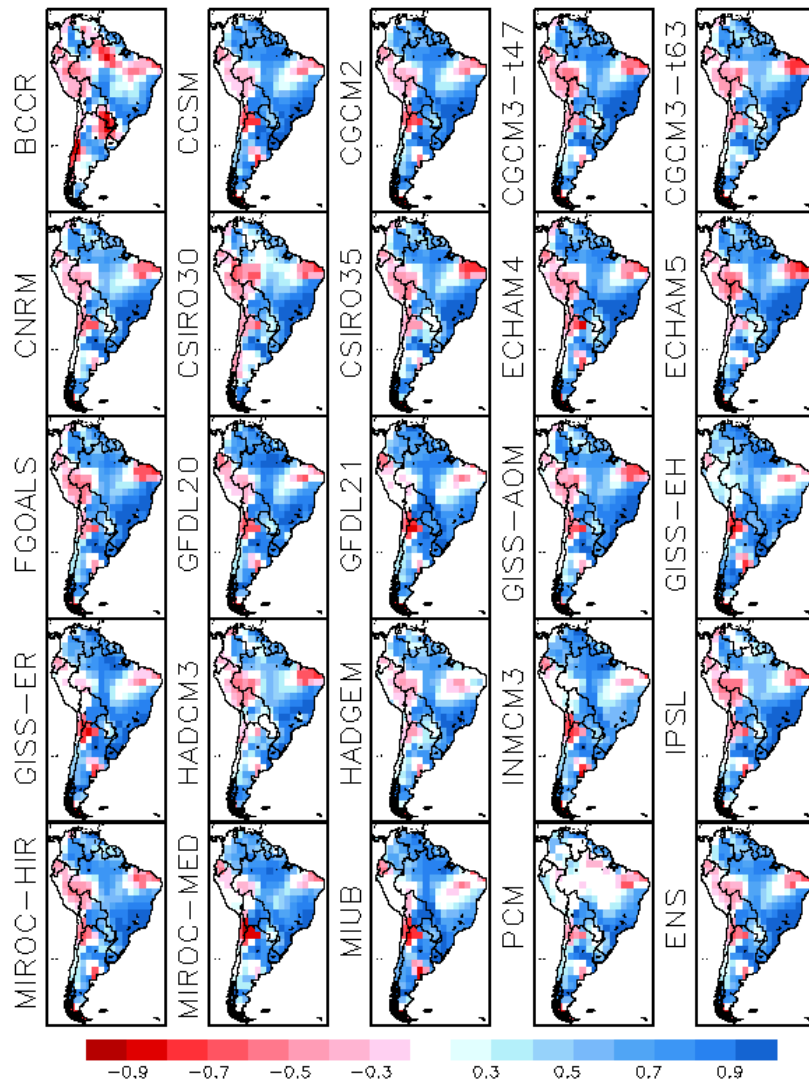


Figura 4.7 - Correlação temporal entre a série de temperatura simulada pelos MCGs do CMIP3 (indicada na esquerda de cada mapa) e a série observada (CRU TS 3.0) para o período de 1901 a 1998. Um filtro média móvel foi aplicado a série para reter somente aquela variabilidade com período maior do que 30 anos. O resultado para a média do conjunto (ENS) é indicado no mapa inferior direito.

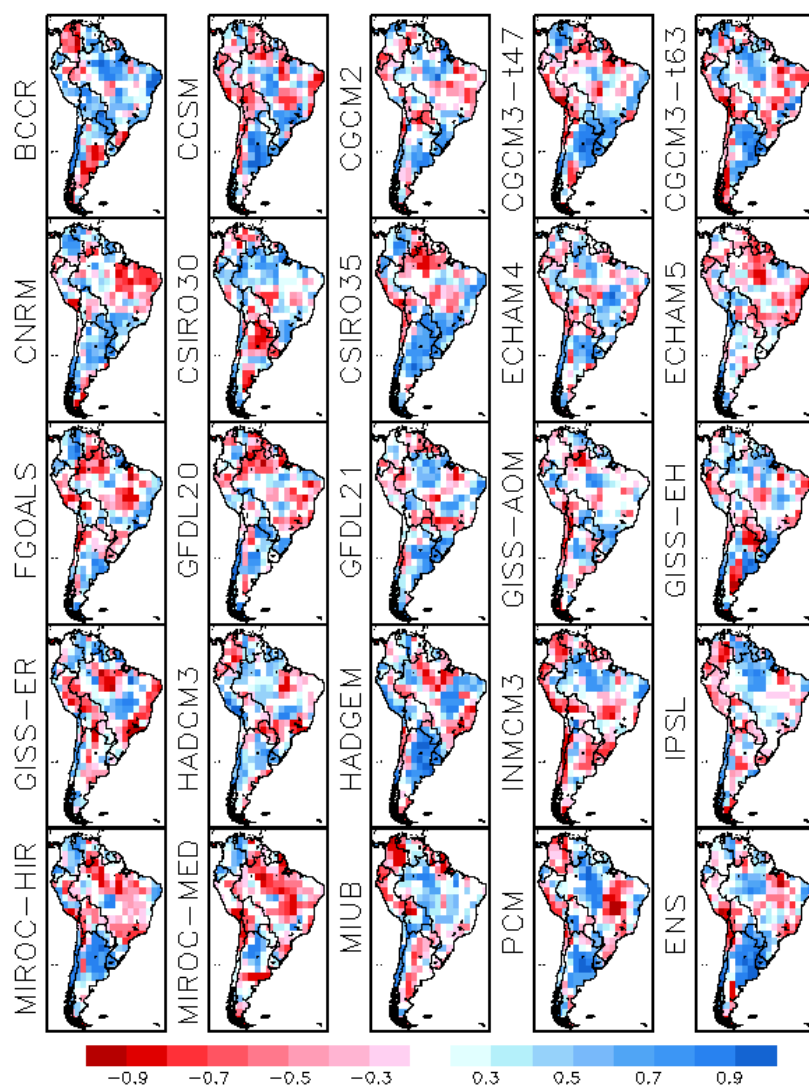


Figura 4.8 - Mesmo que Figura 4.7, exceto para a variável precipitação.

Avaliando os resultados para a correlação temporal de temperatura (Figura 4.7), podemos observar uma similaridade bastante grande entre os padrões obtidos para os diversos MCGs do CMIP3. Valores positivos altos ($>0,8$) podem ser identificados em grande parte do continente, tais como no noroeste da América do Sul, leste da Amazônia, sul, sudeste, e partes do Nordeste brasileiro, Bolívia, nordeste da Argentina, Uruguai, e extremo sul da América do Sul. Por outro lado, localidades com baixa correlação, ou até mesmo correlações negativas, podem ser encontradas no norte do Nordeste brasileiro, no entorno do estado do Acre, Peru, Equador, Chile, e em algumas partes da Argentina (regiões de correlação negativas serão discutidas com maior profundidade na próxima

seção dedicada ao conjunto CMIP5). Com relação à correlação temporal de precipitação (Figura 4.8), no geral os valores são bem mais baixos do que aqueles encontrados para temperatura e, além disso, os padrões espaciais diferem grandemente entre os diversos MCGs. Valores acima de +0,6 podem ser observados somente no norte da Argentina, Uruguai, sul do Brasil, Paraguai, e em partes da Amazônia. Nessas análises podemos constatar novamente a mais baixa acurácia das simulações da variável precipitação quando comparado à temperatura. Adicionalmente, localidades que apresentam altos valores (positivos) para ambas as variáveis podem ser considerados como mais susceptíveis a terem alta confiabilidade em suas projeções climáticas, como é o caso do nordeste da Argentina, Uruguai, sul do Brasil, e leste da Amazônia.

4.2. Modelos do CMIP5

A climatologia média sazonal e anual de precipitação e viés associado para a América do Sul, resultante da média do conjunto das simulações dos MCGs do CMIP5 utilizados nesse estudo, para o período de 1961 a 1990, é mostrada na Figura 4.9. Comparando as climatologias geradas pelos modelos do CMIP3 (Figura 4.1a-e) e CMIP5 (Figura 4.9a-e), podemos notar uma grande similaridade entre elas. Por outro lado, no novo conjunto, uma relevante redução no viés seco pode ser notada no noroeste/norte da América do Sul e na região Amazônica, e uma pequena redução também no viés seco na região da bacia do Prata. Entretanto, apesar de que no conjunto CMIP5 os MCGs possuem uma resolução horizontal maior quando comparado aos do CMIP3 (vide seção 3), nenhum melhoramento é perceptível na região dos Andes/oeste da América do Sul, corroborando as análises feitas anteriormente com os modelos do CMIP3 separados em sub-conjuntos.

Individualmente, as simulações dos diversos MCGs do CMIP5 com relação à precipitação (Figura A.3) apresentam no geral o mesmo padrão recorrente de vieses: subestimativas sobre a Amazônia e norte/noroeste da América do Sul, e superestimativas sobre os Andes. O modelo CSIRO-Mk3-6-0 permanece com os mesmos vieses de suas versões no CMIP3, continuando a se destacar como um dos piores, juntamente com o CanESM2. Por outro lado, existem vários modelos com um bom desempenho em simular

os padrões observados de precipitação, dentro os quais podemos destacar o HadGEM2-CC, HadGEM2-ES, ACCESS1.0, CCSM4, e o EC-EARTH. Além disso, podemos identificar vários modelos que estão presentes em ambos os CMIPs, logicamente em diferentes versões, e que apresentam sensíveis melhoras. Por exemplo, o modelo INMCM4 apresentou considerável redução de viés em várias regiões comparado a sua versão anterior (INMCM3) disponibilizada no CMIP3. As novas versões do IPSL (IPSL-CM5A-LR e IPSL-CM5A-MR) apresentam uma redução no viés seco sobre a Amazônia e sudeste da América do Sul, comparado à versão do CMIP3 (IPSL-CM4). A “família” GFDL apresentou uma leve melhora nas novas versões (GFDL-CM3, GFDL-ESM2G, e GFDL-ESM2M), com uma pequena redução do viés seco no norte/noroeste da América do Sul.

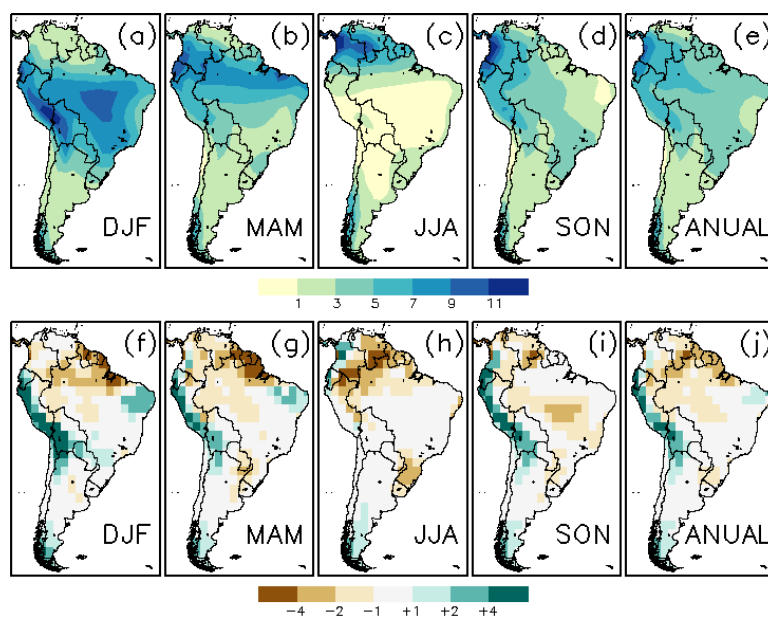


Figura 4.9 - Climatologia média sazonal e anual de precipitação (superior), e viés associado (inferior), resultante da média do conjunto de todos os modelos do CMIP5 utilizados para o período de 1961 a 1990. As unidades estão mm dia^{-1} .

Com relação à variável temperatura, é possível notar uma grande similaridade entre os resultados obtidos com o CMIP3 (Figura 4.2) e CMIP5 (Figura 4.10), tanto nas climatologias geradas pelos MCGs quanto nos vieses apresentados. Entretanto, o viés quente

sobre o leste da Amazônia em SON foi consideravelmente reduzido, e uma sutil redução no viés sobre os Andes/oeste do continente sul-americano pode ser notado nessa nova versão de modelos.

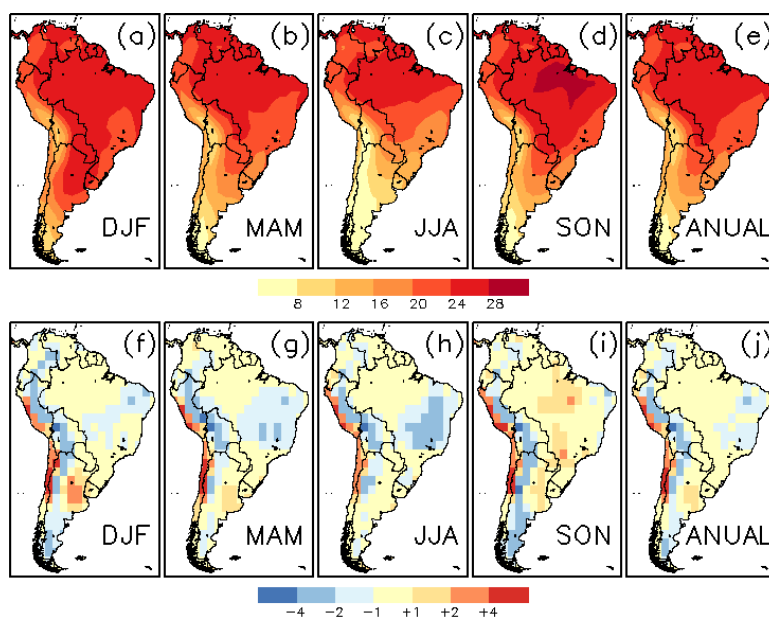


Figura 4.10 - Climatologia média sazonal e anual de temperatura do ar próximo à superfície (superior), e viés associado (inferior), resultante da média do conjunto de todos os modelos do CMIP5 utilizados para o período de 1961 a 1990. As unidades estão °C.

Avaliando individualmente as simulações de temperatura produzidas pelos diferentes MCGs do CMIP5 (Figura A.4), assim como no CMIP3, observamos que os desempenhos dos modelos são variados, e os vieses não obedecem a um padrão comum, ou seja, as regiões que apresentam uma simulação mais deficiente variam de modelo a modelo. O modelo CCSM4 destaca-se como aquele que apresenta os menores vieses em todo o domínio de estudo, inclusive sobre os Andes. Dentre aqueles MCGs que apresentam vieses mais acentuados, destacam-se os modelos CanESM2, EC-EARTH, CSIRO-Mk3-6-0, Giss-E2-R, e INMCM4. Assim como para precipitação, e para as simulações do CMIP3, praticamente todos os MCGs do CMIP5 apresentam baixo desempenho em simular a temperatura observada sobre os Andes e o extremo oeste do continente sul-

americano. No entanto, os vieses sobre a cordilheira andina reduziram visivelmente em magnitude na nova versão de MCGs.




Figura 4.11– Ciclo anual de precipitação observada (azul, CRU TS 3.0) e simulada (cinza) pelos 24 modelos do CMIP5 analisados nas sub-regiões de estudo: leste e oeste da Amazônia (EAMZ e WAMZ, respectivamente), nordeste do Brasil (NEB), e bacia do Prata (LPB). A linha em negrito representa a média de todos os modelos. A média do erro quadrático médio (\overline{RMSE}) de todos os modelos é indicada na figura.

Analisando o ciclo anual de precipitação e temperatura simulado pelos MCGs do CMIP5 (Figuras 4.11 e 4.12, respectivamente), podemos identificar diversos melhoramentos com relação ao CMIP3. Primeiramente, exceto para precipitação na região NEB, o valor médio de $RMSE$ diminuiu para as sub-regiões e variáveis avaliadas, e o espalhamento dos membros do conjunto diminuiu. Com relação à precipitação (Figura 4.11), o viés seco da média do conjunto de MCGs foi reduzido consideravelmente nas regiões EAMZ e WAMZ em todos os meses do ano, assim como também observado por Joetjer et al. (2013). Para EAMZ, Giss-E2-R destaca-se como o melhor modelo ($RMSE = 0,49$) e o CSIRO-Mk3-6-0 como aquele com o pior desempenho ($RMSE = 4,85$); e para

WAMZ os modelos com melhor e pior desempenho são INMCM4 ($RMSE = 0,70$) e CanESM2 ($RMSE = 3,05$), respectivamente. Na região NEB, a superestimativa de precipitação de janeiro a abril aumentou, o que justifica o aumento do $RMSE$ médio no CMIP5. No entanto, a defasagem de cerca de 1 mês do período chuvoso no NEB simulado pela média do conjunto do CMIP3 foi corrigida no CMIP5. Nessa região, o modelo que mais se aproximou das observações foi o HadGEM2-CC ($RMSE = 0,66$), enquanto que o Giss-E2-R foi o que mais se afastou das observações ($RMSE = 3,95$). A sub-região LPB continua sendo aquela cuja precipitação é melhor simulada pelos modelos, e na nova versão de MCGS, os resultados se aproximam ainda mais das observações. O modelo MPI-ESM-LR foi aquele que apresentou o melhor desempenho ($RMSE = 0,37$), e o Giss-E2-R o pior ($RMSE = 1,62$).

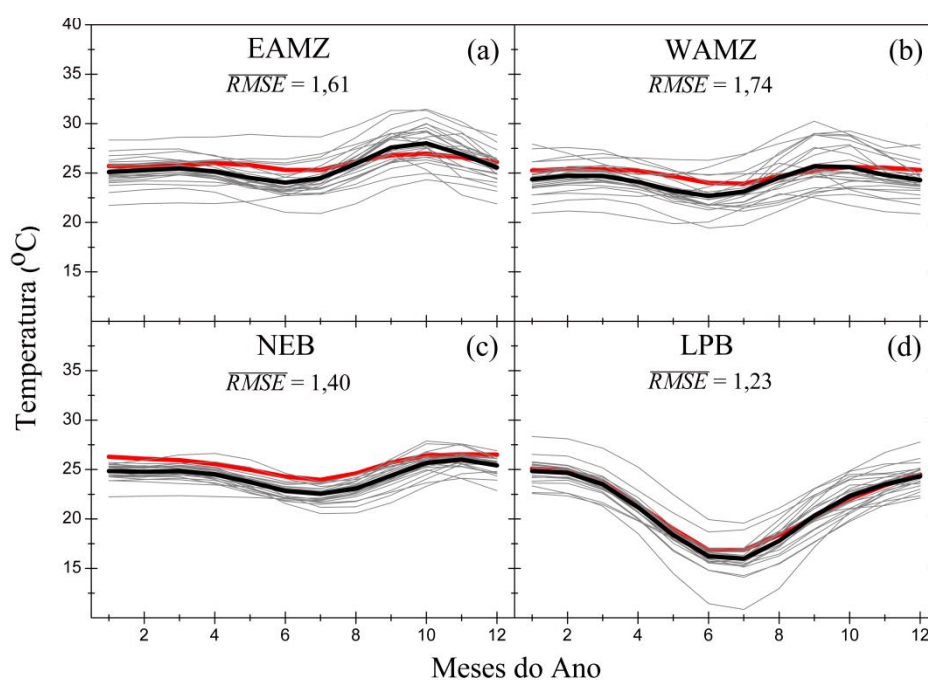


Figura 4.12 - Mesmo que Figura 4.11, exceto para temperatura do ar próximo a superfície. A temperatura observada é indicada em vermelho.

Para a variável temperatura (Figura 4.12), o ciclo anual de todas as sub-regiões é mais bem simulado no conjunto CMIP5, quando comparado ao CMIP3. Em todas as sub-regiões, o valor médio de $RMSE$ diminuiu, assim como o espalhamento dos membros do conjunto. O valor médio de $RMSE$ para EAMZ é 1,61, em que a simulação do modelo

ACCESS1.0 é a que se aproxima mais das observações ($RMSE = 0,51$), e a do modelo CSIRO-Mk3-6-0 a que mais se afasta ($RMSE = 3,32$). Por outro lado, na sub-região WAMZ, o melhor desempenho é encontrado para o modelo IPSL-CM5A-LR ($RMSE = 0,60$), e o pior desempenho para EC-EARTH ($RMSE = 3,97$). No NEB, o modelo mais hábil em simular o ciclo sazonal nessa região foi o ACCESS1.0 ($RMSE = 0,37$), e o menos hábil, assim como em WAMZ, o modelo EC-EARTH ($RMSE = 2,91$). Por fim, assim como para a variável precipitação, a sub-região na qual os MCGs apresentaram maior acurácia ao simular o ciclo sazonal de temperatura foi a LPB ($\overline{RMSE} = 1,23$), na qual o modelo NorESM1-M destaca-se entre todos com o melhor desempenho ($RMSE = 0,40$), e o INMCM4 com o pior ($RMSE = 3,56$).

Nas Figuras 4.13 e 4.14 são apresentados os resultados obtidos para a correlação temporal de todas as simulações dos MCGs do CMIP5 com as observações para as variáveis temperatura e precipitação, respectivamente. De um modo geral, os padrões espaciais de correlação para ambas as variáveis analisadas assemelham-se grandemente com aqueles obtidos com o CMIP3. Valores positivos mais altos de correlação de temperatura (Figura 4.13) continuam sendo localizados no noroeste da América do Sul, leste da Amazônia, sul, sudeste, e partes do Nordeste brasileiro, Bolívia, nordeste da Argentina, Uruguai, e extremos sul da América do Sul; e baixas correlações e correlações negativas são encontradas no estado do Acre e norte do Nordeste do Brasil, Peru, Equador, Chile, e em algumas partes da Argentina. Com relação à variável precipitação, o padrão basicamente se mantém comparado ao CMIP3, com valores positivos e negativos espalhados pelo continente, no qual correlações positivas mais altas são encontradas somente no norte da Argentina, Uruguai, e em partes da Amazônia.

Entretanto, um fato importante que nos chama a atenção no CMIP5 são as correlações de temperatura. No CMIP3 observamos uma similaridade grande entre os padrões de correlação entre todos os MCGs. Porém, para o CMIP5 é possível notar várias disparidades entre os MCGs, os quais se destacam os modelos HadGEM2-CC, HadGEM2-ES, GFDL-ESM2M, e GFDL-ESM2G, por apresentarem uma correlação negativa alta em uma vasta região, que abrange desde o noroeste da América do Sul até o sudeste/sul do Brasil e norte da Argentina.

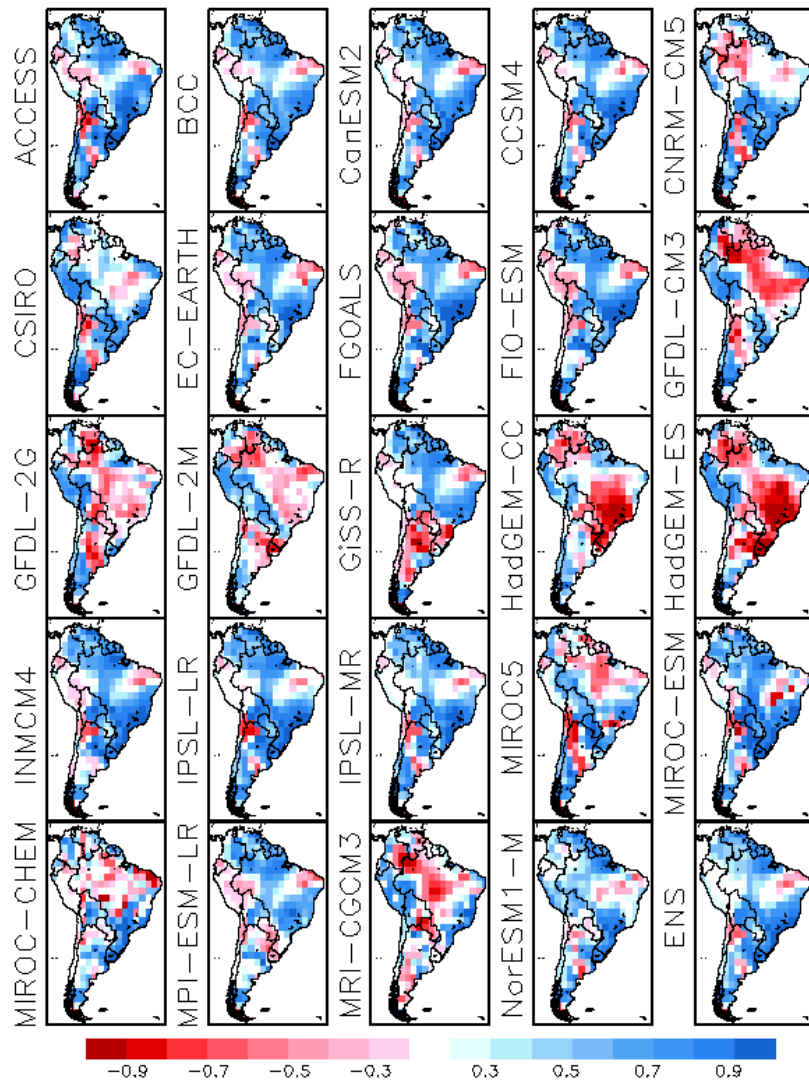


Figura 4.13 - Correlação temporal entre a série de temperatura simulada pelos MCGs do CMIP5 (indicada na esquerda dos mapas) e a série observada (CRU TS 3.0) para o período de 1901 a 1998. Um filtro média móvel foi aplicado a série para reter somente aquela variabilidade com período maior do que 30 anos. O resultado para a média do conjunto (ENS) é indicado no mapa inferior direito.

Para explorar um pouco mais o significado desse resultado, selecionamos dois pontos de grade para avaliarmos a série temporal das simulações (dos modelos com disparidades) e observações, filtradas para reter somente aquela variabilidade com período maior do que 30 anos. Cada um desses pontos foi escolhido para exemplificar uma localidade

com alta correlação positiva e uma com alta correlação negativa, conjuntamente em ambas as variáveis precipitação e temperatura. Nesse sentido, foram escolhidos os pontos (20°S, 50°W; correlação negativa alta) e (10°S, 75°W; correlação positiva alta), localizados na região sudeste do Brasil e Peru, respectivamente. Adicionalmente, as séries temporais projetadas dos modelos supracitados são avaliadas para o período de 2006 a 2100 no cenário forçante RCP4.5. Esses resultados são apresentados na Figura 4.15.

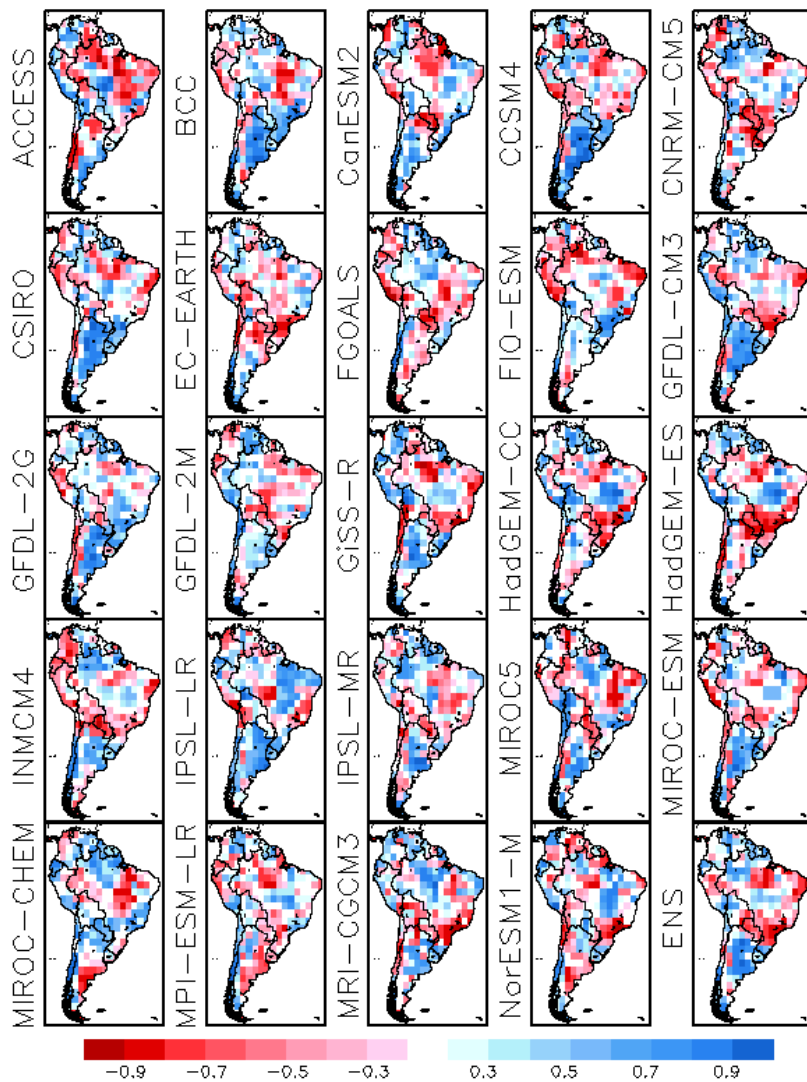


Figura 4.14 - Mesmo que Figura 4.13, exceto para a variável precipitação.

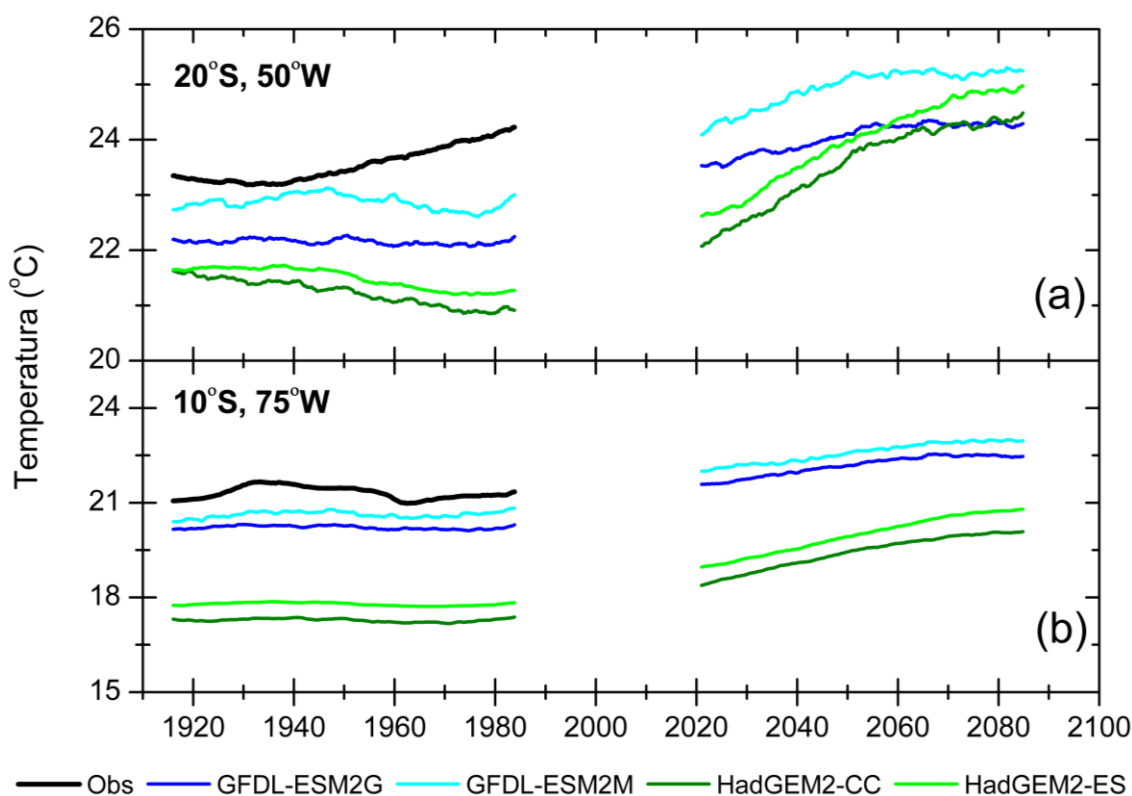


Figura 4.15 - Série temporal de temperatura simulada e projetada no cenário forçante RCP4.5, provenientes de alguns modelos do CMIP5 (GFDL-ESM2G, GFDL-ESM2M, HadGEM2-CC, e HadGEM2-ES) para duas localidades na América do Sul (as coordenadas são indicadas no canto superior esquerdo das imagens). A série observada (CRU TS 3.0) para o período presente está destacada em negrito. Um filtro média móvel foi aplicado às séries para reter somente aquela variabilidade com período maior do que 30 anos.

No ponto representativo de correlação negativa alta (Figura 4.15a), constata-se que as observações apresentam uma tendência de aumento de temperatura acentuada no período presente, enquanto que (curiosamente) os MCGs simulam temperaturas razoavelmente estáveis (GFDL-ESM2G e GFDL-ESM2M) ou com um decréscimo expressivo (HadGEM2-CC e HadGEM2-ES) para o mesmo período. Avaliando o período projetado para essa mesma localidade, observa-se que todos os MCGs indicam aumento de temperatura até o final do século, com baixa consistência com relação ao período simu-

lado. Por outro lado, no ponto representativo de uma alta correlação positiva (Figura 4.15b), as simulações dos MCGs avaliados são consistentes com a observação (a qual se manteve praticamente constante), e as séries projetadas indicam uma tendência de aumento de temperatura, entretanto, mais coerente com as simulações do clima presente. Portanto, aquelas localidades que apresentam uma alta correlação positiva entre as simulações dos MCGs e as observações podem ser entendidas como regiões onde as projeções climáticas podem ser mais consistentes ou confiáveis.

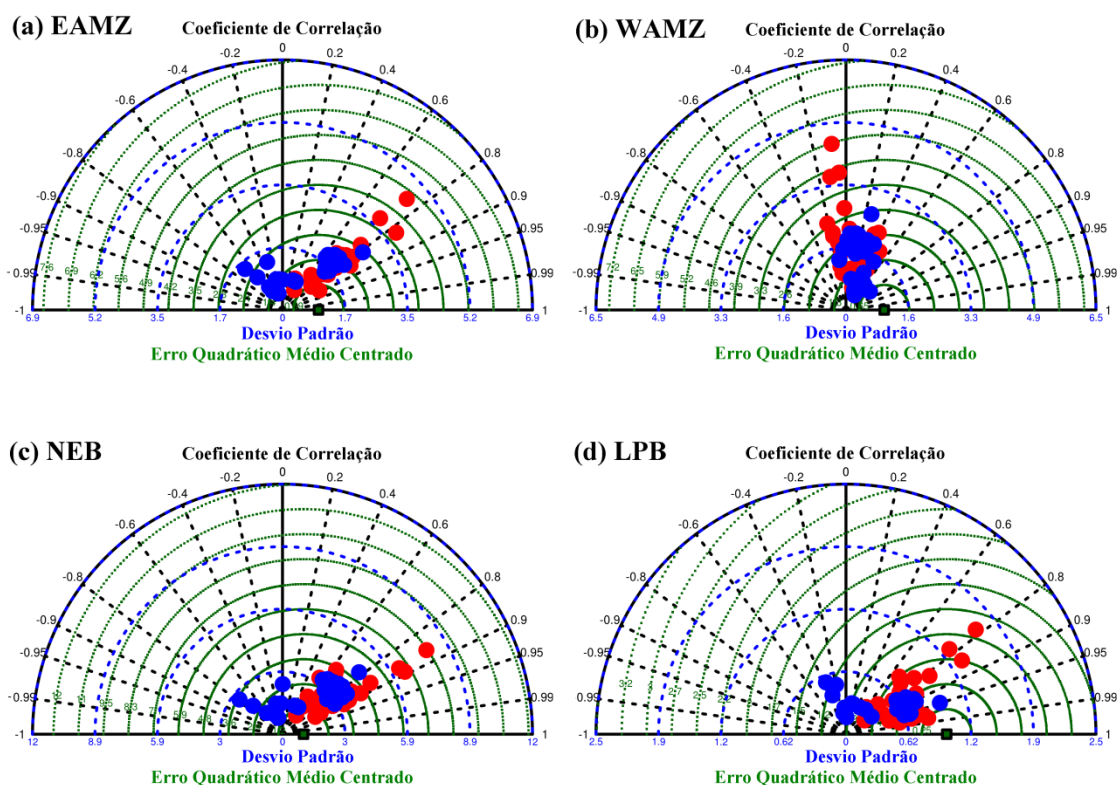


Figura 4.16 - Diagramas de Taylor para as simulações de temperatura nas sub-regiões avaliadas neste estudo para todos os MCGs do CMIP3 (círculos vermelhos) e CMIP5 (círculos azuis), relativos ao período de 1901 a 1998. As observações são indicadas como pequenos quadrados verdes na abcissa.

Por fim, os diagramas de Taylor apresentados nas Figuras 4.16 e 4.17 resumem algumas estatísticas bastante relevantes às avaliações das simulações de temperatura e precipitação, respectivamente, derivadas dos conjuntos CMIP3 e CMIP5, para as quatro sub-regiões avaliadas nesse estudo no período de 1901 a 1998. Da mesma forma que as

análises anteriores, utilizou-se um filtro média móvel nas séries para filtrar somente aquelas variabilidades com período acima de 30 anos. No geral, como observado anteriormente, para todas as sub-regiões os MCGs do CMIP5 apresentam simulações mais próximas das observações para a variável temperatura, quando comparado ao CMIP3. Esta melhora é perceptível pelos menores erros quadráticos médios das simulações, e desvios padrão simulados mais próximos das observações, quando comparados aos MCGs do CMIP3 (Figura 4.16). Quanto aos coeficientes de correlação, conforme discutido anteriormente, os resultados variam de modelo a modelo, mas as correlações positivas predominam em ambos os conjuntos. Entretanto, para a variável precipitação, apesar da melhora apresentada pelos MCGs do CMIP5 em simular os padrões sazonais médios e ciclo anual, as avaliações das séries temporais dos dois conjuntos de modelos continuam bastante comparáveis e deficientes.

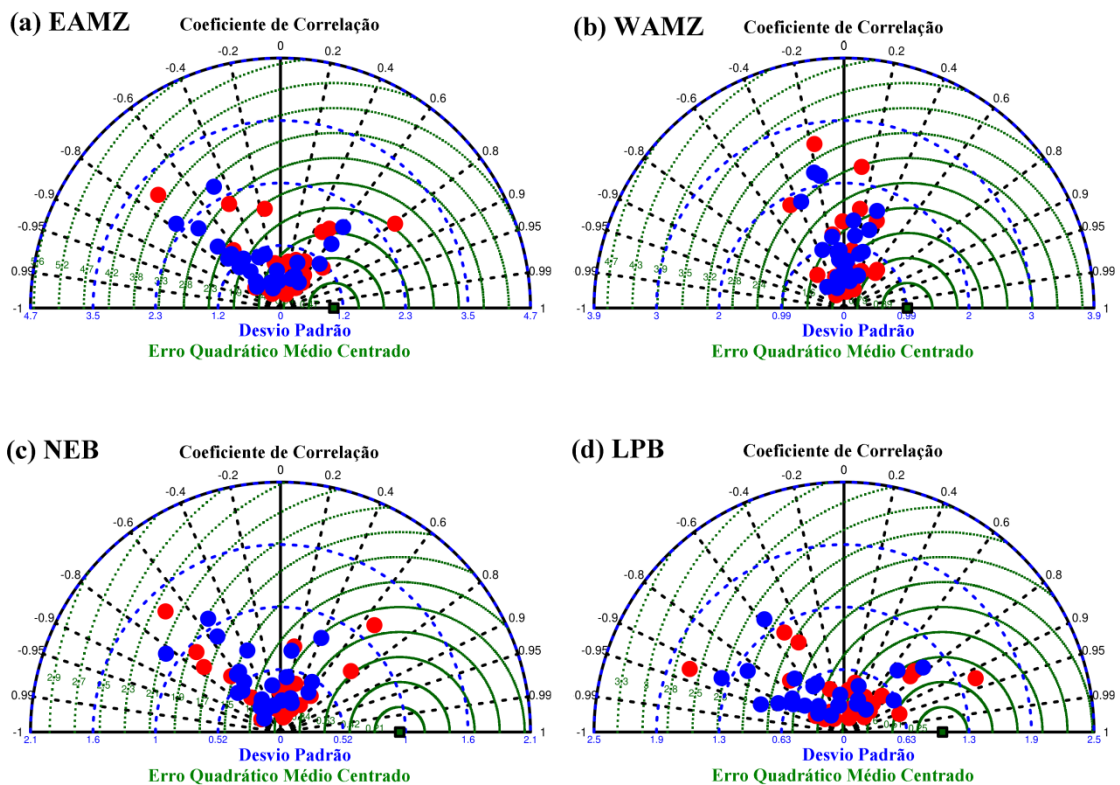


Figura 4.17 - Mesmo que Figura 4.16, exceto para a variável precipitação.

5 PROJEÇÕES DE MUDANÇAS CLIMÁTICAS NA AMÉRICA DO SUL: QUANTIFICAÇÃO DE INCERTEZAS E PROBABILIDADES

Neste capítulo serão avaliadas as projeções dos inúmeros MCGs pertencentes ao CMIP3 e CMIP5 sobre a América do Sul. Primeiramente, essas projeções serão analisadas de uma forma comumente encontrada na literatura: avaliação da média das projeções produzidas por todos os MCGs pertencentes a um determinado conjunto, e avaliação de incertezas baseado na concordância entre todos os membros do conjunto. Nesse sentido, para todas as projeções dos diferentes modelos atribui-se a mesma probabilidade de ocorrência. Em seguida, nas seções 5.1 e 5.2, as incertezas nas projeções de temperatura e precipitação serão investigadas mais profundamente ao aplicarmos as metodologias *Reliability Ensemble Averaging* e Inferência Bayesiana, descritas anteriormente na seção 3.2. Baseando-se no fato de que os padrões de mudanças climáticas diferem somente em magnitude entre os diversos cenários e períodos analisados, no intuito de reduzir o volume de informações e simplificar as análises, em algumas avaliações focaremos no período de 2071 a 2100, e em um único cenário forçante (preferencialmente o mais intenso, ou aquele que contém o maior número de modelos).

Analisando as projeções de mudanças climáticas advindas da média do conjunto de MCGs do CMIP3 (Figuras 5.1 e 5.2), verificamos que os modelos projetam um aumento de temperatura sobre toda a América do Sul, o qual é mais intenso na porção tropical do continente, e para o final do século nos cenários de maiores emissões. De acordo com a média das projeções do conjunto, a mudança de temperatura pode atingir valores acima de 4°C em toda bacia Amazônica durante o inverno e primavera austral em 2071-2100 no cenário SRES A2 (Figura 5.1a-e). Para a América do Sul como um todo, o intervalo de mudança de temperatura projetada pela média do conjunto está entre 1-3°C, 1-4°C, e 2-5°C para os cenários de emissões SRES B1, A1B, e A2, respectivamente (Figura 5.1). Resultados similares podem ser encontrados em Meehl et al. (2007a).

A dispersão entre as projeções dos MCGs (Figura 5.2), medida pelo desvio padrão entre os membros do conjunto, é menor do que 1°C para todo o continente e todos os cenários de emissões, e menor do que 0,5°C para grande parte da América do Sul nos cenários

SRES B1 e A1B. A localização dos valores mais altos varia de acordo com a estação do ano, mas eles se concentram sobre o noroeste da América do Sul, bacia Amazônica, e nas regiões centro-oeste e sudeste do Brasil. Além disso, a dispersão é visivelmente maior no cenário de forçante climática mais intensa – SRES A2).

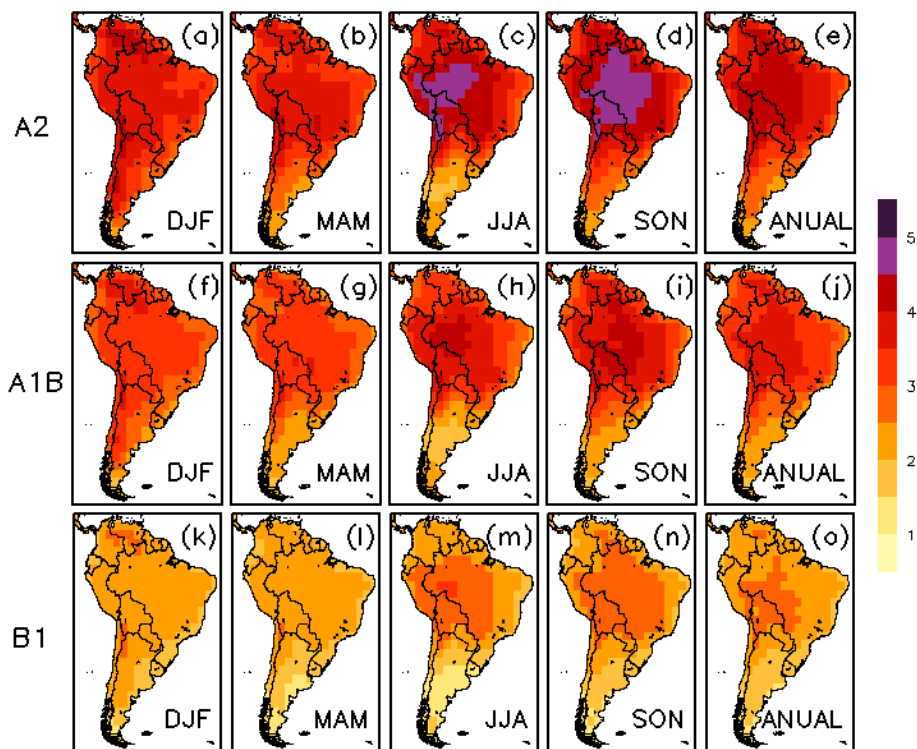


Figura 5.1 - Mudanças sazonal e anual de temperatura do ar próximo à superfície (°C) projetadas para o final do século (2071-2100) nos cenários de emissões SRES A2 (a-e), A1B (f-j), e B1 (k-o), provenientes do conjunto CMIP3. As mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.

Avaliando as projeções individuais dos MCGs do CMIP3 para o final do século no cenário SRES A1B, todos os MCGs projetam para o continente sul-americano um aumento de temperatura acima de 1°C, e a maioria dos modelos indicam um maior aquecimento sobre a bacia Amazônica (Figura B1). O mesmo comportamento se observa para os cenários SRES B1 e A2 (não mostrado). Dentre aqueles modelos que projetam um alto aquecimento sobre a Amazônia (> 5°C), destacam-se: ECHAM5, UKMO-HadCM3, UKMO-HADGEM1, MIROC3.2(hires), e MIROC3.2(medres). Vale ressaltar que os

modelos do CMIP3 UKMO-HADGEM1 e MIROC3.2(hires) foram identificados como aqueles com o melhor desempenho em simular a climatologia sazonal e anual de temperatura sobre a América do Sul, e em especial sobre a Amazônia, apresentando os menores vieses sobre esta região (vide seção 4.1), o que pode ser traduzido em uma confiabilidade maior nos padrões projetados.

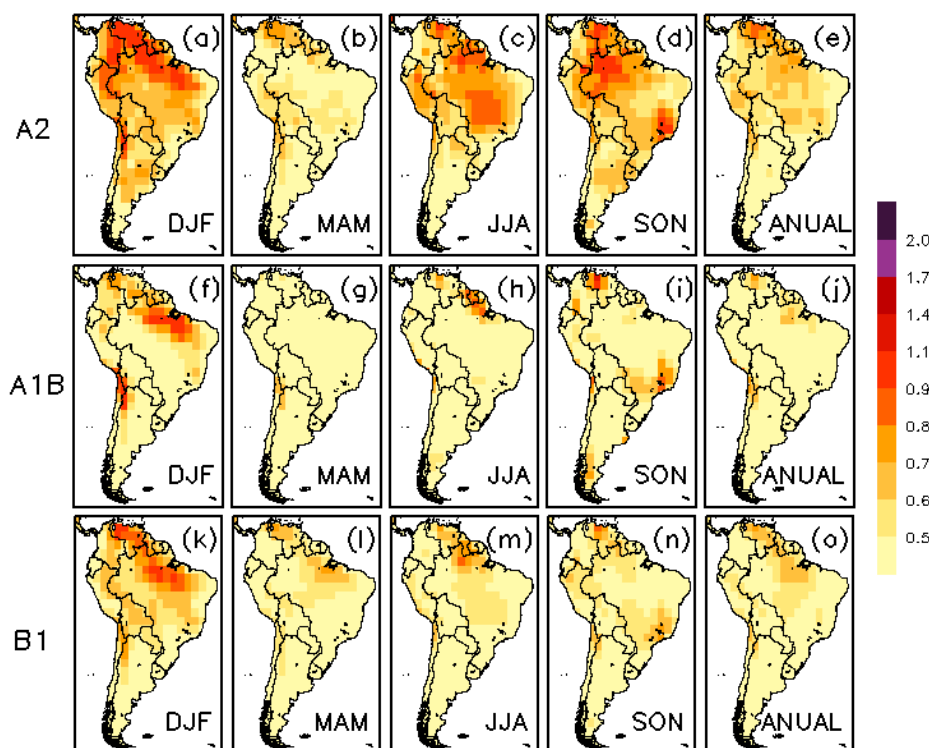


Figura 5.2 - Desvio padrão entre os diversos MCGs do CMIP3, relativo às mudanças sazonal e anual de temperatura do ar próximo à superfície ($^{\circ}\text{C}$) apresentadas na Figura 5.1.

Com relação às projeções de mudanças de precipitação, a média do conjunto de modelos do CMIP3 indica um pequeno aumento de precipitação sobre o verão austral em quase toda América do Sul para 2071-2100, exceto para o leste do NEB, Patagonia, e extremo norte da América do Sul, nos quais se projetam um ligeiro decréscimo de precipitação para todas as estações (Figura 5.3). A média do conjunto também indica um leve aumento de precipitação para LPB, WAMZ, Peru, Equador, e sul da Colômbia em MAM, e uma pequena redução sobre EAMZ e NEB em SON. Os padrões de mudanças

são bastante similares para todos os cenários de emissões, diferindo somente na magnitude das mudanças (Figura 5.3).

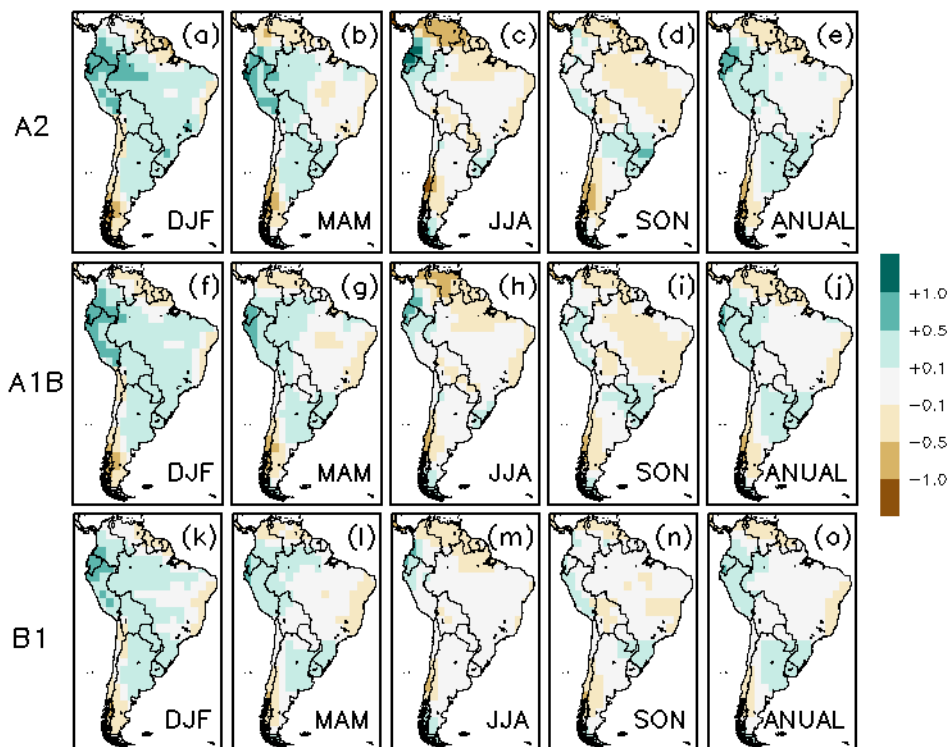


Figura 5.3 - O mesmo que na Figura 5.1, exceto para mudança sazonal e anual de precipitação ($\text{mm}\cdot\text{dia}^{-1}$).

Entretanto, ao contrário das projeções de temperatura, a incerteza com relação às mudanças de precipitação é bem alta, o que pode ser constatado nas disparidades apresentadas entre as projeções individuais dos diversos MCGs (Figura B.1). Por exemplo, para o verão no NEB, os modelos BCCR-BCM2.0, CNRM-CM3, ECHAM5, UKMO-HadGEM1 e IPSL-CM4 projetam um grande aumento de precipitação para o final do século no cenário SRES A1B (Figura B1), enquanto que GFDL-CM2.0, UKMO-HadCM3, MIROC3.2(hires), e MIROC3.2(medres) projetam uma intensa redução. Como indicado por Meehl et al. (2007a) no IPCC AR4, as áreas em que a magnitude das projeções de mudanças de precipitação são maiores do que o desvio padrão entre os MCGs do CMIP3 (uma primeira aproximação da confiabilidade nas projeções do conjunto) representam apenas uma pequena porção do domínio global, e são praticamente

não-existent sobre o continente sul-americano, exceto para uma pequena parte no sul da América do Sul no verão, e para o NEB no inverno.

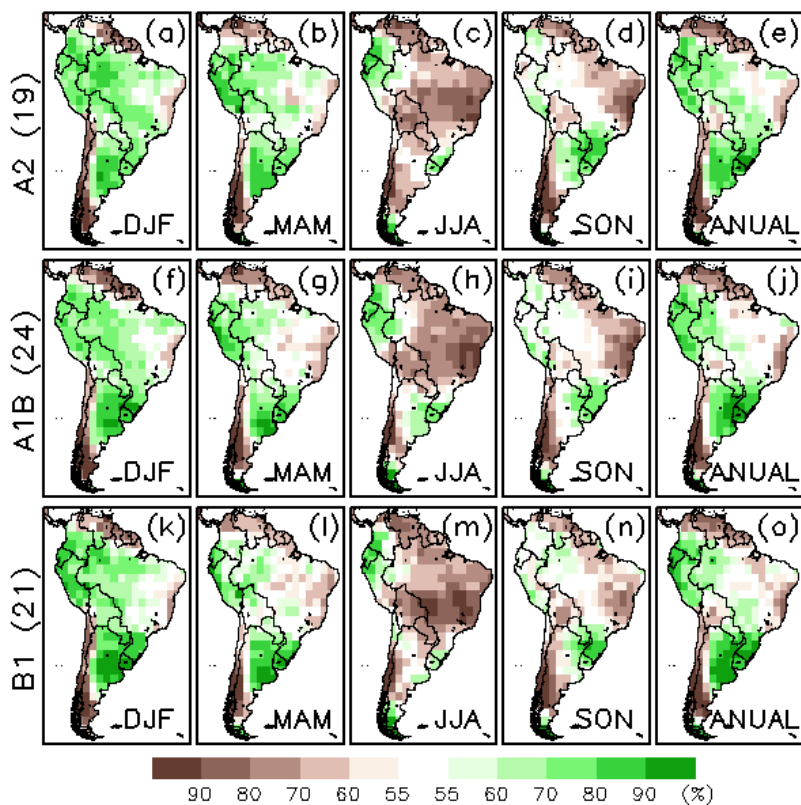


Figura 5.4 - Concordância (%) no sinal projetado de mudança sazonal e anual de precipitação sobre a América do Sul para o final do século (2071-2100), nos cenários SRES A2 (a-e), A1B (f-j), e B1 (k-o), provenientes do conjunto CMIP3. Os tons verdes (marrons) indicam a porcentagem de MCGs que projetam aumento (diminuição) de precipitação sobre a região. O número de modelos utilizados em cada cenário é indicado entre parênteses na esquerda.

Para explorar o tópico acima, a Figura 5.4 apresenta a concordância (%) no sinal projetado de mudança sazonal e anual de precipitação sobre a América do Sul para o final do século. Notavelmente, os padrões de concordância são bem similares para os diversos cenários de emissões, e coerentes com as projeções apresentadas na Figura 5.3, exceto, a priori, para o inverno austral. Além disso, nota-se uma concordância razoavelmente alta (> 70% dos modelos) em um aumento de precipitação sobre o WAMZ (em DJF,

MAM, e média anual), nordeste da Argentina, Uruguai, e região sul do Brasil em quase todas as estações, exceto no inverno. Adicionalmente, no extremo norte da América do Sul, a maioria dos MCGs concordam com uma pequena redução de precipitação nesta região. Durante o inverno austral os modelos concordam bem ($> 80\%$) com uma redução de precipitação sobre as regiões sudeste, centro-oeste, e nordeste do Brasil, no entanto, tal redução é bastante pequena ($< 0,1 \text{ mm.dia}^{-1}$ em magnitude), como vista na Figura 5.3. Por outro lado, como durante o inverno configura-se a estação seca sobre essa região, com valor médio sazonal não ultrapassando 1 mm.dia^{-1} (Figura A.1a-e), esta redução pode representar até 20% da precipitação nessa época do ano.

As Figuras 5.5 a 5.8 apresentam os resultados referentes às projeções de mudança de temperatura e precipitação para o final do século XXI (2071-2100) pertencentes ao conjunto da nova geração de MCGs que integram o CMIP5. Apesar de não ser possível comparar diretamente os cenários forçantes do SRES (CMIP3) com o RCP (CMIP5) por causa de suas naturezas totalmente distintas (VAN VUUREN et al., 2011), podemos observar que as projeções do CMIP5 estão bastante consistentes com aquelas produzidas pelo CMIP3 e discutidas anteriormente. Com relação às projeções de mudança de temperatura referentes à média do conjunto (Figura 5.5), vemos que os cenários forçantes utilizados no CMIP5 resultam em um intervalo maior de possíveis mudanças na América do Sul, isto é, as projeções de aumento de temperatura referentes ao cenário forçante RCP 2.6 são ligeiramente menores do que aquelas referentes ao cenário SRES B1, e as projeções de aumento no RCP 8.5 são consideravelmente maiores do que aquelas projeções no cenário SRES A2. Em geral, as novas projeções continuam indicando um aumento de temperatura superior a 1°C para toda América do Sul, mais proeminente sobre a região tropical, o qual pode chegar até acima de 5°C para o final do século sobre a região Amazônica, Bolívia, e centro-oeste e sudeste brasileiro, no cenário de maior forçante (RCP 8.5). O intervalo de mudança de temperatura projetada pela média do conjunto sobre a América do Sul está entre $1\text{-}2^{\circ}\text{C}$, $2\text{-}3^{\circ}\text{C}$, $2\text{-}4^{\circ}\text{C}$, e 3 a $>5^{\circ}\text{C}$ para os cenários RCP 2.6, 4.5, 6.0, e 8.5, respectivamente (Figura 5.5).

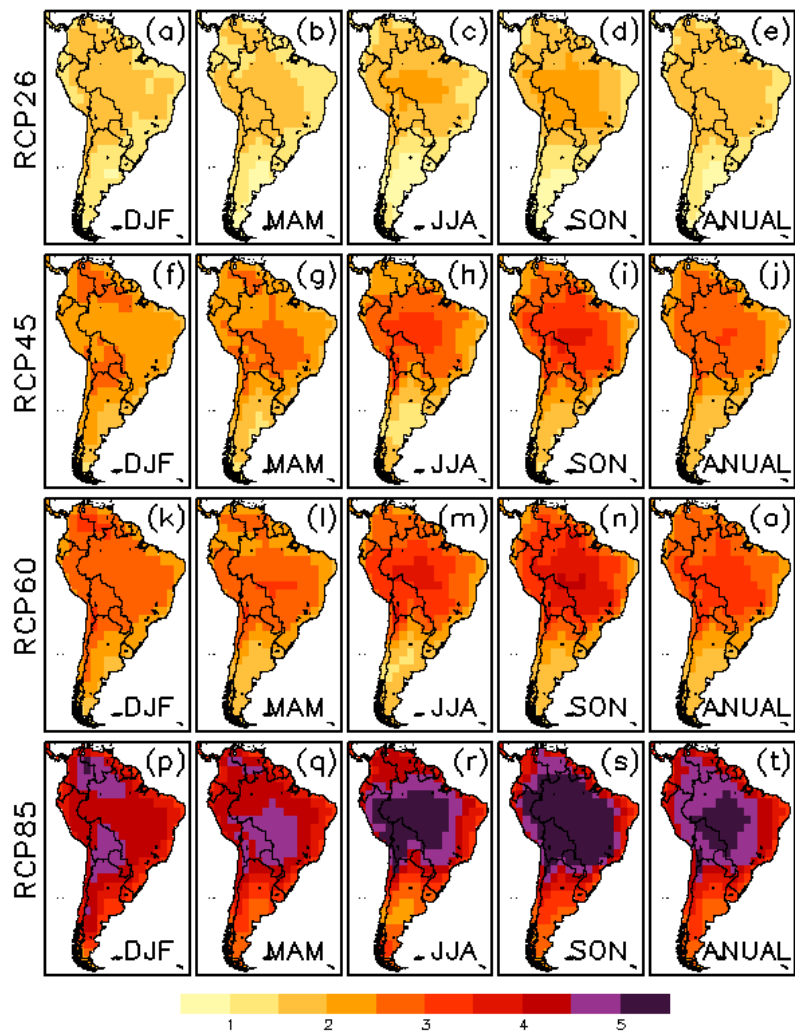


Figura 5.5 - Mudanças sazonal e anual de temperatura do ar próximo à superfície (°C) projetadas para o final do século (2071-2100) nos cenários forçantes RCP2.6 (a-e), RCP4.5 (f-j), RCP6.0 (k-o), e RCP8.5 (p-t), provenientes do conjunto CMIP5. As mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990.

Comparando a dispersão das projeções de mudança de temperatura do CMIP5 (Figura 5.6) com aquelas obtidas com o CMIP3 (Figura 5.2), podemos constatar que a magnitude das dispersões é ligeiramente maior, mas comparáveis para os cenários forçantes RCP 2.6, 4.5, e 6.0. Curiosamente, entre estes três cenários, o RCP 2.6 foi aquele cujas projeções dos MCGs apresentaram-se mais dispersas. Por outro lado, o cenário de maior forçante climática (RCP 8.5) apresentou a maior dispersão entre os MCGs, onde é pos-

sível identificar valores acima de 1°C para todo o noroeste da América do Sul, bacia Amazônica, e centro-oeste brasileiro. Valores acima de 1,7°C podem ser identificados sobre a Amazônia, principalmente na porção oeste durante a primavera.

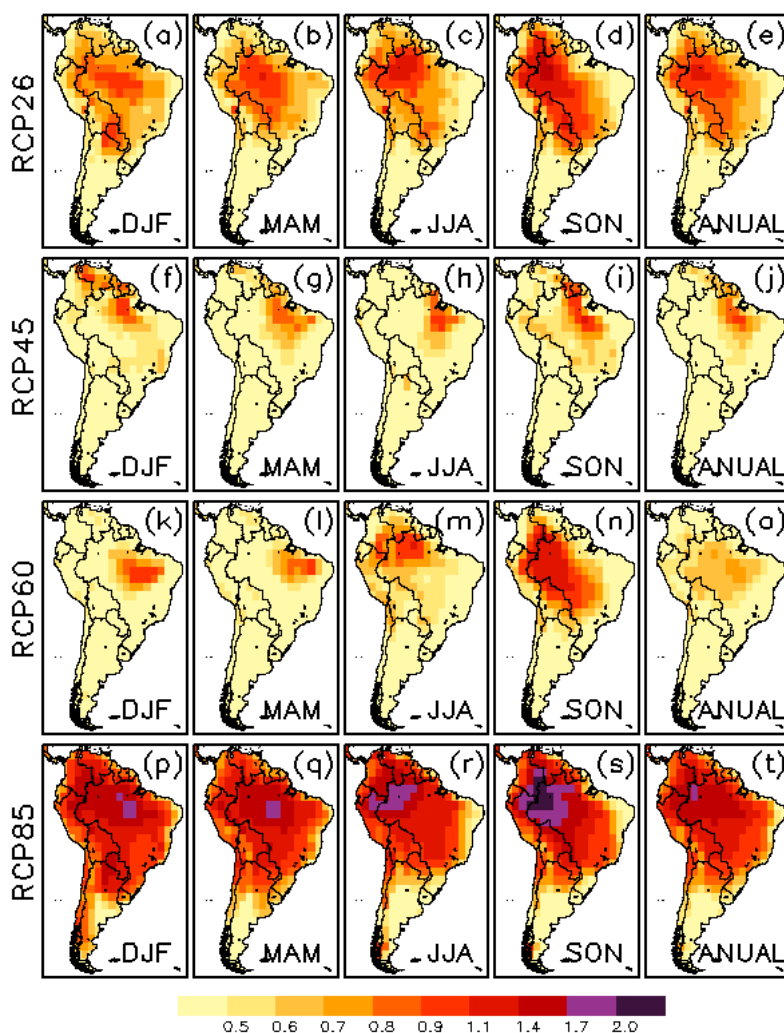


Figura 5.6 - Desvio padrão entre os diversos MCGs do CMIP5, relativo às mudanças sazonal e anual de temperatura do ar próximo à superfície (°C) apresentadas na Figura 5.5.

Assim como no CMIP3, avaliando individualmente as projeções de mudança de temperatura dos MCGs do CMIP5 para o final do século no cenário RCP 4.5 (Figura B.2), constatamos que todos os modelos concordam com uma projeção de aumento de temperatura acima de 1°C sobre toda América do Sul, nos quais as projeções de maiores aumentos estão localizadas na porção tropical do continente. Adicionalmente, as maiores

discordâncias com relação à magnitude das mudanças continuam sobre a bacia Amazônica. Nesse sentido, os modelos CanESM2, CSIRO-Mk3-6-0, GFDL-CM3, HadGEM2-ES, MIROC-ESM, e MIROC-ESM-CHEM destacam-se como aqueles que apresentam as maiores magnitudes de mudança ($> 5^{\circ}\text{C}$) sobre partes da Amazônia. Para as projeções individuais de temperatura dos MCGs no cenário RCP 8.5, 11 de 23 modelos indicam um aumento superior a 5°C em praticamente toda região compreendida entre as latitudes de cerca de 20°S a 10°N (não mostrado).

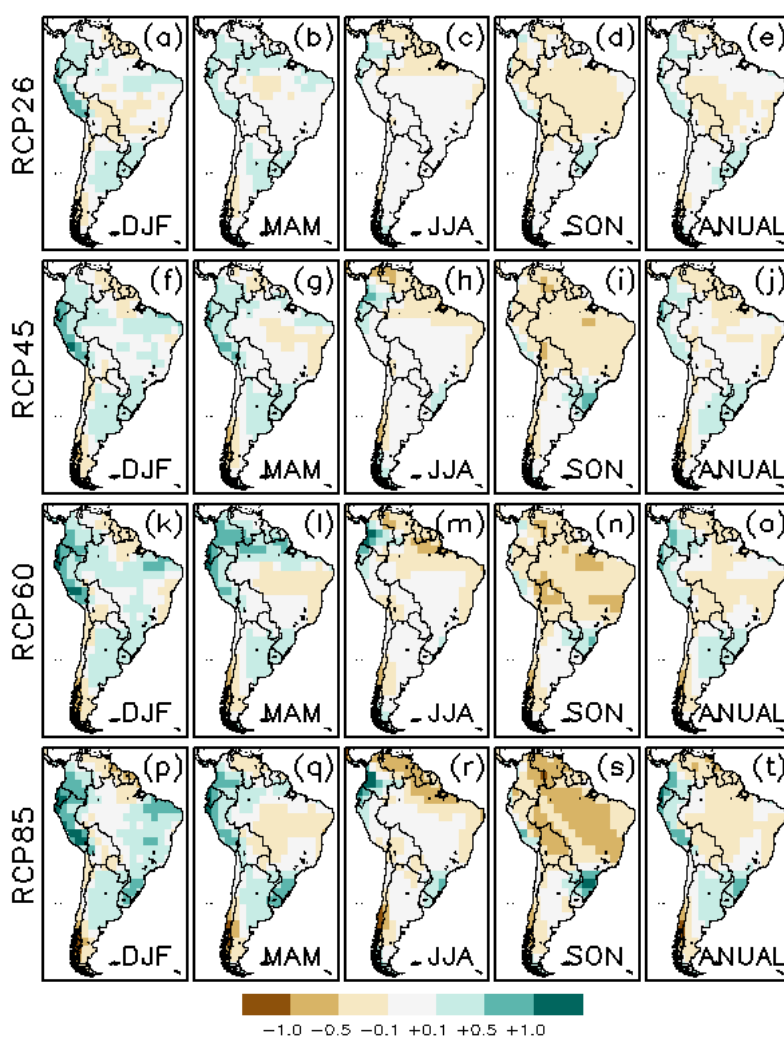


Figura 5.7 - O mesmo que na Figura 5.5, exceto para mudança sazonal e anual de precipitação ($\text{mm}\cdot\text{dia}^{-1}$).

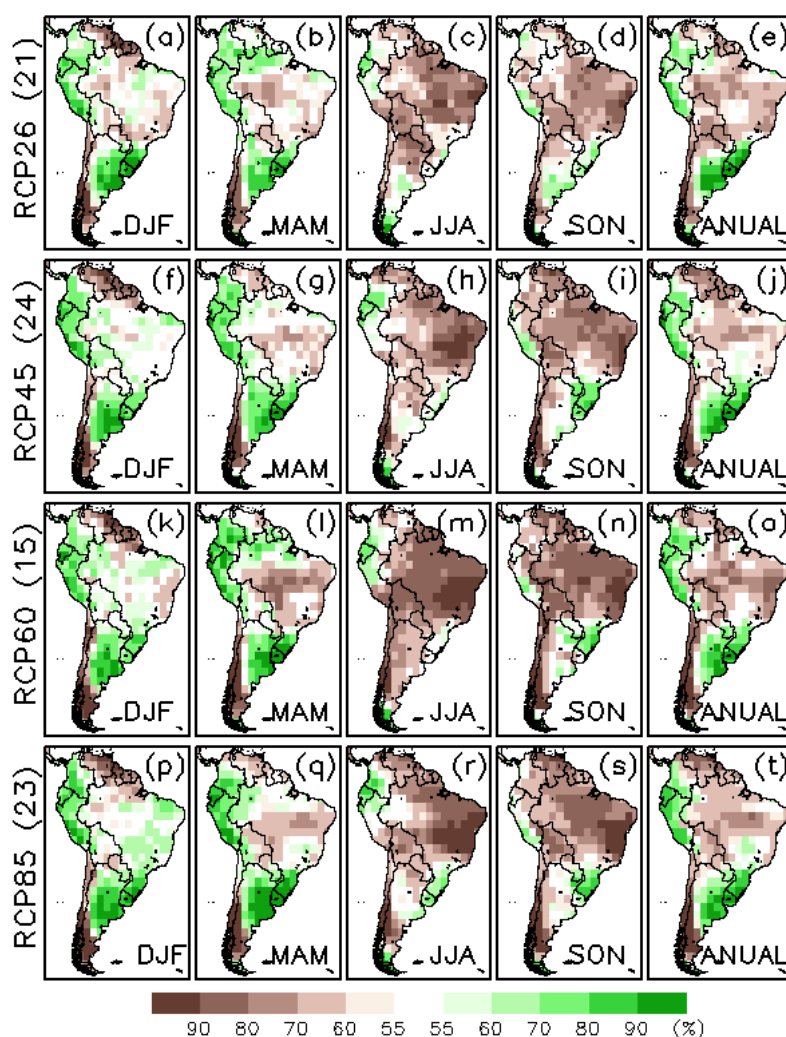


Figura 5.8 - Concordância (%) no sinal projetado de mudança sazonal e anual de precipitação sobre a América do Sul para o final do século (2071-2100), nos cenários RCP2.6 (a-e), RCP4.5 (f-j), RCP6.0 (k-o), e RCP8.5 (p-t), provenientes do conjunto CMIP5. Os tons verdes (marrons) indicam a porcentagem de MCGs que projetam aumento (diminuição) de precipitação sobre a região. O número de modelos utilizados em cada cenário é indicado entre parênteses na esquerda.

Com relação às projeções de mudança de precipitação (Figura 5.7), os padrões de mudança do CMIP5 são praticamente idênticos àqueles do CMIP3 discutidos anteriormente, mesmo para o cenário de maior forçante (RCP 8.5), apresentando magnitudes de mudança muito pequenas ($< 1 \text{ mm.dia}^{-1}$). Além disso, as projeções de precipitação dos

MCGs individuais (Figura B.2) continuam divergindo entre si, na qual é possível identificar diversas localidades em que projeções de aumento e diminuição de precipitação podem ser vistas em quase iguais proporções, conferindo a essa variável um alto nível de incerteza. Com relação às análises de concordância dos MCGs quanto ao sinal de mudança de precipitação projetada para o final do século (Figura 5.8), uma similaridade bastante grande pode ser notada entre os conjuntos CMIP5 e CMIP3, exceto para um aumento considerável na concordância de projeção de redução na precipitação sobre a Amazônia e NEB em SON na nova geração de modelos.

Portanto, apesar da maior complexidade, realismo, e resolução espacial dos MCGs do CMIP5 conduzir a uma maior confiabilidade nos padrões projetados, pouca ou nenhuma redução de incerteza pode ser claramente identificada na América do Sul. Entretanto, como enfatizado por Trenberth et al. 2010, quanto maior o nosso conhecimento do sistema climático, maior a compreensão de sua complexidade e dos fatores que não havíamos levado em consideração anteriormente na tentativa de sua simulação. Assim sendo, é errônea a premissa de que uma maior complexidade dos modelos numéricos e uma maior compreensão de todos os processos físicos envolvidos levam, ou levará, a uma substancial redução das incertezas envolvidas na simulação do sistema climático.

Adicionalmente, Knutti e Sedláček (2013) indicam diversas hipóteses que potencialmente explicam a falta de convergência e a conseqüente falta de redução de incertezas nas projeções do CMIP5, sendo elas: a) limitações inerentes à forma como os modelos são construídos, dado os limitados recursos computacionais e resolução espacial, b) falta de um entendimento mais aprofundado em alguns processos físicos, c) falta de observações de longo prazo acuradas para “calibrar” os modelos, d) falta de consenso sobre métricas de avaliação de desempenho dos modelos que claramente separem os melhores dos piores, para produzir uma projeção de maior qualidade, e) inerente limitação que fazem as mudanças climáticas não serem previsíveis¹⁰ devido à sua variabilidade

¹⁰ Devemos ressaltar que o termo “previsibilidade” é utilizado nas previsões de tempo e clima, dado que o comportamento do sistema climático envolvido nas escalas temporais inerentes à essas previsões (1 dia a 3 meses) são regidos puramente por aspectos físicos, e que possuem certa previsibilidade naquelas escalas

de interna, f) inclusão de modelos dissimilares e advindos de novas instituições no CMIP5, e g) adição no CMIP5 de novos processos, componentes, ou forçantes que ainda não são bem entendidas, bem representadas nos modelos, ou não bem “calibradas” pelas observações.

Entretanto, vale ressaltar que neste estudo estamos fazendo uma análise bastante crítica e aprofundada com relação aos MCGs, na tentativa de avaliarmos as incertezas envolvidas nas projeções de mudanças climáticas na América do Sul, e possivelmente, estabelecermos direções ou processos que ainda precisam ser melhor explorados ou aprimorados pela comunidade científica para obtermos projeções climáticas cada vez mais confiáveis. No entanto, este criticismo não deve ofuscar os enormes avanços alcançados nas últimas décadas (e principalmente aqueles obtidos do CMIP3 para o CMIP5) em produzir modelos que simulam o sistema climático de forma cada vez mais realista e mais próximo das condições observadas. Assim como em diversas áreas do conhecimento, depois de um enorme avanço científico em um dado aspecto, muitas vezes, os próximos melhoramentos (no nosso caso, um aumento no desempenho dos MCGs em reproduzir as condições observadas do sistema climático) se dão de forma gradativa, paulatinamente, mas são de suma importância. Além disso, como descrito no Capítulo 2, um modelo, em particular um modelo do sistema climático, nunca reproduzirá de forma perfeita todos os aspectos climáticos, dado a variabilidade interna natural desse sistema, governado por aspectos estocásticos e não-lineares. No entanto, quanto mais nos aproximarmos da representação do sistema climático, e sabermos, com a melhor confiabilidade possível, qual será sua resposta às enormes forçantes impostas pelas atividades antropogênicas, melhor será o nosso conhecimento de quais medidas adaptativas e mitigativas que a humanidade terá que tomar.

Por fim, apesar das avaliações supracitadas serem úteis para caracterizarmos as projeções de mudanças climáticas na região de estudo, este tipo de análise comumente en-

temporais. Com relação às mudanças climáticas, o termo “projeção” é mais adequado, pois o comportamento do sistema climático depende também de diversos outros fatores aleatórios (e.g., erupções vulcânicas) e de processos não físicos, tais como desenvolvimento econômico.

contrada na literatura não nos permite identificar quantitativamente as incertezas envolvidas, e como elas distribuem-se geograficamente. Por exemplo, as análises de validação das climatologias simuladas pelos MCGs realizadas no capítulo 4 ficam de certa forma desacopladas das projeções, uma vez que para todos os modelos atribui-se a mesma probabilidade de ocorrência na produção da média do conjunto, independente de seu realismo em representar o clima presente, e da coerência de sua projeção com relação às projeções dos outros membros do conjunto. Conforme ressaltado por Knutti (2010) e Junquas et al. (2012), sintetizar os resultados, extrair a informação mais útil, e estimar incertezas a partir de um grande número de resultados de modelos climáticos ainda é um grande desafio. Para algumas regiões, eliminar os modelos que representam deficientemente o clima presente ou exibem comportamentos físicos incoerentes no clima futuro, resulta frequentemente em uma redução ou estreitamento “artificial” do espalhamento do conjunto multi-modelos (KNUTTI, 2010; JUNQUAS et al., 2012). Nesse sentido, nas seções seguintes trataremos as projeções de todos os MCGs do CMIP3 e CMIP5 no intuito de estimar um intervalo de incertezas, definir uma confiabilidade na média do conjunto, e produzir resultados probabilísticos a partir do emprego dos métodos REA e através de inferência bayesiana.

5.1. Resultados obtidos a partir do método REA

Para as projeções de mudança de temperatura do CMIP3, quando comparamos os padrões de mudança obtidos pela média aritmética simples (i.e., como analisado anteriormente na Figura 5.1, aonde assumimos o mesmo peso para todos os membros do conjunto) com aqueles obtidos pela aplicação do método REA (Figura 5.9), é possível notar que quando levamos em consideração as confiabilidades dos MCGs (medidas pelos critérios de desempenho e convergência no método REA, como mencionado na seção 3.2.1), a magnitude das projeções de mudança de temperatura diminuem em boa parte do domínio de estudo e para todos os cenários avaliados. Essa diminuição é mais pronunciada sobre WAMZ, onde este decréscimo atinge aproximadamente 1°C para as projeções no final deste século.

Apesar de todos os MCGs do CMIP3 sempre projetarem um aumento de temperatura para a América do Sul, a bacia Amazônica é a região que exhibe as maiores discrepâncias entre os modelos a respeito da magnitude dos padrões de mudança de temperatura esperados, o que fica evidente ao analisarmos o parâmetro de intervalo de incerteza ($\tilde{\delta}_{\Delta T}$) apresentado na Figura 5.10 f-j para o cenário SRES A2. No entanto, apesar do intervalo de incerteza ser mais alto na Amazônia, principalmente no inverno ($\tilde{\delta}_{\Delta T} \sim 1,4^{\circ}\text{C}$), ele é bem inferior à média REA na região ($\sim 4^{\circ}\text{C}$). Para o restante do continente, o intervalo de incerteza é menor do que 1°C , e portanto, sempre inferior à média REA.

Razoável confiabilidade no conjunto de projeções de mudanças de temperatura ($\tilde{\rho}_{\Delta T}$) do CMIP3 é encontrado sobre partes da bacia do Prata para todas as estações, e na Patagônia no inverno (Figura 5.10 k-o). Entretanto, este parâmetro de confiabilidade proposto por Giorgi e Mearns (2002) não parece ser consistente, ou retratar corretamente as análises tratadas até aqui. Uma vez que os intervalos de incerteza são menores (e em algumas regiões, bem menores) do que a média REA, esperava-se valores mais altos, como por exemplo, acima de 0.5 (ou 50% de confiabilidade), em boa parte do continente. Portanto, a formulação matemática proposta na Equação 3.4 não condiz com as análises qualitativas realizadas anteriormente.

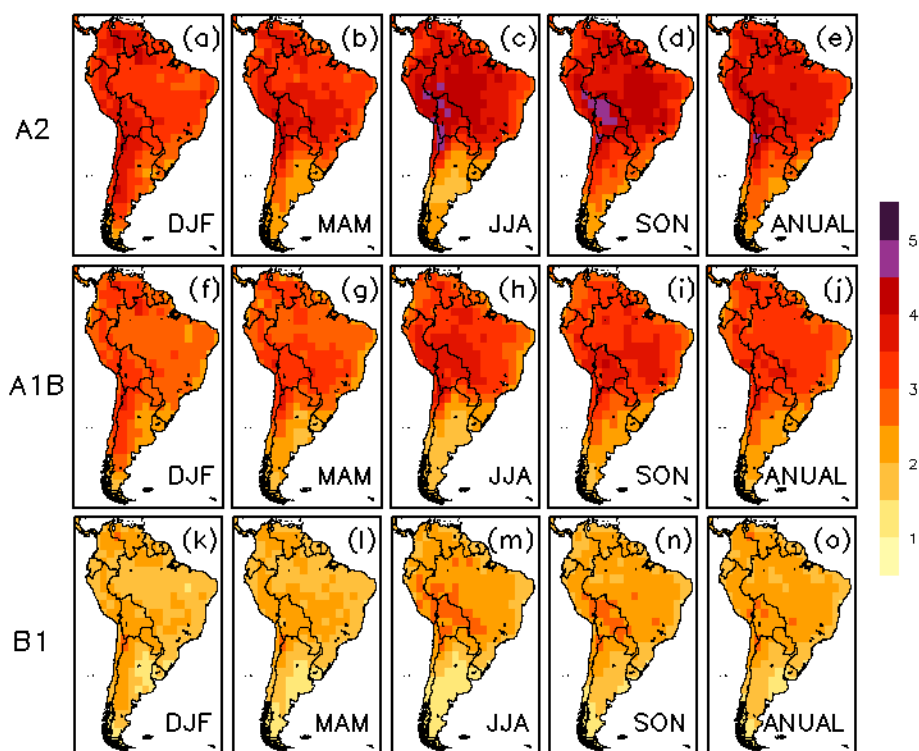


Figura 5.9 - Média REA para mudanças sazonal e anual de temperatura do ar próximo à superfície ($^{\circ}\text{C}$) utilizando as projeções dos MCGs do CMIP3 para 2071-2100 nos cenários SRES A2 (a-e), A1B (f-j), e B1 (k-o).

Analisando os dois critérios de confiabilidade dos modelos separadamente para a variável temperatura (Figura 5.10p-z), o valor médio do parâmetro relativo ao critério de convergência (R_D) é o fator predominante em determinar a região de maior confiança no domínio estudado. Isto se deve ao fato de que o intervalo de mudanças de temperatura projetada entre os MCGs é grande, e a variabilidade natural é geralmente pequena (Figura 5.10a-e). Segundo este parâmetro, regiões um pouco mais confiáveis ($> 0,5$), nas quais as projeções dos modelos tendem a convergir em torno de um determinado valor, podem ser localizadas para algumas estações somente sobre o Paraguai, noroeste da Bolívia/sul do Peru, Uruguai, sul da Argentina, e no estado brasileiro do Rio Grande do Sul (Figura 5.10u-z), os quais possuem uma variabilidade natural de temperatura mais alta (Figura 5.10a-e). Isto evidencia que a distância dos modelos para a média REA é geralmente maior do que a variabilidade natural de temperatura (Figura 5.10a-e). Com relação ao valor médio do parâmetro relativo ao critério de desempenho (R_B), uma vez

que o viés nas simulações de temperatura do CMIP3 (Figura 4.2f-j) tem magnitudes próximas da variabilidade natural (Figura 5.10a-e) sobre praticamente toda a região sul-americana, valores relativamente altos de R_B podem ser encontrados sobre quase todo o domínio de estudo.

Diferentemente da variável temperatura, a média REA para mudanças de precipitação (Figura 5.11) não apresenta uma diferença expressiva quando comparado à média aritmética simples do conjunto (Figura 5.3), exceto nas regiões do norte do Peru/sul da Colômbia durante DJF, e no leste da Amazônia em SON, nos quais a magnitude das mudanças de precipitação projetadas reduz-se sutilmente (aproximadamente 0,4 e 0,2 mm.dia⁻¹, respectivamente). Intervalos de incerteza relativamente grandes (comparados às magnitudes das projeções de precipitação) são notáveis sobre o norte da América do Sul em todas as estações, e sobre a bacia Amazônica, NEB, e centro-oeste do Brasil no verão austral (Figura 5.12f-j). Para esta variável, ambos os valores de R_D e R_B são maiores do que aqueles encontrados para a variável temperatura. Além disso, o parâmetro de convergência é maior do que o parâmetro de desempenho ($R_D > R_B$) para toda América do Sul (Figura 5.12p-z), apresentando valores próximos à unidade para grande parte do continente, principalmente durante MAM e JJA. Isto se deve ao fato de que os vieses dos modelos (Figura 4.1f-j) são maiores do que a magnitude das mudanças de precipitação projetada, e as magnitudes das distâncias dos diversos modelos à média REA são pequenas e comparáveis à variabilidade natural da precipitação (Figura 5.12a-e).

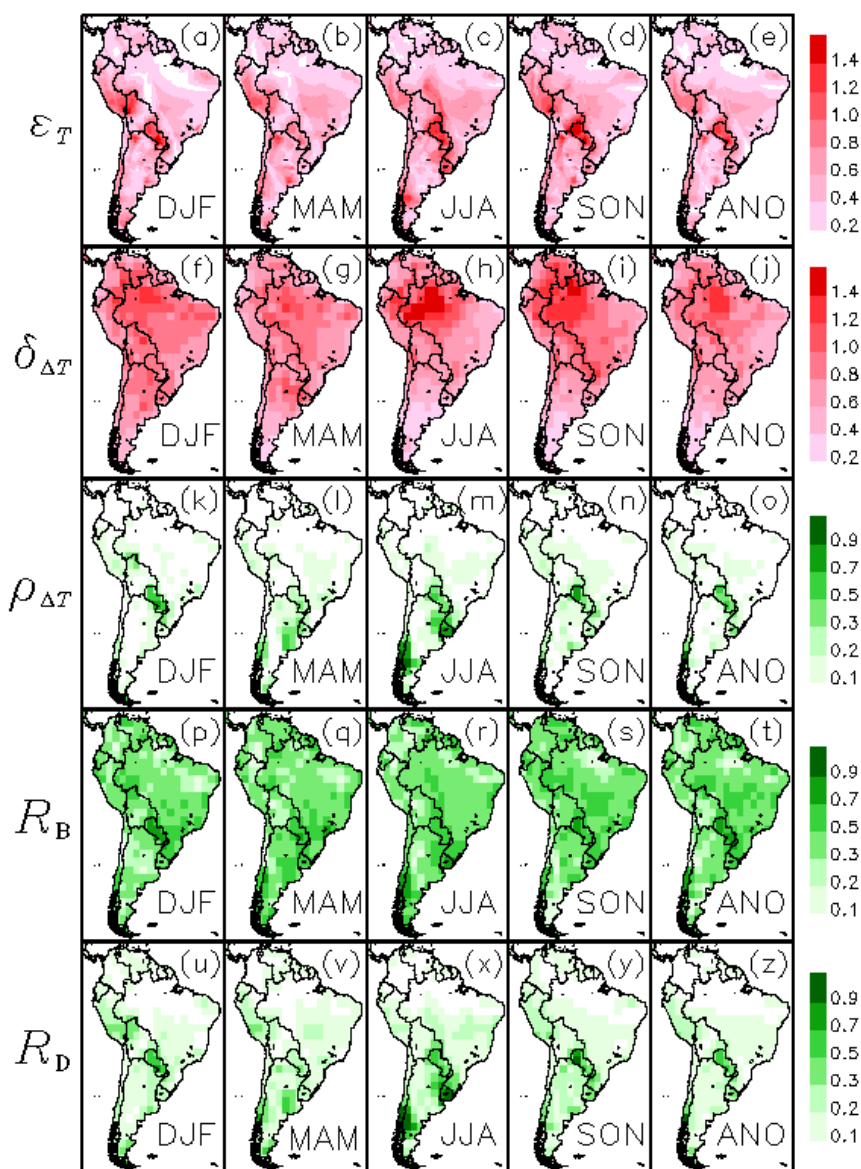


Figura 5.10 - Variabilidade natural observada de temperatura (ε_T , a-e) calculada para o período de 1901 a 2000, e intervalo de incerteza ($\delta_{\Delta T}$, f-j), confiabilidade no conjunto ($\rho_{\Delta T}$, k-o), e média dos parâmetros de desempenho (R_B , p-t) e convergência (R_D , u-z) do método REA para as mudanças sazonal e anual de temperatura utilizando as projeções dos MCGs do CMIP3 para 2071-2100 no cenário SRES A2. As unidades de ε_T e $\delta_{\Delta T}$ estão em $^{\circ}\text{C}$, e os demais parâmetros são adimensionais.

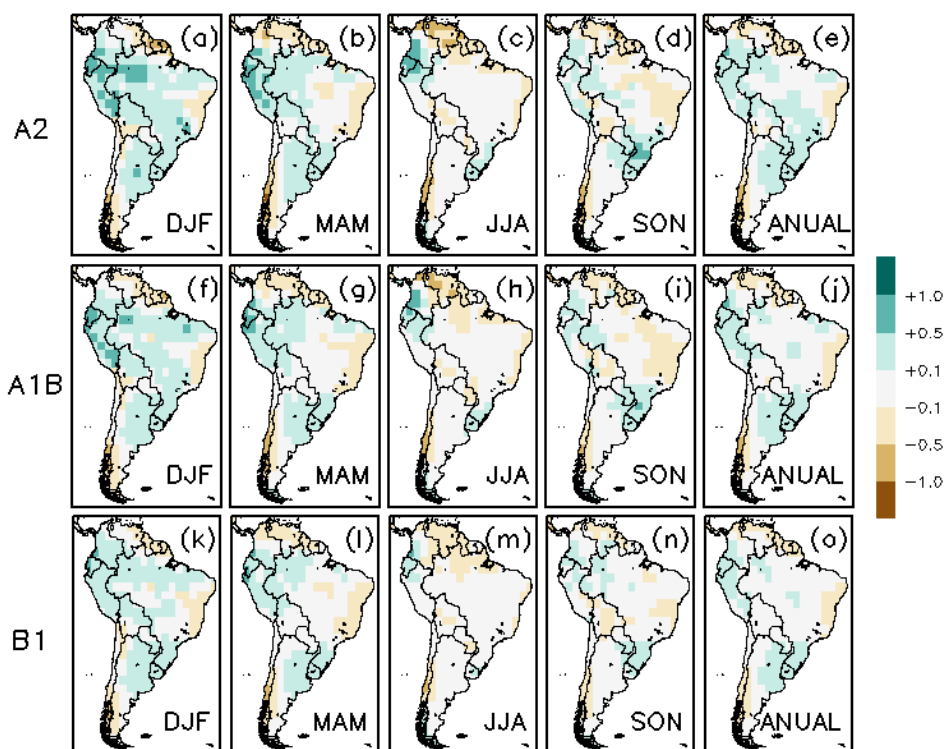


Figura 5.11 - Média REA para mudanças sazonal e anual de precipitação ($\text{mm}\cdot\text{dia}^{-1}$) utilizando as projeções dos MCGs do CMIP3 para 2071-2100 nos cenários SRES A2 (a-e), A1B (f-j), e B1 (k-o).

A confiabilidade no conjunto é acima de 0,5 em aproximadamente todo o continente sul-americano, e uma vez que as projeções de mudanças são pequenas ($< 1 \text{ mm}\cdot\text{dia}^{-1}$), isto pode indicar que existe uma alta confiabilidade em uma projeção de nenhuma mudança expressiva na precipitação média sazonal. Resultados similares podem ser encontrados por Giorgi e Mearns (2002), quando aplicando o método REA a um conjunto de projeções de 18 MCGs diferentes mediados sobre 22 regiões continentais sobre o globo. Entretanto, vale ressaltar que estes resultados não se aplicam as projeções de eventos extremos de precipitação. A América do Sul tem experimentado um aumento de eventos extremos de temperatura e precipitação nas últimas décadas (MARENGO et al., 2010a; RUSTICUCCI et al., 2010), e muitos modelos climáticos projetam um aumento ainda maior no número de casos de tais eventos para o final do século XXI (TEBALDI et al., 2006; MARENGO et al., 2009; IPCC, 2012).

Baseando-se nos fatores de confiabilidade (R_i) e utilizando a Equação 3.5, a Figura 5.13 apresenta as probabilidades sazonais das mudanças de temperatura exceder determinados limiares (2°, 3°, 4°, e 5°C), obtidas através das projeções dos modelos do CMIP3 para 2071-2100 no cenário SRES A2. Com base nessas análises, existe uma probabilidade bem grande (>90%) de que o aumento de temperatura seja maior do que 2°C para quase todo continente e para todas as estações. Uma possível probabilidade (>50%) de exceder 4°C é encontrada sobre o noroeste da América do Sul, bacia Amazônica, Bolívia, e Peru de junho a novembro, e NEB em SON. Estas são as mesmas áreas indicadas por Fung et al. (2011), as quais podem experimentar um aumento no stress hídrico com uma temperatura global 2 ou 4°C mais quente do que a média em 1961-1990 para a década de 2060. Betts et al. (2011) argumentam que as projeções do CMIP3 claramente sugerem que níveis muito maiores de aquecimento são possíveis para o final do século XXI na ausência de mitigação. O valor central do intervalo de aquecimento global no CMIP3 é aproximadamente 4°C. A extremidade superior do aquecimento projetado está associada com os cenários de maiores emissões, e com modelos que incluem feedbacks mais intensos do ciclo de carbono. Devido à alta incerteza e falta de uma mudança expressiva, como enfatizado nos resultados anteriores, os mapas das probabilidades das possíveis mudanças de precipitação exceder determinados limiares serão omitidos.

Funções distribuição acumulada (do inglês, *Cumulative Density Functions* - CDFs) de mudanças de temperatura e precipitação para os modelos do CMIP3 processados pelo método REA nos cenários SRES B1, A1B, e A2 para as quatro sub-regiões (Figura 3.1) analisadas nesse estudo são apresentadas nas Figuras 5.14 e 5.15. Note, entretanto, que para mudanças de precipitação positivas, o valor nas curvas fornece a probabilidade de determinada mudança ser maior do que um determinado limiar, e para mudanças de precipitação negativas, as probabilidades são dadas por 1 menos o valor obtido na curva. Além disso, curvas mais acentuadas indicam regiões com maior concordância entre as projeções dos MCGs.

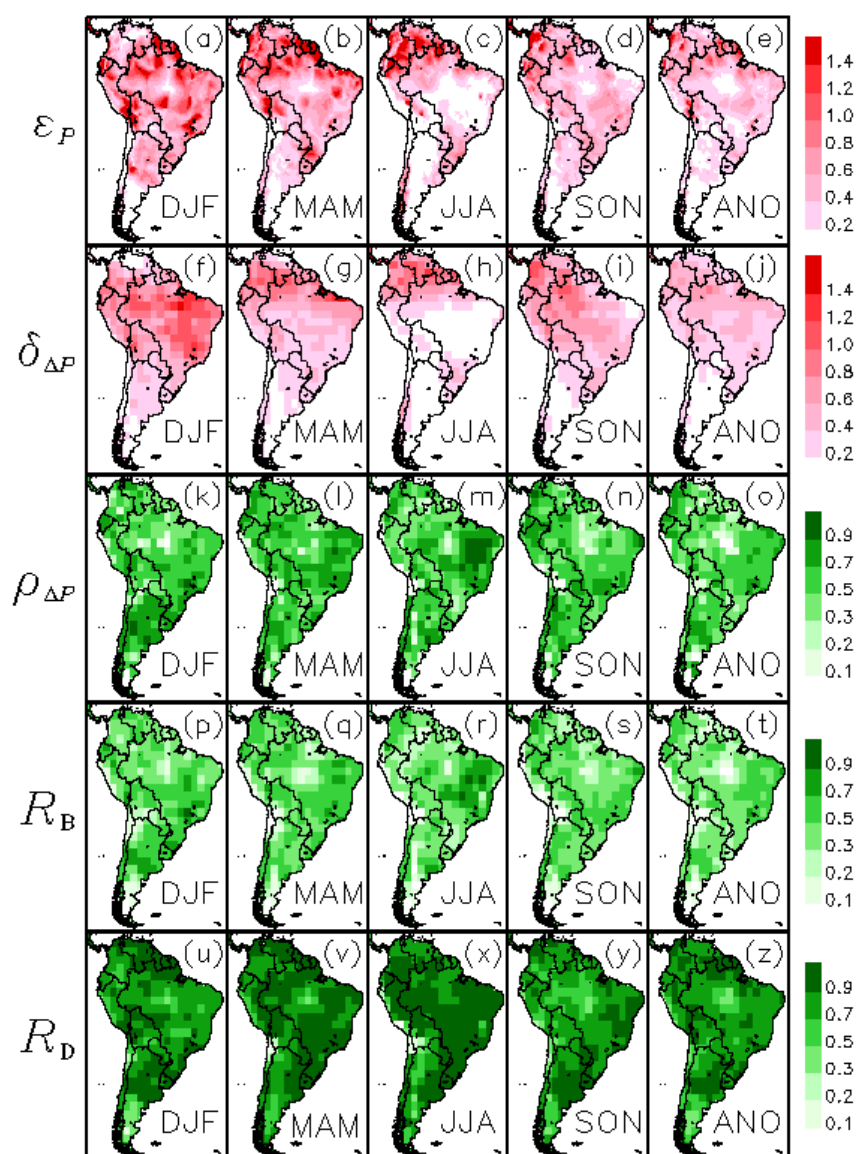


Figura 5.12 - Variabilidade natural observada de precipitação (ε_p , a-e) calculada para o período de 1901 a 2000, e intervalo de incerteza ($\delta_{\Delta p}$, f-j), confiabilidade no conjunto ($\rho_{\Delta p}$, k-o), e média dos parâmetros de desempenho (R_B , p-t) e convergência (R_D , u-z) do método REA para as mudanças sazonal e anual de precipitação utilizando as projeções dos MCGs do CMIP3 para 2071-2100 no cenário SRES A2. As unidades de ε_p e $\delta_{\Delta p}$ estão em mm.dia^{-1} , e os demais parâmetros são adimensionais.

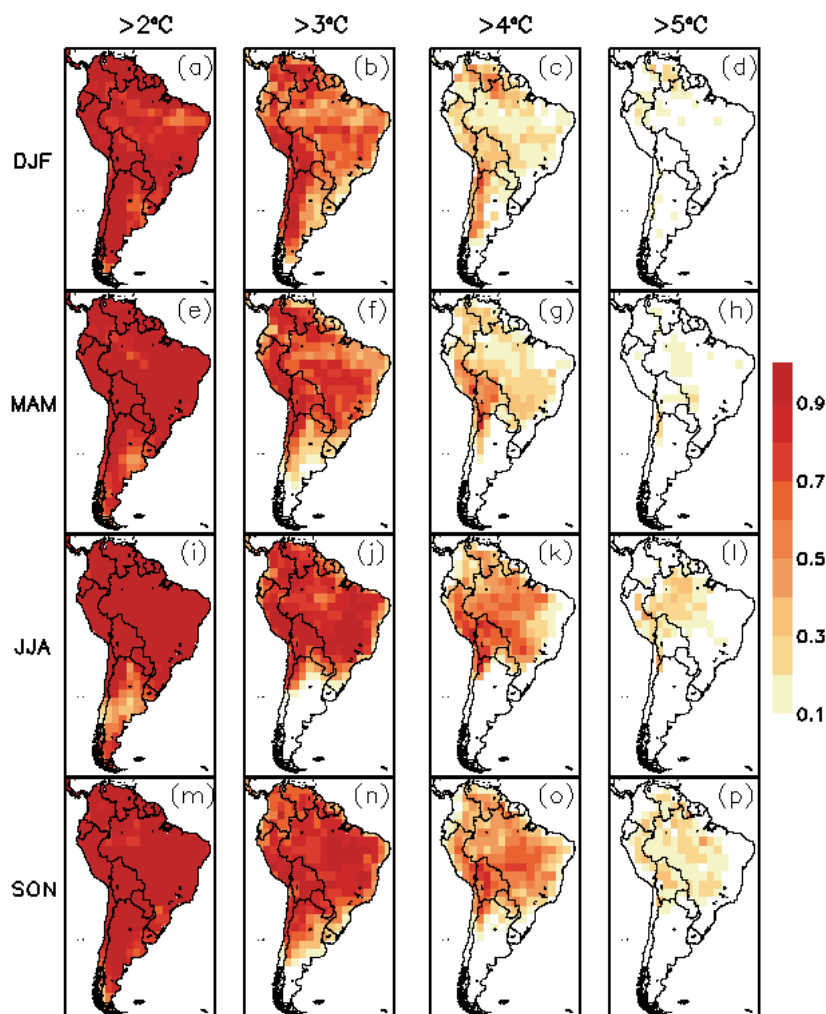


Figura 5.13 - Probabilidades sazonais das mudanças de temperatura excederem determinados limiares (2°, 3°, 4°, e 5°C), obtidas através das projeções dos modelos do CMIP3 para 2071-2100 no cenário SRES A2

Avaliando as CDFs de temperatura (Figura 5.14), como todos os MCGs projetam um aumento dessa variável sobre a América do Sul em todas as estações, escalas temporais, e cenários de emissões, a probabilidade de aquecimento é igual a 1 (ou 100%). A probabilidade de exceder limiares de aumento de temperatura mais elevados aumenta (e a concordância entre os modelos diminuem) de 2041-2070 para 2071-2100, e de cenários de mais baixas emissões para aqueles de emissões mais altas. Para a bacia Amazônica, a probabilidade de aumentos mais elevados de temperatura sobre a sua porção oeste é maior do que sobre a sua porção leste, e é maior para o inverno do que para o verão.

Exceto para a bacia Amazônica, nenhuma diferença expressiva é encontrada entre o verão e inverno para as outras sub-regiões analisadas. O máximo aumento de temperatura projetado para o final do século por um MCG pertencente ao conjunto CMIP3 (indicado quando a probabilidade aproxima-se de zero) é da ordem de 4,0-5,5°C em EAMZ, 4,5-5,5°C em WAMZ, 3,5-4,5°C no NEB, e 3,5-5,0 em LPB, nos quais os valores mais baixos e mais altos representam os cenários SRES B1 e A2, respectivamente.

Investigando as CDFs para as projeções de mudança de precipitação no CMIP3 (Figura 5.15), constatamos que os resultados dos MCGs estão distribuídos ao longo de uma mudança zero, exceto para as sub-regiões LPB e WAMZ, nas quais as curvas deslocam-se ligeiramente em direção a valores positivos de mudança. Os maiores espalhamentos entre os resultados dos modelos podem ser notados sobre o NEB no verão. Adicionalmente, existe uma grande discordância no sinal de mudança entre aqueles modelos que indicam alguma alteração sazonal na precipitação. Apesar disso, mudanças nas quantidades de precipitação parecem ser mais prováveis de ocorrer no verão do que no inverno, em concordância com os padrões apresentados nas Figuras 5.3 e 5.11. Entretanto, no geral, as CDFs indicam uma alta probabilidade de não haver nenhuma mudança expressiva nas quantidades de precipitação para os períodos futuros e regiões analisadas.

Avaliando os resultados do método REA aplicados ao conjunto CMIP5, podemos observar resultados bastante consistentes e comparáveis àqueles descritos anteriormente para o CMIP3. A média REA das projeções de temperatura para o final do século XXI (Figura 5.16), assim como no CMIP3, apresentam magnitudes de mudanças ligeiramente menores ($\sim 0,5^\circ\text{C}$) quando comparado à média aritmética simples dos membros do conjunto (Figura 5.5) para diversas áreas na América do Sul, concentrando-se principalmente sobre a região tropical do continente e nas estações de inverno e primavera austral, aonde as maiores magnitudes de mudanças são projetadas. Isto indica que aqueles modelos cujas projeções de aumento de temperatura são mais elevadas foram “*downweighted*” (i.e., os pesos atribuídos a esses MCGs são menores comparados aos outros membros do conjunto). No entanto, valores de projeções acima de $4,5^\circ\text{C}$ continuam sendo mantidos sobre a Amazônia, Bolívia, e regiões centro-oeste e sudeste do Brasil, principalmente no inverno e na primavera.

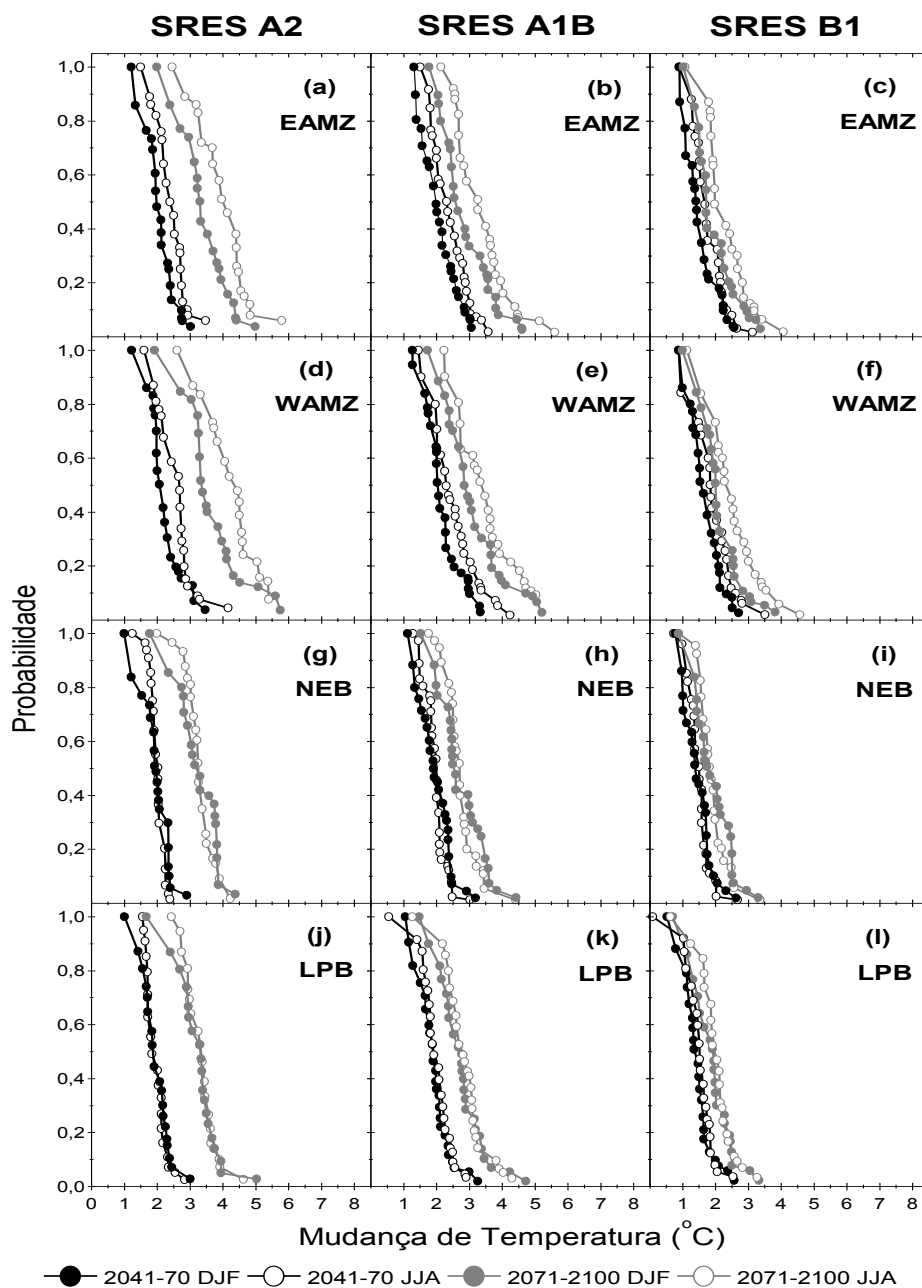


Figura 5.14 - Funções distribuição acumulada de mudança de temperatura ($^{\circ}\text{C}$) para os modelos do CMIP3 processados pelo método REA nos cenários A2 (esquerda), A1B (centro), e B1 (direita), e projetadas para as regiões leste e oeste da Amazônia (a-c e d-f, respectivamente), Nordeste do Brasil (g-i), e bacia do Prata (j-l). As linhas pretas representam o período de 2041 a 2070, e as linhas cinza o período de 2071-2100. Círculos preenchidos indicam DJF e círculos vazios JJA.

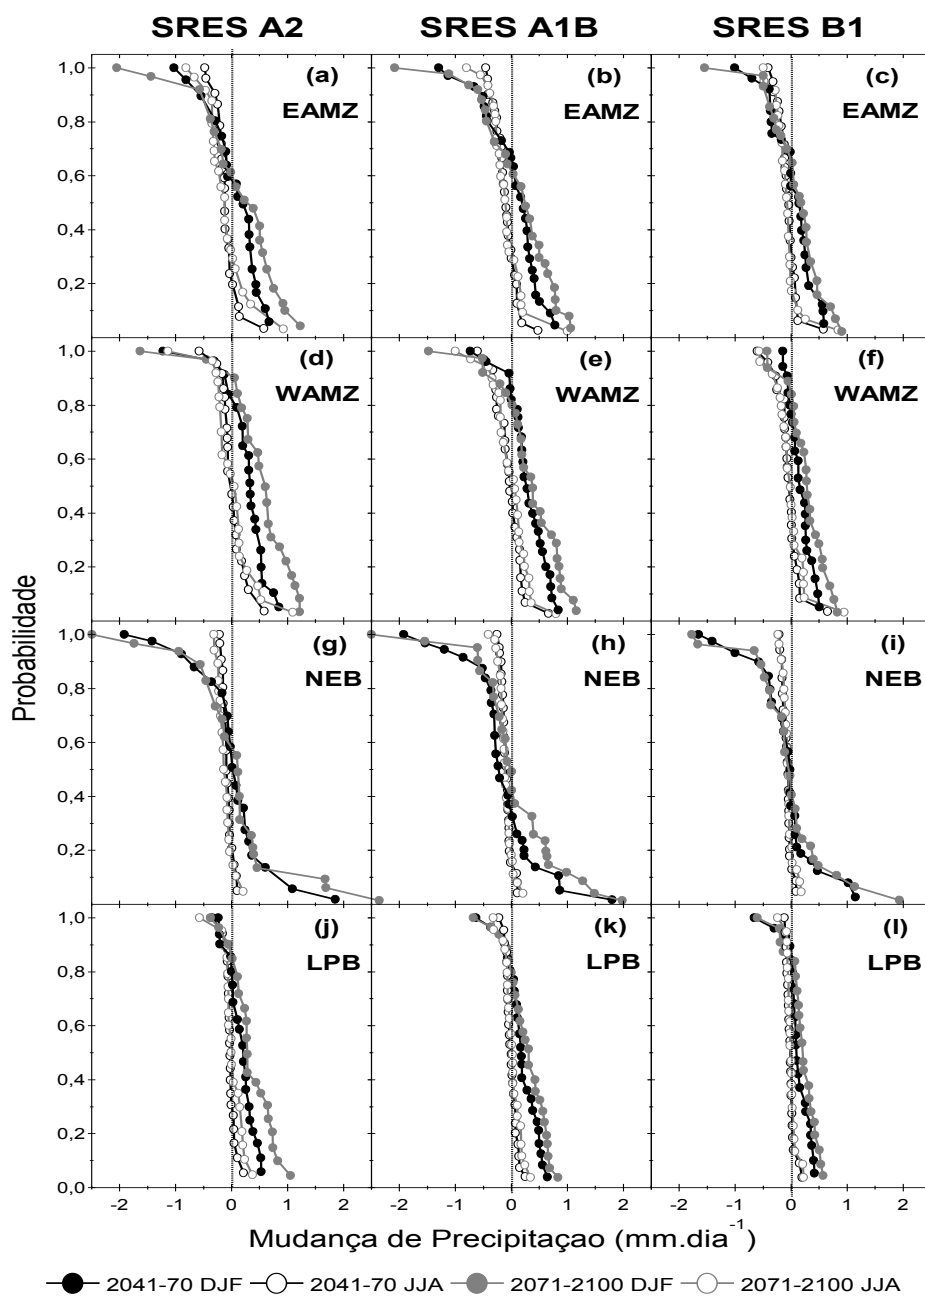


Figura 5.15 - Mesmo que Figura 5.14, exceto para precipitação ($\text{mm}\cdot\text{dia}^{-1}$).

Para a variável temperatura, os intervalos de incerteza aumentam gradualmente, e a confiabilidade no conjunto diminui, com o aumento da forçante radiativa (do RCP 2.6 para RCP 8.5) (não mostrado). No entanto, para todos os cenários, o intervalo de incerteza é sempre menor do que a magnitude da mudança projetada. Coerentemente com as análises de dispersão realizadas anteriormente (Figura 5.6), o intervalo de incerteza para o

cenário RCP 8.5 destaca-se como aquele com os valores mais altos (Figura 5.17), atingindo valores acima de 1,4°C sobre o noroeste da América do Sul e bacia Amazônica, principalmente na primavera, regiões essas que apresentam as maiores dispersões entre as projeções dos MCGs. Avaliando separadamente os parâmetros de desempenho e convergência (Figura 5.17p-z), podemos notar que eles se assemelham muito com aqueles obtidos para o CMIP3, sendo $R_B > R_D$ para todo o domínio de estudo.

Baseado no método REA, regiões com valores de confiabilidade um pouco mais expressivos relativos às projeções de mudanças de temperatura para o CMIP5, continuam sendo localizados apenas em algumas estações sobre pequenas partes da bacia do Prata e da Patagônia no cenário RCP 8.5 (Figura 5.17k-o). As regiões com valores um pouco mais consideráveis de confiabilidade ($\sim 0,5$) expandem-se quando analisamos os cenários RCP 2.6 e RCP 4.5 (não mostrado), mas mantem-se centrados sobre a bacia do Prata/sul da América do Sul. No entanto, como mencionado nas análises para o CMIP3, este parâmetro de confiabilidade do método REA não parece ser consistente com as análises qualitativas realizadas anteriormente para as projeções.

Com relação à média REA das projeções de mudança na variável precipitação sobre a América do Sul utilizando os MCGs do CMIP5, assim como para o CMIP3, pouca ou nenhuma modificação expressiva pode ser notada com relação ao padrão de mudança apresentado na Figura 5.7. Quanto aos parâmetros individuais do método REA, eles também não diferem expressivamente daqueles avaliados para o CMIP3 na Figura 5.12, e são invariantes quanto aos cenários forçantes empregados. Portanto, baseando-se no método REA e no novo conjunto de MCGs, mantem-se o indicativo citado anteriormente de que existe uma alta confiabilidade em uma projeção de nenhuma mudança expressiva na precipitação média sazonal. Com isso, os mapas espaciais relativos à precipitação serão omitidos no restante desta seção.

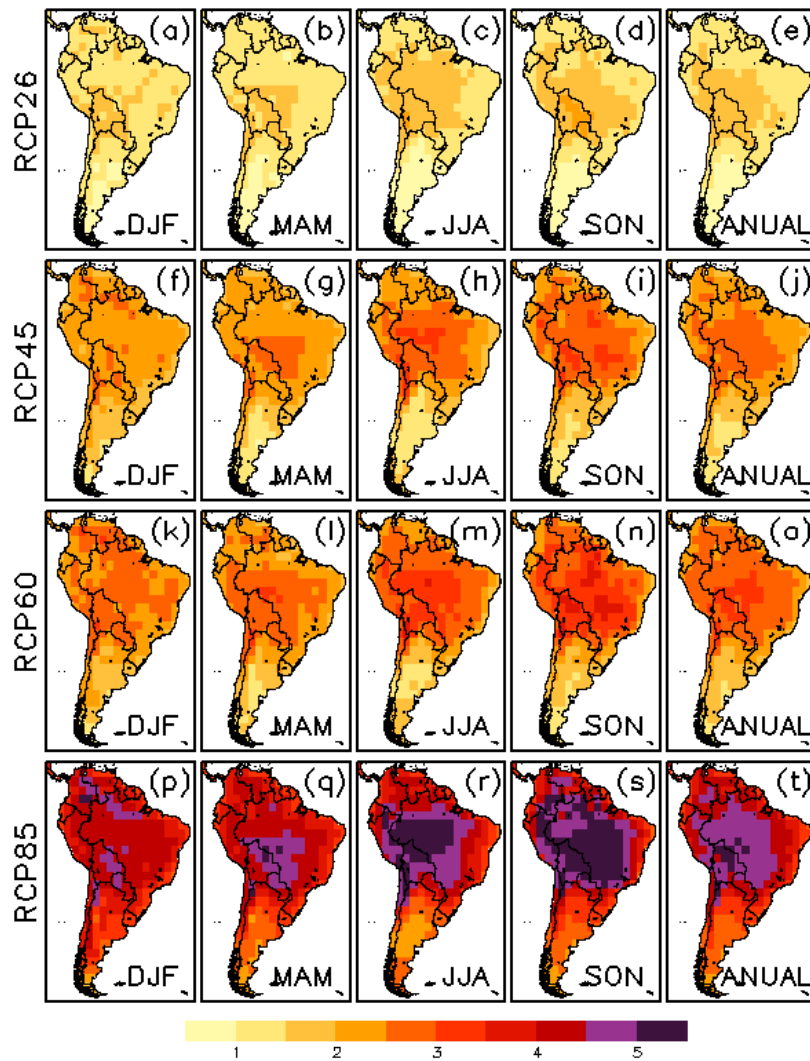


Figura 5.16 - Média REA para mudanças sazonal e anual de temperatura do ar próximo à superfície (°C) utilizando as projeções dos MCGs do CMIP5 para 2071-2100 nos cenários RCP 2.6 (a-e), RCP 4.5 (f-j), RCP 6.0 (k-o), e RCP 8.5 (p-t).

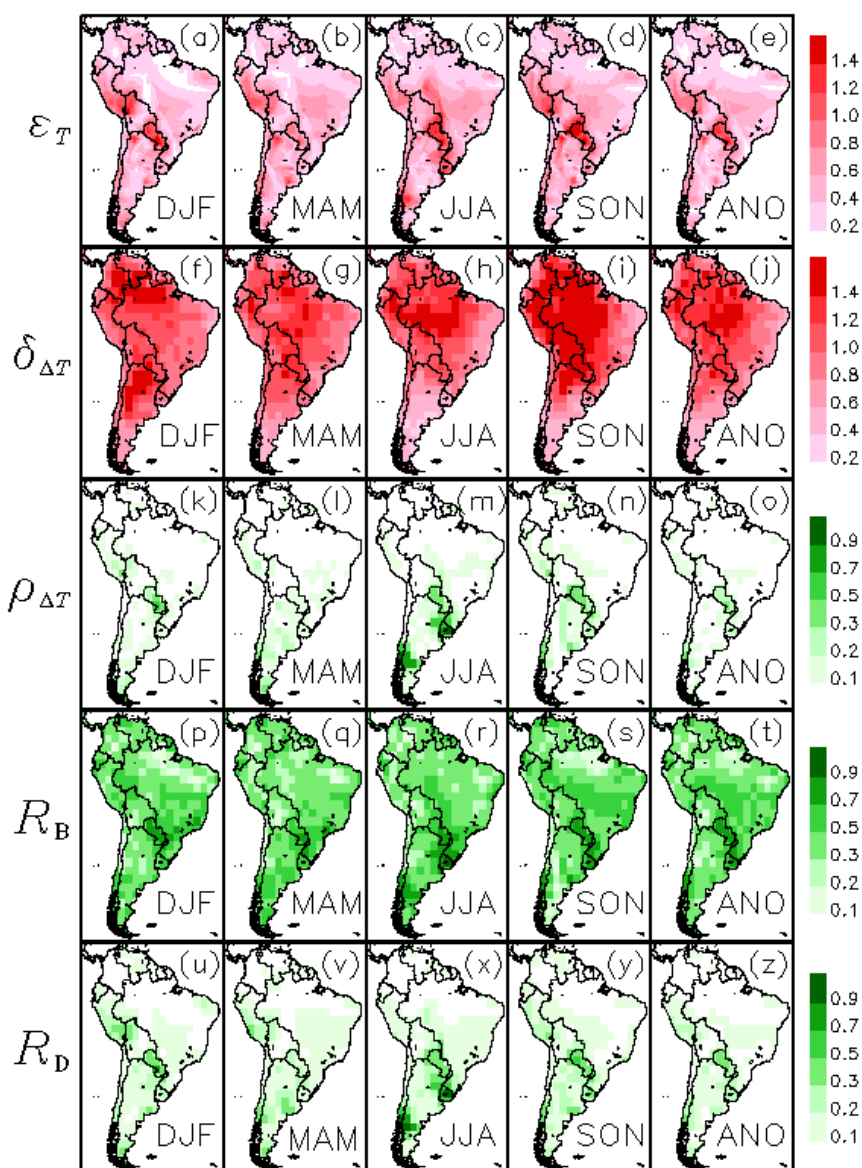


Figura 5.17 - Variabilidade natural observada de temperatura (ε_T , a-e) calculada para o período de 1901 a 2000, e intervalo de incerteza ($\delta_{\Delta T}$, f-j), confiabilidade no conjunto ($\rho_{\Delta T}$, k-o), e média dos parâmetros de desempenho (R_B , p-t) e convergência (R_D , u-z) do método REA para as mudanças sazonal e anual de temperatura utilizando as projeções dos MCGs do CMIP5 para 2071-2100 no cenário RCP 8.5. As unidades de ε_T e $\delta_{\Delta T}$ estão em $^{\circ}\text{C}$, e os demais parâmetros são adimensionais.

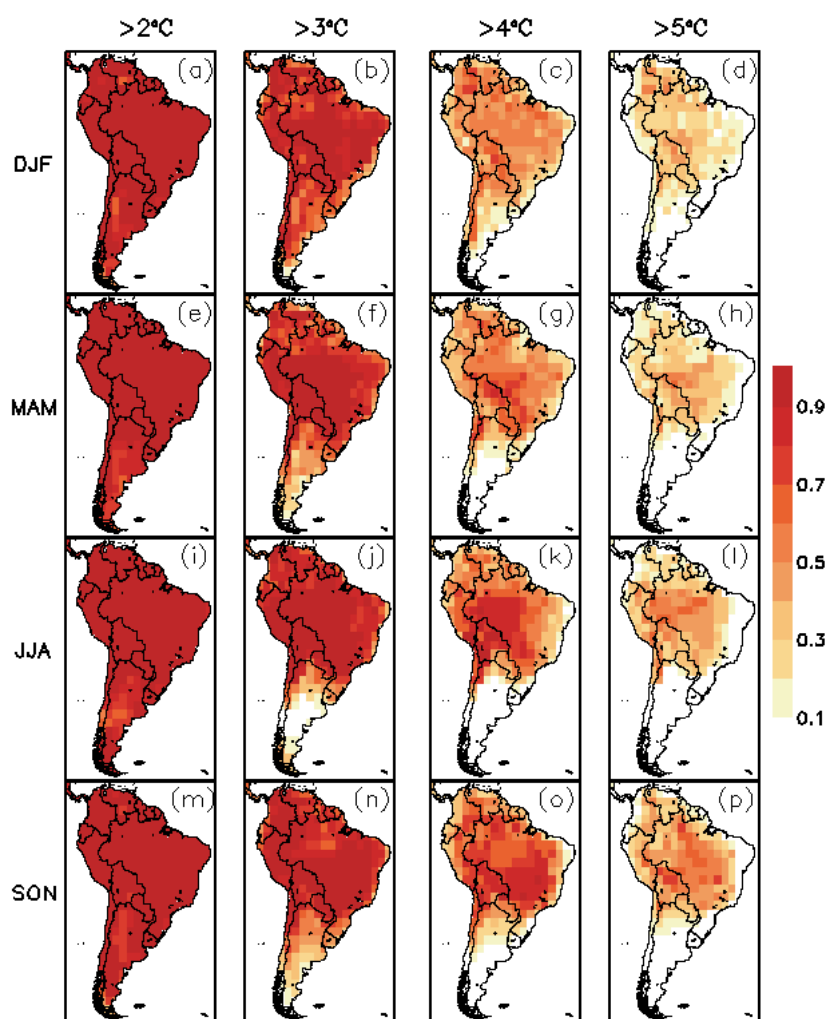


Figura 5.18 - Probabilidades sazonais das mudanças de temperatura excederem determinados limiares (2°, 3°, 4°, e 5°C), obtidas através das projeções dos modelos do CMIP5 para 2071-2100 no cenário RCP 8.5.

A Figura 5.18 apresenta as probabilidades sazonais das mudanças de temperatura excederem determinados limiares (2°, 3°, 4°, e 5°C), obtidas através das projeções dos modelos do CMIP5 para 2071-2100 no cenário RCP 8.5. Segundo a nova geração de modelos, a probabilidade das mudanças de temperatura exceder 2°C aproxima-se enormemente de 100% em todo o continente sul-americano no cenário RCP 8.5, e são invariáveis quanto às estações, assim como identificado no cenário SRES A2 do CMIP3. Probabilidades próximas a 100% também são identificadas em quase toda a faixa de latitudes entre aproximadamente 10°N – 25°S para o limiar de temperatura de 3°C, e diferente-

mente das análises do CMIP3, as probabilidades das mudanças excederem 4°C nesta mesma faixa são razoavelmente expressivas (50%) para o cenário RCP 8.5. Avaliando todos os cenários de emissões (não mostrado), constatamos que, além do RCP 8.5, nos cenários RCP 4.5 e RCP 6.0 os MCGs projetam um aumento de temperatura acima de 2°C com boa confiabilidade (>80%) para boa parte da faixa de latitudes supracitada. Adicionalmente, o RCP 2.6 é o único cuja probabilidade da mudança de temperatura exceder 2°C é desprezível. Por fim, exceto como visto para o RCP 8.5, a probabilidade de exceder o limiar de 3°C é menor do que 40% para outros cenários forçantes.

As CDFs para as mudanças de temperatura e precipitação para os MCGs do CMIP5 processados pelo método REA nos cenários RCP 2.6, 4.5, 6.0, e 8.5 para as quatro sub-regiões analisadas neste estudo são apresentadas nas Figuras 5.19 e 5.20. As distribuições relativas à mudança de temperatura (Figura 5.19) são bastante análogas e consistentes com aquelas produzidas com o CMIP3, apesar do cenário RCP 8.5 apresentar limiares de mudança de temperatura um pouco mais elevados. No geral, assim como no CMIP3, a probabilidade de exceder limiares de aumento de temperatura mais elevados aumenta (e a concordância entre os modelos diminuem) de 2041-2070 para 2071-2100, e de cenários forçantes menos intensos para aqueles mais intensos. Além disso, as probabilidades de exceder limiares mais elevados independem das estações de inverno/verão para o NEB e LPB, e para a bacia Amazônica a probabilidade é maior para o inverno do que o verão, condizente com as projeções apresentadas nas Figuras 5.5 e 5.16.

Para as CDFs de precipitação, como no CMIP3, as curvas se distribuem quase que simetricamente ao longo de uma mudança nula. Sobre o NEB, uma probabilidade um pouco maior de aumento de precipitação é notado para o verão austral, no entanto, com grande incerteza envolvida, o que pode ser constatado pelo espalhamento da distribuição. Além disso, corroborando também os resultados do CMIP3, a sub-região da LPB é aquela que apresenta a maior confiabilidade nos resultados apresentados (espalhamento pequeno, com distribuição bastante íngreme).




Figura 5.19 - Funções distribuição acumulada de mudança de temperatura (°C) para os modelos do CMIP5 processados pelo método REA nos cenários RCP 2.6, RCP 4.5, RCP 6.0, e RCP 8.5, e projetadas para as regiões leste e oeste da Amazônia (a-c e d-f, respectivamente), Nordeste do Brasil (g-i), e bacia do Prata (j-l). As linhas pretas representam o período de 2041 a 2070, e as linhas cinza o período de 2071-2100. Círculos preenchidos indicam DJF e círculos vazios JJA.




Figura 5.20 - Mesmo que Figura 5.19, exceto para precipitação ($\text{mm}\cdot\text{dia}^{-1}$).

Apesar do método REA demonstrar-se útil para o estudo de incertezas, dois pontos são bastante questionáveis quanto à atribuição de pesos aos modelos: 1) a utilização de uma única variável pode fornecer apenas uma medida relativamente fraca do desempenho de um modelo, e 2) o critério de convergência dos modelos pode causar um possível estreitamento artificial do intervalo de incerteza das mudanças, caso todo o conjunto de mo-

delos produza resultados enviesados, e mascarar importantes informações sobre projeções mais extremas. Nesse sentido, conforme discutido na seção 3.2.1, Xu et al. (2010) propuseram a inclusão de mais de uma variável e estatística no cálculo do parâmetro de confiabilidade atribuída ao desempenho do modelo em representar o clima presente, assim como a exclusão do critério de convergência. Dessa forma, para avaliarmos a sensibilidade dos resultados apresentados até aqui quanto ao tipo de ponderamento utilizado, iremos a seguir avaliar os resultados anteriores utilizando a formulação do método REA proposto por Xu et al. (2010), ao qual denominaremos REA modificado.

As Figuras 5.21 a 5.25 apresentam os resultados da aplicação do método REA modificado nas projeções para o final do século advindas dos conjuntos CMIP3 e CMIP5. Da mesma forma como visto anteriormente, os resultados referentes à variável precipitação não diferem substancialmente daqueles produzidos pela média aritmética simples dos modelos. Além disso, o intervalo de incertezas relacionado a essas projeções (Figura 5.22a-e, Figura 5.24a-e) continuam sendo bem maiores do que as magnitudes projetadas das mudanças. Dessa forma, os padrões espaciais de projeções de mudança de precipitação serão omitidos novamente.

Avaliando conjuntamente os padrões de mudança de temperatura do CMIP3 (Figura 5.21) e CMIP5 (Figura 5.23) após a aplicação do método REA modificado, vemos que, em geral, a magnitude das projeções de mudanças diminui em boa parte do domínio de estudo e para todos os cenários forçantes, quando comparado à média aritmética simples do conjunto, assim como constatado no método REA original. Exceção é feita para as projeções de DJF e MAM do conjunto CMIP5 no cenário RCP 8.5 (Figura 5.23p-q), em que as magnitudes das mudanças aumentaram para toda bacia Amazônica em comparação à média aritmética simples. De modo geral, as projeções indicadas pela média REA modificado ocupam uma posição intermediária entre a média REA original (limite inferior) e a média aritmética simples dos modelos (limite superior).

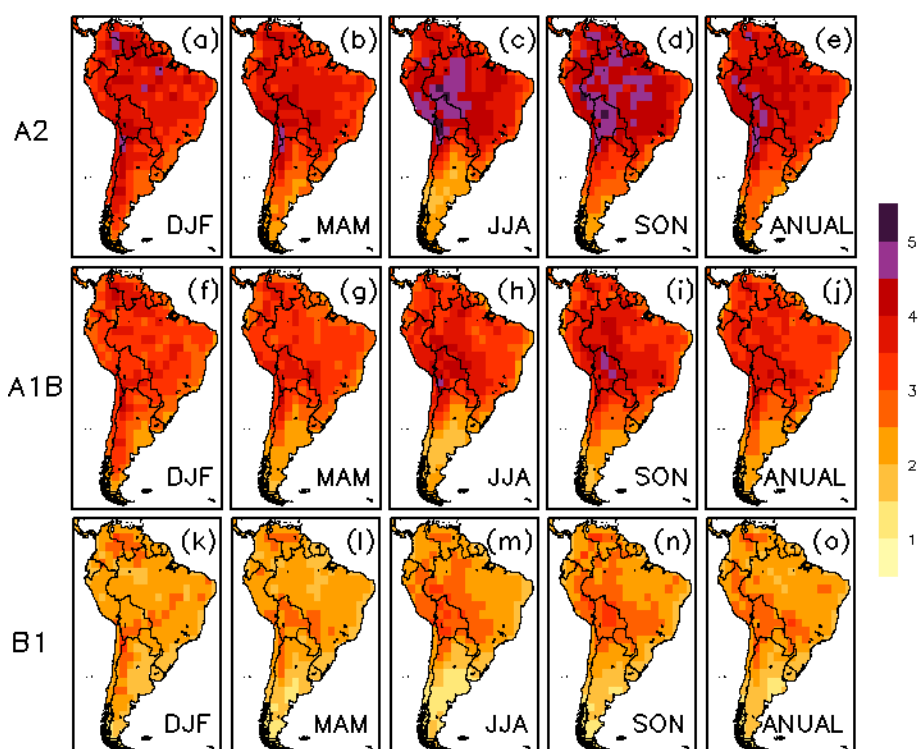


Figura 5.21 - Média REA modificado para mudanças sazonal e anual de temperatura do ar próximo à superfície ($^{\circ}\text{C}$) utilizando as projeções dos MCGs do CMIP3 para 2071-2100 nos cenários SRES A2 (a-e), A1B (f-j), e B1 (k-o).

Comparando os resultados do REA modificado com o REA original, observamos que essa redução supracitada é ligeiramente menor, principalmente sobre a parte tropical do continente. Isso indica que o “*downweighting*” daqueles modelos que projetam mudanças mais acentuadas é bem menor, dado que eles devem representar razoavelmente bem o clima presente. Este é o caso, por exemplo, dos modelos UKMO-HADGEM1 e MIROC3.2(hires) pertencentes ao CMIP3, os quais apresentam um dos melhores desempenhos em representar a climatologia observada de precipitação e temperatura, e ao mesmo tempo apresentam as projeções mais extremas de aquecimento.

Os intervalos de incerteza computados com o REA modificado (Figuras 5.22a-j e 5.24a-j) são consideravelmente maiores do que aqueles obtidos com o REA original (e.g., Figuras 5.10f-j e 5.12f-j), tanto para precipitação quanto para temperatura, principalmente sobre o noroeste da América do Sul e bacia Amazônica. No entanto, para a variável temperatura, a magnitude das projeções continua sendo bem maior do que o intervalo de

incertezas associado. Por outro lado, os intervalos de incerteza para precipitação obtidos pelo REA modificado são ainda maiores do que a magnitude de mudança projetada, corroborando as análises feitas anteriormente, e realçando ainda mais a baixa credibilidade nas projeções de mudanças para essa variável.

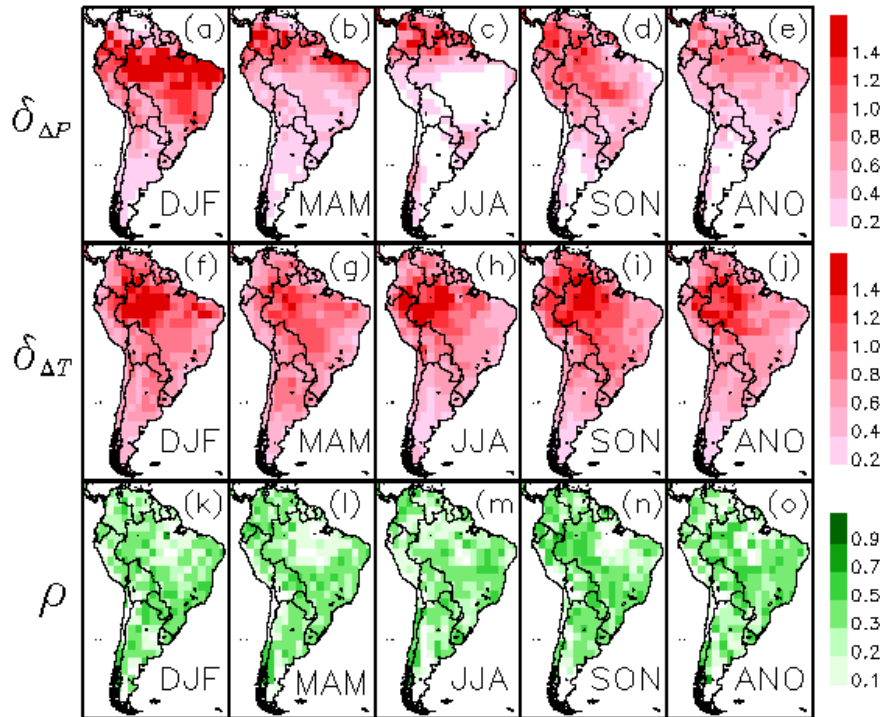


Figura 5.22 - Intervalo de incerteza para precipitação ($\tilde{\delta}_{\Delta P}$, a-e) e temperatura ($\tilde{\delta}_{\Delta T}$, f-j), e confiabilidade no conjunto ($\tilde{\rho}$, k-o), derivado do método REA modificado, para as mudanças sazonal e anual utilizando as projeções dos MCGs do CMIP3 para 2071-2100 no cenário SRES A2. As unidades de $\tilde{\delta}_{\Delta P}$ e $\tilde{\delta}_{\Delta T}$ são $\text{mm}\cdot\text{dia}^{-1}$ e $^{\circ}\text{C}$, respectivamente, e $\tilde{\rho}$ é adimensional.

Pela comparação entre os intervalos de incerteza obtidos pelo método REA original e REA modificado, fica visível que o REA original causa um estreitamento maior nos limites de incerteza das projeções, como mencionado por Xu et al. (2010). Entretanto, não temos condições para julgar se esse estreitamento é artificial ou não, ou seja, se o método REA original realmente capta as características fundamentais que devem ser representadas pelos MCGs, e que levarão a uma determinação melhor do intervalo de incerteza quanto às projeções futuras. Os modelos de tempo, clima, e do sistema climá-

tico são calibrados com relação aos aspectos climatológicos observados. Uma vez que forçantes climáticas sem precedentes nos registros paleoclimáticos são projetados para os próximos séculos (IPCC, 2007, 2013), a resposta do sistema climático (por exemplo, através de *feedbacks* positivos e negativos) ainda é uma grande incógnita, de tal forma que não temos total confiabilidade de que o desempenho dos modelos climáticos em representar a climatologia observada será fielmente mantido. Nesse sentido, a atribuição de um grau de credibilidade a um determinado modelo baseando-se também na convergência de sua projeção com relação à média do conjunto, assim como proposto no REA original, aparenta ser também bastante plausível.

A confiabilidade nas projeções dos MCGs pertencentes ao CMIP3 (Figura 5.22k-o) e CMIP5 (Figura 5.24k-o) obtidos pelo REA modificado (lembrando que neste método a confiabilidade é igual para todas as variáveis projetadas) são razoavelmente bem semelhantes, uma vez que os desempenhos dos MCGs em simular a climatologia observada não diferem grandemente entre ambos os conjuntos, conforme discutido no Capítulo 4. Consistentemente, os valores atribuídos à confiabilidade no REA modificado ocupam uma posição intermediária entre aquelas atribuídas à precipitação (limite superior) e temperatura (limite inferior) no método REA original. Baseado neste critério de confiabilidade em ambos os conjuntos de modelos, duas regiões se destacam por apresentar baixos valores ($< 0,2$): partes da bacia Amazônica e sul da América do Sul.

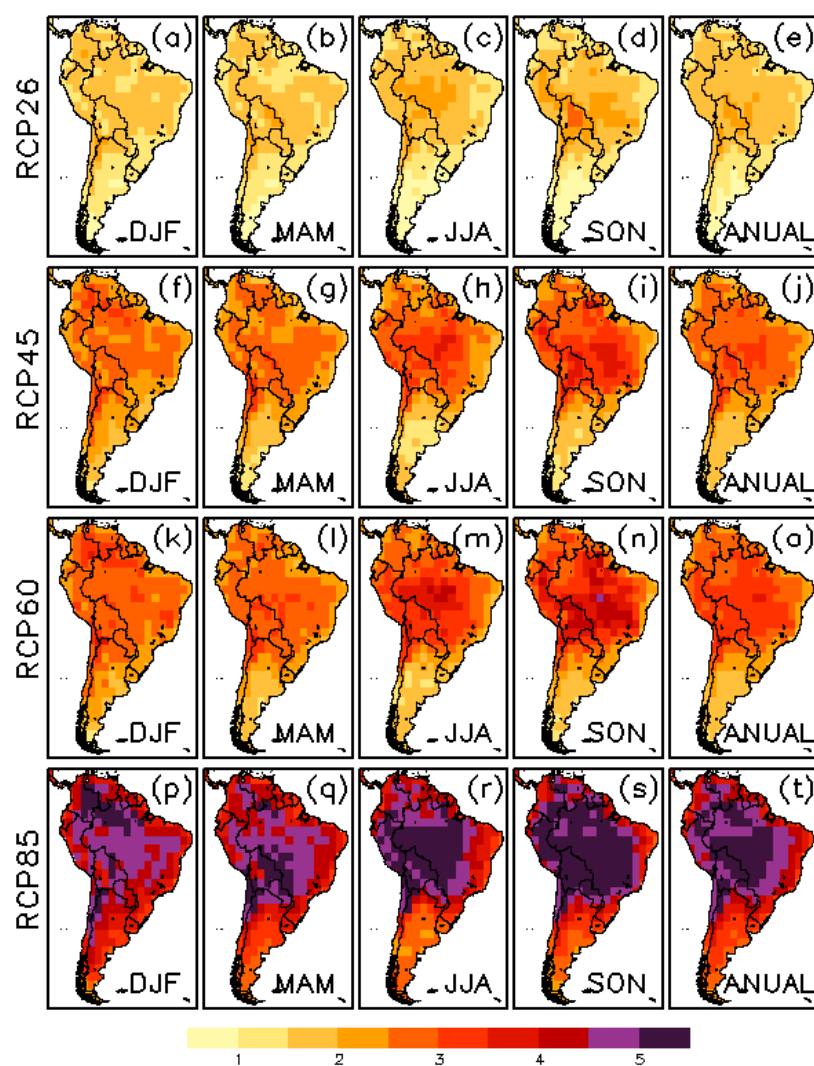


Figura 5.23 - Média REA modificado para mudanças sazonal e anual de temperatura do ar próximo à superfície (°C) utilizando as projeções dos MCGs do CMIP5 para 2071-2100 nos cenários RCP 2.6 (a-e), RCP 4.5 (f-j), RCP 6.0 (k-o), e RCP 8.5 (p-t).

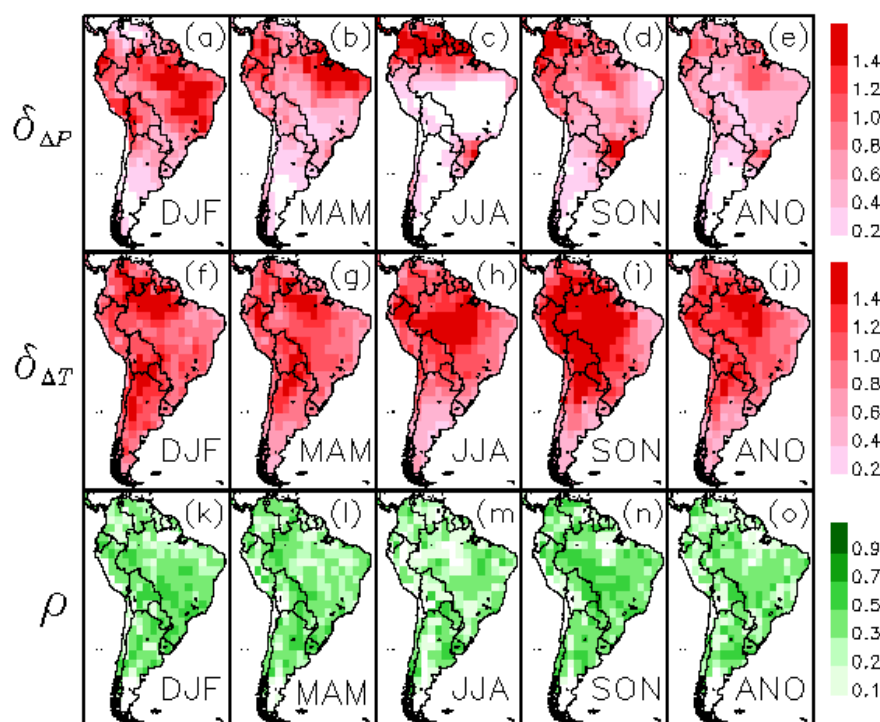


Figura 5.24 - Intervalo de incerteza para precipitação ($\tilde{\delta}_{\Delta P}$, a-e) e temperatura ($\tilde{\delta}_{\Delta T}$, f-j), e confiabilidade no conjunto ($\tilde{\rho}$, k-o), derivado do método REA modificado, para as mudanças sazonal e anual utilizando as projeções dos MCGs do CMIP5 para 2071-2100 no cenário RCP 8.5. As unidades de $\tilde{\delta}_{\Delta P}$ e $\tilde{\delta}_{\Delta T}$ são $\text{mm}\cdot\text{dia}^{-1}$ e $^{\circ}\text{C}$, respectivamente, e $\tilde{\rho}$ é adimensional.

A Figura 5.25 ilustra as contribuições das 5 funções peso da Equação 3.8 na atribuição do peso total de cada modelo do CMIP3 para uma média nas 4 sub-regiões analisadas neste estudo. As mesmas considerações descritas a seguir se aplicam ao CMIP5. Notavelmente, as funções peso atribuídas às correlações espaciais entre a PNM observada e aquelas simuladas pelos modelos (f_5) apresentam altos valores (acima de 0,9 para a grande maioria dos MCGs) em todas as estações e sub-regiões, e apresentam um pequeno espalhamento entre os MCGs. Quanto aos pesos atribuídos aos modelos pelos desempenhos em simular a variabilidade da temperatura (f_2) e precipitação (f_4), vemos que eles são razoavelmente bem comparáveis quando analisando a mediana das distribuições; entretanto, o espalhamento dos resultados é bem maior para a variável precipitação. Quanto aos fatores atribuídos aos MCGs pelo desempenho em simular os padrões

sazonais médios de temperatura (f_1) e precipitação (f_3), vemos que eles se destacam como tendo os menores valores, sendo, portanto, determinantes na produção dos baixos valores dos pesos totais. Por fim, no geral, a LPB destaca-se como aquela cujos modelos apresentam o melhor desempenho geral em simular as variáveis selecionadas, e por conseguinte, cujos pesos dos modelos são relativamente maiores comparado às outras sub-regiões. Por outro lado, as sub-regiões da Amazônia são aquelas cujos modelos apresentam mais deficiência em representar as variáveis e estatísticas climáticas investigadas neste estudo.

As Tabelas 5.1 a 5.4 sintetizam os resultados obtidos com o REA original e REA modificado (resultados contidos entre parênteses) referentes às projeções de mudança de temperatura e precipitação para o período de 2071-2100 (relativos a 1961-1990) advindos do CMIP3 e CMIP5 em todos os cenários forçantes investigados anteriormente, e mediados para as quatro sub-regiões analisadas neste estudo. Para as projeções de mudanças de precipitação (Tabelas 5.2 e 5.4), os intervalos de incerteza, obtidos com ambas as versões do método REA, possuem magnitudes bem maiores do que a mudança projetada em todas as sub-regiões analisadas, e em todos os cenários forçantes e conjuntos de MCGs, indicando que as projeções de mudanças são bastante incertas.

Por outro lado, para as projeções de temperatura (Tabelas 5.1 e 5.3), os intervalos de incerteza são sempre menores do que as magnitudes de aquecimento projetadas. Além disso, os intervalos de incerteza são geralmente menores para o método REA modificado, quando comparado ao REA original. Para o REA original, quando aplicado a variável temperatura, a magnitude das mudanças reduz-se quando comparado à média aritmética simples dos modelos em todas as sub-regiões e cenários forçantes. Por outro lado, a magnitude das mudanças geralmente se mantém, ou um leve aumento na magnitude projetada é observado quando o método REA modificado é aplicado, principalmente sobre as sub-regiões da bacia Amazônica. Resultados e conclusões semelhantes foram obtidos analisando-se os períodos de 2011-2040 e 2041-2070 (não mostrado).




Figura 5.25 - Contribuição sazonal e anual das 5 funções peso (a-z) da Equação 3.8, assim como o referido peso total (aa-ae), mediado sobre as 4 sub-regiões de estudo para os modelos do CMIP3.

Tabela 5.1 – Média aritmética simples do conjunto (ΔT_{ENS} , °C), média REA (ΔT_{REA} , °C), intervalo de incerteza (δ , °C), confiabilidade no conjunto (ρ , adimensional), e média do critério de convergência (R_d , adimensional), relativos à mudança de temperatura para o verão e inverno projetado pelos modelos do CMIP3 para 2071-2100 nos cenários SRES A2, A1B, e B1. Os valores entre parênteses indicam os resultados obtidos pelo REA modificado.

Região	Estação	SRES	ΔT_{ENS}	ΔT_{REA}	δ	ρ	R_d
EAMZ	DJF	A2	3,6	3,3 (3,6)	0,9 (1,0)	0,1 (0,3)	0,1
		A1B	3,1	2,8 (3,2)	0,8 (1,0)	0,1 (0,3)	0,1
		B1	2,2	1,9 (2,2)	0,7 (0,7)	0,1 (0,2)	0,2
	JJA	A2	4,0	3,9 (3,9)	0,9 (0,9)	0,1 (0,3)	0,1
		A1B	3,5	3,3 (3,3)	0,9 (0,8)	0,1 (0,4)	0,2
		B1	2,5	2,2 (2,3)	0,7 (0,6)	0,2 (0,4)	0,2
WAMZ	DJF	A2	3,8	3,5 (3,8)	1,1 (1,2)	0,1 (0,4)	0,2
		A1B	3,3	3,0 (3,3)	1,0 (1,1)	0,1 (0,3)	0,2
		B1	2,3	2,0 (2,2)	0,7 (0,8)	0,2 (0,3)	0,3
	JJA	A2	4,4	4,2 (4,4)	1,1 (1,2)	0,1 (0,3)	0,1
		A1B	3,8	3,4 (3,7)	1,1 (1,1)	0,1 (0,3)	0,2
		B1	2,7	2,3 (2,6)	0,9 (0,8)	0,2 (0,2)	0,2
NEB	DJF	A2	3,3	3,0 (3,3)	0,8 (0,8)	0,1 (0,4)	0,1
		A1B	2,8	2,6 (2,9)	0,8 (0,8)	0,1 (0,4)	0,2
		B1	2,0	1,8 (2,1)	0,7 (0,7)	0,2 (0,4)	0,2
	JJA	A2	3,2	3,3 (3,3)	0,5 (0,5)	0,1 (0,4)	0,2
		A1B	2,8	2,7 (2,8)	0,5 (0,5)	0,1 (0,4)	0,2
		B1	1,9	1,8 (2,0)	0,5 (0,5)	0,2 (0,3)	0,3
LPB	DJF	A2	3,3	3,1 (3,3)	0,8 (0,7)	0,2 (0,4)	0,2
		A1B	2,9	2,6 (2,9)	0,8 (0,8)	0,2 (0,4)	0,3
		B1	2,0	1,8 (2,1)	0,7 (0,6)	0,4 (0,4)	0,4
	JJA	A2	3,3	3,3 (3,3)	0,6 (0,6)	0,3 (0,4)	0,3
		A1B	2,9	2,7 (3,0)	0,8 (0,7)	0,3 (0,4)	0,4
		B1	2,1	1,9 (2,1)	0,7 (0,5)	0,4 (0,4)	0,5

Tabela 5.2 – O mesmo que na Tabela 5.1, exceto para precipitação (mm.dia⁻¹).

Região	Estação	SRES	ΔP_{ENS}	ΔP_{REA}	δ	ρ	R_d
EAMZ	DJF	A2	0,1	0,1 (-0,4)	0,9 (1,4)	0,5 (0,3)	0,8
		A1B	0,1	0,1 (-0,2)	0,9 (1,2)	0,5 (0,3)	0,9
		B1	0,1	0,1 (-0,1)	0,6 (0,7)	0,5 (0,2)	0,9
	JJA	A2	-0,2	-0,1 (-0,2)	0,3 (0,5)	0,6 (0,3)	0,9
		A1B	-0,1	-0,1 (-0,1)	0,3 (0,4)	0,6 (0,4)	0,9
		B1	-0,1	-0,1 (-0,1)	0,2 (0,3)	0,6 (0,4)	1,0
WAMZ	DJF	A2	0,5	0,4 (0,4)	0,7 (1,2)	0,5 (0,4)	0,9
		A1B	0,3	0,3 (0,3)	0,7 (1,0)	0,5 (0,3)	0,9
		B1	0,3	0,2 (0,3)	0,5 (0,6)	0,6 (0,3)	0,9
	JJA	A2	0,0	0,0 (-0,1)	0,5 (0,6)	0,5 (0,3)	0,9
		A1B	0,0	0,0 (-0,1)	0,4 (0,5)	0,5 (0,3)	0,9
		B1	0,0	-0,1 (-0,1)	0,4 (0,4)	0,5 (0,2)	1,0
NEB	DJF	A2	0,1	0,0 (-0,2)	0,9 (1,4)	0,6 (0,4)	0,8
		A1B	0,1	0,0 (-0,2)	0,8 (1,3)	0,6 (0,4)	0,8
		B1	0,0	-0,1 (-0,2)	0,7 (1,0)	0,7 (0,4)	0,9
	JJA	A2	-0,1	-0,1 (-0,1)	0,2 (0,2)	0,8 (0,4)	1,0
		A1B	-0,1	-0,1 (-0,1)	0,2 (0,2)	0,8 (0,4)	1,0
		B1	-0,1	-0,1 (0,0)	0,1 (0,2)	0,8 (0,3)	1,0
LPB	DJF	A2	0,3	0,3 (0,3)	0,5 (0,6)	0,7 (0,4)	0,9
		A1B	0,3	0,2 (0,3)	0,5 (0,5)	0,7 (0,4)	0,9
		B1	0,2	0,2 (0,2)	0,4 (0,4)	0,7 (0,4)	0,9
	JJA	A2	0,0	0,0 (0,0)	0,2 (0,2)	0,6 (0,4)	0,9
		A1B	0,0	0,0 (0,0)	0,2 (0,2)	0,6 (0,4)	0,9
		B1	0,0	0,0 (0,0)	0,1 (0,1)	0,6 (0,4)	1,0

Tabela 5.3 – Média aritmética simples do conjunto (ΔT_{ENS} , °C), média REA (ΔT_{REA} , °C), intervalo de incerteza (δ , °C), confiabilidade no conjunto (ρ , adimensional), e média do critério de convergência (R_d , adimensional), relativos à mudança de temperatura para o verão e inverno projetado pelos modelos do CMIP5 para 2071-2100 nos cenários RCP 2.6, 4.5, 6.0 e 8.5. Os valores entre parênteses indicam os resultados obtidos pelo REA modificado.

Região	Estação	RCP	ΔT_{ENS}	ΔT_{REA}	δ	ρ	R_d
EAMZ	DJF	2.6	1,5	1,4 (1,5)	0,5 (0,5)	0,2 (0,3)	0,3
		4.5	2,3	2,3 (2,5)	0,7 (0,7)	0,1 (0,3)	0,2
		6.0	2,6	2,5 (2,7)	0,6 (0,7)	0,1 (0,3)	0,2
		8.5	4,1	4,0 (4,4)	1,1 (1,1)	0,1 (0,3)	0,1
	JJA	2.6	1,8	1,5 (1,7)	0,6 (0,7)	0,3 (0,3)	0,4
		4.5	2,8	2,6 (2,8)	0,8 (0,9)	0,2 (0,3)	0,2
		6.0	3,0	2,9 (3,1)	0,7 (0,8)	0,1 (0,3)	0,2
		8.5	4,8	4,5 (4,9)	1,2 (1,3)	0,1 (0,3)	0,1
WAMZ	DJF	2.6	1,6	1,4 (1,6)	0,5 (0,5)	0,3 (0,3)	0,4
		4.5	2,5	2,4 (2,7)	0,7 (0,7)	0,2 (0,3)	0,3
		6.0	2,7	2,6 (2,9)	0,6 (0,7)	0,2 (0,3)	0,2
		8.5	4,5	4,3 (4,8)	1,3 (1,3)	0,1 (0,3)	0,1
	JJA	2.6	1,9	1,6 (1,9)	0,6 (0,8)	0,2 (0,2)	0,4
		4.5	2,9	2,7 (2,9)	0,8 (0,8)	0,1 (0,2)	0,2
		6.0	3,2	3,0 (3,2)	0,8 (0,9)	0,1 (0,2)	0,2
		8.5	5,0	4,8 (5,1)	1,3 (1,3)	0,1 (0,2)	0,1
NEB	DJF	2.6	1,4	1,3 (1,5)	0,4 (0,5)	0,2 (0,3)	0,4
		4.5	2,1	2,1 (2,3)	0,5 (0,5)	0,1 (0,3)	0,2
		6.0	2,4	2,3 (2,5)	0,5 (0,5)	0,1 (0,3)	0,2
		8.5	3,7	3,7 (4,0)	0,8 (0,8)	0,1 (0,3)	0,2
	JJA	2.6	1,3	1,2 (1,3)	0,4 (0,4)	0,4 (0,3)	0,5
		4.5	2,1	2,0 (2,1)	0,5 (0,5)	0,2 (0,3)	0,3
		6.0	2,4	2,3 (2,4)	0,4 (0,4)	0,2 (0,3)	0,3
		8.5	3,7	3,5 (3,6)	0,7 (0,8)	0,1 (0,4)	0,2
LPB	DJF	2.6	1,4	1,3 (1,4)	0,5 (0,6)	0,5 (0,5)	0,6
		4.5	2,2	2,0 (2,2)	0,6 (0,7)	0,3 (0,5)	0,4
		6.0	2,4	2,3 (2,4)	0,6 (0,7)	0,3 (0,4)	0,4
		8.5	4,0	3,8 (4,0)	1,1 (1,1)	0,2 (0,5)	0,2
	JJA	2.6	1,4	1,3 (1,4)	0,5 (0,6)	0,6 (0,3)	0,7
		4.5	2,2	2,0 (2,2)	0,6 (0,7)	0,5 (0,4)	0,6
		6.0	2,5	2,4 (2,5)	0,6 (0,7)	0,4 (0,3)	0,5
		8.5	3,9	3,7 (4,0)	0,9 (0,9)	0,3 (0,4)	0,3

Tabela 5.4 – O mesmo que a Tabela 5.3, exceto para precipitação (mm.dia⁻¹).

Região	Estação	RCP	ΔP_{ENS}	ΔP_{REA}	δ	ρ	R_d
EAMZ	DJF	2.6	0,0	-0,1 (-0,1)	0,5 (0,6)	0,6 (0,3)	0,9
		4.5	0,0	0,0 (-0,2)	0,7 (0,9)	0,6 (0,3)	0,9
		6.0	0,1	-0,1 (-0,1)	0,7 (0,9)	0,6 (0,3)	0,9
		8.5	0,0	-0,1 (-0,3)	1,0 (1,3)	0,6 (0,3)	0,8
	JJA	2.6	-0,1	-0,1 (-0,1)	0,3 (0,4)	0,6 (0,3)	0,9
		4.5	-0,2	-0,2 (-0,2)	0,4 (0,4)	0,6 (0,3)	0,9
		6.0	-0,2	-0,2 (-0,3)	0,4 (0,5)	0,6 (0,3)	0,9
		8.5	-0,3	-0,3 (-0,4)	0,5 (0,7)	0,6 (0,3)	0,8
WAMZ	DJF	2.6	0,1	0,1 (0,0)	0,4 (0,5)	0,6 (0,3)	1,0
		4.5	0,2	0,1 (0,1)	0,5 (0,6)	0,6 (0,3)	0,9
		6.0	0,2	0,1 (0,2)	0,6 (0,7)	0,6 (0,3)	0,9
		8.5	0,2	0,1 (0,0)	0,8 (1,0)	0,6 (0,3)	0,8
	JJA	2.6	0,0	-0,1 (0,0)	0,4 (0,4)	0,5 (0,2)	1,0
		4.5	0,0	0,0 (0,0)	0,4 (0,5)	0,5 (0,2)	0,9
		6.0	0,0	0,0 (0,0)	0,5 (0,6)	0,5 (0,2)	0,9
		8.5	0,0	-0,1 (0,0)	0,6 (0,8)	0,5 (0,2)	0,9
NEB	DJF	2.6	0,0	0,0 (0,0)	0,6 (0,7)	0,6 (0,3)	0,9
		4.5	0,2	0,2 (0,2)	0,7 (0,9)	0,6 (0,3)	0,9
		6.0	0,1	0,1 (0,1)	0,8 (0,9)	0,5 (0,3)	0,9
		8.5	0,3	0,3 (0,4)	0,9 (1,3)	0,6 (0,3)	0,8
	JJA	2.6	-0,1	-0,1 (-0,1)	0,1 (0,2)	0,8 (0,3)	1,0
		4.5	-0,2	-0,1 (-0,2)	0,2 (0,2)	0,8 (0,3)	1,0
		6.0	-0,2	-0,2 (-0,2)	0,2 (0,3)	0,8 (0,3)	0,9
		8.5	-0,3	-0,2 (-0,3)	0,2 (0,3)	0,8 (0,4)	0,9
LPB	DJF	2.6	0,1	0,1 (0,0)	0,3 (0,4)	0,7 (0,5)	1,0
		4.5	0,1	0,1 (0,1)	0,4 (0,5)	0,7 (0,5)	0,9
		6.0	0,2	0,2 (0,2)	0,4 (0,5)	0,7 (0,4)	0,9
		8.5	0,2	0,2 (0,2)	0,6 (0,7)	0,7 (0,5)	0,9
	JJA	2.6	0,0	0,0 (0,0)	0,1 (0,2)	0,6 (0,3)	1,0
		4.5	0,0	0,0 (0,0)	0,2 (0,2)	0,6 (0,4)	0,9
		6.0	0,0	0,0 (0,0)	0,2 (0,2)	0,6 (0,3)	0,9
		8.5	0,1	0,1 (0,1)	0,3 (0,3)	0,6 (0,4)	0,9

5.2. Resultados obtidos a partir da inferência bayesiana

Como enfatizado por Räisänen et al. (2010), diversos métodos tem sido propostos na literatura nos quais modelos climáticos são ponderados de acordo com seu desempenho em simular o clima presente ou mudanças climáticas recentes, ou de acordo com sua concordância com outros modelos. Dentre esses métodos podemos destacar o método REA utilizado neste estudo, originalmente proposto por Giorgi e Mearns (2002) e modificado por Xu et al. (2010), o índice de previsão climática de Murphy et al. (2004), o ponderamento estatístico M utilizado por Watterson (2008), e diversos outros métodos baseados em estatística bayesiana (TEBALDI et al., 2005; GREENE et al., 2006; FURRER et al., 2007). Entretanto, nenhum desses métodos tem sido amplamente aceitos, uma vez que a melhor maneira de realizar o ponderamento é difícil de determinar. Qualquer esquema de ponderamento inclui elementos subjetivos, tais como a seleção das informações/variáveis a serem inseridas, e a maneira como estas informações são utilizadas. Nesse sentido, optamos por avaliar também as incertezas relacionadas às projeções de mudanças climáticas na América do Sul utilizando o método de inferência bayesiana proposto por Tebaldi et al. (2005), o qual é comparável ao método REA original descrito anteriormente, mas que trata de forma aleatória os dados utilizados, e nos quais todos os parâmetros de análise são tratados como curvas de densidade de probabilidade, e portanto, reduz-se um pouco a subjetividade feita nas escolhas realizadas no ponderamento.

As Figuras 5.26 e 5.27 apresentam a distribuição espacial da estimativa central das projeções de mudanças sazonal e anual de temperatura para 2071-2100 utilizando os resultados do CMIP3 e CMIP5, respectivamente, após a aplicação do método de inferência bayesiana. Os padrões projetados de mudanças com a aplicação da inferência bayesiana são muito consistentes com aqueles obtidos com o método REA, principalmente o REA modificado. Assim como observado anteriormente, quando utilizando a inferência bayesiana, as magnitudes das mudanças decrescem ($\sim 0,5^{\circ}$ - 1° C) em quase todo o continente sul-americano quando comparando com a média aritmética simples dos MCGs.

Como identificado também com o REA modificado, exceção é feita em algumas localidades, tais como sobre a Amazônia/centro-oeste brasileiro, em que as projeções de aquecimento no cenário RCP 8.5 em DJF e MAM tornam-se aproximadamente 0,5°-1°C maior.

Em geral, o decréscimo nas projeções de temperatura e a consistência entre os diversos métodos de ponderamento utilizados também são observados nos períodos de 2011-2040 e 2041-2070 (não mostrado). Com relação à variável precipitação, nenhuma modificação substancial foi identificada comparando os resultados bayesianos com a média aritmética simples dos MCGs, assim como constatado anteriormente com os outros métodos utilizados. Nesse sentido, por brevidade, as distribuições espaciais projetadas de mudanças de precipitação serão omitidas.

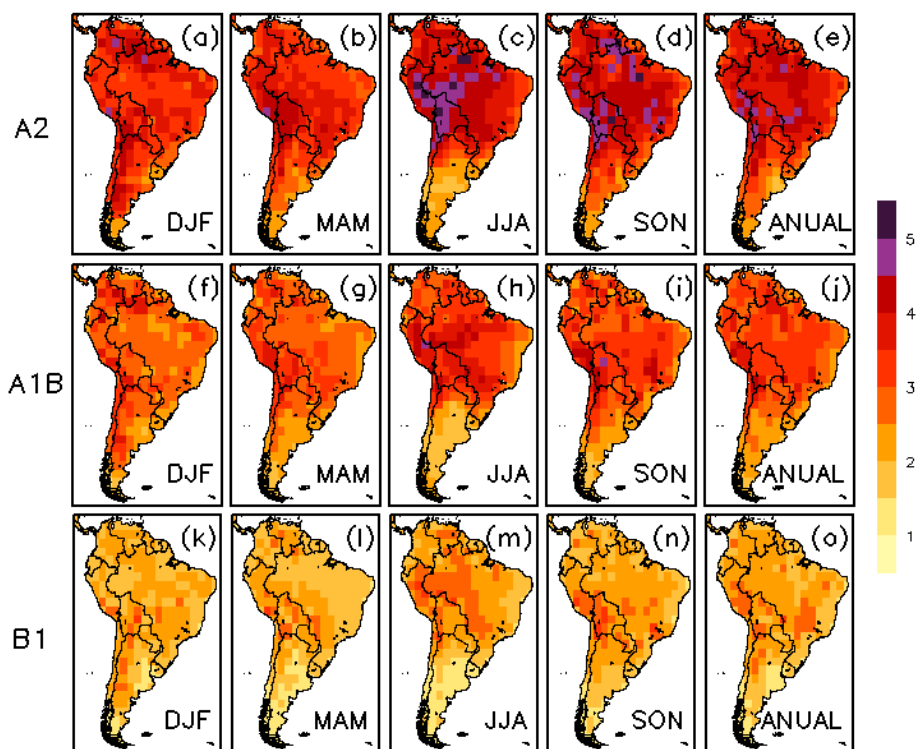


Figura 5.26 - Estimativa central das mudanças sazonal e anual de temperatura (°C) após a aplicação do método de inferência bayesiana, utilizando as projeções dos MCGs do CMIP3 para 2071-2100 nos cenários SRES A2 (a-e), A1B (f-j), e B1 (k-o).

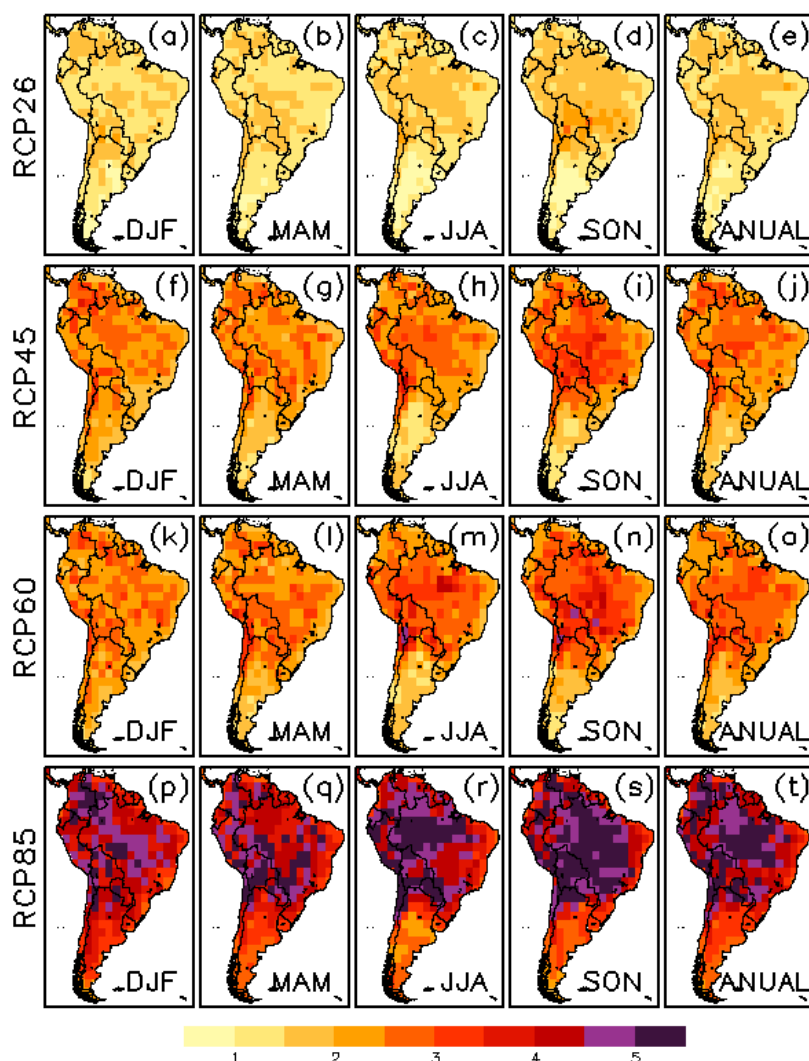


Figura 5.27 - Estimativa central das mudanças sazonal e anual de temperatura ($^{\circ}\text{C}$) após a aplicação do método de inferência bayesiana, utilizando as projeções dos MCGs do CMIP5 para 2071-2100 nos cenários RCP 2.6 (a-e), RCP 4.5 (f-j), RCP 6.0 (k-o), e RCP 8.5 (p-t).

A seguir são apresentadas as PDFs referentes às projeções de mudanças de temperatura e precipitação para 2071-2100 nos diversos cenários forçantes e para as quatro sub-regiões analisadas neste estudo, obtidas com o método de inferência bayesiana aplicado ao conjunto CMIP3 e CMIP5 (Figuras 5.28 a 5.31). Uma importante característica das PDFs geradas pela inferência bayesiana é que as distribuições são concentradas para aquelas regiões em que os MCGs apresentam bom desempenho com relação às simulações do clima observado, e cujas projeções são coerentes com os outros membros do

conjunto. Adicionalmente, curvas unimodais são estimadas em regiões em que existe um grande consenso entre os MCGs, ou onde modelos *outliers* são *downweighted* devido a apresentarem grandes vieses. Em contrapartida, curvas multimodais caracterizam regiões em que os modelos produzem projeções discrepantes, e que não são descontadas com base nos seus vieses.

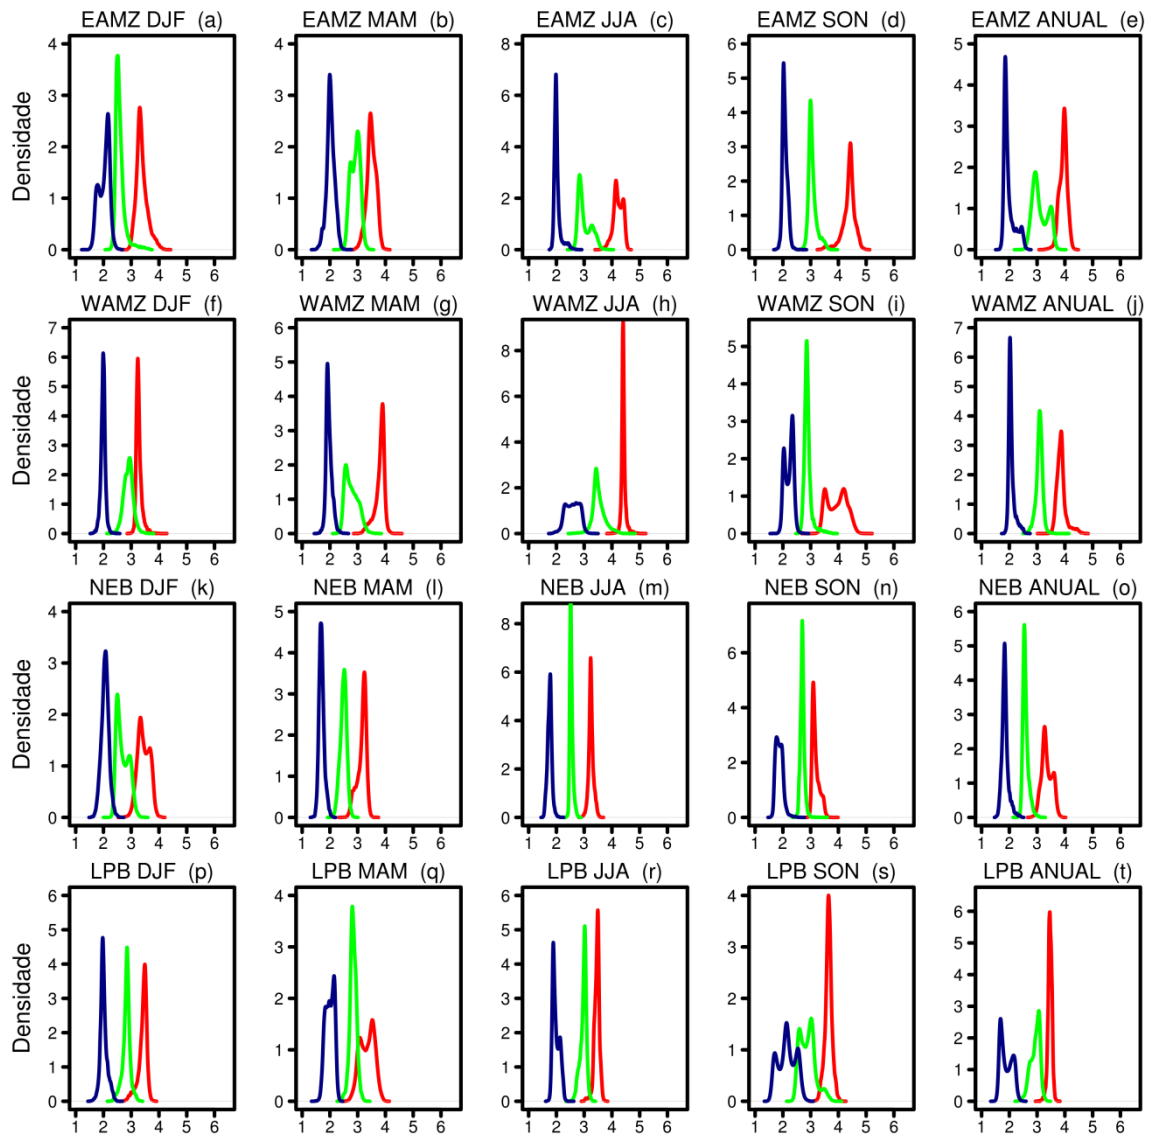


Figura 5.28 - Funções densidade de probabilidade para mudanças sazonal e anual de temperatura (°C) para 2071-2100 nos cenários SRES B1 (azul), A1B (verde), e A2 (vermelho), obtidas com o método de inferência bayesiana aplicado ao conjunto CMIP3.

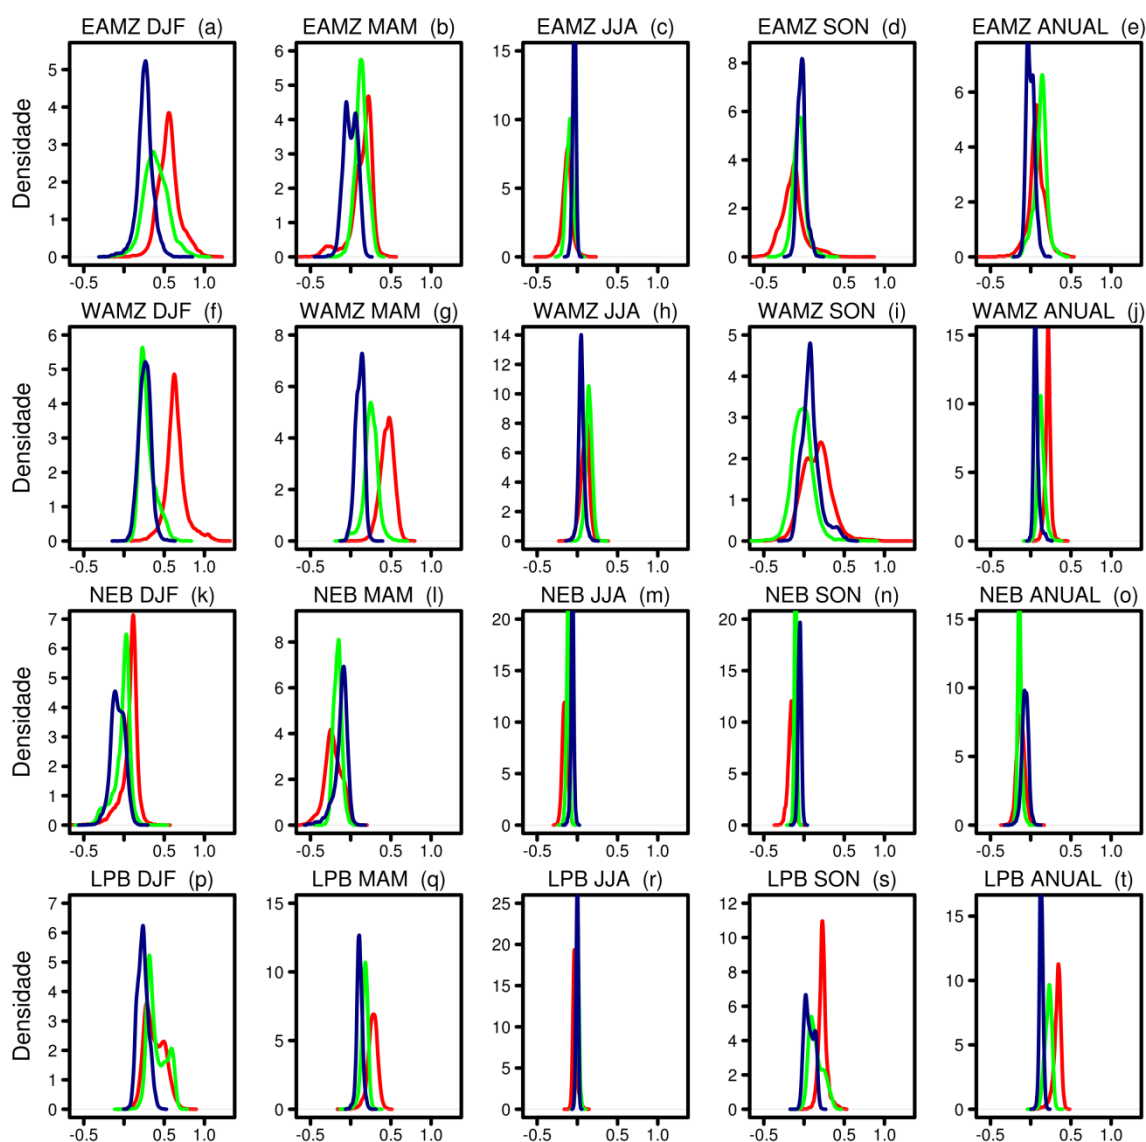


Figura 5.29 - Mesmo que Figura 5.28, exceto para precipitação ($\text{mm}\cdot\text{dia}^{-1}$).

Avaliando as PDFs para as mudanças projetadas de temperatura tanto pelos MCGs do CMIP3 quanto para o CMIP5 (Figuras 5.28 e 5.30), podemos observar que, no geral, as distribuições são predominantemente unimodais e razoavelmente bem concentradas no entorno de um valor específico, no qual a largura da distribuição não excede $\sim 1^\circ\text{C}$, o que caracteriza uma situação de boa concordância entre os modelos quanto as projeções de mudanças para essa variável. Exceções são feitas no conjunto CMIP3 para as sub-regiões WAMZ em SON no cenário SRES A2, e LPB em SON nos cenários B1 e A1B, e MAM no A2; e no conjunto CMIP5 para EAMZ em MAM no cenário RCP 4.5 e SON

no RCP 8.5, WAMZ em SON nos cenários RCP 4.5, 6.0, e 8.5, e para LPB em JJA para RCP 8.5. Nestas regiões as curvas são em geral bimodais, e as larguras das PDFs apresentam uma magnitude de cerca de 2°C, o que implica em um intervalo de incerteza bem maior sobre aquelas regiões.

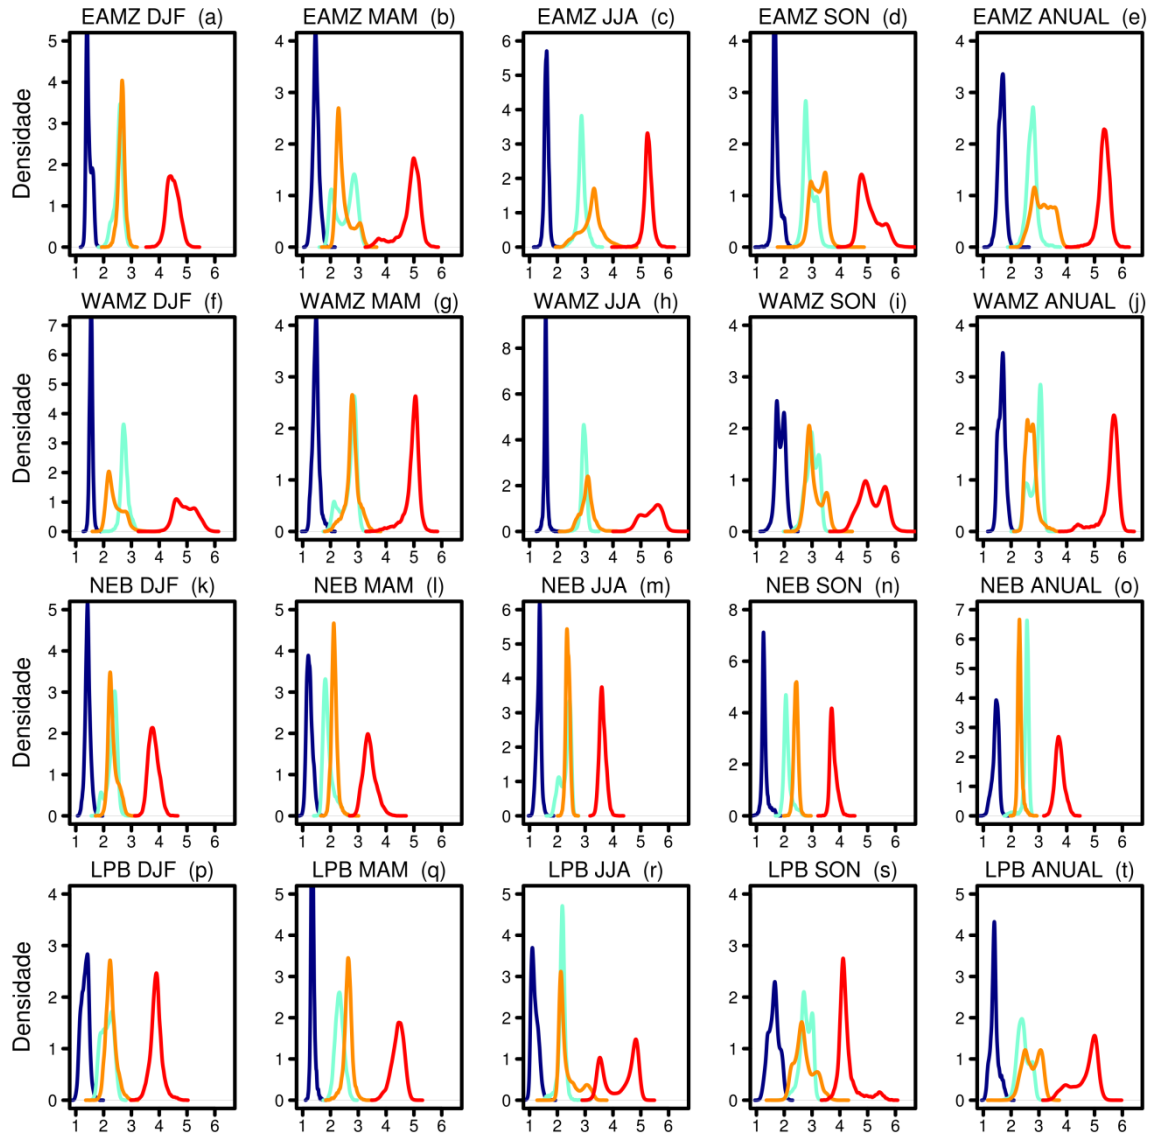


Figura 5.30 - Funções densidade de probabilidade para mudanças sazonal e anual de temperatura (°C) para 2071-2100 nos cenários RCP 2.6 (azul escuro), RCP 4.5 (azul claro), RCP 6.0 (laranja) e RCP 8.5 (vermelho), obtidas com o método de inferência bayesiana aplicado ao conjunto CMIP5.

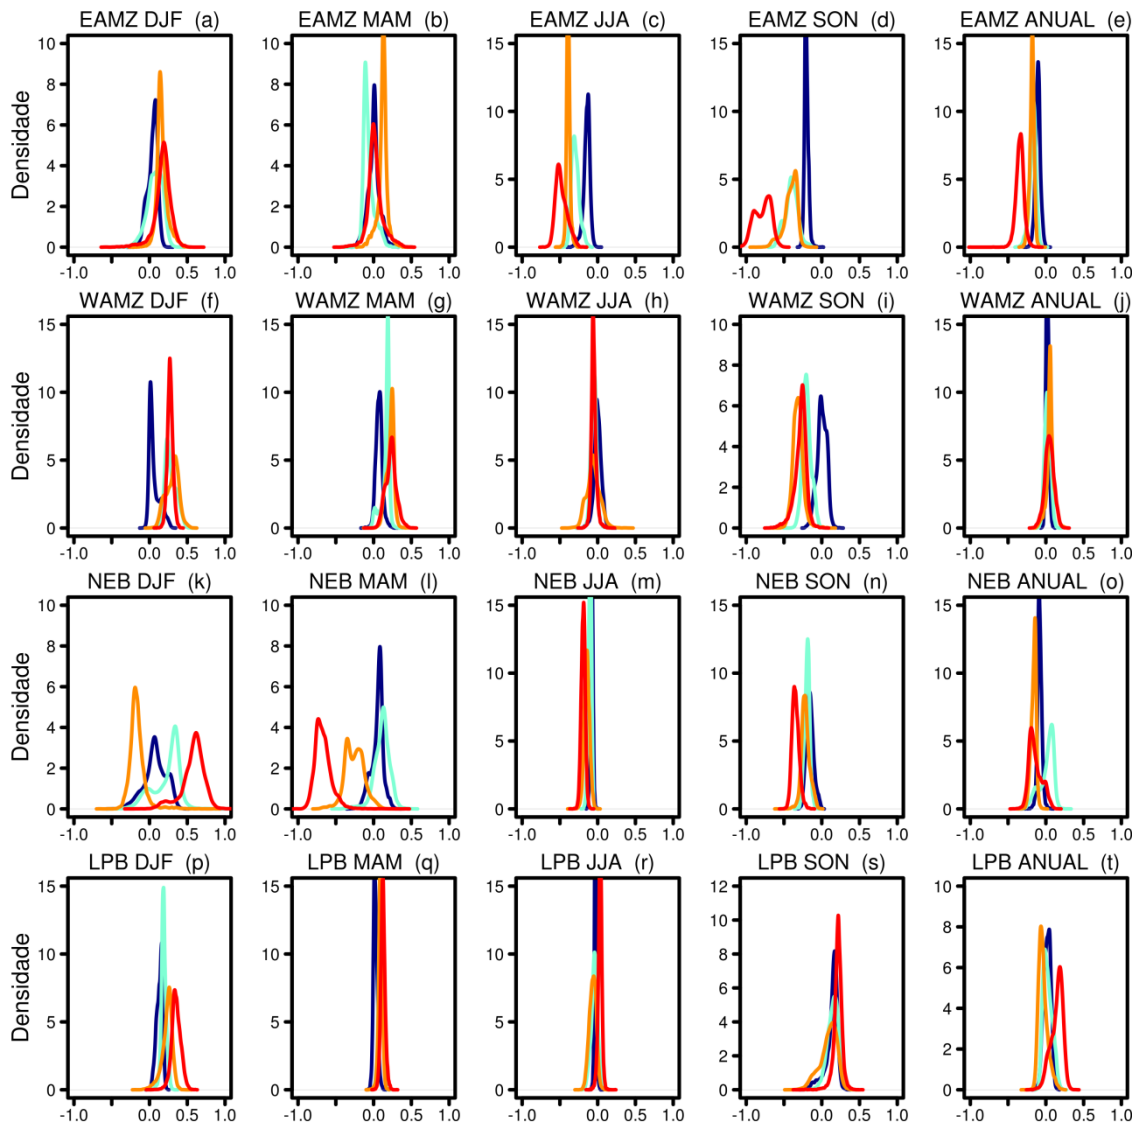


Figura 5.31 - Mesmo que Figura 5.30, exceto para precipitação ($\text{mm}\cdot\text{dia}^{-1}$).

Como constatado nas seções anteriores, as projeções do CMIP5 abrangem um intervalo maior de possíveis magnitudes de aquecimento, devido principalmente ao espectro mais amplo de forçantes climáticas (por exemplo, de 2.6 a $8.5 \text{ W}\cdot\text{m}^{-2}$), quando comparado às forçantes utilizadas no CMIP3. Este comportamento pode ser observado nas PDFs do CMIP3 e CMIP5 (Figuras 5.28 e 5.30), nas quais podemos identificar que as PDFs do CMIP5 se deslocam para regiões de maior magnitude de aquecimento, e abrangem o intervalo de 1 a 6°C para algumas sub-regiões (e.g., EAMZ e WAMZ). Adicionalmente, para as projeções de temperatura do conjunto CMIP3 (Figura 5.28) é possível observar

uma distinção clara entre as PDFs relativas aos diferentes cenários forçantes, no qual um aumento de concentração de GEE e aerossóis nos cenários (e.g., do SRES B1 para o A2) implica em um maior aquecimento. Este comportamento também é observado no conjunto CMIP5 (Figura 5.30), exceto pelo fato de que nos cenários forçantes RCP 4.5 e 6.0 as PDFs praticamente se sobrepõem umas às outras, o que pode ser talvez atribuído a menor diferença entre esses cenários forçantes ($1,5 \text{ W.m}^{-2}$). Por fim, as Tabelas 5.5 e 5.6 sintetizam os percentis das PDFs estimadas para mudanças de temperatura no verão e inverno austral para 2071-2100 nos conjuntos CMIP3 e CMIP5, e para os diversos cenários forçantes.

Analisando as PDFs relativas às mudanças de precipitação advindas dos conjuntos CMIP3 e CMIP5 (Figuras 5.29 e 5.31), constatamos que elas são predominantemente unimodais. Além disso, essas PDFs não demonstram uma relação clara entre a intensificação da forçante climática e um aumento ou redução de precipitação nas sub-regiões avaliadas. Exceção talvez possa ser feita no conjunto CMIP3 para as sub-regiões EAMZ em DJF e WAMZ em DJF e MAM, sobre as quais um leve aumento de precipitação é projetado, e esse aumento ligeiramente se amplifica na medida em que a forçante climática devido à emissão de GEEs e aerossóis se intensifica. Para o CMIP5, as exceções podem ser aplicadas às sub-regiões EAMZ (JJA e SON) e WAMZ (SON), que diferentemente do CMIP3, as PDFs indicam um decréscimo de precipitação que aumenta com a intensificação do cenário forçante. Por outro lado, no NEB, um aumento de precipitação é projetado em DJF, e uma redução em MAM, nos quais ambos aumentam de magnitude com a intensificação do cenário forçante. No geral, os aumentos/diminuições de precipitação não excedem em magnitude 1 mm.dia^{-1} , e muitas das distribuições estão centradas próximas ou sob o eixo de mudança nula.

As distribuições posteriores dos parâmetros de precisão de cada MCG (λ_i) pertencentes ao CMIP3 e CMIP5 relativos a precipitação e temperatura, e correspondentes aos cenários SRES A1B e RCP 4.5, são apresentados nas Figuras 5.32 a 5.35. A abcissa encontra-se em escala logarítmica devido ao alto grau de assimetria da distribuição desse parâmetro. O parâmetro λ_i é equivalente aos pesos atribuídos a cada modelo no método REA, exceto pelo fato de se tratar na inferência bayesiana de uma variável aleatória. Os

λ_i 's dos MCGs que possuem mediana menor do que 1 indicam que os resultados desses modelos são *downweighted* no cômputo da média final, enquanto que aqueles que possuem mediana maior do que 1 são *upweighted*. Nesse sentido, os λ_i 's foram organizados (ou ranqueados) de forma decrescente nas figuras mencionadas de acordo com o valor de sua mediana, e podem ser entendidos como um parâmetro de desempenho ou credibilidade de um determinado modelo em uma dada região, e para um determinado cenário forçante.

Como podemos notar claramente, os MCGs são ponderados diferentemente nas diversas regiões e estações. Ou seja, isto sugere diferentes destrezas em simular a climatologia regional observada, e um variado grau de consenso entre os MCGs para diferentes sinais regionais de mudanças climáticas. Por exemplo, relativo a precipitação, o modelo MRI-CGCM2.3.2 configura-se nesta metodologia como sendo o melhor modelo para as sub-regiões EAMZ e WAMZ em MAM, e como um dos piores em JJA para essas mesmas localidades no conjunto CMIP3 (Figura 5.33). Portanto, como enfatizado por Tebaldi et al. (2005), este fato realça a necessidade de avaliar os GCMs sobre várias regiões, tipos de clima, e variáveis, antes de atribuímos uma alta ou baixa confiabilidade neles. Nesse sentido, justifica-se a utilização do maior número possível de GCMs para uma dada análise de mudanças climáticas, e a aplicação de uma metodologia para ponderar diferentemente esses modelos para cada localidade e variável investigada, de forma análoga àquelas realizadas nesse estudo.

Tabela 5.5 – Percentis das PDFs estimadas para mudanças de temperatura (°C) no verão e inverno austral para 2071-2100 nos cenários SRES A2, A1B, e B1, obtidas com o método de inferência bayesiana aplicado ao conjunto CMIP3.

Região	Estação	SRES	Percentil				
			5%	25%	50%	75%	95%
EAMZ	DJF	A2	3,10	3,25	3,35	3,48	3,78
		A1B	2,41	2,48	2,55	2,65	2,92
		B1	1,70	1,86	2,07	2,17	2,28
	JJA	A2	3,92	4,12	4,21	4,36	4,47
		A1B	2,75	2,83	2,92	3,21	3,45
		B1	1,90	1,96	1,99	2,05	2,32
WAMZ	DJF	A2	3,15	3,21	3,25	3,31	3,47
		A1B	2,62	2,79	2,91	3,00	3,17
		B1	1,85	1,94	1,99	2,03	2,11
	JJA	A2	4,31	4,38	4,41	4,44	4,54
		A1B	3,20	3,39	3,48	3,63	3,94
		B1	2,21	2,38	2,59	2,78	2,94
NEB	DJF	A2	3,12	3,29	3,43	3,62	3,79
		A1B	2,42	2,51	2,65	2,88	3,07
		B1	1,83	1,97	2,06	2,15	2,28
	JJA	A2	3,11	3,20	3,24	3,29	3,41
		A1B	2,46	2,50	2,53	2,56	2,65
		B1	1,62	1,71	1,76	1,80	1,88
LPB	DJF	A2	3,08	3,35	3,45	3,52	3,60
		A1B	2,57	2,77	2,84	2,90	3,04
		B1	1,83	1,94	1,99	2,07	2,25
	JJA	A2	3,31	3,41	3,47	3,52	3,60
		A1B	2,75	2,92	3,00	3,05	3,13
		B1	1,83	1,89	1,95	2,08	2,21

Tabela 5.6 – Percentis das PDFs estimadas para mudanças de temperatura (°C) no verão e inverno austral para 2071-2100 nos cenários RCP 2.6, 4.5, 6.0, e 8.5, obtidas com o método de inferência bayesiana aplicado ao conjunto CMIP5.

Região	Estação	RCP	Percentil				
			5%	25%	50%	75%	95%
EAMZ	DJF	2.6	1,35	1,40	1,44	1,54	1,65
		4.5	2,23	2,46	2,57	2,64	2,76
		6.0	2,44	2,58	2,65	2,72	2,83
		8.5	4,16	4,34	4,48	4,64	4,86
	JJA	2.6	1,49	1,56	1,61	1,65	1,73
		4.5	2,60	2,80	2,87	2,95	3,13
		6.0	2,52	3,00	3,27	3,42	3,84
		8.5	5,03	5,19	5,26	5,35	5,50
WAMZ	DJF	2.6	1,46	1,51	1,55	1,58	1,64
		4.5	2,54	2,67	2,74	2,82	3,00
		6.0	2,06	2,18	2,32	2,60	2,91
		8.5	4,42	4,64	4,91	5,23	5,55
	JJA	2.6	1,49	1,55	1,58	1,61	1,68
		4.5	2,79	2,90	2,96	3,02	3,10
		6.0	2,67	2,93	3,07	3,18	3,42
		8.5	4,78	5,09	5,42	5,65	5,86
NEB	DJF	2.6	1,28	1,37	1,43	1,48	1,59
		4.5	1,92	2,22	2,35	2,44	2,54
		6.0	2,11	2,21	2,28	2,41	2,66
		8.5	3,52	3,66	3,78	3,92	4,12
	JJA	2.6	1,19	1,28	1,35	1,39	1,46
		4.5	1,95	2,16	2,37	2,45	2,52
		6.0	2,26	2,33	2,37	2,43	2,49
		8.5	3,45	3,55	3,62	3,70	3,83
LPB	DJF	2.6	1,11	1,23	1,34	1,43	1,54
		4.5	1,80	1,96	2,14	2,30	2,45
		6.0	2,00	2,14	2,24	2,36	2,59
		8.5	3,55	3,77	3,89	4,00	4,24
	JJA	2.6	1,02	1,09	1,16	1,27	1,41
		4.5	1,93	2,11	2,17	2,23	2,34
		6.0	2,05	2,12	2,20	2,51	3,14
		8.5	3,45	3,61	4,53	4,81	4,92

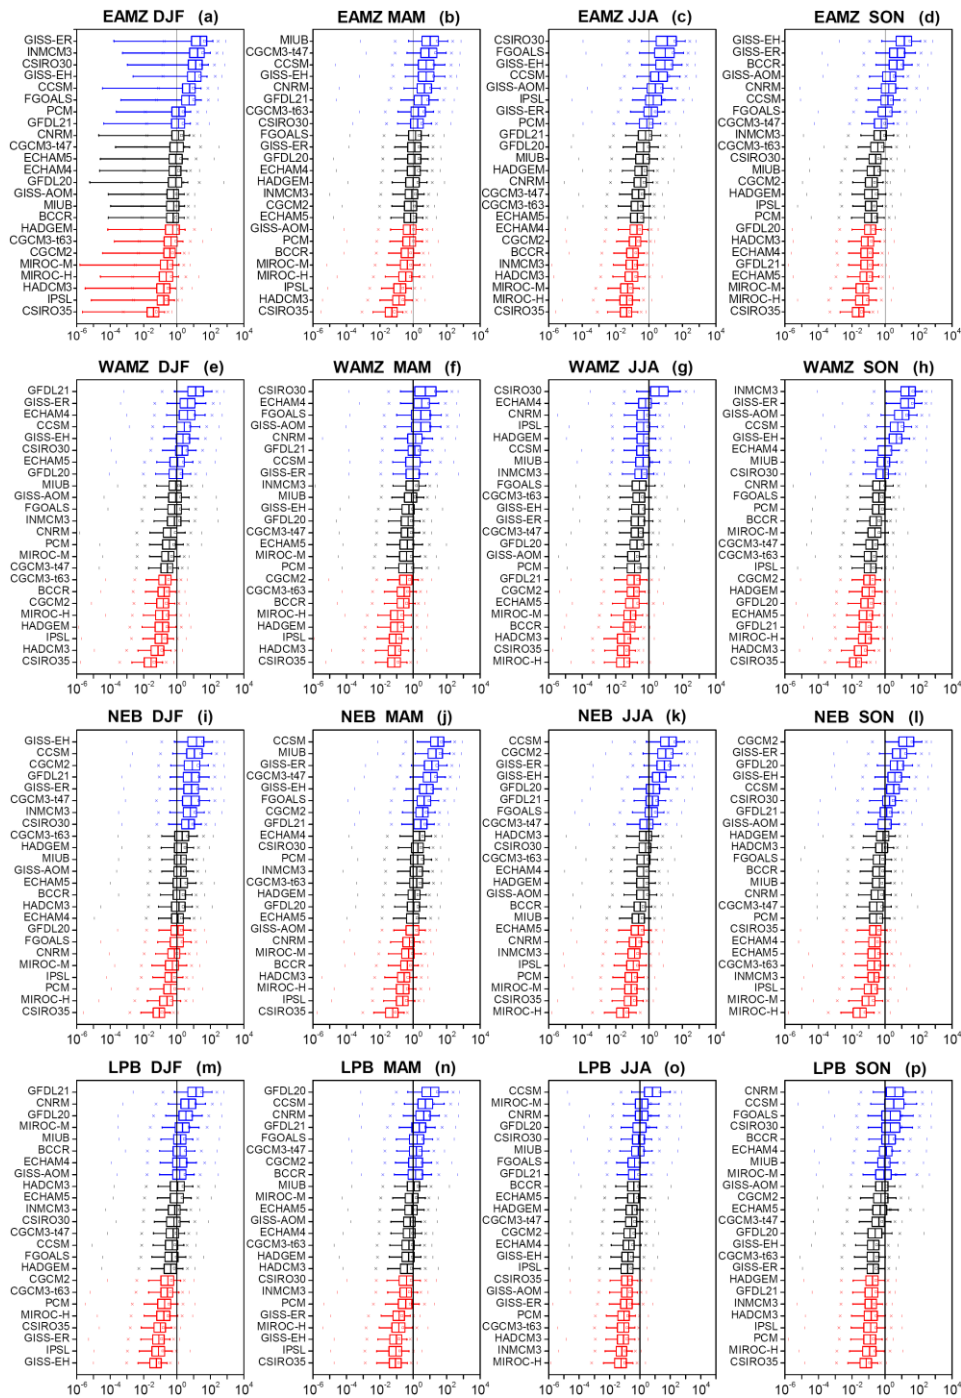


Figura 5.32 - Distribuição posterior dos parâmetros de precisão de cada MCG (λ_i) pertencentes ao CMIP3 e relativos à variável temperatura e o cenário SRES A1B, para cada uma das quatro sub-regiões de estudo analisadas, ordenados por sua mediana. As caixas azuis indicam os oito primeiros MCGs, as pretas os oito intermediários, e as vermelhas os oito últimos.

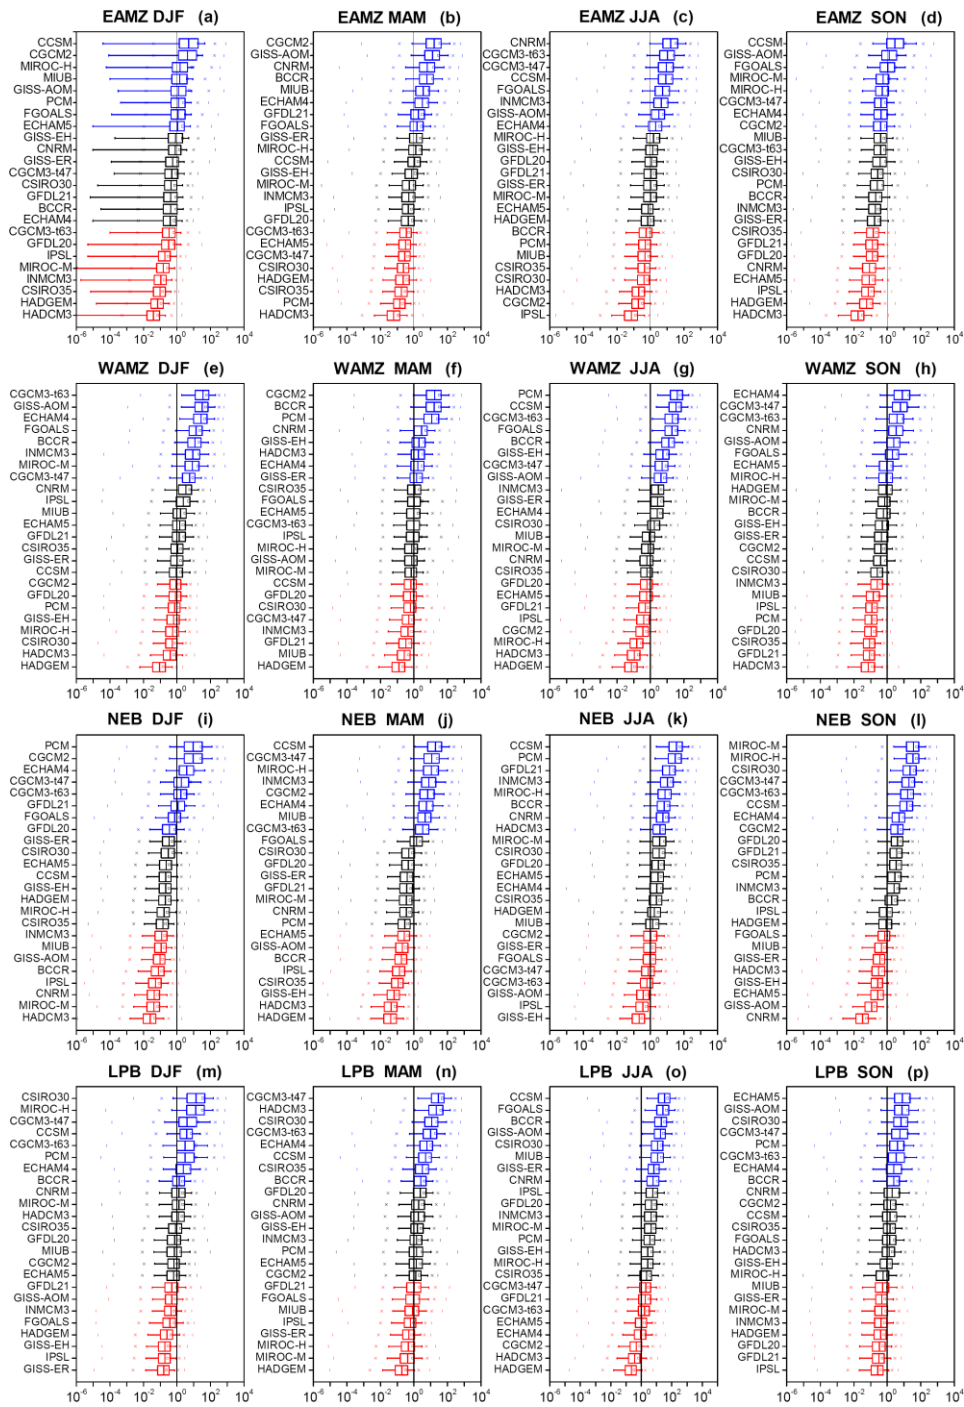


Figura 5.33 - Mesmo que Figura 5.32, exceto para precipitação.

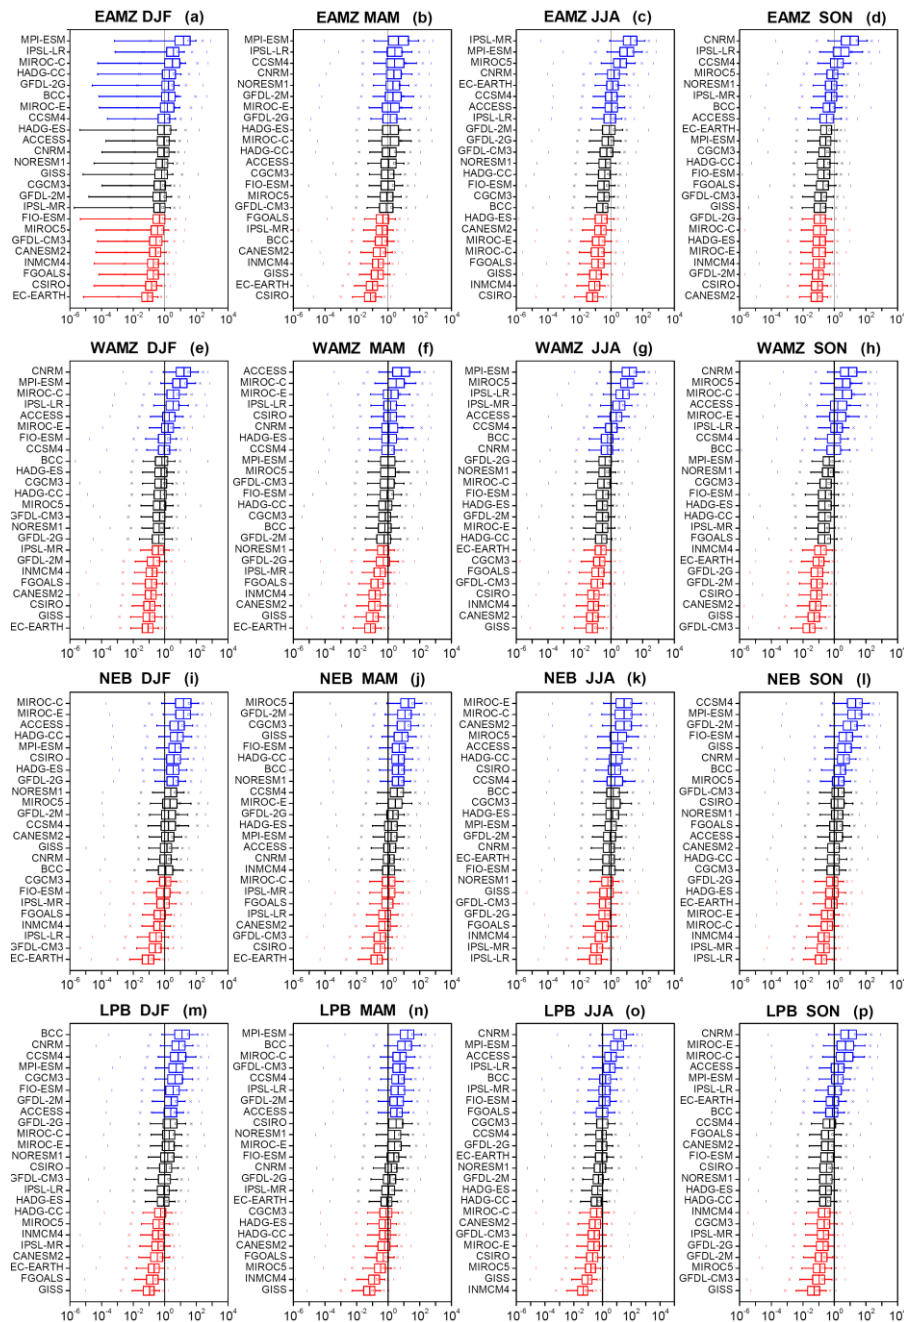


Figura 5.34 - Distribuição posterior dos parâmetros de precisão específicos de cada MCG (λ_i) pertencentes ao CMIP5 e relativos à variável temperatura e o cenário RCP 4.5, para cada uma das quatro sub-regiões de estudo analisadas, ordenados por sua mediana. As caixas azuis indicam os oito primeiros MCGs, as pretas os oito intermediários, e as vermelhas os oito últimos.

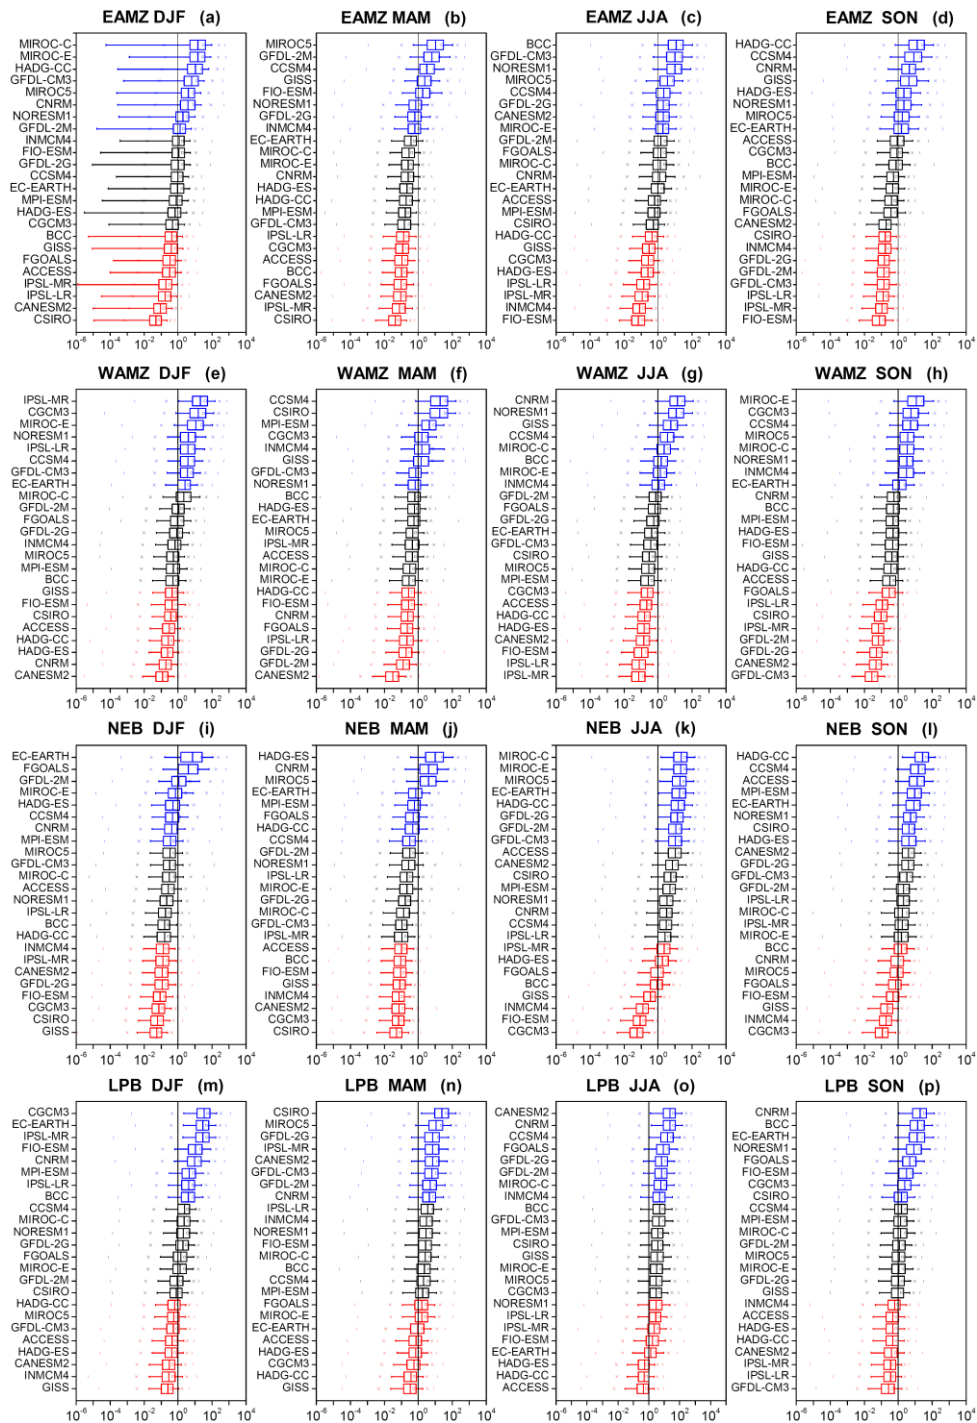


Figura 5.35 - Mesmo que Figura 5.34, exceto para precipitação.

6 IDENTIFICAÇÃO DE HOTSPOTS NA AMÉRICA DO SUL

Apesar das análises realizadas anteriormente possibilitarem um entendimento mais aprofundado sobre as incertezas envolvidas nas projeções de mudanças climáticas na América do Sul, assim como detalhar como essas incertezas se distribuem geograficamente, surge a difícil tarefa de sintetizar todas as informações provenientes de diversas análises e baseadas em uma ampla gama de experimentos, MCGs, e cenários de emissões, no intuito de transmitir esses resultados para outras áreas do conhecimento científico, assim como, para políticos e tomadores de decisão. As análises realizadas anteriormente são extremamente úteis, no entanto, o seu profundo entendimento torna-se quase que restrito a especialistas na área de climatologia.

Como mencionado anteriormente, uma possibilidade de atender essa necessidade de um breve panorama dos fatos científicos é a criação de índices de mudanças climáticas que agreguem diversas informações e estimativas de incertezas (GIORGI, 2006; BAETTIG et al., 2007; DIFFENBAUGH; GIORGI, 2012; TORRES et al., 2012). Nesse sentido, o índice climático *Regional Climate Change Index – RCCI* (GIORGI, 2006) descrito na seção 3.2.3 foi escolhido para sintetizar as inúmeras projeções avaliadas anteriormente.

Portanto, neste capítulo iremos aplicar o *RCCI* para toda América do Sul, utilizando todos os MCGs do CMIP3 e CMIP5 avaliados anteriormente. Uma vez que a geração desse índice envolve outras variáveis além da média sazonal de precipitação e temperatura, tais como mudanças na variabilidade interanual de precipitação e temperatura, o ponderamento dos MCGs utilizados anteriormente não poderão ser aplicados nesta metodologia. No entanto, iremos investigar a confiabilidade dos resultados ao aplicar diferentes conjuntos de projeções de mudanças climáticas como variáveis de entrada, e identificar os principais *hotspots* de mudanças climáticas que persistirem sobre a América do Sul, ou seja, identificar as possíveis localidades nas quais as mudanças climáticas podem ser mais exacerbadas.

A configuração espacial do *RCCI* com as projeções climáticas do CMIP3 para o final do século XXI sobre a América do Sul é apresentado na Figura 6.1a. É possível identificar a ocorrência de *hotspots* climáticos cobrindo toda a bacia Amazônica, noroeste da Amé-

rica do Sul, centro-oeste do Brasil, e oeste do Nordeste Brasileiro. Além disso, é possível identificar que os valores mais altos estão localizados sobre o noroeste do estado brasileiro de Mato Grosso. Valores intermediários podem ser identificados sobre a Bolívia, Chile, e nos estados brasileiros de Mato Grosso do Sul e norte de São Paulo. Por outro lado, valores baixos podem ser identificados sobre o oeste do Peru, Equador, Suriname, Guiana Francesa, Paraguai, Uruguai, por toda Argentina, nos estados brasileiros do Amapá, nordeste do Pará, sul de São Paulo, e em partes do Nordeste brasileiro (porções norte e leste) e região sul do Brasil (Figura 6.1a).

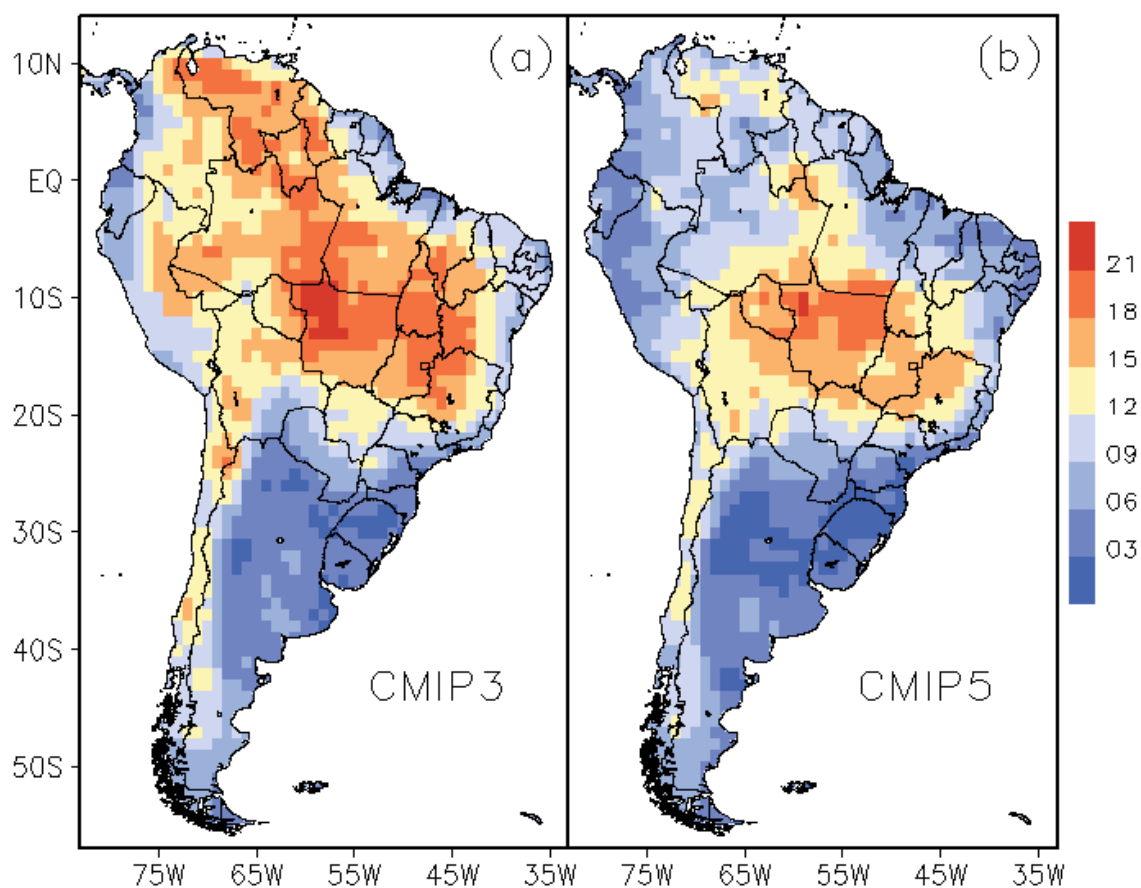


Figura 6.1 - *Regional Climate Change Index (RCCI)* para a América do Sul, utilizando as projeções climáticas dos MCGs dos conjuntos CMIP3 (a) e CMIP5 (b) para o final do século XXI. As unidades são adimensionais.

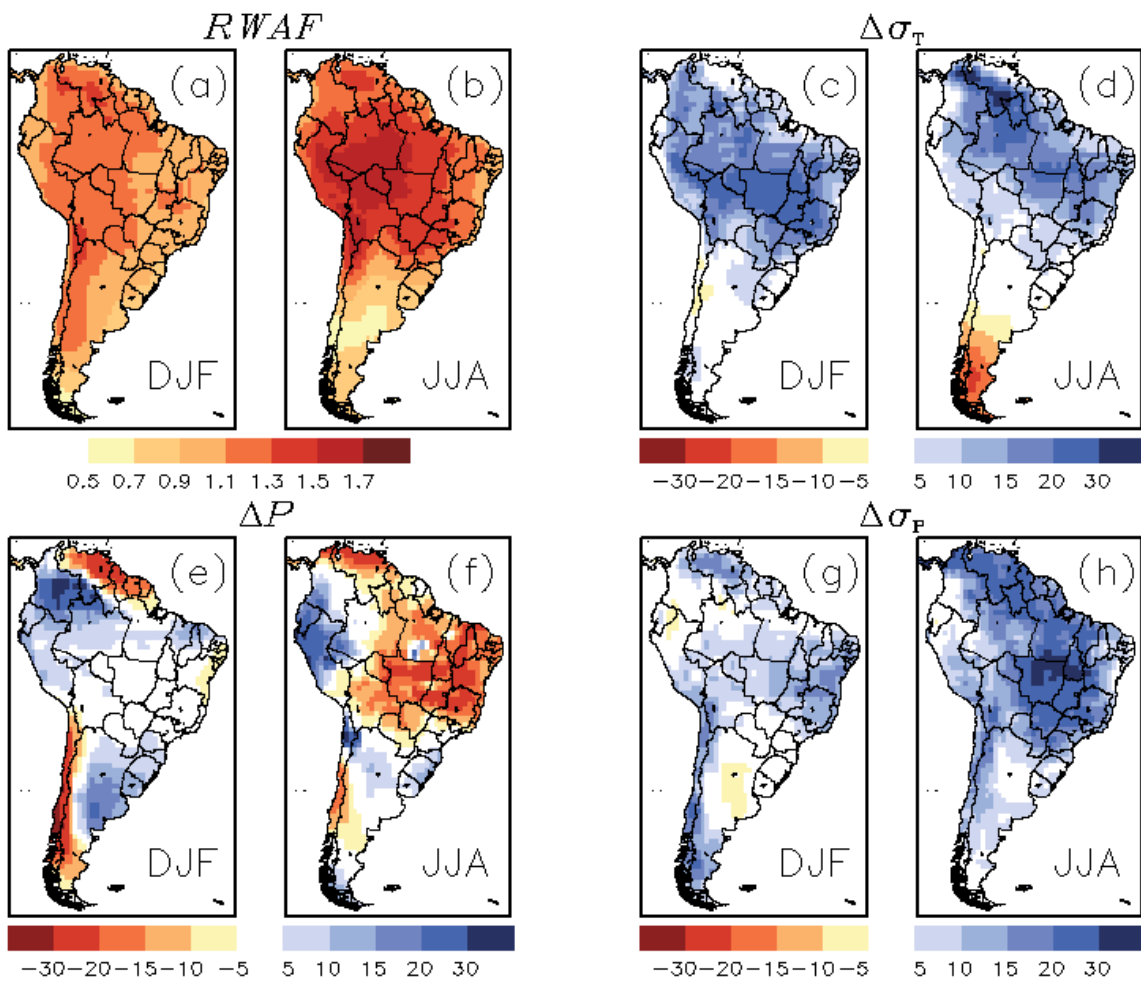


Figura 6.2 - As quatro componentes de mudanças climáticas utilizadas no cálculo do *RCCI* para as projeções advindas do conjunto CMIP3 para o final do século XXI: *Regional Warming Amplification Factor* (*RWAFF*, adimensional), mudança na precipitação sazonal média (ΔP , %), e mudança na variabilidade interanual de temperatura ($\Delta\sigma_T$, %) e precipitação ($\Delta\sigma_P$, %). Os resultados são apresentados para o verão e inverno austral (DJF e JJA, respectivamente). As porcentagens são relacionadas aos valores médios climatológicos de 1961-1990 tomados como referência.

Em geral, os valores altos indicados no mapa do *RCCI* com os dados do CMIP3 são devidos às projeções de aumento de temperatura durante o verão, mas principalmente durante o inverno austral, como pode ser identificado pelo *RWAFF* (Figura 6.2a, b), e também devido às projeções de aumento da variabilidade interanual de temperatura em

ambas as estações (Figura 6.2c, d), e mudança na precipitação sazonal e variabilidade interanual da precipitação durante o inverno austral (Figura 6.2f, h).

No intuito de avaliar as incertezas envolvidas nos *hotspots* climáticos extraídos do mapa de *RCCI* com o CMIP3, devido à escolha do conjunto de MCGs utilizado, o índice *RCCI* foi recalculado para o novo conjunto de MCGs pertencentes ao CMIP5 (Figuras 6.1b e 6.3). Entretanto, vale ressaltar que, como pode ser visto nas Tabelas 3.1 e 3.2, o conjunto CMIP5 não provê uma nova fonte independente de informação sobre mudanças climáticas, quando comparado com o CMIP3. Na verdade, a maioria dos MCGs integrantes do CMIP3 está presente no CMIP5, mas é claro, em uma nova e mais complexa e completa (*climate-comprehensive*) versão de representação do sistema climático (TAYLOR et al, 2012), e utilizando cenários de forçantes climáticas mais realistas e fisicamente plausíveis (MOSS et al., 2010). Portanto, nestas análises, será possível especular sobre as incertezas com relação às estruturas dos modelos e forçantes climáticas.

Analisando o mapa do *RCCI* gerado com o conjunto CMIP5 (Figura 6.1b), uma notável diferença aparece no noroeste da América do Sul e nos estados brasileiros do Maranhão, Piauí, e noroeste do Pará, quando comparado com os resultados do CMIP3 (Figura 6.1a). Por outro lado, fora das regiões supracitadas, o padrão de *RCCI* é bastante comparável entre os dois conjuntos multi-modelos, demonstrando consistência entre os resultados do CMIP3 e CMIP5. Uma vez que alguns estudos (assim como as análises realizadas neste estudo) tem identificado uma leve melhora na representação climatológica da América do Sul no CMIP5 (BLÁZQUEZ; NUÑEZ, 2013; JONES; CARVALHO, 2013), esta consistência entre as duas diferentes gerações de MCGs, juntamente com uma melhor representação das condições climáticas observadas no CMIP5, aumenta a confiabilidade dos resultados apresentados. O *RCCI* calculado com o CMIP5 designa Bolívia e principalmente o Brasil como aqueles países da América do Sul que possuem os mais intensos *hotspots* climáticos. No Brasil, os maiores valores de *RCCI* estão concentrados no sul da Amazônia, norte do Mato Grosso do Sul, e na porção oeste do estado de Minas Gerais.

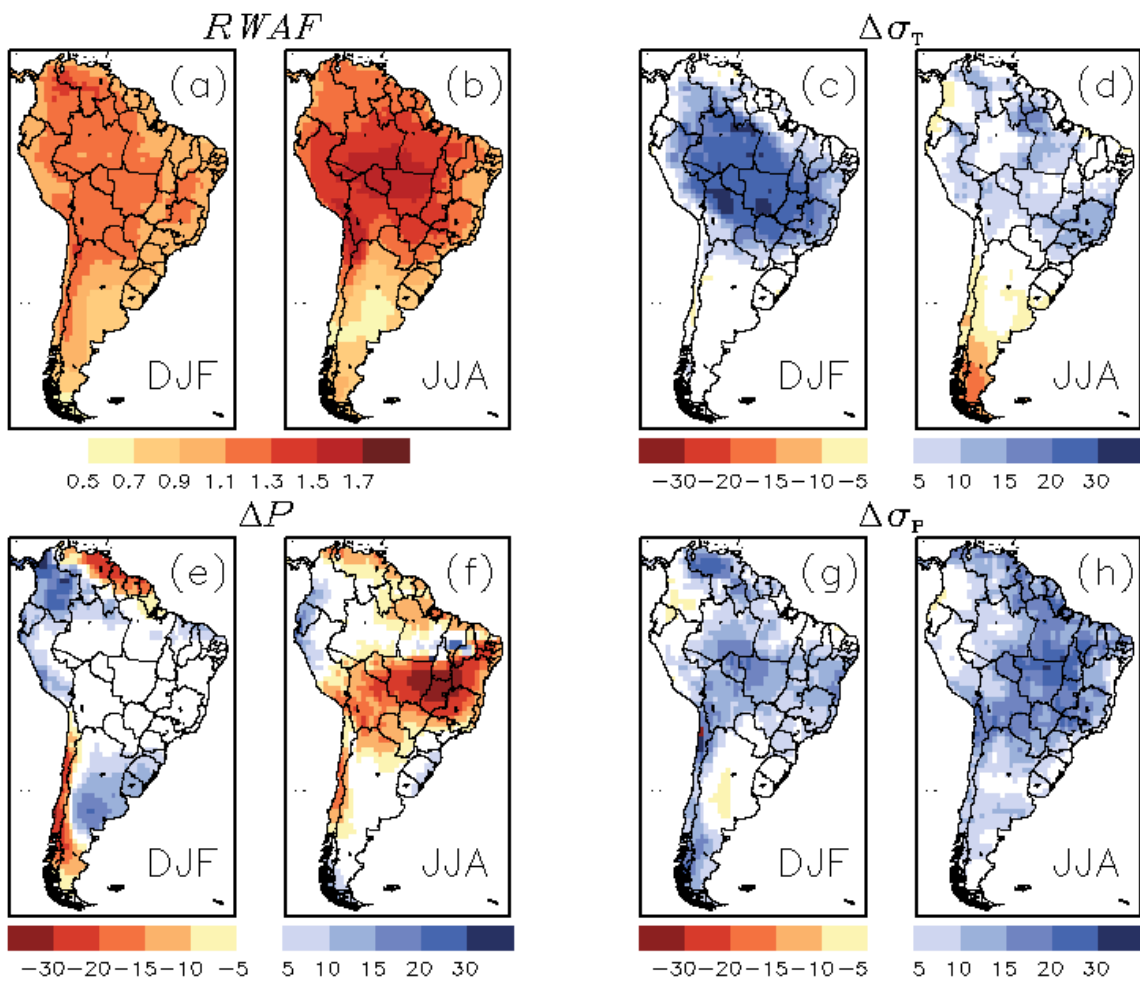


Figura 6.3 - Mesmo que Figura 6.4, exceto para o conjunto CMIP5.

Avaliando as quatro componentes de mudanças climáticas utilizadas no cálculo do *RCCI* com os dados do CMIP5 (Figura 6.3), e comparando com aqueles obtidos com o uso do CMIP3 (Figura 6.2), é possível notar que as distribuições espaciais das mudanças são bastante similares entre os dois conjuntos de dados. Em geral, as magnitudes das mudanças analisadas reduzem-se em quase toda a área de estudo, mais notável no noroeste da América do Sul. Uma exceção pode ser feita para as mudanças na variabilidade interanual de temperatura e precipitação no verão austral, em que um leve aumento no sinal da mudança pode ser observado (Figura 6.3c, g). Além disso, outro importante aspecto observado no novo conjunto de simulações dos MCGs é a intensificação das mudanças de temperatura (aumento de *RWAf*) no sul da bacia Amazônica (Figura 6.3b), e nas mudanças de precipitação (projeção de redução mais intensa de precipitação) na

região centro-oeste do Brasil (Figura 6.3f), quando comparado com a geração de modelos anterior.

Para avaliarmos a dependência dos *hotspots* com relação aos cenários forçantes, o *RCCI* foi recalculado para cada cenário separadamente, e os resultados podem ser avaliados na Figura 6.4. Como pode ser visto na Figura 6.4, o sul da Amazônia e as regiões centro-oeste e a parte oeste de Minas Gerais no Brasil são persistentes *hotspots* de mudanças climáticas para todos os diferentes cenários forçantes e conjuntos de MCGs, proporcionando dessa forma uma alta confiabilidade neste padrão projetado. Em geral, na medida em que os cenários variam do mais baixo ao mais alto nível de forçante (e.g., do cenário SRES B1 ao A2, ou do RCP 2.6 ao 8.5), as áreas de altos valores de *RCCI* aumentam e a magnitude intensifica-se do centro-oeste e sudeste do Brasil em direção ao noroeste da América do Sul (Figura 6.4). Além disso, a Figura 6.4a-c mostra que os intensos valores projetados no mapa do *RCCI* com o CMIP3 sobre o noroeste da América do Sul (Figura 6.1a) são grandemente influenciados pelo cenário SRES A2 (Figura 6.4a). Nos RCPs (Figura 6.4d-g), o único cenário em que algumas partes do noroeste da América do Sul aparecem como *hotspots* climáticos é o RCP 8.5. Além disso, curiosamente, a similaridade dos padrões de *RCCI* entre os cenários forçantes SRES A1B e RCP 8.5 (Figura 6.4b, d) é notável.

Na produção/elaboração dos cenários forçantes SRES e RCPs, nenhuma probabilidade é atribuída a eles (NAKICENOVIC et al., 2000; MOSS et al., 2010). Portanto, todos os padrões apresentados nas Figuras 6.1 e 6.4 podem ser entendidos como plausíveis. Todavia, atenção especial deve ser dada aos resultados do CMIP5, uma vez que no geral, os MCGs pertencentes a esse conjunto possuem resoluções horizontais mais altas e simulam o sistema climático de forma mais completa quando comparado com aqueles integrantes do CMIP3 (TAYLOR et al., 2012; SILLMANN et al., 2013a), o que pode resultar em simulações climáticas mais realistas. Por exemplo, como identificado no capítulo 4, o noroeste da América do Sul apresenta grandes vieses nas simulações sazonais médias e no ciclo anual da precipitação mensal nos MCGs do CMIP3, quando comparado com as observações (BOMBARDI; CARVALHO, 2009; TORRES; MARENGO, 2013). No entanto, aqueles vieses são levemente reduzidos nas simulações do

CMIP5 (JONES; CARVALHO, 2013), e isto pode ter contribuído para as diferenças entre os mapas do *RCCI* com o CMIP3 e CMIP5 sobre o noroeste da América do Sul, embora as diferenças nos cenários forçantes empregados em ambos os conjuntos multimodelos devem ter contribuído primordialmente para as diferenças nas projeções climáticas (KNUTTI; SEDLÁČEK, 2013).

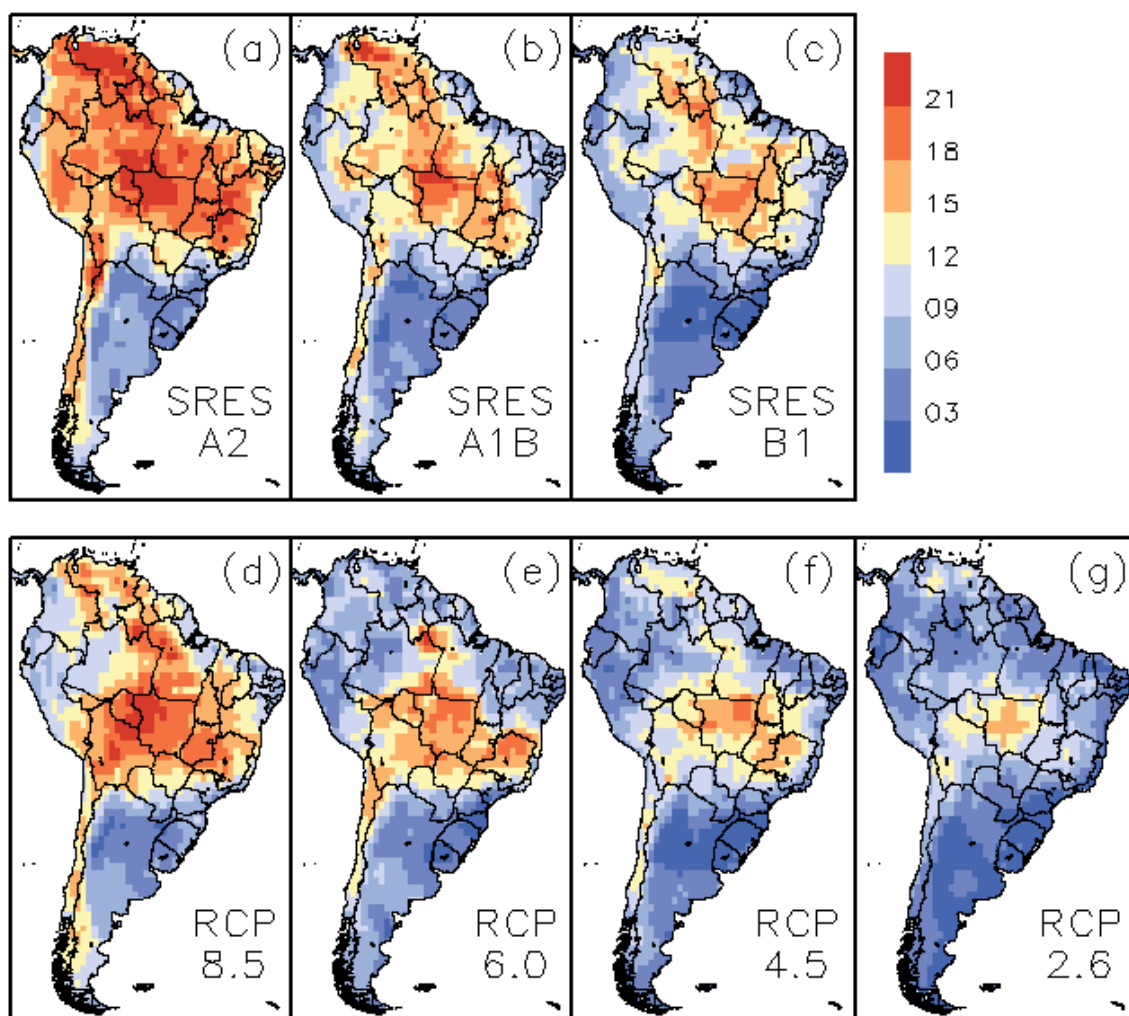


Figura 6.4 - *RCCI* calculado para a América do Sul, discriminando cada cenário forçante separadamente. Na parte superior encontram-se os mapas de *RCCI* computado para os cenários SRES A2 (a), A1B (b), e B1 (c) advindos do CMIP3, e na parte inferior, o *RCCI* para os cenários RCP 8.5 (d), 6.0 (e), 4.5 (f), e 2.6 (g) advindos do CMIP5. As unidades são adimensionais.

Sobre as regiões identificadas neste estudo como *hotspots* de mudanças climáticas, nomeadamente sul da Amazônia e centro-oeste e porção oeste do estado de Minas Gerais no Brasil, tanto as projeções de mudanças relacionadas à temperatura quanto precipitação contribuem quase que igualmente para os altos valores do *RCCI*. Apesar da inerente incerteza associada com as projeções de mudanças climáticas (GIORGI, 2005; KNUTTI et al., 2008), particularmente com relação à precipitação, boa parte dos MCGs analisados neste estudo apresentam bom desempenho em simular as condições climáticas observadas sobre aquelas regiões (TORRES; MARENGO, 2013; JONES; CARVALHO, 2013), e os MCGs concordam razoavelmente com o sinal e magnitude das mudanças projetadas nesta parte da América do Sul, o que aumenta a confiabilidade dos resultados. Entretanto, certamente as projeções de mudanças de precipitação (principalmente média zonal) deverão ser analisadas mais profundamente em estudos futuros, pois como vimos, elas contribuem significativamente para o *RCCI*, apesar de indicarmos no capítulo 5 que exista uma grande possibilidade de não haver uma mudança representativa na média sazonal para essa grandeza. Por outro lado, as projeções sazonais de mudanças de precipitação mostrados nas Figuras 6.2 e 6.3 estão extremamente coerentes com as análises de concordância realizadas nas Figuras 5.4 e 5.8, ou seja, as regiões cujas projeções de mudanças possuem uma magnitude maior estão localizadas exatamente aonde os modelos possuem um nível maior de concordância.

Um outro ponto que deve ser ressaltado é que os *hotspots* identificados nesse estudo dizem respeito somente aos aspectos climáticos, ou seja, apenas indicam as regiões aonde as mudanças climáticas podem ser mais intensas, relativamente à América do Sul como um todo. O *RCCI* não deve ser confundido como um índice de impacto ou vulnerabilidade. A identificação de vulnerabilidades em uma população envolve análises muito mais complexas e com uma resolução espacial extremamente alta (pouco quilômetros ou menos), e também deve levar em consideração diversos indicadores de vulnerabilidade social que não foram tratados aqui, tais como densidade populacional, IDH (índice de desenvolvimento humano), informações epidemiológicas, informações sobre susceptibilidade de um local a deslizamentos e enchentes, disponibilidade de água, entre outros (TORRES et al., 2012). Nesse sentido, o *RCCI* é útil, e deve ser usado como um

índice auxiliar nos debates de mudanças climáticas, e não como substituto de outros índices específicos de vulnerabilidade e impactos.

Finalmente, os *hotspots* climáticos identificados neste estudo são corroborados com alguns estudos encontrados na literatura. Por exemplo, o mapa de *RCCI* elaborado com o CMIP3 é comparável ao *Climate Change Index* desenvolvido por Baettig et al. (2007), embora utilizando diferentes conjuntos de MCGs e cenários forçantes. Além disso, os resultados do *RCCI* calculados com o CMIP5 são bastante comparáveis com o índice produzido por Diffenbaugh e Giorgi (2012) e computados com um subconjunto menor de MCGs e cenários forçantes do CMIP5. Adicionalmente, os resultados do *RCCI* são coerentes com estudos prévios de mudanças climáticas na América do Sul (MARENGO et al., 2010a,b; 2011, 2012; BLÁZQUEZ; NUÑEZ, 2013; CARVALHO; JONES, 2013; JONES; CARVALHO, 2013; TORRES; MARENGO, 2013).

7 CONSIDERAÇÕES FINAIS

7.1. Conclusões

Nas últimas décadas, a interferência antropogênica no sistema climático e as consequentes contribuições humanas às mudanças climáticas tornaram-se indubitáveis. Nesse sentido, inúmeros estudos têm sido produzidos para quantificar os impactos decorrentes dessas interferências, e para propor estratégias de mitigação e adaptação. Entretanto, uma vez que os processos que ocorrem no sistema climático não podem ser reproduzidos em laboratório, os cientistas baseiam-se na utilização de modelos climáticos para compreender o comportamento desse sistema quando da atuação de determinadas forçantes, e para projetar o clima do planeta no futuro. Entretanto, a sequência de etapas envolvidas na elaboração de projeções climáticas está sujeita a inúmeras incertezas que vão sendo agregadas paulatinamente ao processo.

Do ponto de vista somente das simulações e projeções com modelos climáticos, uma das maneiras mais comumente utilizadas para abranger o amplo espectro de incertezas envolvidas é a utilização de inúmeros modelos climáticos diferentes e diversos cenários forçantes. Por outro lado, extrair as informações mais úteis e estimar as incertezas envolvidas a partir de um grande número de simulações e projeções de modelos climáticos ainda continua sendo um grande desafio encontrado pela comunidade científica. Dessa forma, este estudo teve como objetivo avaliar a magnitude das incertezas envolvidas nas projeções de mudanças climáticas na América do Sul geradas por inúmeros modelos climáticos, e identificar como essas incertezas distribuem-se geograficamente, no intuito de fornecer subsídios importantes para os estudos de impacto, adaptação e vulnerabilidade desta região, tais como informações mais confiáveis, sintéticas, e probabilísticas. Especificamente, simulações e projeções de mudança de temperatura e precipitação sazonal sobre a América do Sul foram analisadas por meio da utilização de inúmeros MCGs pertencentes ao CMIP3 e CMIP5, totalizando 48 modelos e cerca de 450 experimentos (ou rodadas), abrangendo sete diferentes cenários forçantes: SRES B1, A1B, e A2; e RCP 2.6, 4.5, 6.0, e 8.5. Especial atenção foi dada naquelas projeções de mudanças para o final do século (2071-2100), com relação ao período de referência 1961-

1990, mas períodos intermediários também foram investigados. Por fim, três diferentes métodos foram utilizados para estimar as incertezas envolvidas nas projeções, e produzir resultados mais confiáveis e probabilísticos: método REA e método REA modificado, e inferência bayesiana.

Ao avaliarmos as simulações dos MCGs pertencentes tanto ao conjunto CMIP3 quanto ao CMIP5, constatamos que eles são capazes de representar bem os aspectos climatológicos básicos observados para as variáveis temperatura e precipitação, tais como média sazonal e ciclo anual, apesar de alguns vieses serem identificáveis, localizados principalmente sobre os Andes, noroeste da América do Sul, bacia Amazônica, e Nordeste brasileiro. Entretanto, os MCGs do CMIP5 apresentaram simulações mais próximas das observações quando comparado àqueles do CMIP3, tanto na média sazonal quanto no ciclo anual, principalmente para o noroeste da América do Sul, bacia Amazônica, e Nordeste brasileiro, aumentando a confiabilidade nos resultados gerados por esse novo conjunto de modelos.

Quando levando em consideração o desempenho de cada modelo em representar o clima observado e a convergência ou consistência de sua projeção com relação à média do conjunto, como proposto explicitamente pelo método REA e intrinsecamente pela inferência bayesiana, é notado que a média das projeções de mudança de temperatura decresce ligeiramente ($\sim 0,5^{\circ}\text{C} - 1^{\circ}\text{C}$) sobre todo o continente sul-americano, quando comparado à média aritmética simples dos modelos, tanto para o conjunto CMIP3 quanto para o CMIP5. Isso indica que resultados discrepantes dos MCGs são *downweighted* quando ponderando diferentemente os membros do conjunto. Esse mesmo comportamento foi também constatado quando excluindo o critério de convergência (REA modificado). Em geral, em todas as metodologias e conjuntos de MCGs avaliados constatou-se que as mudanças na magnitude de temperatura são maiores do que os intervalos de incerteza associados para toda América do Sul e nos diversos períodos e cenários forçantes, indicando uma alta confiabilidade nas projeções de mudanças para esta variável. Uma maior confiabilidade nos resultados produzidos foram encontrados sobre a bacia do Prata, enquanto que os maiores intervalos de incerteza foram notados sobre a bacia Amazônica.

Segundo o método REA, e avaliando as projeções do conjunto CMIP3 no cenário SRES A2 e as do CMIP5 no cenário RCP 8.5, a probabilidade de um aumento de temperatura que exceda 2°C em 2071-2100 é extremamente alta (> 90%) para todas as estações e para a América do Sul como um todo. Além disso, uma probabilidade considerável (> 50%) do aumento de temperatura exceder 4°C é encontrada sobre a faixa de latitudes entre 10°N – 25°S. Estas conclusões também são consistentes com as análises realizadas com o REA modificado e de inferência bayesiana. Adicionalmente, a faixa de latitudes entre 10°N – 25°S são as mesmas áreas indicadas por Fung et al. (2011) que podem experimentar um aumento no *stress* hídrico com um aumento de temperatura global de +2°C ou +4°C.

Quando aplicado à precipitação, todos os métodos não resultaram em padrões de mudanças de precipitação substancialmente diferentes daqueles obtidos com uma média aritmética simples dos modelos, tanto para o CMIP3 quanto para o CMIP5. Em geral, os intervalos de incerteza possuem magnitudes comparáveis ou maiores do que a das mudanças projetadas. Portanto, baseando-se nos conjuntos de MCGs e nas metodologias utilizadas, existe uma alta confiabilidade de uma projeção de mudanças na precipitação sazonal média substancialmente pequena ou inexistente sobre todo o continente sul-americano. Entretanto, estes resultados não se aplicam às projeções de extremos climáticos. A América do Sul tem experimentado um aumento na frequência de eventos extremos de precipitação e temperatura na última metade do século XX (MARENGO et al., 2010a; RUSTICUCCI et al., 2010; SILLMANN et al., 2013a), e muitos modelos climáticos projetam um aumento ainda maior na frequência de tais eventos até o final do século XXI (TEBALDI et al., 2006; MARENGO et al., 2009; SILLMANN et al., 2013b).

Na literatura, existem diversos métodos propostos para combinar as projeções advindas de conjuntos de inúmeros MCGs (tais como o CMIP3 e CMIP5), reduzir as incertezas, e estimar um intervalo para essas incertezas. Entretanto, nenhum deles tem-se demonstrado mais adequado ou mais confiável, ou ainda, amplamente aceito pela comunidade científica. Além disso, este tema está longe de ser trivial, como indicado por Knutti et al. (2010). O ponderamento de modelos, como aplicado no método REA e na inferência

bayesiana, impõe uma forte hipótese nas análises de mudanças climáticas quando explicitamente assume que o desempenho dos modelos climáticos no passado nos fornece certas garantias para o desempenho das projeções climáticas no futuro. Este assunto é amplamente debatido na comunidade científica, e até o momento, nenhum consenso tem sido alcançado. Além disso, na aplicação de todos os métodos utilizados, foi assumido que os MCGs fornecem informações independentes entre eles, de tal forma que, analogamente a uma variável aleatória, a média de todos se aproxima grandemente do valor esperado para aquela variável. No entanto, os conjuntos CMIP3 e CMIP5 são conhecidos como “*ensembles of opportunity*”, no sentido de que eles não são delineados (pelo menos na prática) para cobrir exatamente todo o intervalo de incerteza possível. De fato, muitos deles são versões do mesmo modelo ou compartilham muitas partes do código computacional, referentes, por exemplo, a esquemas de convecção, radiação, etc. O método REA (e REA modificado) e o método de inferência bayesiana foram escolhidos por sua simplicidade e pelos vários tipos de informações que eles podem fornecer. Nesse sentido outras metodologias devem ser também aplicadas para comparar esses resultados.

Em adição, este estudo também visou à identificação de possíveis *hotspots* de mudanças climáticas sobre a América do Sul através da verificação dos padrões espaciais impostos pelo índice *RCCI* sobre a região para o final do século XXI. A confiabilidade e as incertezas dos resultados foram avaliadas ao utilizarmos os inúmeros MCGs e forçantes climáticas dos conjuntos CMIP3 e CMIP5. O sul da Amazônia, o centro-oeste e a porção oeste do estado de Minas Gerais no Brasil configuram-se como persistentes *hotspots* de mudanças climáticas em todos os diferentes cenários forçantes e conjuntos de MCGs utilizados, o que provê uma alta confiabilidade neste padrão projetado. Além disso, na medida em que os cenários variam do mais baixo ao mais alto nível de forçante (como por exemplo, do RCP 2.6 ao RCP 8.5), a distribuição espacial de altos valores do índice *RCCI* aumenta e a magnitude intensifica-se do centro-oeste/sudeste do Brasil em direção ao noroeste da América do Sul. Em geral, os *hotspots* são caracterizados por um aumento da temperatura, principalmente no inverno, por um aumento na variabilidade

interanual de temperatura, predominantemente no verão, e por uma mudança na precipitação sazonal média e na variabilidade interanual durante o inverno.

Entretanto, as regiões que não foram classificadas como *hotspots* climáticos neste estudo não podem ser negligenciadas. Áreas que exibem valores relativamente baixos do índice *RCCI*, tais como o sul da América do Sul, podem ainda ser vulneráveis a outros “estressores climáticos” não incluídos aqui, tais como extremos climáticos (TEBALDI et al., 2006; IPCC 2012; DONAT et al., 2013; SILLMANN et al., 2013a, b). Além disso, conforme também identificado neste estudo, o desempenho dos MCGs em regiões de topografia complexa, tais como sobre a cordilheira dos Andes, ainda é extremamente baixo. Os Andes já experimentam mudanças nos regimes de temperatura e precipitação, e certamente é vulnerável às mudanças climáticas futuras (HERZOG et al., 2011), embora o índice *RCCI* não pôde apropriadamente identificar esta região como um *hotspot* climático. Além disso, quando agregando as informações climáticas com informações de vulnerabilidade local das populações, em uma forma mais relevante as análises de vulnerabilidade social, a designação daquelas áreas potencialmente mais afetadas pelas mudanças climáticas podem ser bastante diferentes (TORRES et al., 2012). Portanto, as distribuições espaciais do índice *RCCI* devem ser utilizadas e interpretadas como uma informação auxiliar nos debates de mudanças climáticas entre cientistas de diferentes áreas e tomadores de decisão.

Finalmente, as duas principais novidades e contribuições desse estudo foram: 1) abordar pela primeira vez, explicitamente e de forma mais pormenorizada, as incertezas envolvidas nas projeções de mudanças climáticas na América do Sul; e 2) produzir informações sumarizadas e probabilísticas sobre as possíveis mudanças climáticas que poderão ser enfrentadas na América do Sul até o final desse século, de uma forma mais adequada para estudos de impacto, adaptação, e vulnerabilidade.

7.2. Sugestões para trabalhos futuros

Como sugestão para trabalhos futuros, duas vertentes podem ser investigadas para entender o presente estudo:

- 1) Avaliar e comparar os resultados obtidos neste estudo com as mesmas metodologias aplicadas a um conjunto de vários modelos regionais, tais como aqueles produzidos no projeto Claris-LPB (BOULANGER et al., 2010);
- 2) E investigar as incertezas referentes a extremos climáticos.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADLER, R. F. et al. The version-2 global precipitation climatology project (GPCP) monthly precipitation analysis (1979-present). **Journal of Hydrometeorology**, v. 4, p. 1147-1167, 2003.
- ALLAN, R.; ANSELL, T. A new globally complete monthly historical gridded mean sea level pressure dataset (HadSLP2): 1850–2004. **Journal of Climate**, v. 19, p. 5816–5842, 2006.
- 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.
- ANNAN, J. D., HARGREAVES, J. C. Reliability of the CMIP3 ensemble. **Geophysical Research Letters**, v. 37, L02703, 2010.
- BAETTIG, M. B.; WILD, M.; IMBODEN, D. M. A climate change index: Where climate change may be most prominent in the 21st century. **Geophysical Research Letters**, v. 34, p. L01705, 2007.
- BETTS, R. A.; COLLINS, M.; HEMMING, D. L.; JONES, C. D.; LOWE, J. A.; SANDERSON, M. G. When could global warming reach 4 C?. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 369, n. 1934, p. 67-84, 2011.
- BIDEGAIN, M.; CORONEL, G.; RÍOS, N.; SANTOS, B. Escenarios climáticos futuros para Paraguay. **Meteorologica**, v. 37, n. 2, p. 47-55, 2012.
- 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.
- BOMBARDI, R. J.; CARVALHO, L. M. V. IPCC Global coupled climate model simulations of the South America Monsoon System. **Climate Dynamics**, v. 33, p. 893-916, 2009.
- BOULANGER, J. P.; MARTINEZ, F.; SEGURA, E. C. Projection of future climate change conditions using IPCC simulations, neural networks and Bayesian statistics. Part 1: temperature mean state and seasonal cycle in South America. **Climate Dynamics**, v. 27, p. 233–259, 2006.

BOULANGER, J. P.; MARTINEZ, F.; SEGURA, E. C. Projection of future climate change conditions using IPCC simulations, neural networks and Bayesian statistics. Part 2: precipitation mean state and seasonal cycle in South America. **Climate Dynamics**, v. 28, p. 255–271, 2007.

BOULANGER, J. P.; BRASSEUR, G.; CARRIL, A. F.; CASTRO, M.; DEGALLIER, N.; EREÑO, C.; TREUT, H. L.; MARENGO, J. A.; MENENDEZ, G.; NUÑEZ, M. N.; PENALBA, O. C.; ROLLA, A. L.; RUSTICUCCI, M.; TERRA, R. A. A Europe-South America network for climate change assessment and impact studies. **Climatic Change**, v. 98, p. 307-329, 2010.

CHOU, S. C.; MARENGO, J. A.; LYRA, A.; SUEIRO, G.; PESQUERO, J.; ALVES, L. M.; KAY, G.; BETTS, R.; CHAGAS, D.; GOMES, J.; BUSTAMANTE, J. Downscaling of South America present climate driven by 4-member HadCM3 runs. **Climate Dynamics**, v. 38, p. 635-653, 2012.

CHRISTENSEN, J. H.; CARTER, T. R.; RUMMUKAINEN, M.; AMANATIDIS, G. Evaluating the performance and utility of regional climate models: the PRUDENCE project. **Climatic Change**, v. 81, p. 1-6, 2007a.

CHRISTENSEN, J. H.; HEWITSON, B.; BUSUIOC, A.; CHEN, A.; GAO, X.; HELD, I.; JONES, R.; KOLLI, R. K.; KWON, W.-T.; LAPRISE, R.; MAGAÑA RUEDA, V.; MEARNS, L.; MENÉNDEZ, C. G.; RÄISÄNEN, J.; RINKE, A.; SARR, A.; WHETTTON, P. Regional Climate Projections. In: SOLOMON, S.; QIN, D.; MANNING, M.; CHEN, Z.; MARQUIS, M.; AVERYT, K. B.; TIGNOR, M.; MILLER, H. L. (eds.). **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 University Press, Cambridge, United Kingdom and New York, NY, USA, 2007b.

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.

DIFFENBAUGH, N. S.; GIORGI, F.; RAYMOND, L.; BI, X. Indicators of 21st century socioclimatic exposure. **Proceedings of the National Academy of Sciences**, v. 104, p. 20195-20198, 2007.

DIFFENBAUGH, N. S.; GIORGI, F.; PAL, J. S. Climate change hotspots in the United States. **Geophysical Research Letters**, v. 35, p. L16709, 2008.

DIFFENBAUGH, N. S.; GIORGI, F. Climate change hotspots in the CMIP5 global climate model ensemble. **Climatic Change**, v. 114, p. 813-822, 2012.

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

DOYLE, M. E.; BARROS, V. R. Midsummer low-level circulation and precipitation in subtropical South America and related sea surface temperature anomalies in the South Atlantic. **Journal of Climate**, v. 15, p. 3394–3410, 2002.

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.

FUNG, F.; LOPEZ, A.; NEW, M. Water availability in +2 C and +4 C worlds. **Philosophical transactions of the Royal Society A: mathematical, physical and engineering sciences**, v. 369, n. 1934, p. 99-116, 2011.

FURRER, R.; SAIN, S. R.; NYCHKA, D.; MEEHL, G. A. Multivariate Bayesian analysis of atmosphere–ocean general circulation models. **Environmental and Ecological Statistics**, v. 14, p. 249–266, 2007.

GIORGI, F.; FRANCISCO, R. Evaluating uncertainties in the prediction of regional climate change. **Geophysical Research Letters**, v. 27, p. 1295–1298, 2000.

GIORGI, F.; BI, X. Q. Updated regional precipitation and temperature changes for the 21st century from ensembles of recent AOGCM simulations. **Geophysical Research Letters**, v. 32, p. L21715, 2005.

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.; MEARNNS, L. O. Probability of regional climate change calculated using the Reliability Ensemble Averaging (REA) method. **Geophysical Research Letters**, v. 30, n.12, p. 1629, 2003.

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

GIORGI, F. Climate change hot-spots. **Geophysical Research Letters**, v. 33, p. L08707, 2006.

GIORGI, F. A simple equation for regional climate change and associated uncertainties. **Journal of Climate**, v. 21, p. 1589-1604, 2008.

- GREENE, A. M.; GODDARD, L.; UPMANU, L. Probabilistic multi-model regional temperature change projections. **Journal of Climate**, v. 19, p. 4326-4343, 2006.
- GULIZIA, C.; CAMILLONI, I.; DOYLE, M. Identification of the principal patterns of summer moisture transport in South America and their representation by WCRP/CMIP3 global climate models. **Theoretical and Applied Climatology**, v. 112, p. 227–241, 2013.
- HARRIS, I.; JONES, P. D.; OSBORN, T. J.; LISTER, D. H. Updated high-resolution grids of monthly climatic observations – the CRU TS3.10 Dataset. **International Journal of Climatology**, 2013.
- HEGERL, G. C.; ZWIERS, F. W.; BRACONNOT, P.; GILLETT, N. P.; LUO, Y.; MARENGO, J. A.; NICHOLLS, N.; PENNER, J. E.; STOTT, P. A. Understanding and Attributing Climate Change. In: SOLOMON, S.; QIN, D.; MAMMING, M.; CHEN, Z.; MARQUIS, M.; AVERYT, K. B.; TIGNOR, M.; MILLER, H. L. (eds.). **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 University Press, Cambridge, United Kingdom and New York, NY, USA, 2007.
- HERZOG, S. K.; MARTÍNEZ, R.; JORGENSEN, P. M.; TIESSEN, H. **Climate change and biodiversity in the tropical Andes**. Inter-American Institute for Global Change Research (IAI) and Scientific Committee on Problems of the Environment (SCOPE), 348 pp, 2011. Disponível em: www.iai.int/index.php?option=com_content&view=article&id=118&Itemid=73. Acessado em 15 de Junho de 2013.
- HEWITSON, B. C., CRANE, R. G. Consensus between GCM climate change projections with empirical downscaling: precipitation downscaling over South Africa. **International Journal of Climatology**, v. 26, p. 1315–1337, 2006.
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Climate change 2001, the scientific basis, summary for policymakers**. Cambridge University Press, Cambridge, U.K., 20 p., 2001.
- 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. (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2007.
- 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.; 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. (eds.)]. Cambridge University Press, Cambridge, 582 p., 2012.

IPCC. Summary for Policymakers. In: **Climate change 2013: the physical science basis**. Contribution of working group I to the fifth assessment report of the intergovernmental panel on climate change. Disponível em:

http://www.climatechange2013.org/images/uploads/WGIAR5-SPM_Approved27Sep2013.pdf. Acesso em 05.10.2013.

JOETZJER, E.; DOUVILLE, H.; DELIRE, C.; CIAIS, P. Present-day and future Amazonian precipitation in global climate models: CMIP5 versus CMIP3. **Climate Dynamics**, p. 1-16, 2013.

JONES, P. W. First- and Second-Order Conservative Remapping Schemes for Grids in Spherical Coordinates. **Monthly Weather Review**, v. 127, p. 2204-2210, 1999.

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

JUNQUAS, C.; VERA, C.; LI, L.; LE TREUT, H. Summer precipitation variability over Southeastern South America in a global warming scenario. **Climate Dynamics**, v. 38, p. 1867–1883, 2012.

KIM, H. J.; WANG, B.; DING, Q. The Global Monsoon Variability Simulated by CMIP3 Coupled Climate Models. **Journal of Climate**, v. 21, p. 5271-5294, 2008.

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.

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

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

LI, J.; LIN, X.; CHEN, A.; PETERSON, T.; MA, K.; BERTZKY, M.; CIAIS, P.; KAPOV, V.; PENG, C.; POULTER, B. (2013) Global Priority Conservation Areas in the Face of 21st Century Climate Change. **PLoS ONE**, v. 8, p. e54839, 2013.

LIEBMANN, B.; MARENGO, J. A. Interannual variability of the rainy season and rainfall in the Brazilian Amazon Basin. **Journal of Climate**, v. 14, p. 4308-4318, 2001.

LIN, J-L. The Double-ITCZ Problem in IPCC AR4 Coupled GCMs: Ocean-Atmosphere Feedback Analysis. **Journal of Climate**, v. 20, p. 4497-4525, 2007.

MARENGO, J. A.; JONES, R.; ALVES, L. M.; VALVERDE, M. Future change of temperature and precipitation extremes in South America as derived from the PRECIS regional climate modeling system. **International Journal of Climatology**, v. 30, p. 1-15, 2009.

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.; NOBRE, C. A.; CHOU, S. H.; TOMASELLA, J.; SAMPAIO, G.; ALVES, L. M.; OBREGÓN, G. O.; SOARES, W. R.; BETTS, R.; KAY, G. Dangerous Climate Change. A Brazil-UK analysis of climate change and deforestation impacts in the Amazon. 2011, 55 p. Disponível em: <http://mudancasclimaticas.cptec.inpe.br/~rmclima/pdfs/destaques/relatorio_ingl.pdf>. Acesso em: 31 agosto 2013.

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

MASSON, D.; KNUTTI, R. Climate model genealogy. **Geophysical Research Letters**, v. 38, L08703, 2011.

MAY, W. Assessing the strength of regional changes in near-surface climate associated with a global warming of 2° C. **Climatic Change**, v. 110, p. 619-644, 2012.

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. (eds.), **Climate change 2001: the scientific basis**. Capítulo 13, Contribution of Working Group I to the Third Assessment Report of the Intergovernmental Panel on Climate Change (IPCC), Cambridge University Press, Cambridge, UK, p. 739–768, 2001.

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: **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. (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2007a.

MEEHL, G. A.; COVEY, C.; DELWORTH, T.; MOJIB, L.; MCAVANEY, B.; MITCHELL, J. F. B.; STOUFFER, R. J.; TAYLOR, K. E. The WCRP CMIP3 multi-model dataset: a new era in climate change research. **Bulletin of the American Meteorological Society** 88, 1383–1394, 2007b.

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.

MURPHY, J. M.; SEXTON, D. M. H.; BARNETT, D. N.; JONES, G. S.; WEBB, M. J.; COLLINS, M.; STAINFORTH, D. A. Quantification of modelling uncertainties in a large ensemble of climate change simulations. **Nature**, v. 430, p. 768–772, 2004.

MURPHY, J. M.; BOOTH, B. B. B.; COLLINS, M.; HARRIS, G. R.; SEXTON, D. M. H.; WEBB, M. J. A methodology for probabilistic predictions of regional climate change from perturbed physics ensembles. **Philosophical Transactions of the Royal Society A**, v. 365, p. 1993-2028, 2007.

NAKICENOVIC, N.; ALCAMO, J.; DAVIS, G.; DE VRIES, B.; FENHANN, J.; GAFFIN, S.; GREGORY, K.; GRUBLER, A.; JUNG, T. Y.; KRAM, T.; LA ROVERE, E. L.; MICHAELIS, L.; MORI, S.; MORITA, T.; PEPPER, W.; PITCHER, H.; PRICE, L.; RIAHI, K.; ROEHL, A.; ROGNER, H. H.; SANKOVSKI, A.; SCHLESINGER, M.; SHUKLA, P.; SMITH, S.; SWART, R.; VAN ROOIJEN, S.; VICTOR, N.; DADI, Z. **Special report on emissions scenarios**, Cambridge University Press, UK, 2000.

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.

NUÑEZ, M. N.; SOLMAN, S. A.; CABRÉ, M. F. Regional climate change experiments over southern South America. II: Climate change scenarios in the late twenty-first century. **Climate Dynamics** v. 32, p. 1081-1095, 2008.

- OSORIO, G. J. D.; GALIANO, G. S. G. Building hazard maps of extreme daily rainy events from PDF ensemble, via REA method, on Senegal River Basin. **Hydrology and Earth System Sciences**, v. 15, n. 11, p. 3605-3615, 2011.
- OSORIO, G. J. D.; GALIANO, G. S. G. Assessing uncertainties in the building of ensemble RCMs over Spain based on dry spell lengths probability density functions. **Climate Dynamics**, p. 1-20, 2013.
- PRESTON, B. L.; YUEN, E. J.; WESTAWAY, R. M. Putting vulnerability to climate change on the map: a review of approaches, benefits, and risks. **Sustainability Science**, v. 6, p. 177-202, 2011.
- RÄISÄNEN, J. CO₂-induced changes in interannual temperature and precipitation variability in 19 CMIP2 experiments. **Journal of Climate**, v. 15, p. 2395-2411, 2002.
- RÄISÄNEN, J. How reliable are climate models?. **Tellus**, v. 59, p. 2 - 29, 2007.
- RÄISÄNEN, J.; RUOKOLAINEN, L.; YLHÄISI, J. Weighting of model results for improving best estimates of climate change. **Climate dynamics**, v. 35, n. 2-3, p. 407-422, 2010.
- RANDALL, D. A.; WOOD, R. A.; BONY, S.; COLMAN, R.; FICHEFET, T.; FYFE, J.; KATSOV, V.; PITMAN, A.; SHUKLA, J.; SRINIVASAN, J.; STOUFFER, R. J.; SUMI, A.; TAYLOR, K. E. Climate Models and Their Evaluation. 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.; MANNING, M.; CHEN, Z.; MARQUIS, M.; AVERYT, K. B.; TIGNOR, M.; MILLER, H. L. (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2007.
- RAO, V. B.; LIMA, M. C.; FRANCHITO, S. H. Seasonal and interannual variations of rainfall over eastern northeast Brazil. **Journal of Climate**, v. 6, p. 1754-1763, 1993.
- RUSTICUCCI, 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.
- SETH, A.; ROJAS, M.; RAUSCHER, S. A. CMIP3 projected changes in the annual cycle of the South American Monsoon. **Climatic Change**, v. 98, p. 331-357, 2010.
- 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.

- STOTT, P.A.; GILLETT, N. P.; HEGERL, G. C.; KAROLY, D. J.; STONE, A.; ZHANG, X.; ZWIERS, F. Detection and attribution of climate change: a regional perspective. **Wiley Interdisciplinary Reviews: Climate Change**, v. 1, n. 2, p. 192-211, 2010.
- 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.; MEARN, L. O. Quantifying uncertainty in projections of regional climate change: a bayesian approach to the analysis of multi-model 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.
- TEBALDI, C.; KNUTTI, R. The use of the multi-model ensemble in probabilistic climate projections. **Philosophical Transactions of the Royal Society A**, v. 365, p. 2053-2075, 2007.
- TORRES, R. R.; LAPOLA, D. M.; MARENGO, J. A.; LOMBARDO, M. A. Socio-climatic hotspots in Brazil. **Climatic Change**, v. 115, p. 597-609, 2012.
- TORRES, R. R.; MARENGO, J. A. Uncertainty assessments of climate change projections over South America. **Theoretical and Applied Climatology**, v. 112, p. 253-272, 2013.
- TRENBERTH, K.E. More knowledge, less certainty. **Nature Reports Climate Change**, v. 4, p. 20-21, 2010.
- URRUTIA, R.; VUILLE, M. Climate change projections for the tropical Andes using a regional climate model: temperature and precipitation simulations for the end of the 21st century. **Journal of Geophysical Research**, v. 114, D02108, 2009.
- 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.

VERA, C.; SILVESTRI, G.; LIEBMANN, B.; GONZÁLEZ, P. Climate change scenarios for seasonal precipitation in South America from IPCC-AR4 models. **Geophysical Research Letters**, v. 33, L13707, 2006.

VERA, C.; SILVESTRI, G. Precipitation interannual variability in South America from the WCRP-CMIP3 multi-model dataset. **Climate Dynamics**, v. 32, p. 1003-1014, 2009.

WATTERSON, I. G. Calculation of probability density functions for temperature and precipitation change under global warming. **Journal of Geophysical Research**, v. 113, n. D12, 2008.

WEILAND, S. F. C.; van BEEK, L. P. H.; WEERTS, A. H.; BIERKENS, M. F. P. Extracting information from an ensemble of GCMs to reliably assess future global runoff change. **Journal of Hydrology**, v. 412, p. 66-75, 2012.

WIGLEY, T. M.; RAPER, S. C. Interpretation of high projections for global-mean warming. **Science**, v. 293, p. 451-454, 2001.

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.

YIN, L.; Fu, R.; SHEVLIAKOVA, E.; DICKINSON, R. E. How well can CMIP5 simulate precipitation and its controlling processes over tropical South America?. **Climate Dynamics**, 1-17, 2013.

APÊNDICE A – SIMULAÇÕES INDIVIDUAIS DOS MODELOS

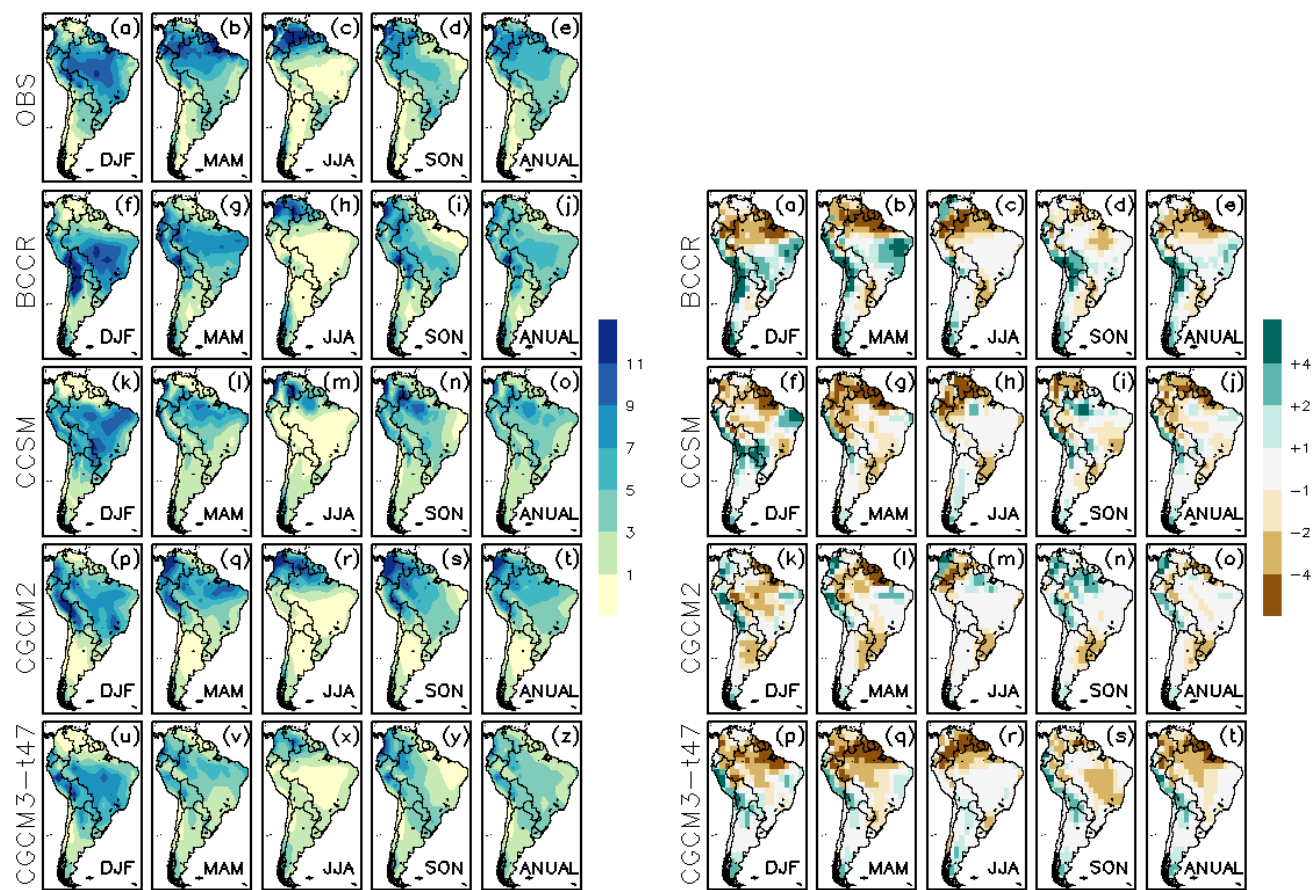


Figura A.1 – Climatologia média sazonal e anual de precipitação (esquerda), e viés associado (direita), simulada pelos MCGs do CMIP3 para o período de 1961 a 1990. A climatologia observada encontra-se no canto superior esquerdo. As unidades estão em $\text{mm}\cdot\text{dia}^{-1}$.

(continua)

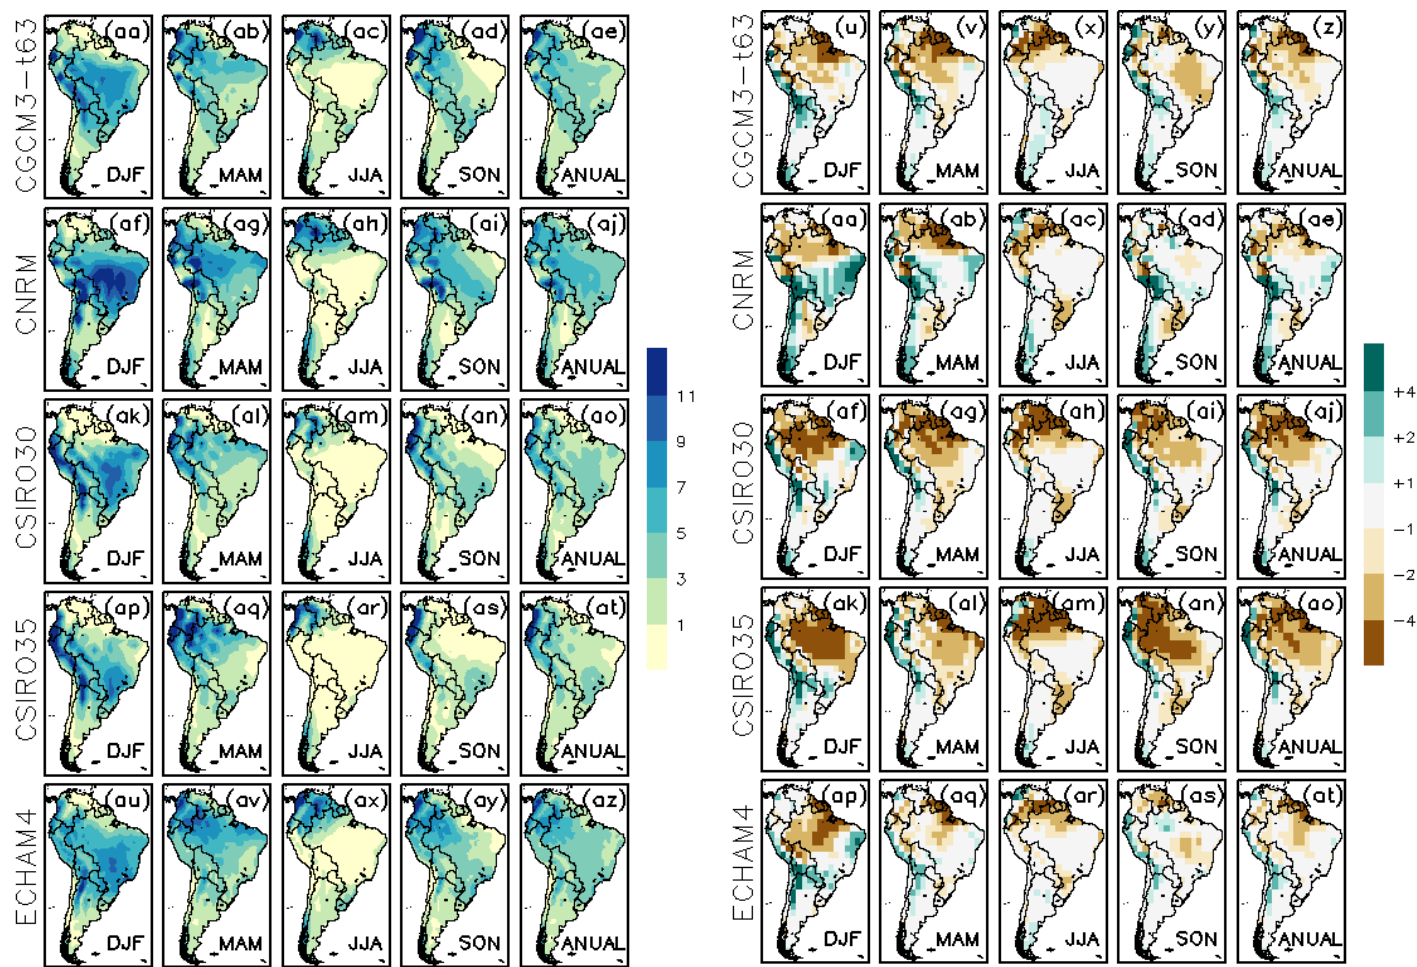


Figura A.1 – Continuação

(continua)

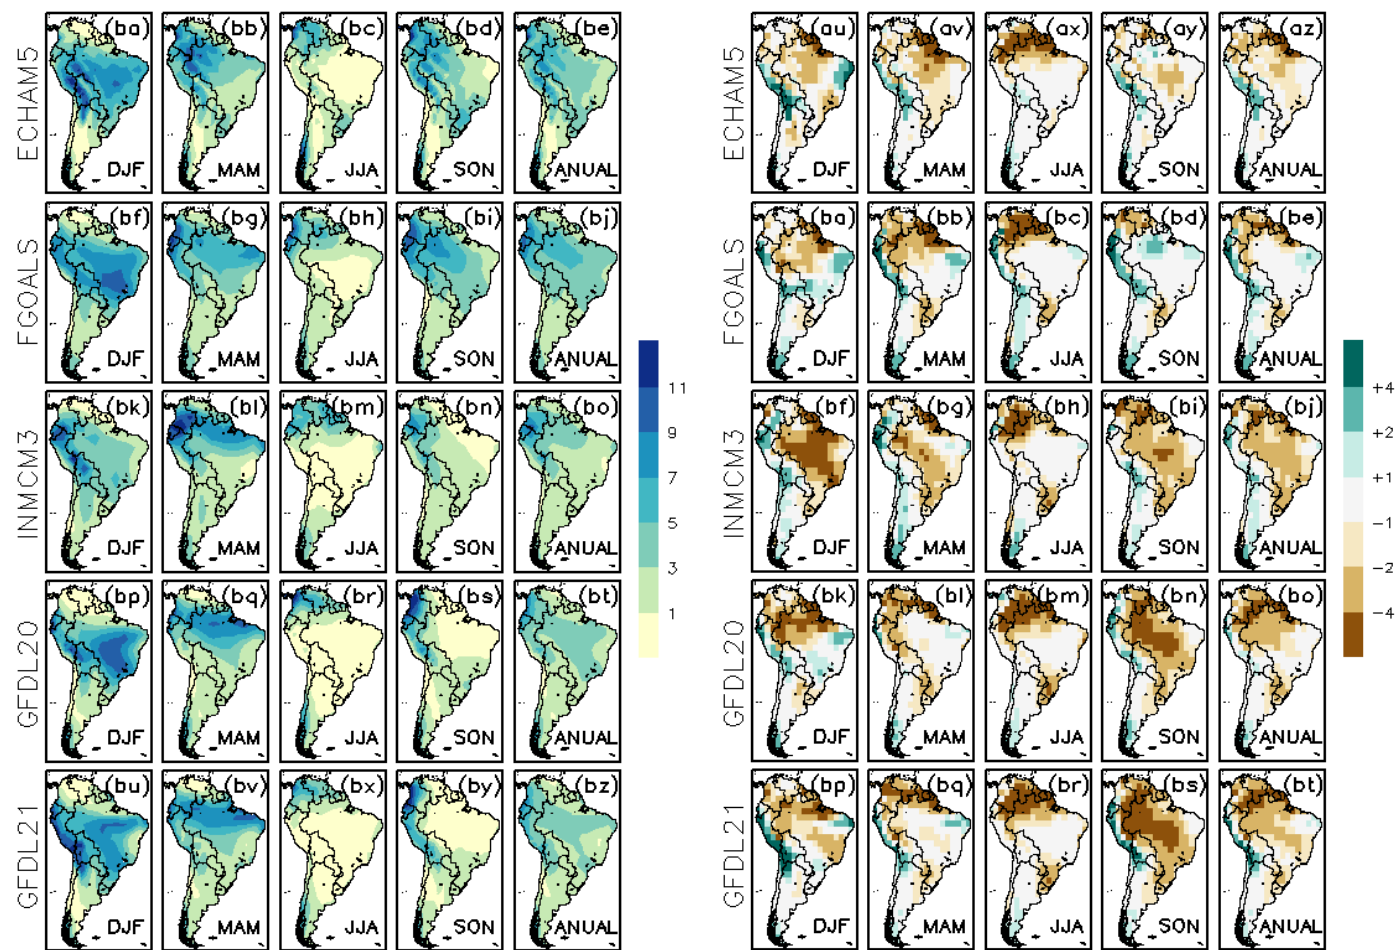


Figura A.1 – Continuação

(continua)

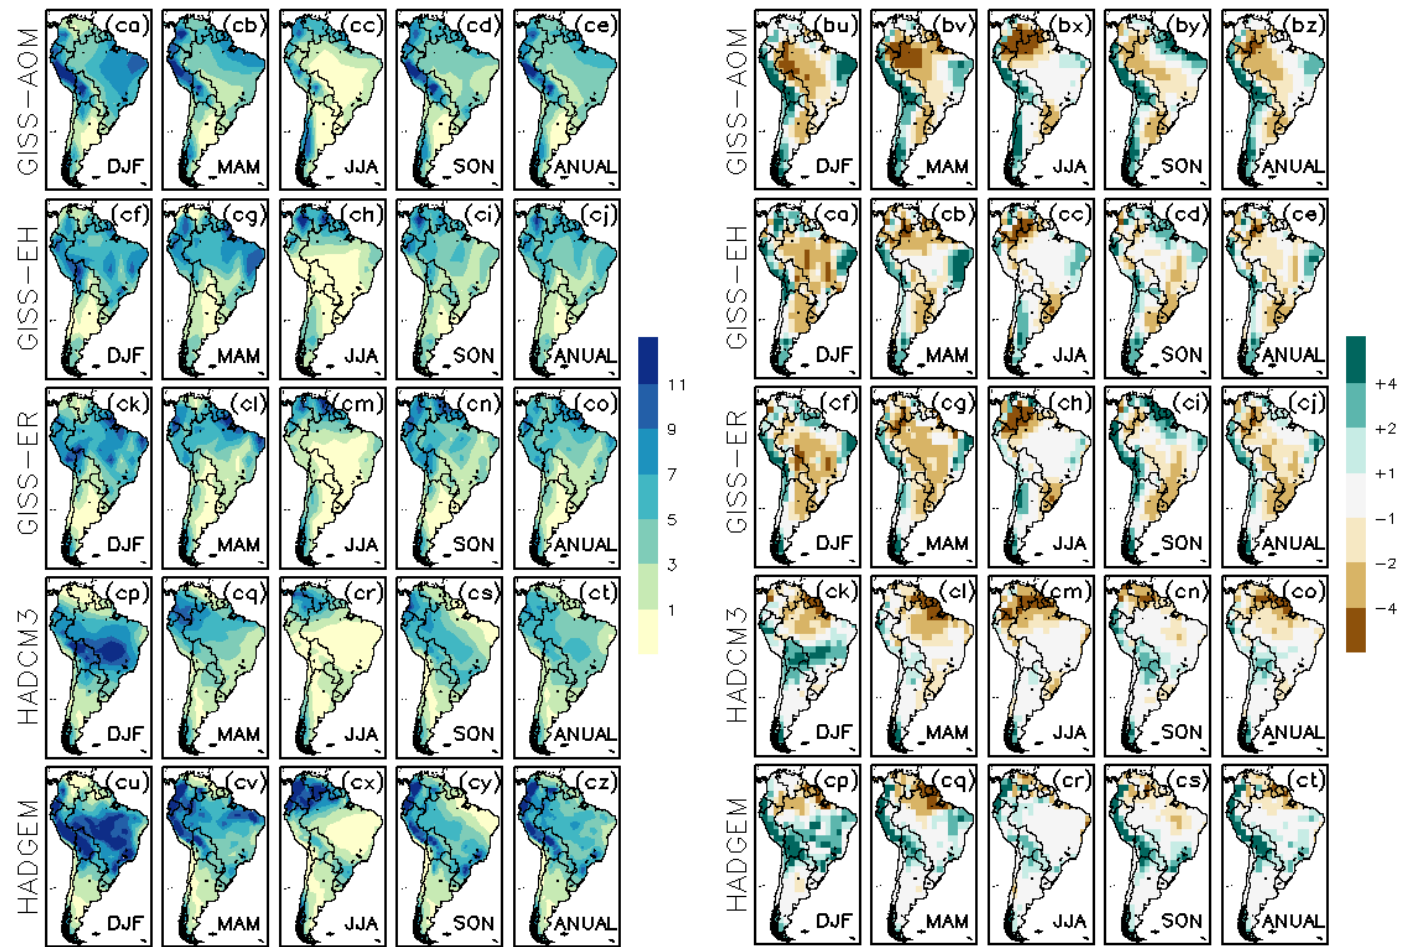


Figura A.1 – Continuação

(continua)

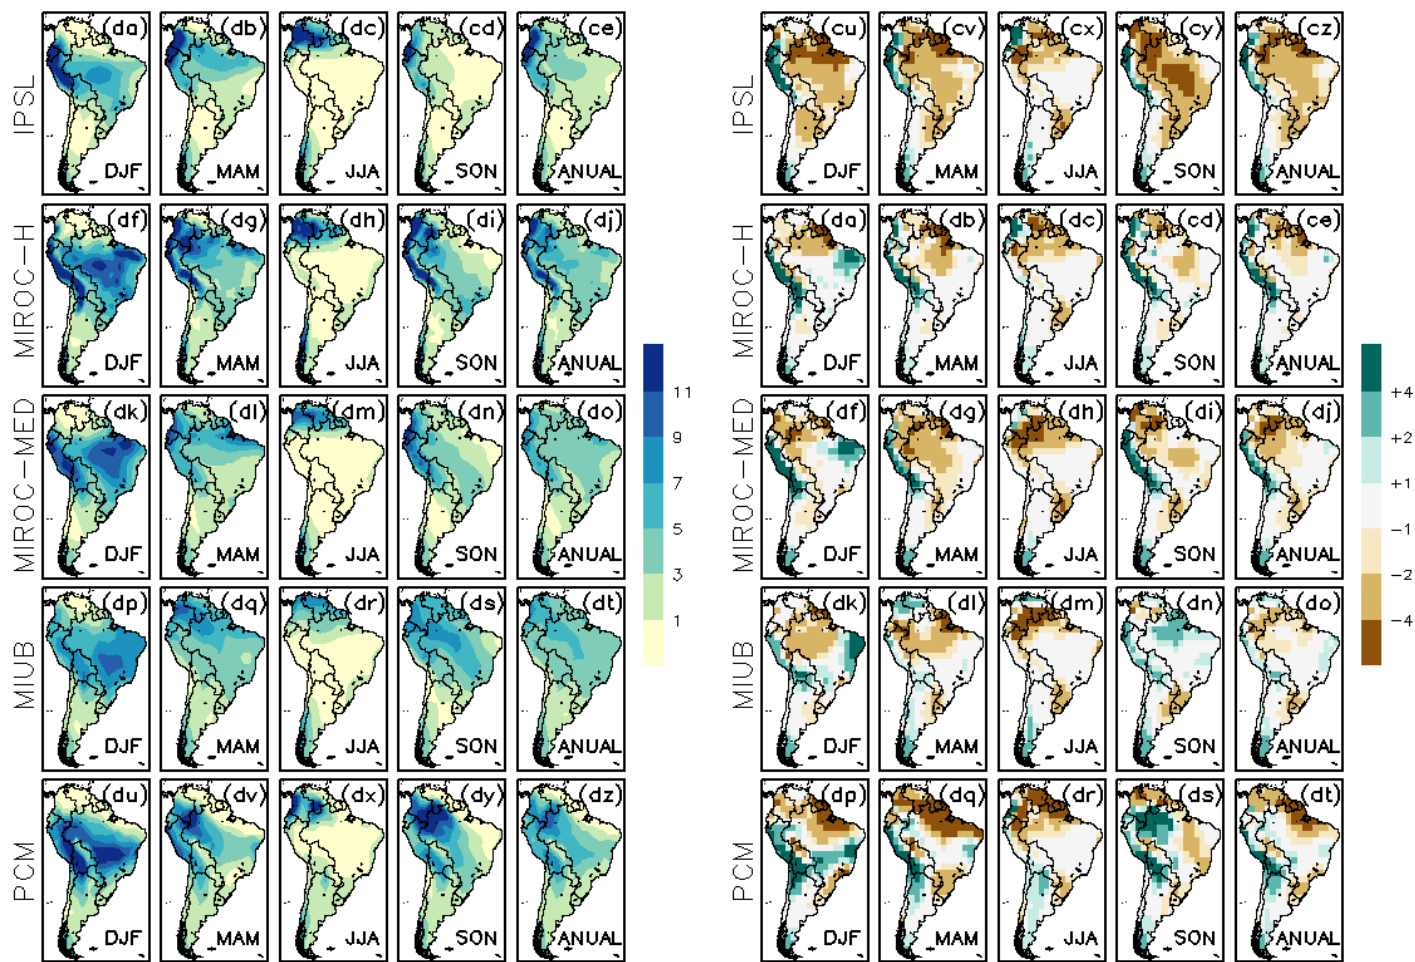


Figura A.1 – Conclusão.

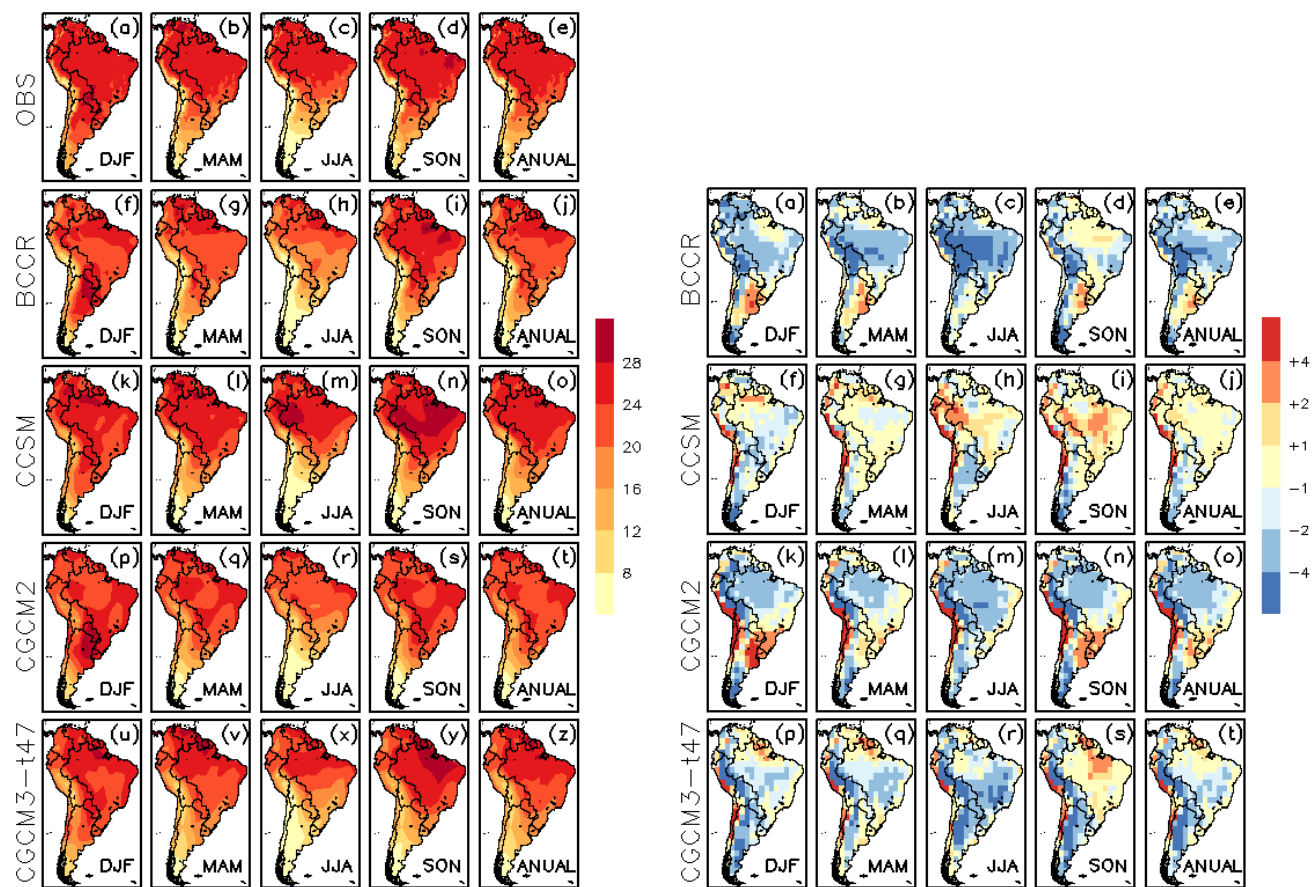


Figura A.2 – Climatologia média sazonal e anual de temperatura (esquerda), e viés associado (direita), simulada pelos MCGs do CMIP3 para o período de 1961 a 1990. A climatologia observada encontra-se no canto superior esquerdo. As unidades estão °C.

(continua)

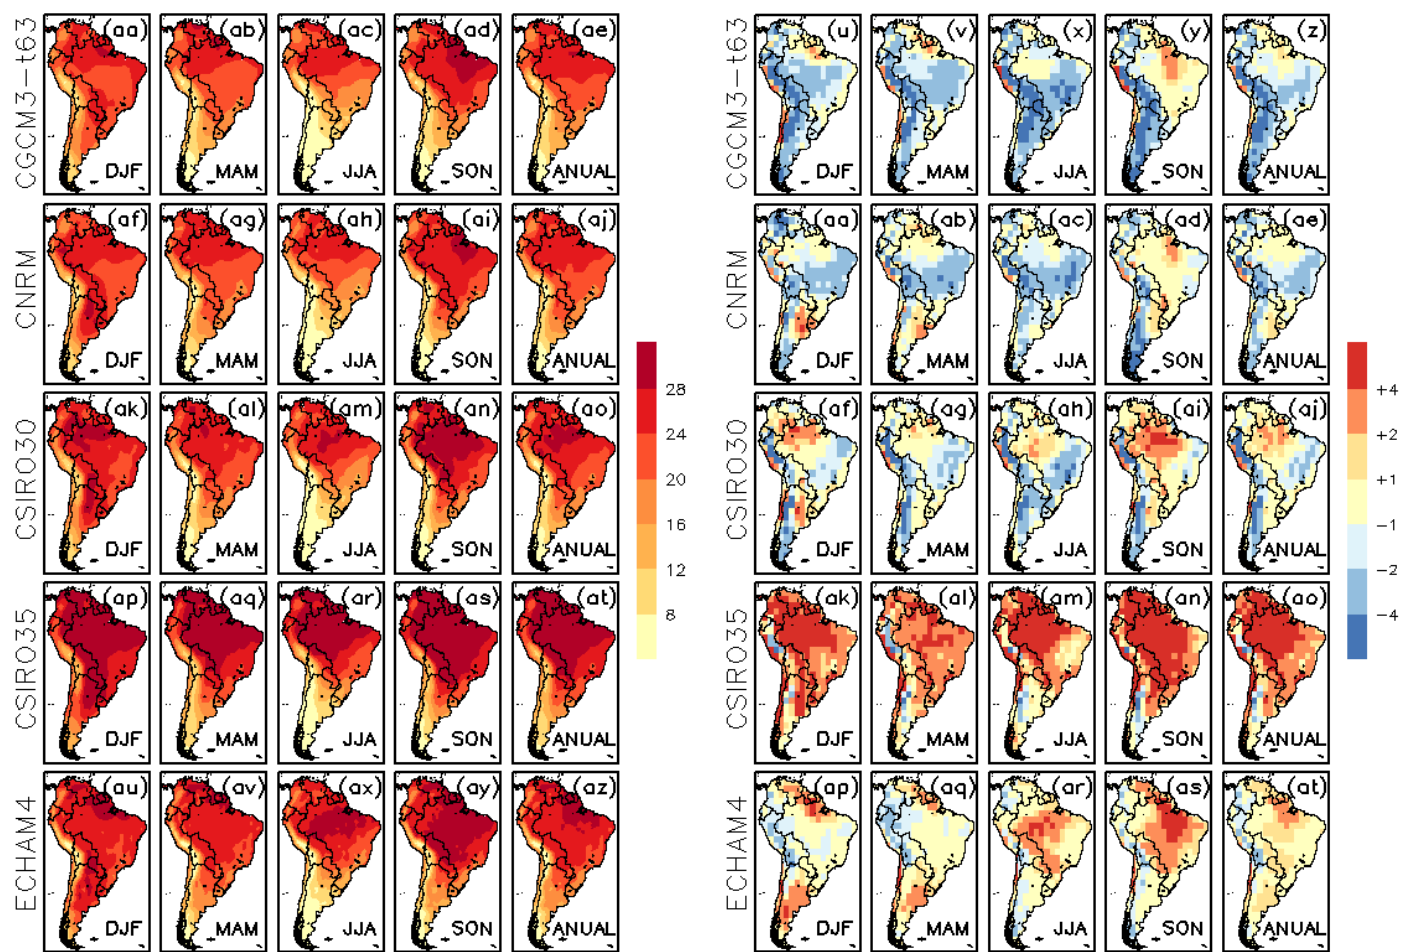


Figura A.2 – Continuação

(continua)

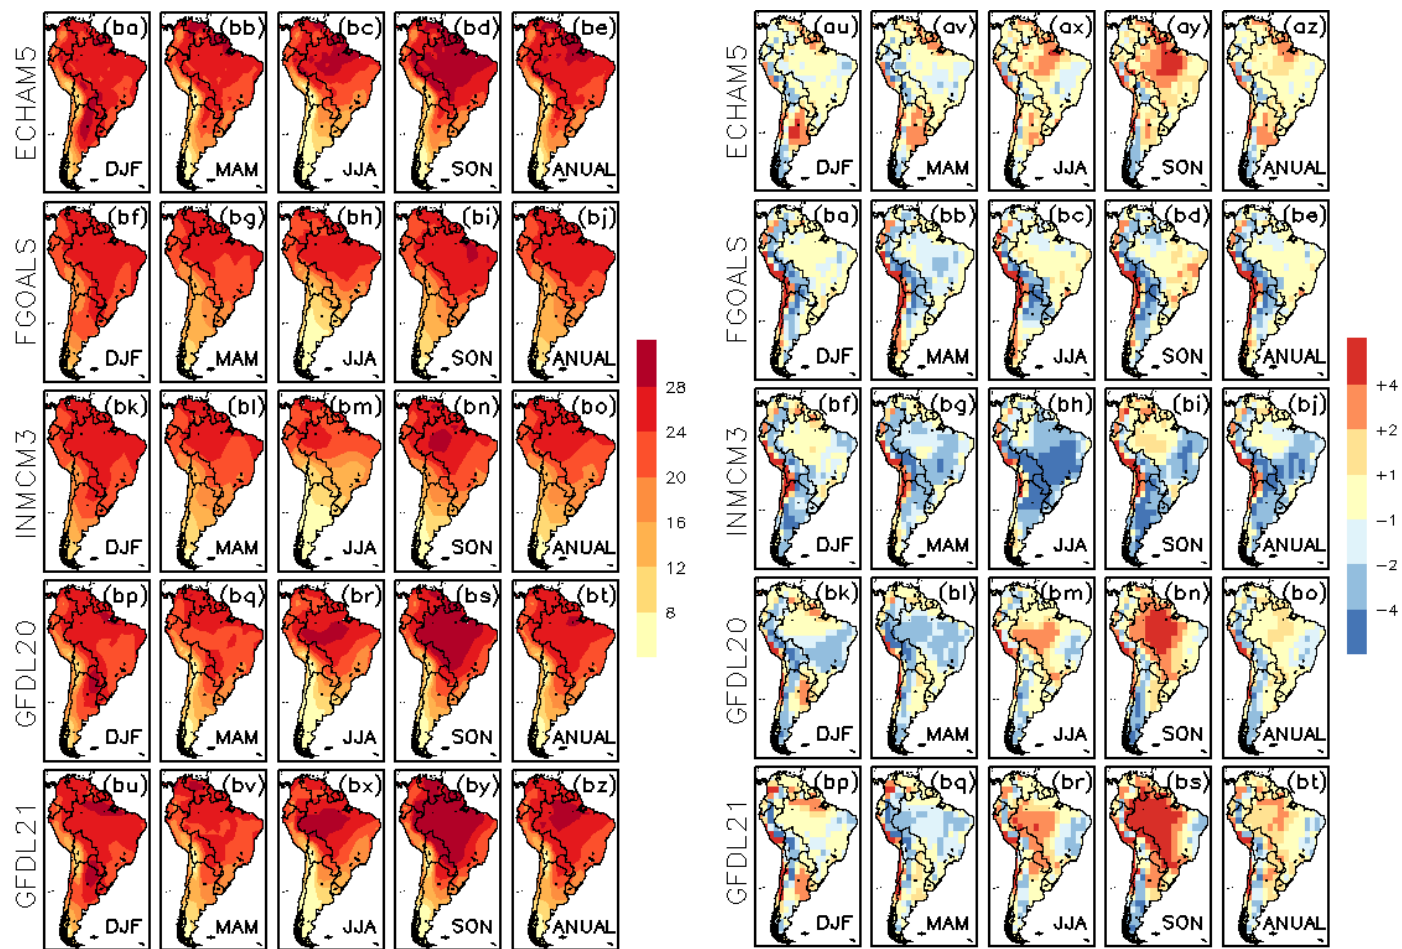


Figura A.2 – Continuação

(continua)

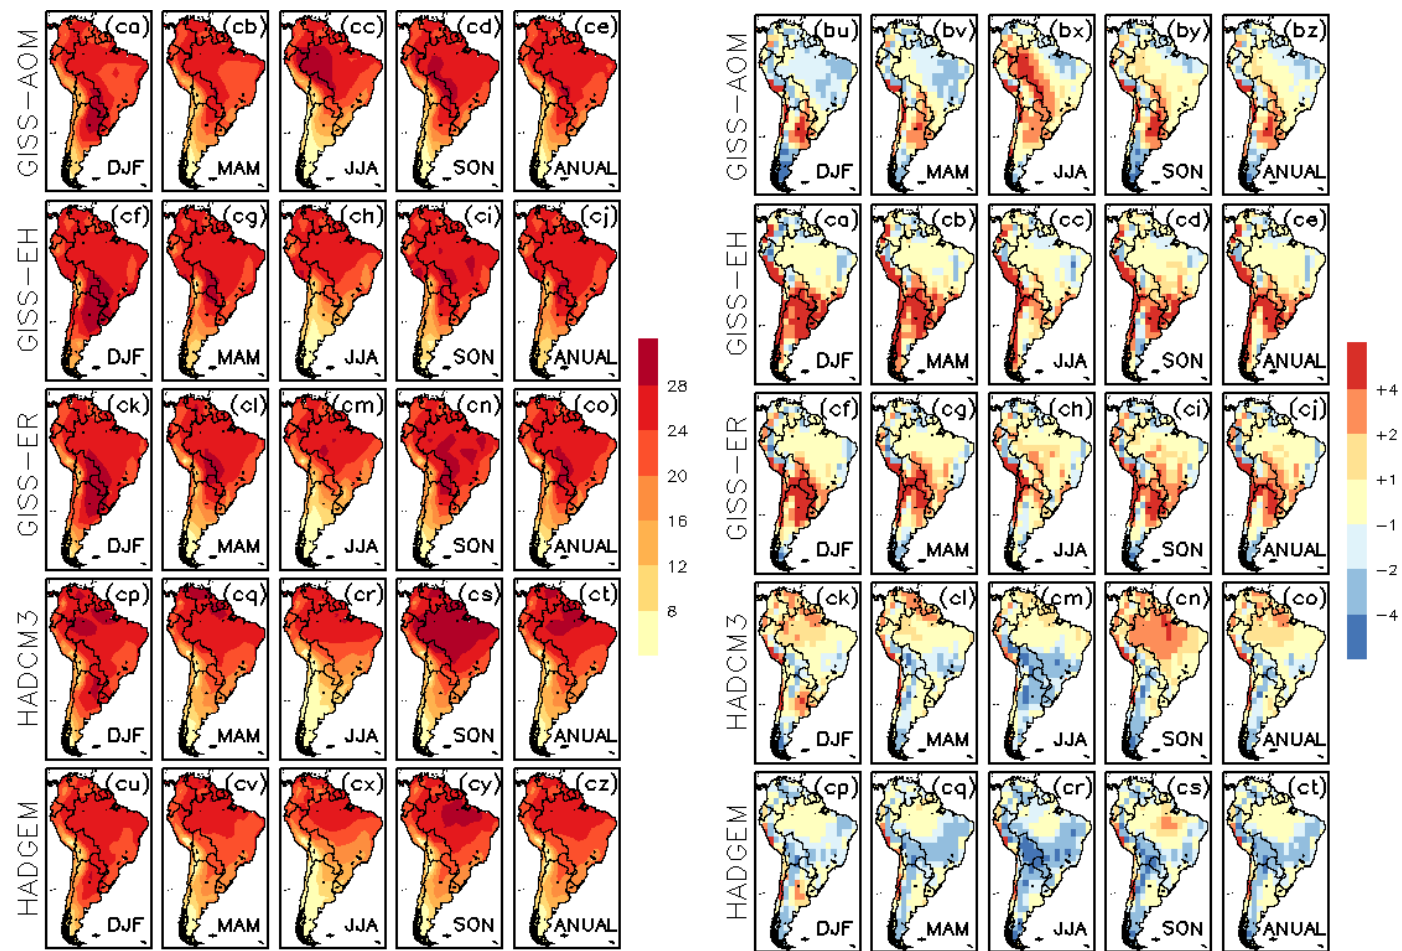


Figura A.2 – Continuação

(continua)

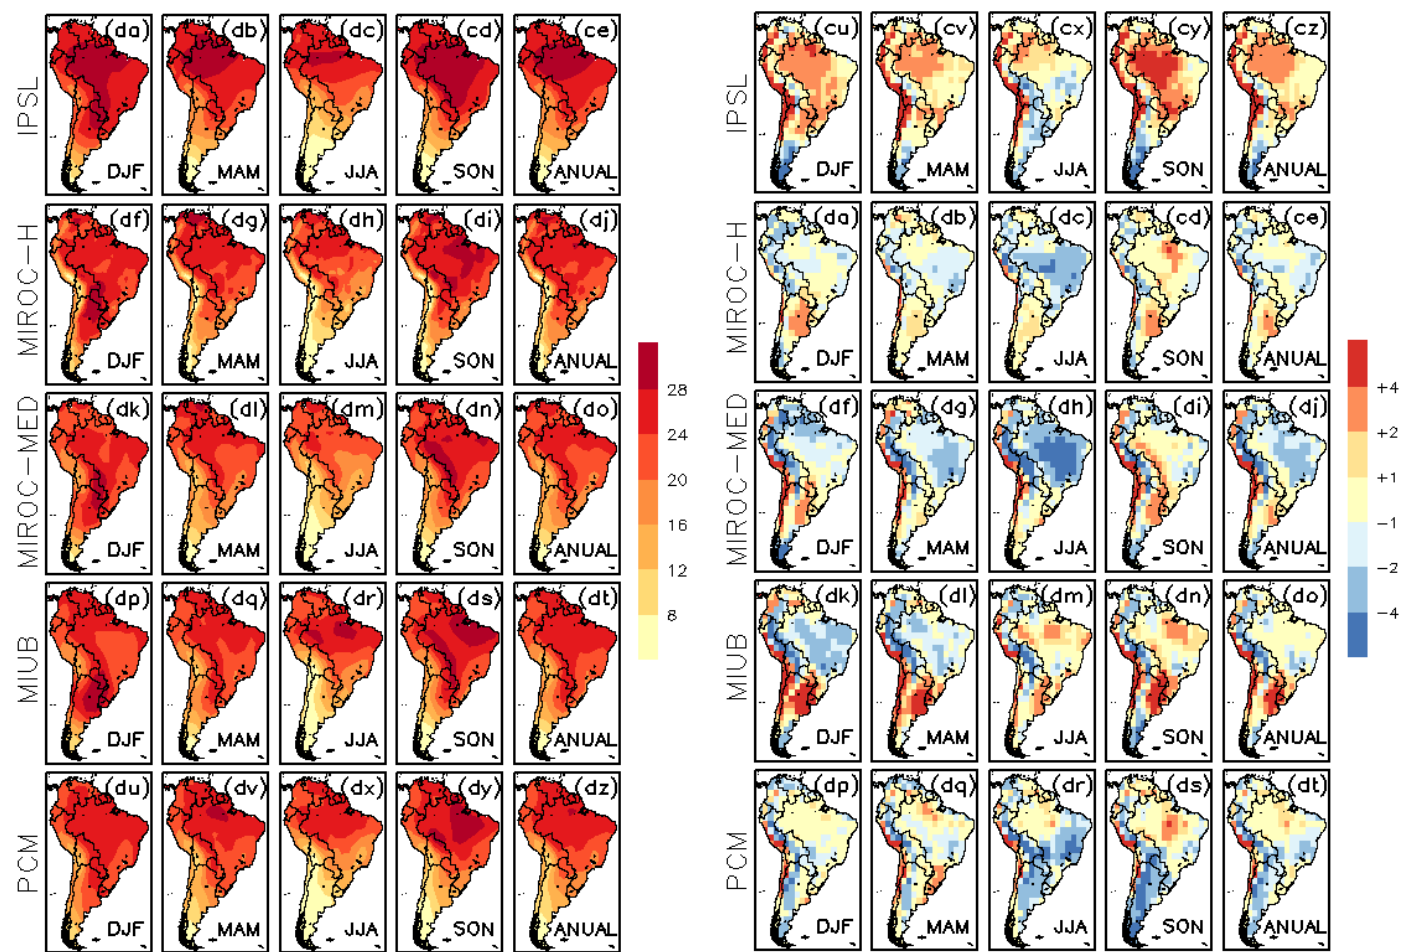


Figura A.2 – Conclusão.

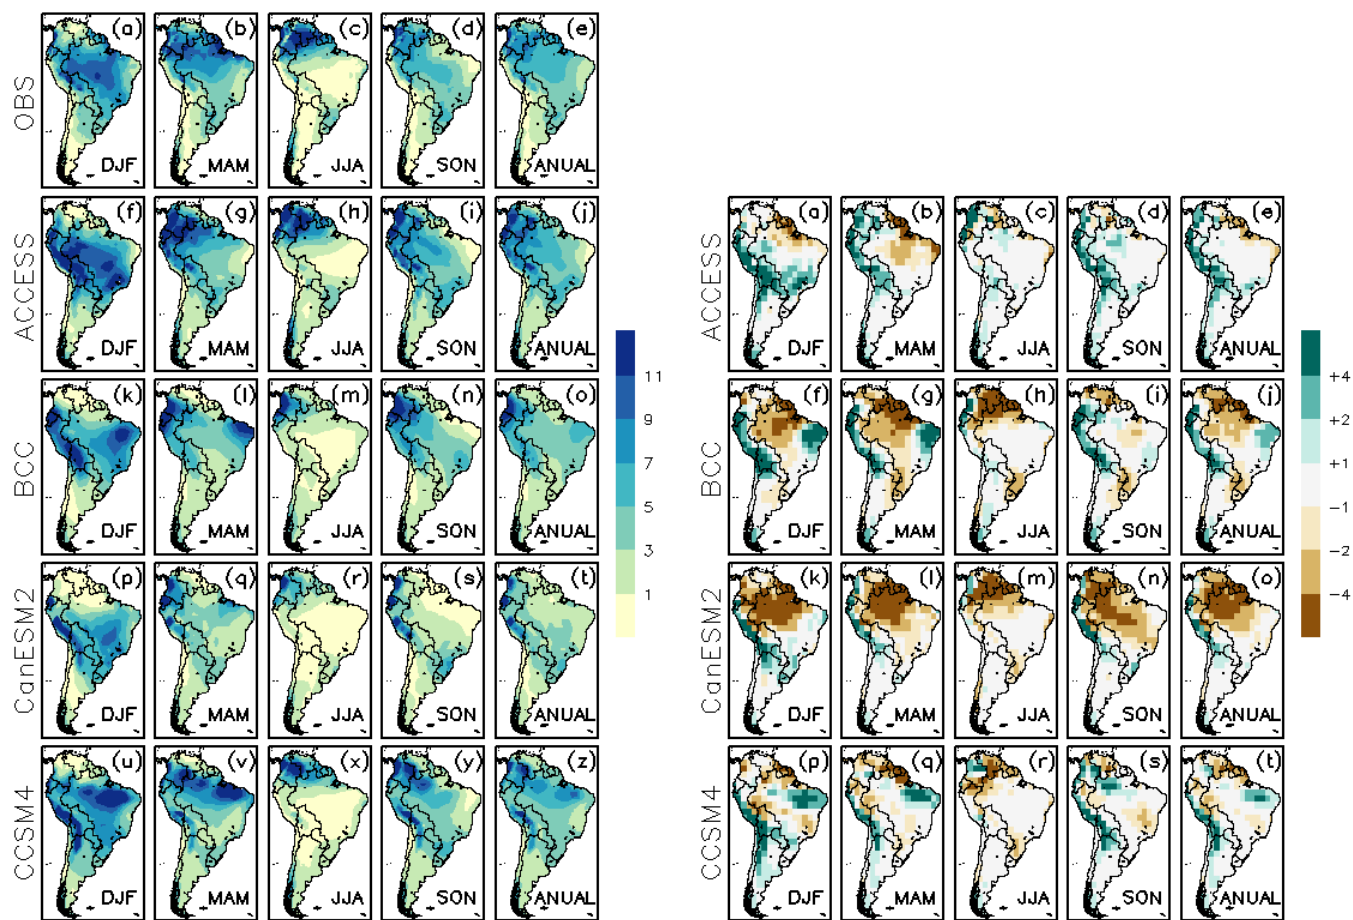


Figura A.3 – Climatologia média sazonal e anual de precipitação (esquerda), e viés associado (direita), simulada pelos MCGs do CMIP5 para o período de 1961 a 1990. A climatologia observada encontra-se no canto superior esquerdo. As unidades estão em $\text{mm}\cdot\text{dia}^{-1}$.

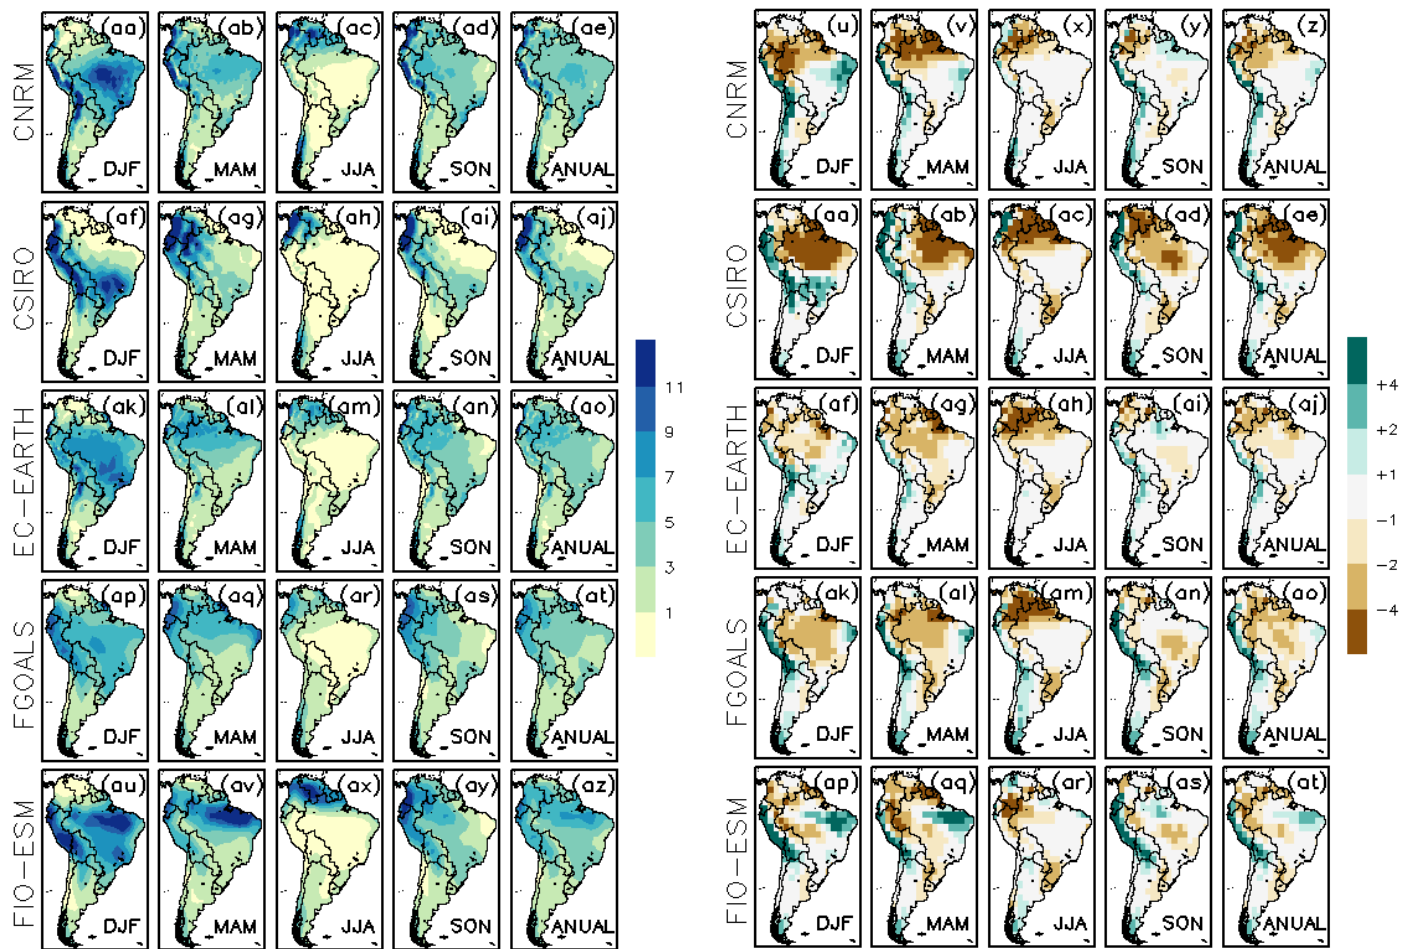


Figura A.3 – Continuação

(continua)

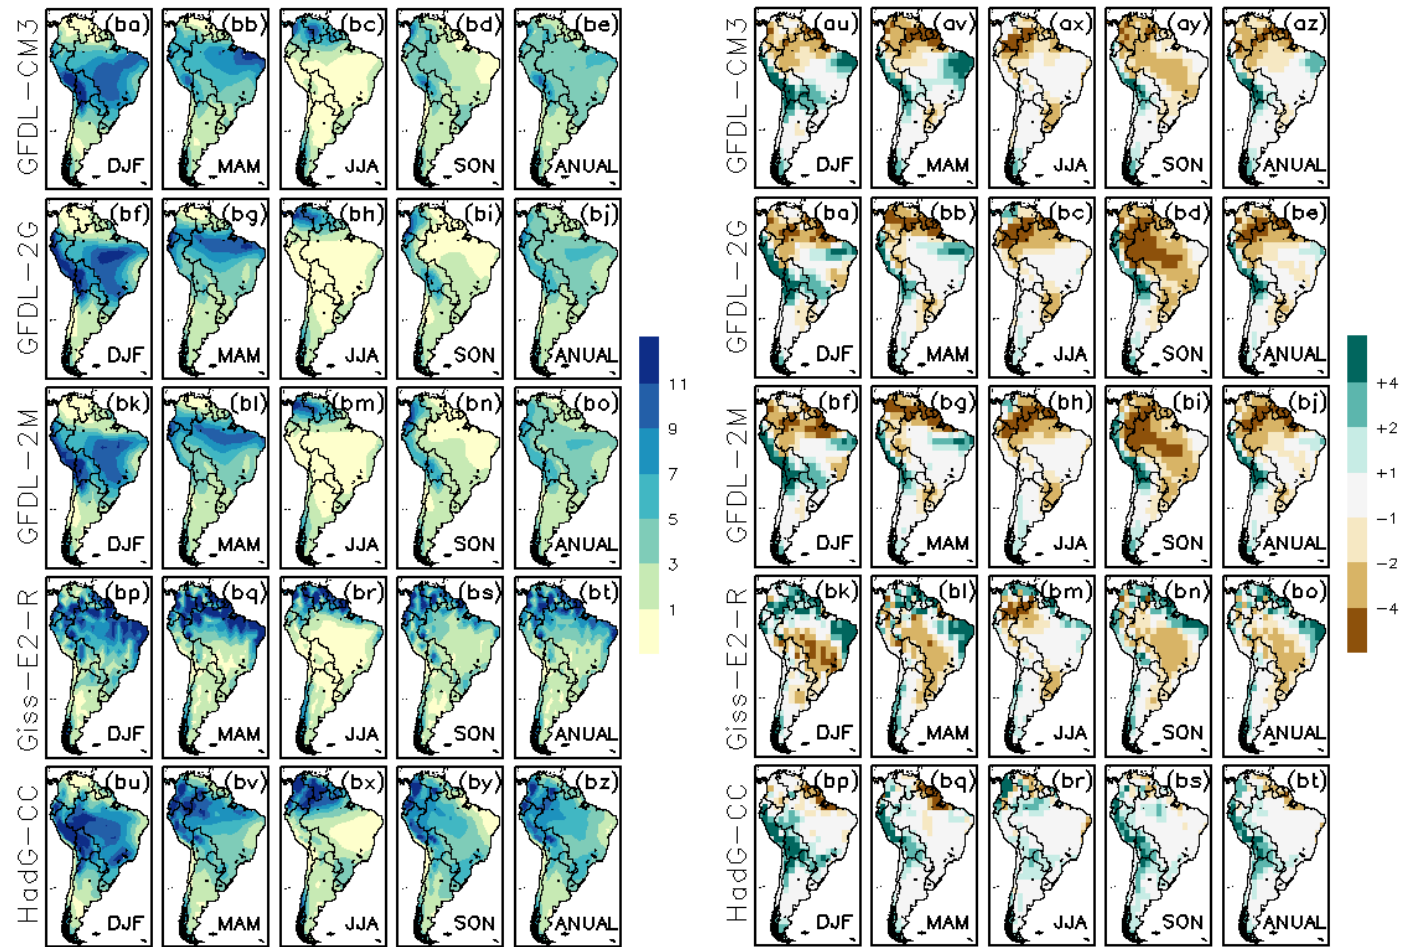


Figura A.3 – Continuação

(continua)

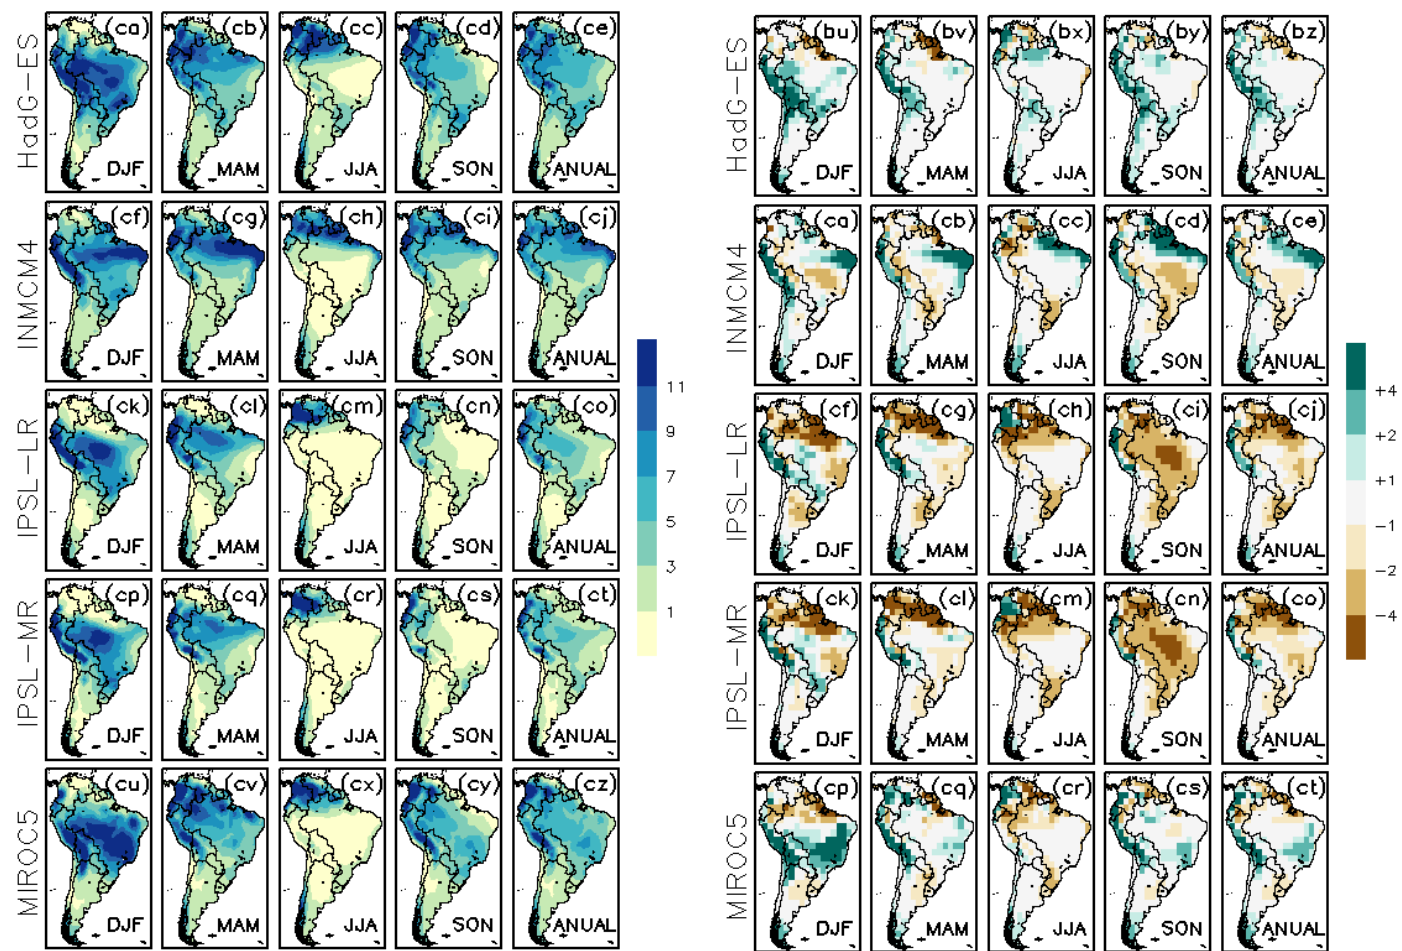


Figura A.3 – Continuação

(continua)

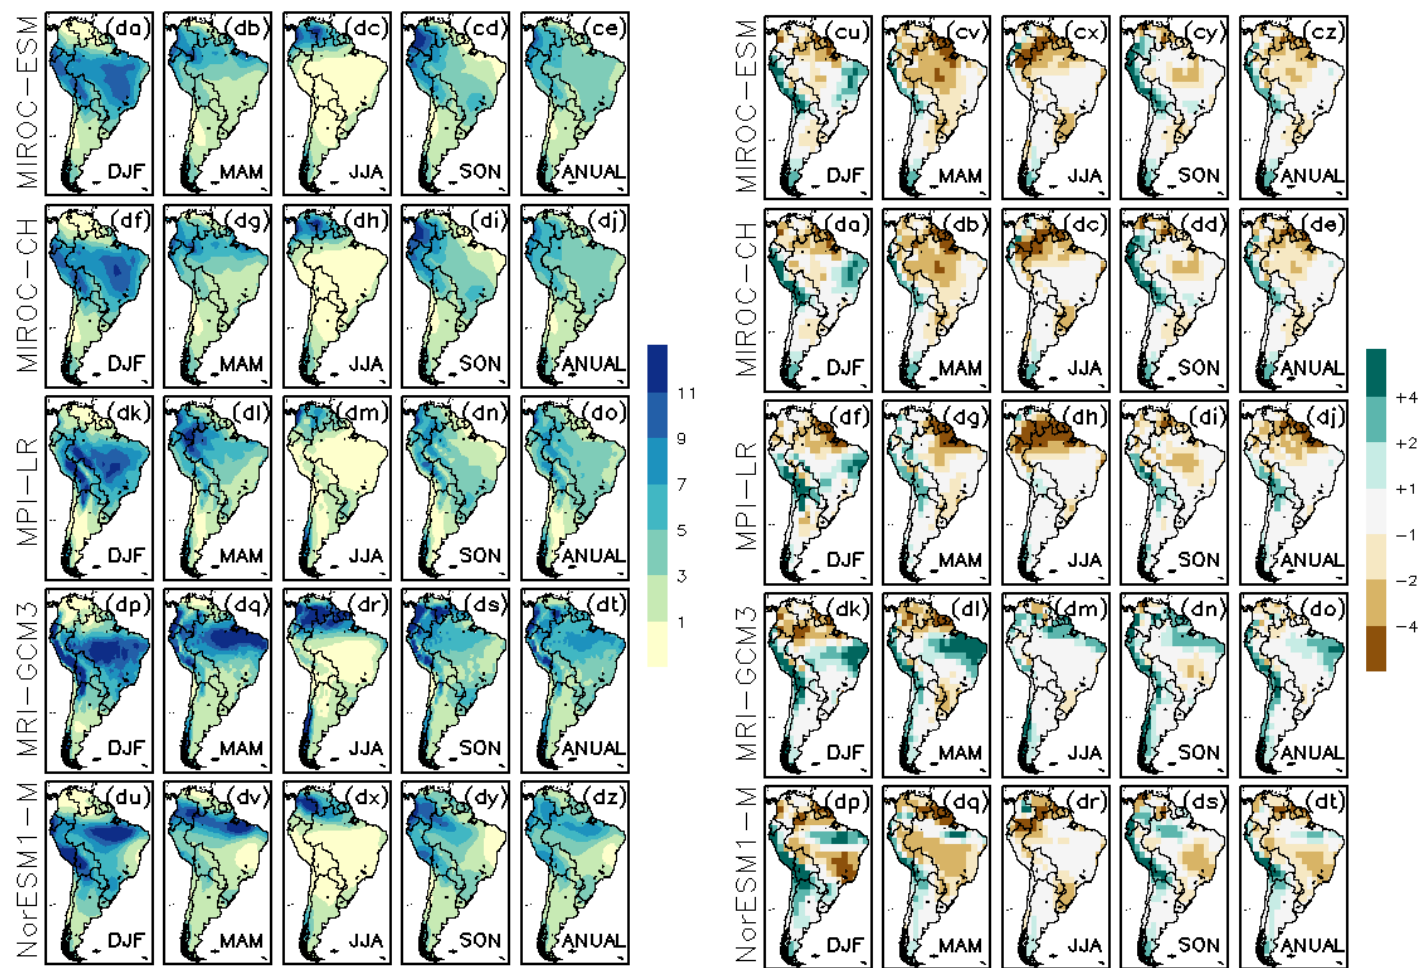


Figura A.3 – Conclusão.

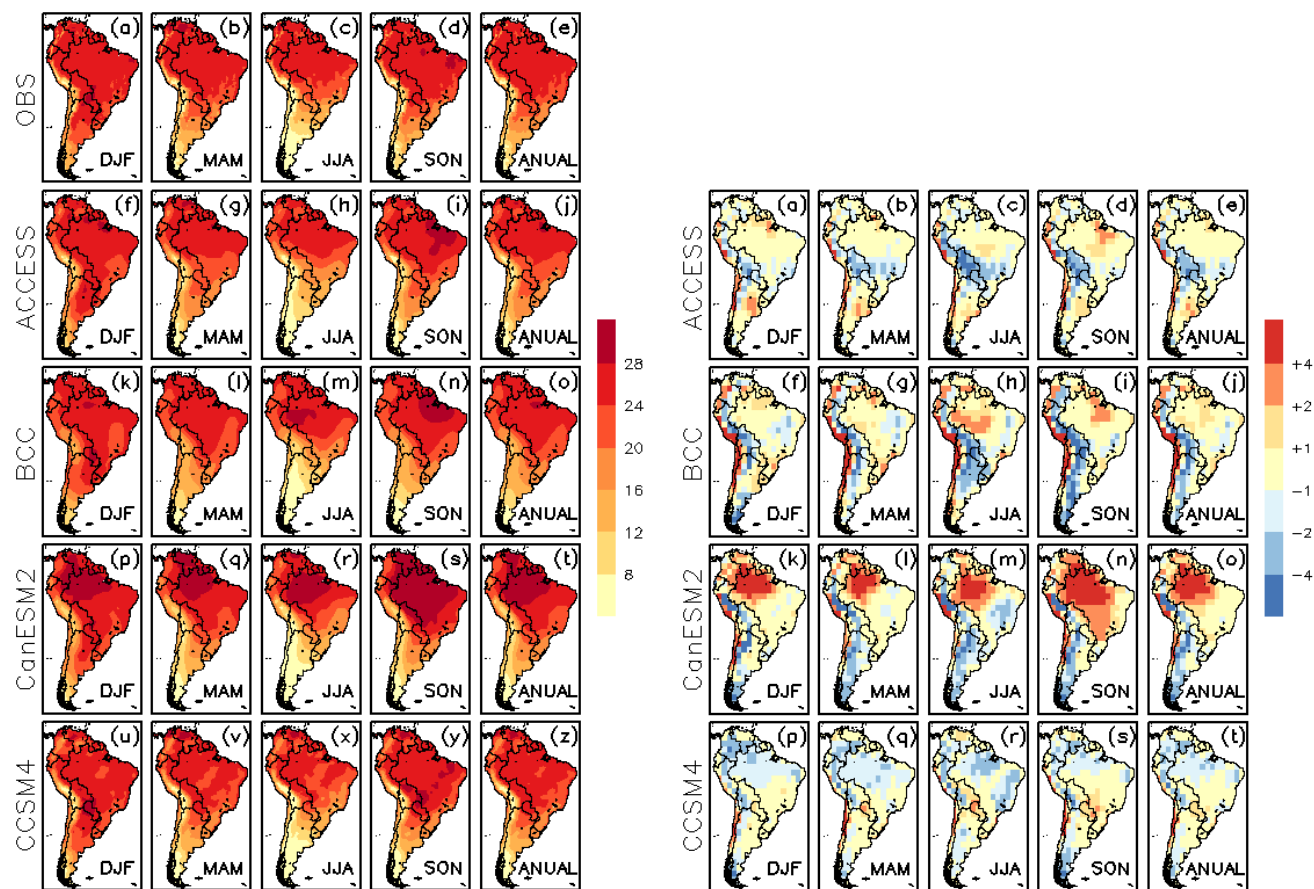


Figura A.4 – Climatologia média sazonal e anual de temperatura (esquerda), e viés associado (direita), simulada pelos MCGs do CMIP5 para o período de 1961 a 1990. A climatologia observada encontra-se no canto superior esquerdo. As unidades estão °C.

(continua)

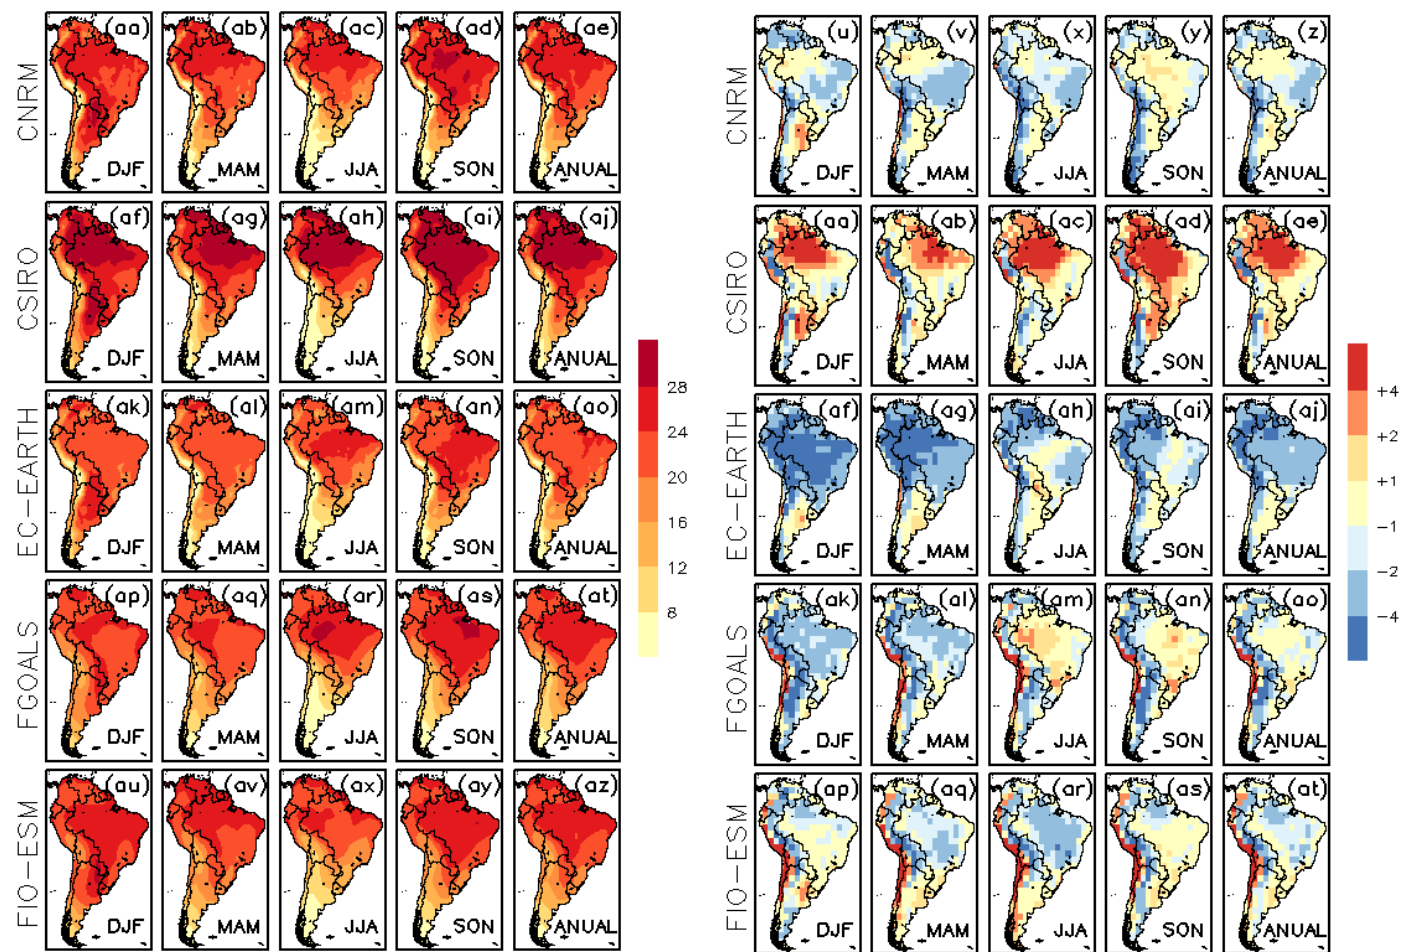


Figura A.4 – Continuação

(continua)

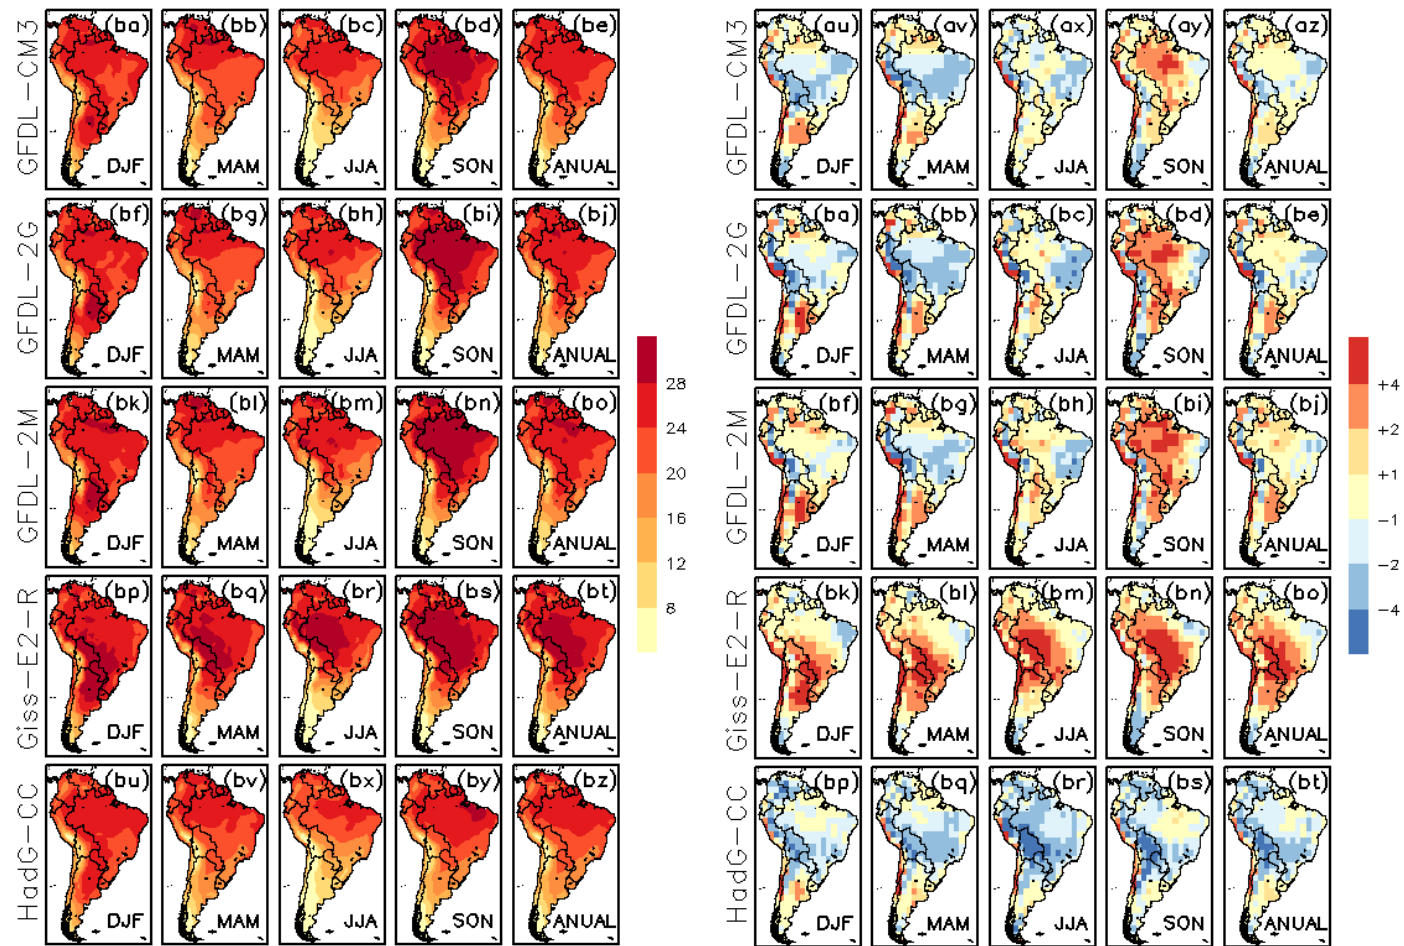


Figura A.4 – Continuação

(continua)

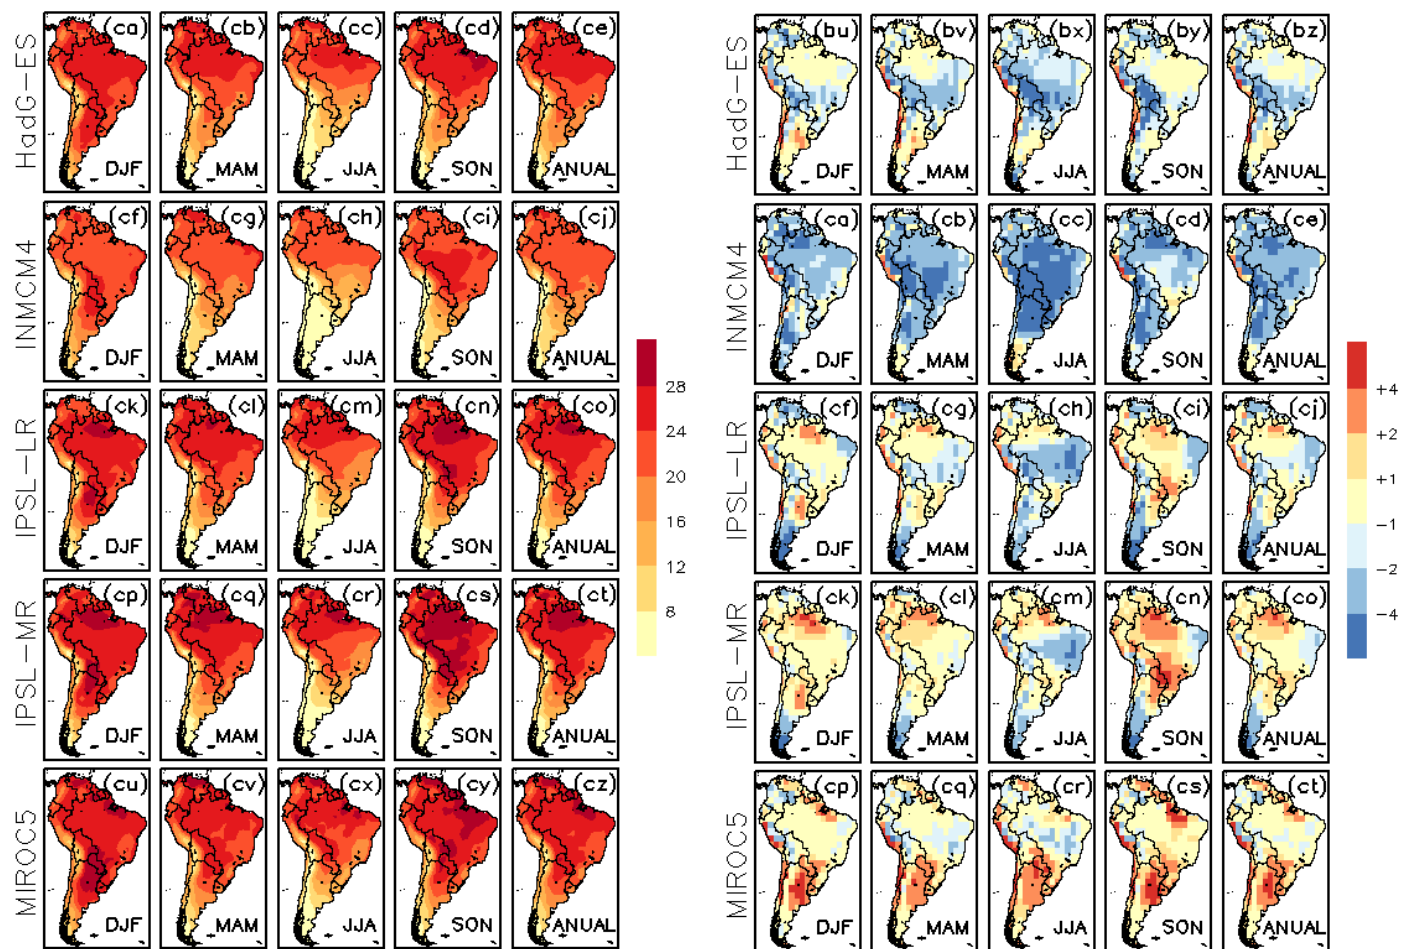


Figura A.4 – Continuação

(continua)

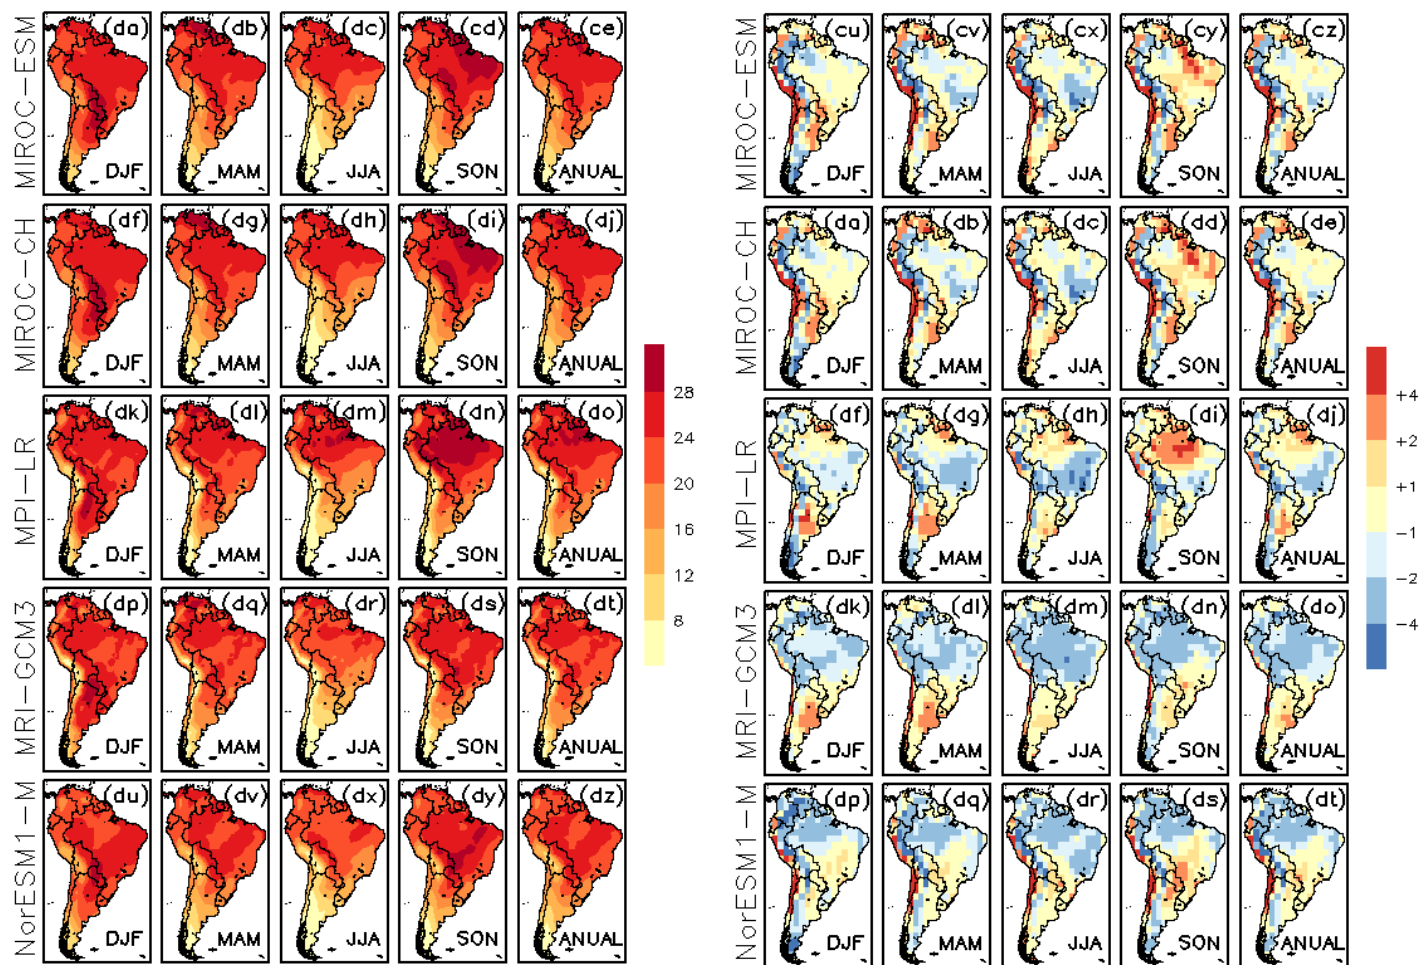


Figura A.4 – Conclusão.

APÊNDICE B – PROJEÇÕES INDIVIDUAIS DOS MODELOS

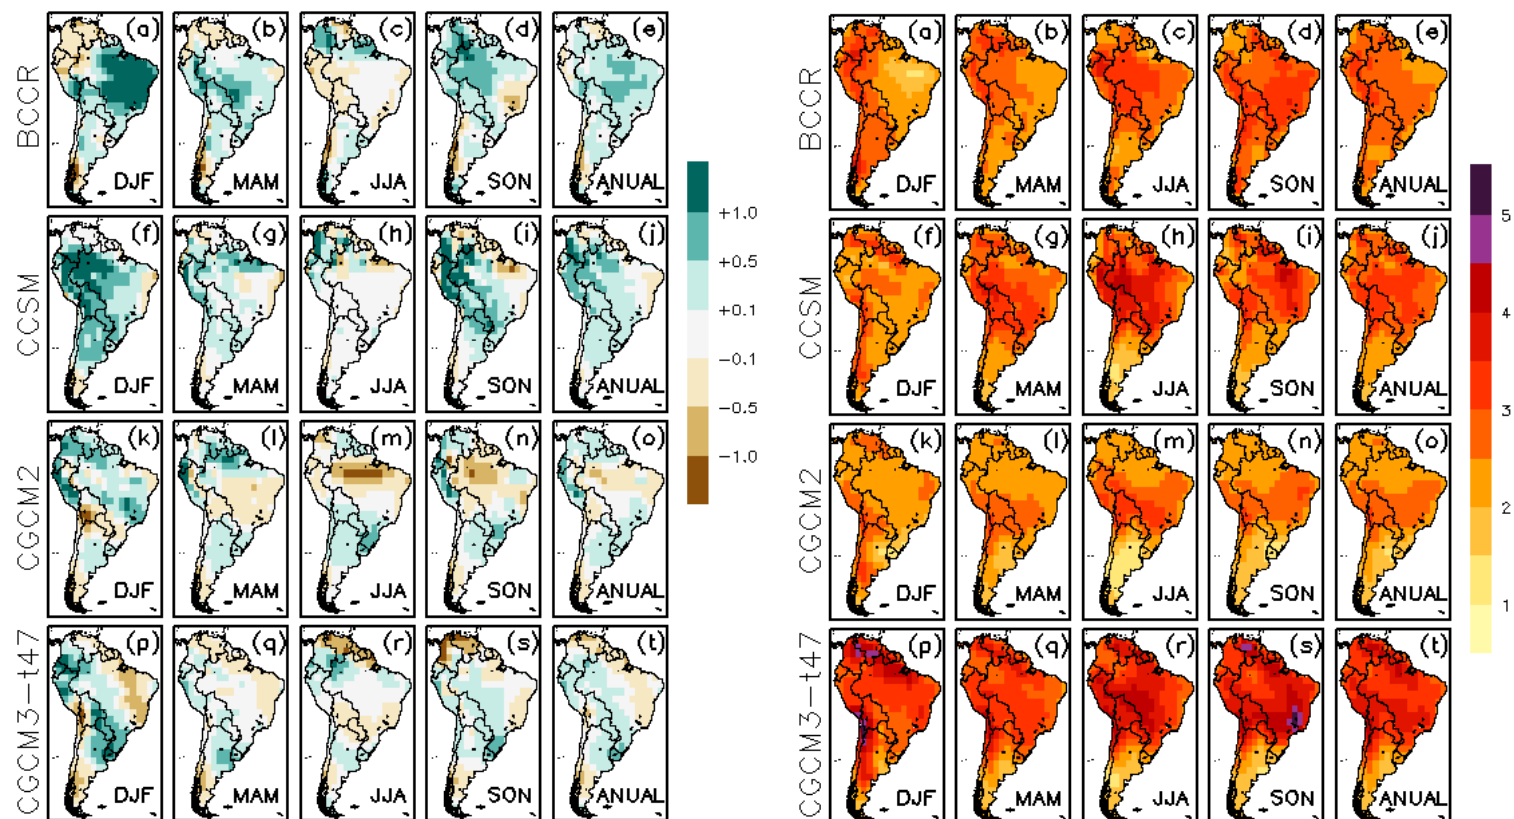


Figura B.1 – Mudanças sazonal e anual de temperatura do ar próximo à superfície (painéis da direita) e precipitação (painéis da esquerda) projetadas para o final do século XXI (2071-2100) no cenário de emissões SRES A1B, provenientes do conjunto CMIP3. As mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990. As unidades de temperatura e precipitação são $^{\circ}\text{C}$ e $\text{mm}\cdot\text{dia}^{-1}$, respectivamente.

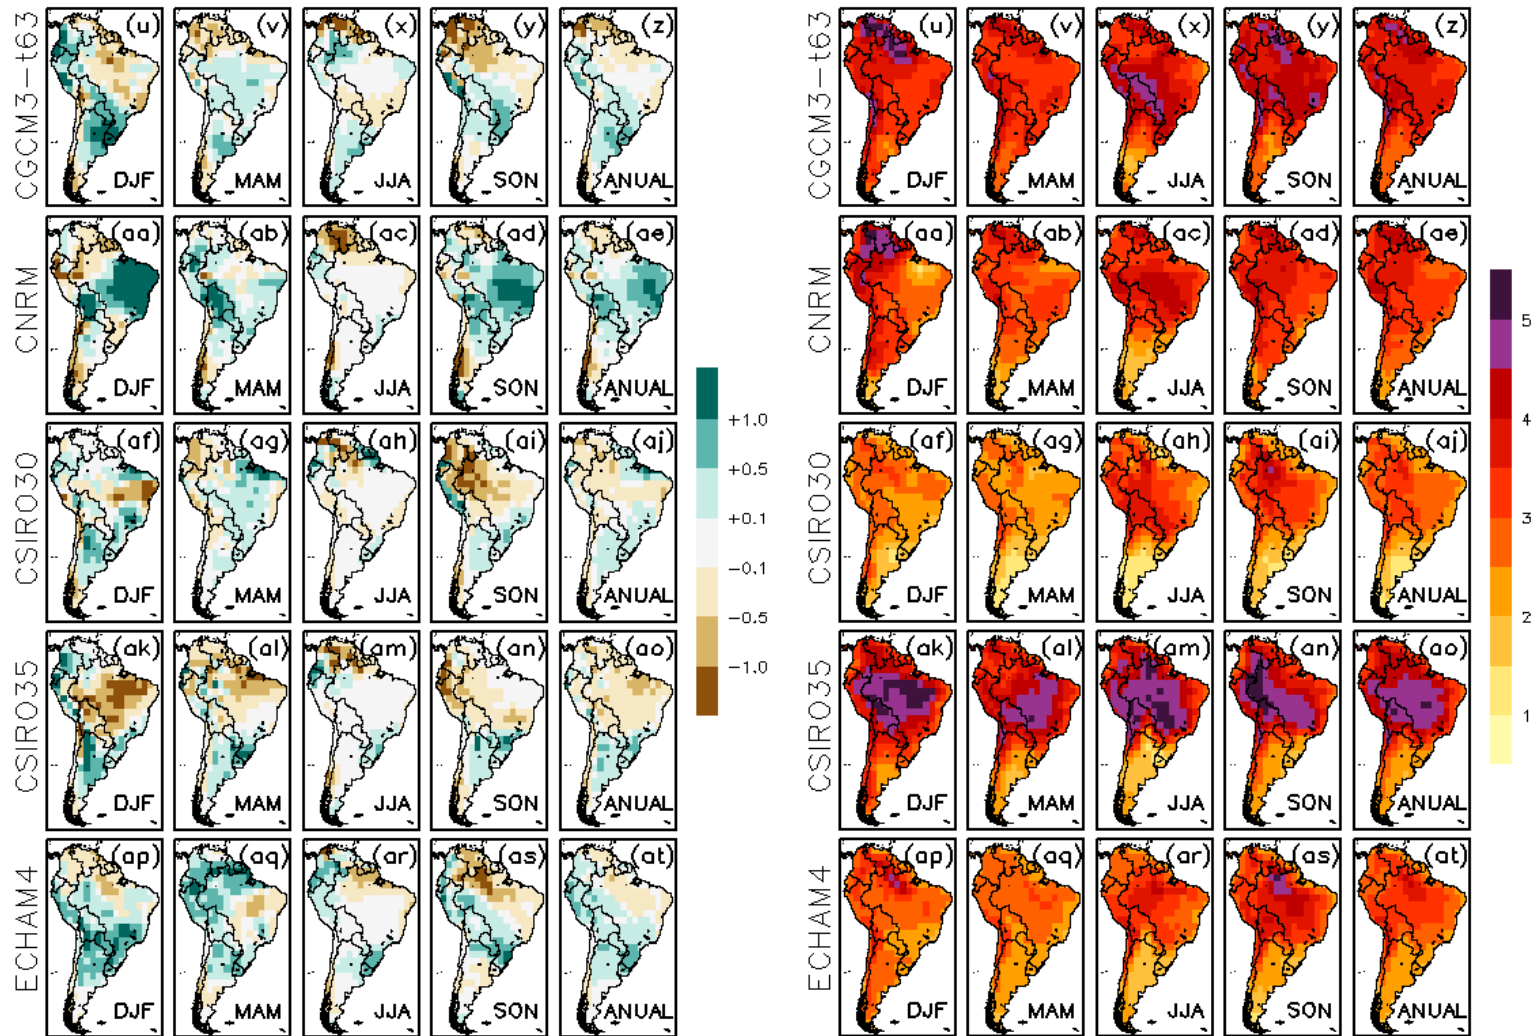


Figura B.1 – Continuação

(continua)

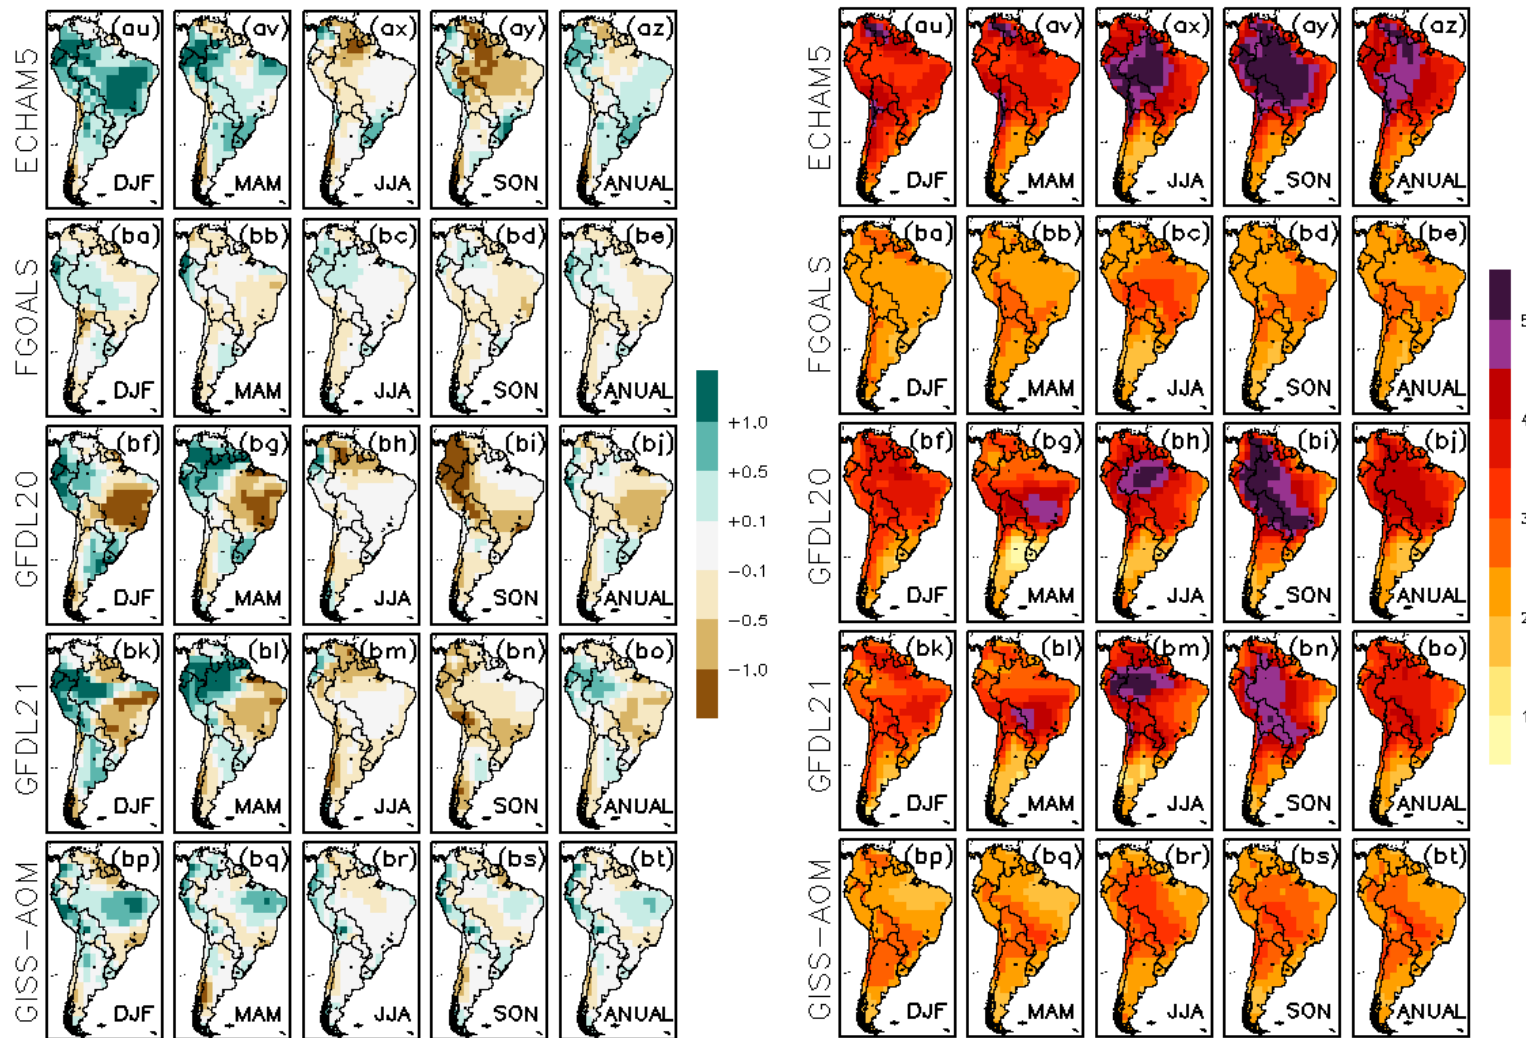


Figura B.1 – Continuação

(continua)

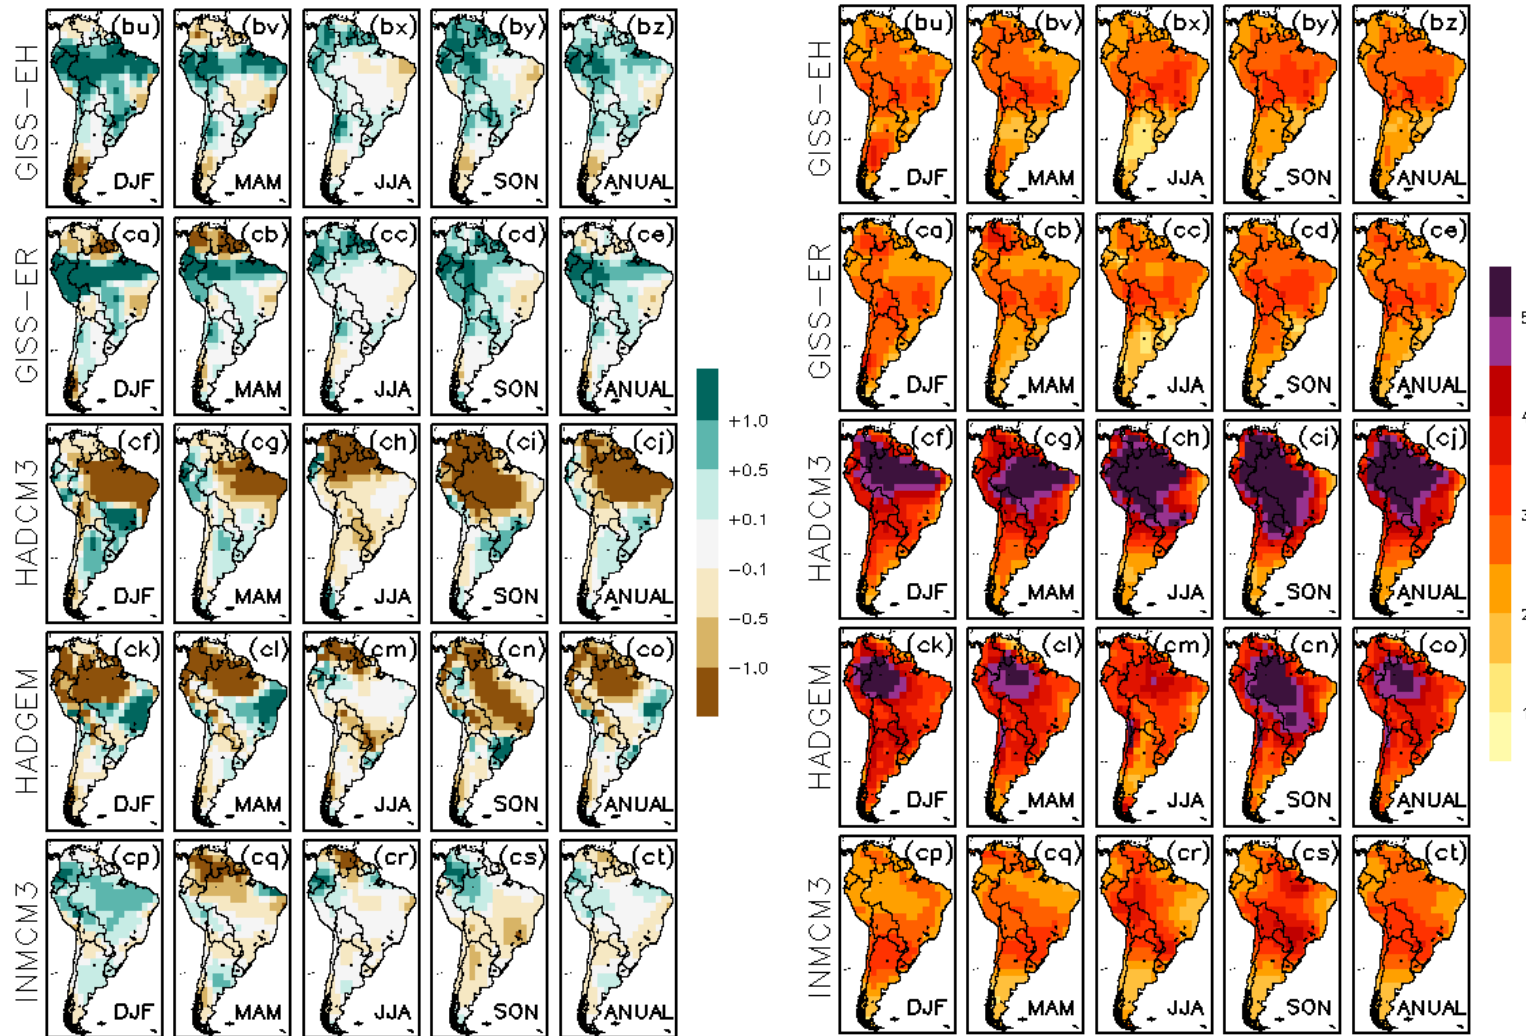


Figura B.1 – Continuação

(continua)

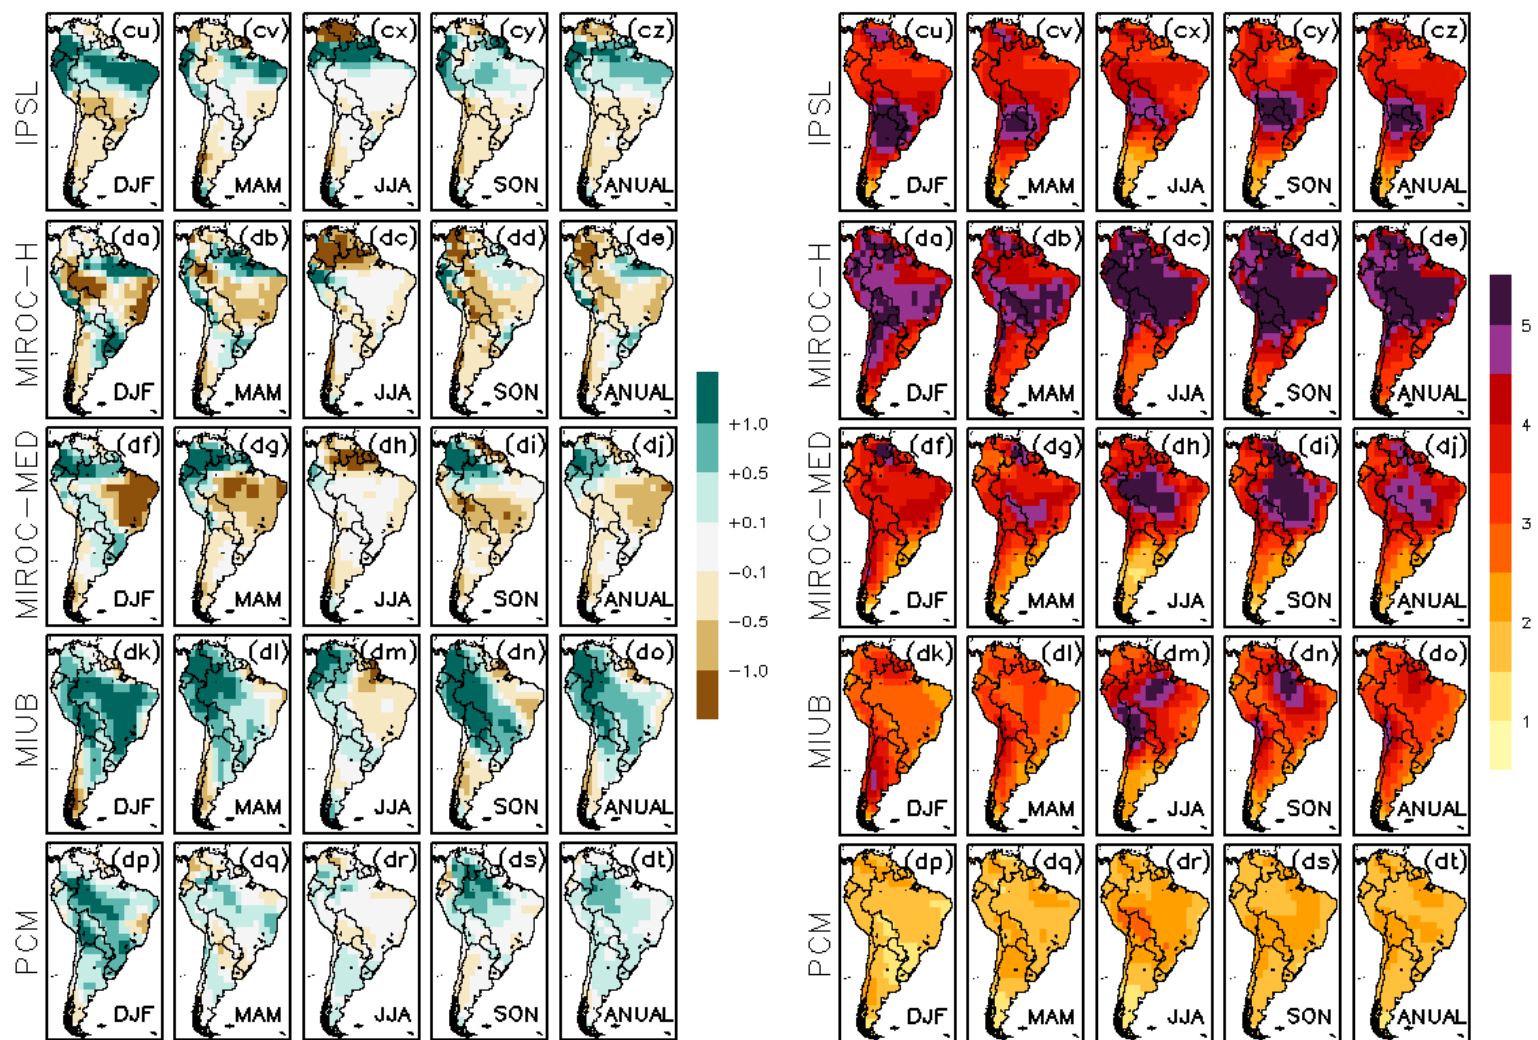


Figura B.1 – Conclusão.

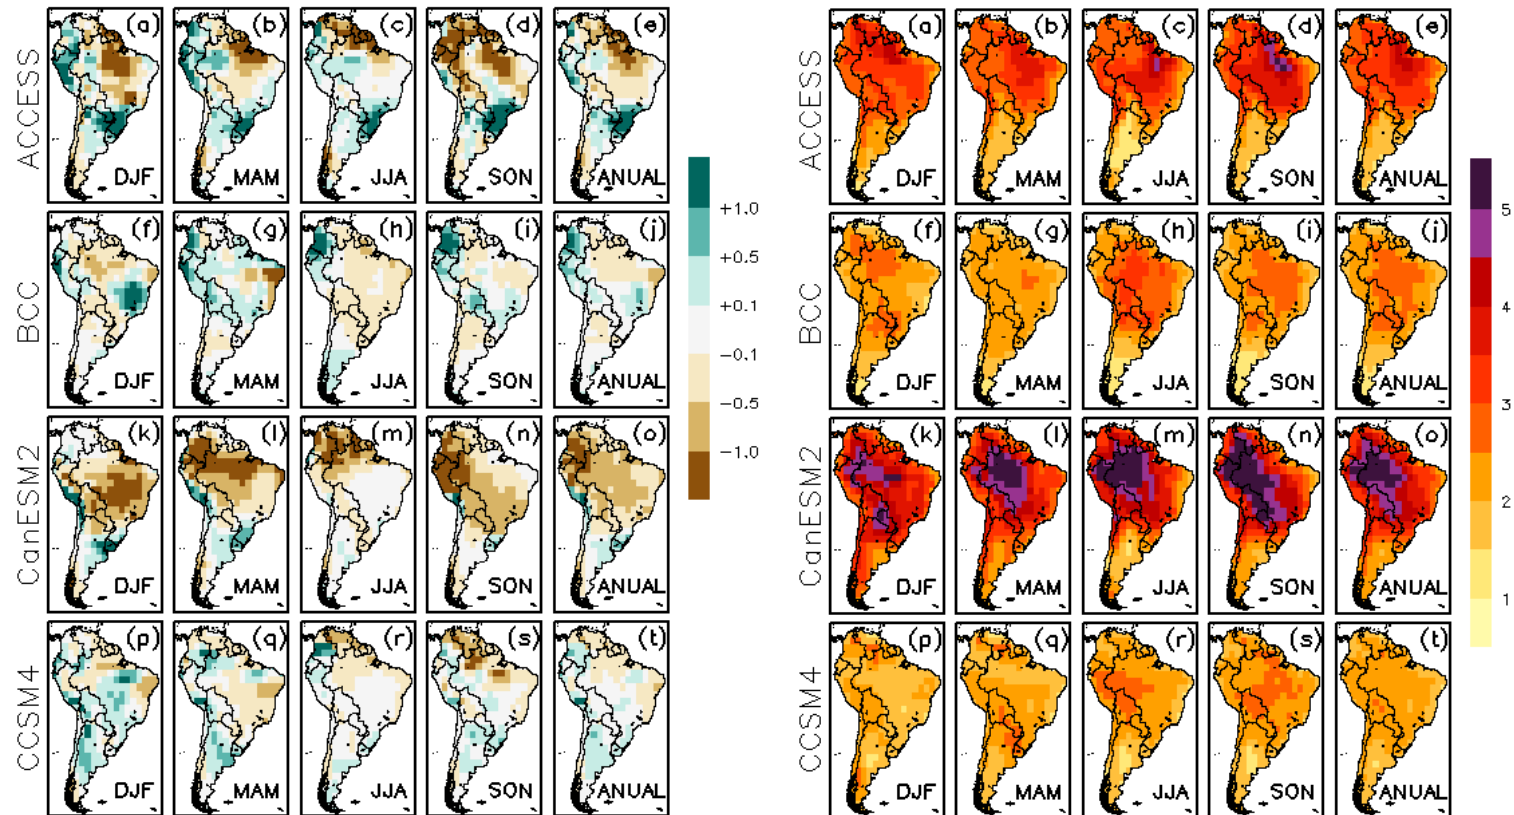


Figura B.2 – Mudanças sazonal e anual de temperatura do ar próximo à superfície (painéis da direita) e precipitação (painéis da esquerda) projetadas para o final do século XXI (2071-2100) no cenário de emissões RCP4.5, provenientes do conjunto CMIP5. As mudanças são definidas como a diferença entre os períodos de 2071-2100 e 1961-1990. As unidades de temperatura e precipitação são °C e mm.dia⁻¹, respectivamente.

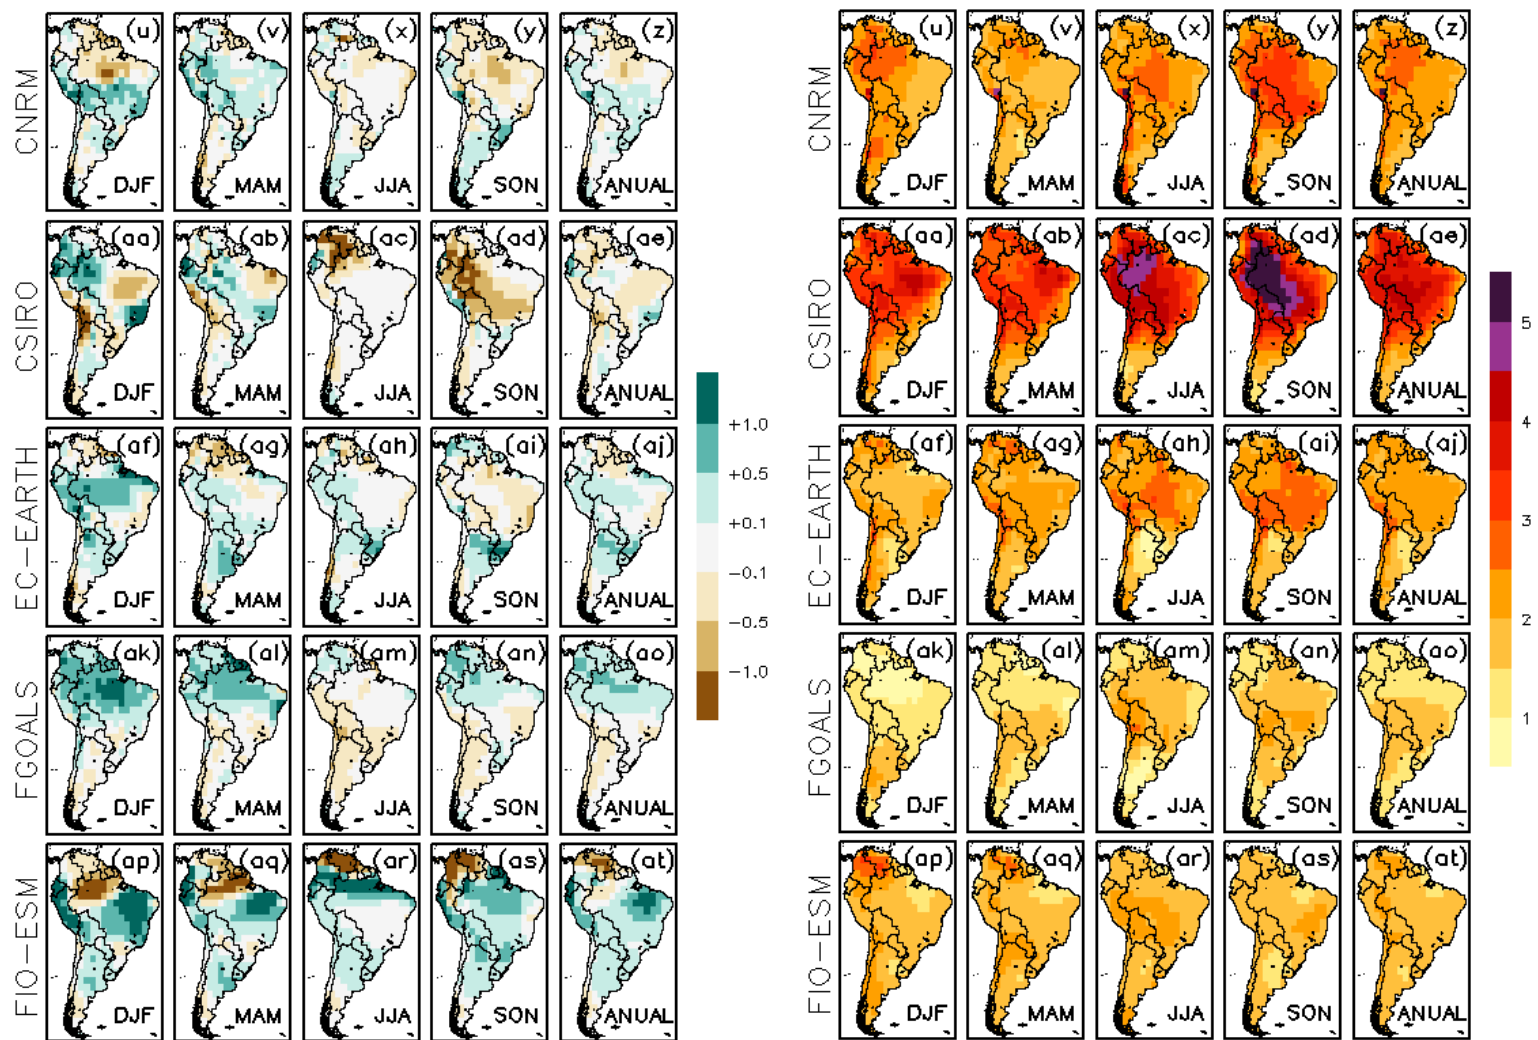


Figura B.2 – Continuação

(continua)

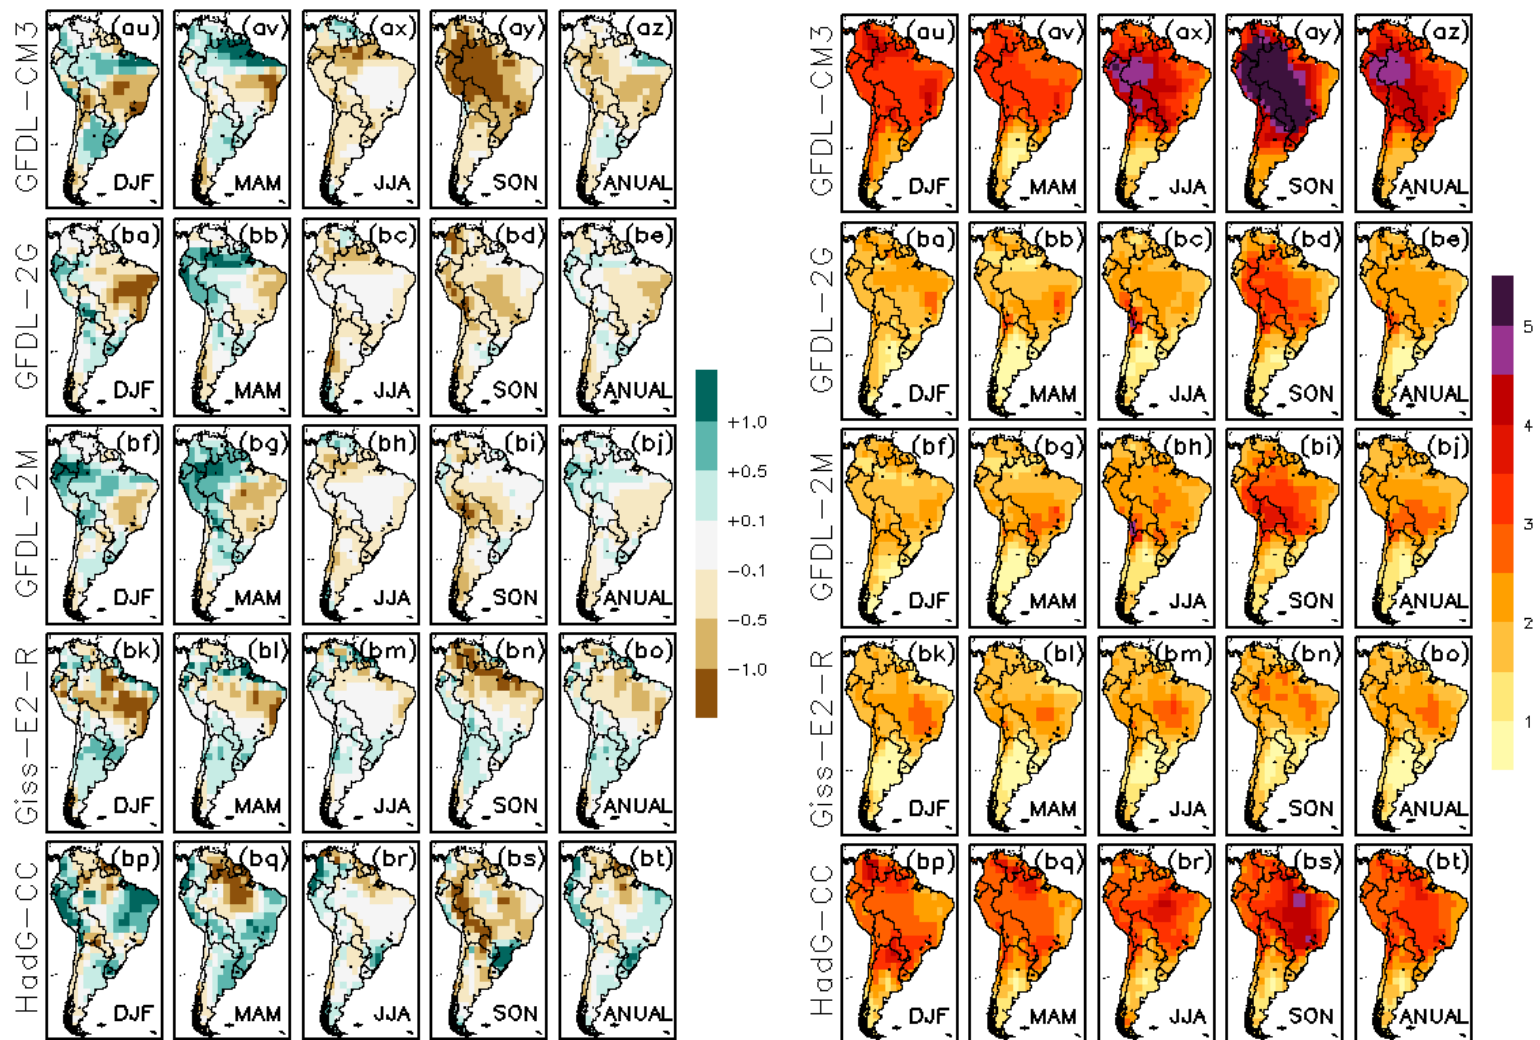


Figura B.2 – Continuação

(continua)

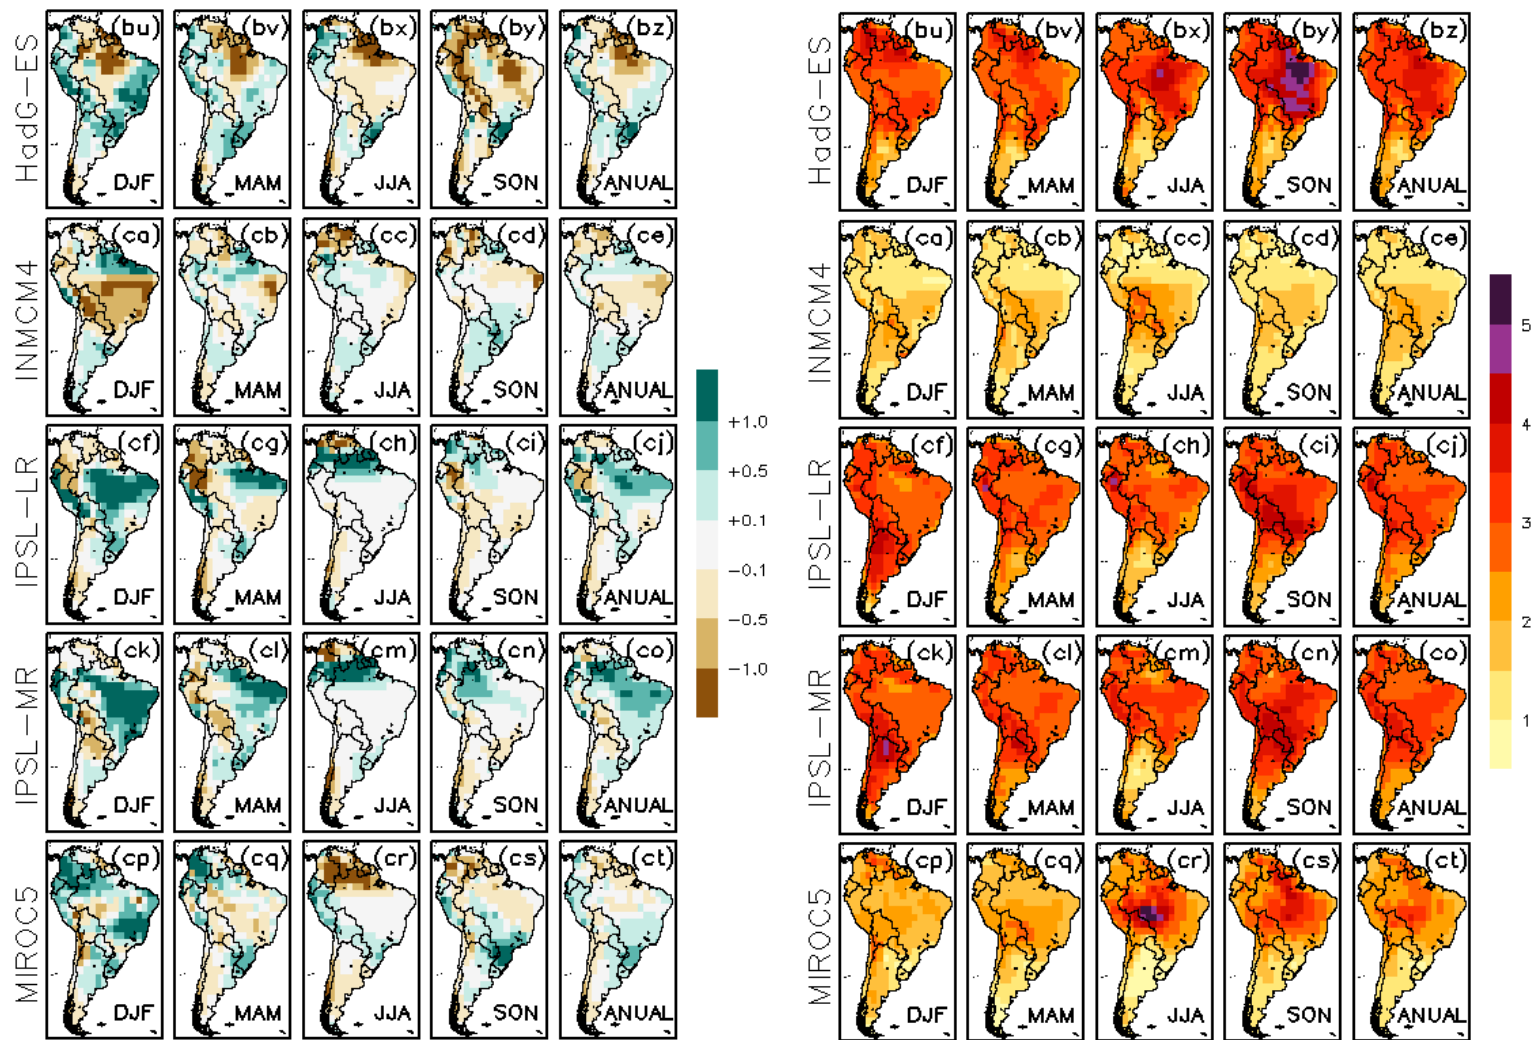


Figura B.2 – Continuação

(continua)

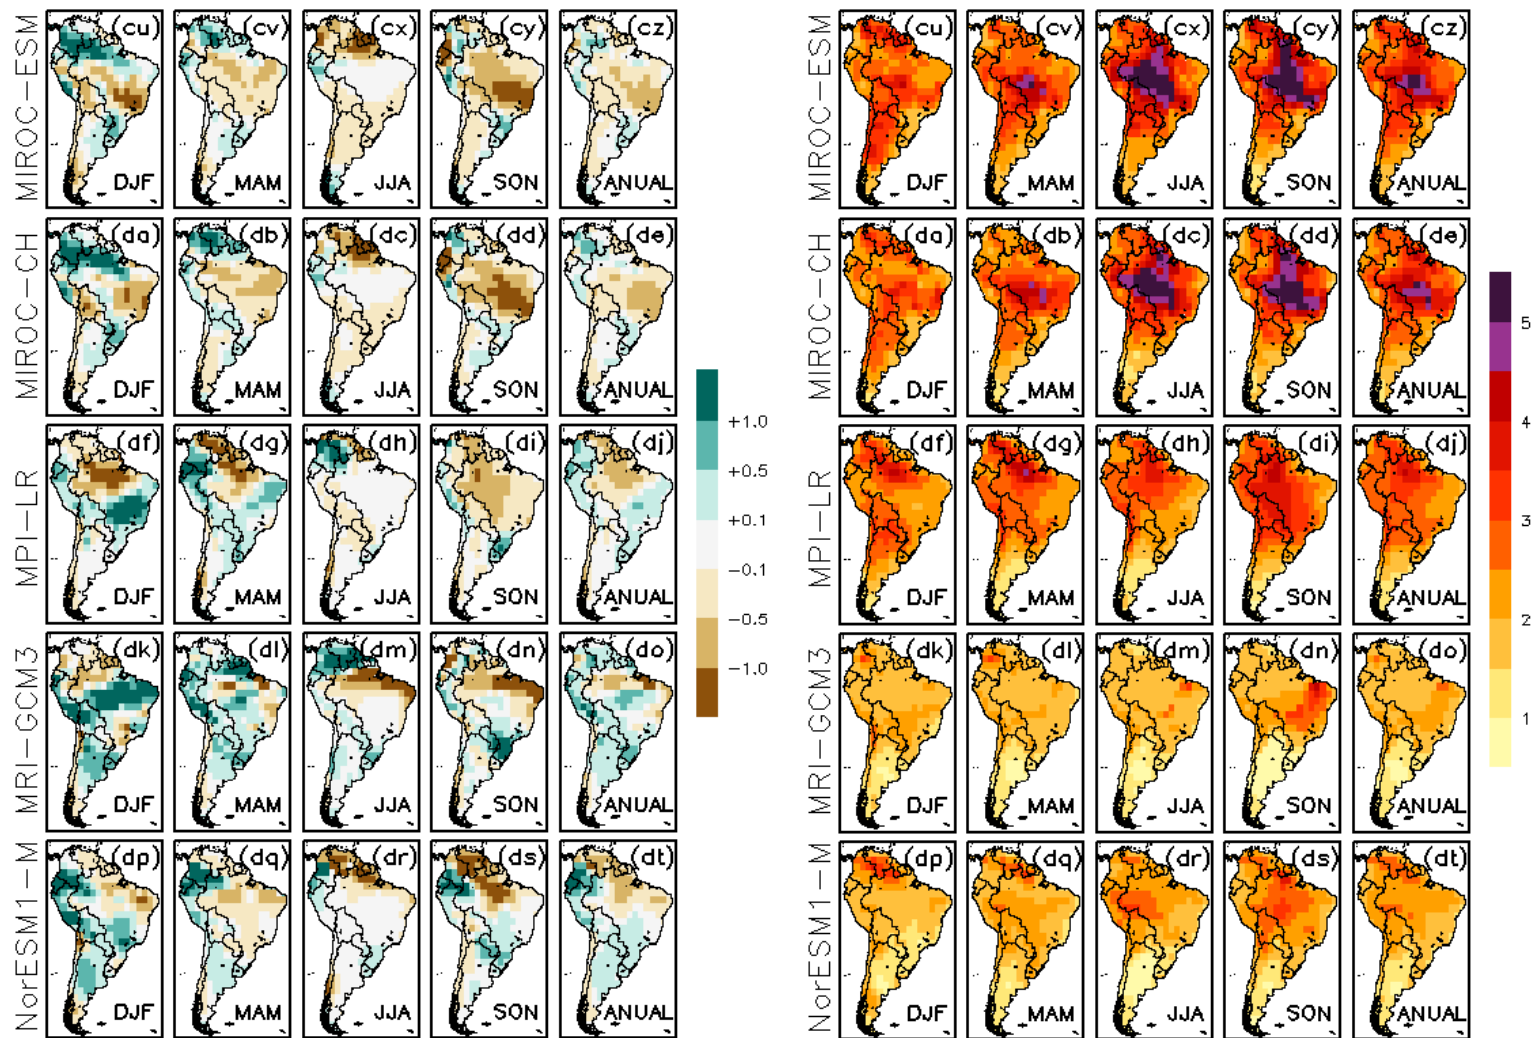


Figura B.2 – Conclusão.

ANEXO A – PRIMEIRO ARTIGO PUBLICADO NO PERIÓDICO *THEORETICAL AND APPLIED CLIMATOLOGY*

**UNCERTAINTY ASSESSMENTS OF CLIMATE CHANGE PROJECTIONS
OVER SOUTH AMERICA**

RESUMO

Este artigo avalia as incertezas envolvidas nas projeções de mudanças sazonais de temperatura e precipitação sobre a América do Sul no século XXI. Simulações climáticas geradas por vinte e quatro Modelos de Circulação Geral são ponderados de acordo com o método *Reliability Ensemble Averaging* (REA). Os resultados mostram que a temperatura média REA é ligeiramente menor sobre a América do Sul quando comparado à média aritmética simples do conjunto. Uma maior confiabilidade nas projeções de temperatura é encontrada sobre a bacia do Prata, e um maior intervalo de incerteza é localizado na bacia Amazônica. Um aumento de temperatura superior a 2 °C apresenta-se com uma probabilidade muito grande (> 90%) para todo o continente sul-americano e em todas as estações, e um aumento que exceda 4 °C no final deste século é identificado como possível sobre o noroeste da América do Sul, bacia Amazônica, e Nordeste do Brasil. Para a variável precipitação, as mudanças projetadas possuem a mesma magnitude dos intervalos de incertezas e são comparáveis à variabilidade natural.

Uncertainty assessments of climate change projections over South America

Roger Rodrigues Torres · Jose Antonio Marengo

Received: 14 December 2011 / Accepted: 5 July 2012
© Springer-Verlag 2012

Abstract This paper assesses the uncertainties involved in the projections of seasonal temperature and precipitation changes over South America in the twenty-first century. Climate simulations generated by 24 general circulation models are weighted according to the reliability ensemble averaging (REA) approach. The results show that the REA mean temperature change is slightly smaller over South America compared to the simple ensemble mean. Higher reliability in the temperature projections is found over the La Plata basin, and a larger uncertainty range is located in the Amazon. A temperature increase exceeding 2 °C is found to have a very likely (>90 %) probability of occurrence for the entire South American continent in all seasons, and a more likely than not (>50 %) probability of exceeding 4 °C by the end of this century is found over northwest South America, the Amazon Basin, and Northeast Brazil. For precipitation, the projected changes have the same magnitude as the uncertainty range and are comparable to natural variability.

1 Introduction

Although the great scientific and computational advances over the last few decades have enabled a better understanding of the dynamics of the global climate system and greatly contributed to the analysis of the possible causes and the future impacts of climate change, the uncertainties in these climate projections based on numerical models continue to be high, with higher uncertainties on a regional scale. The uncertainties in the future projections of climate change arise from different sources and are introduced in the sequence of steps in the modeling process, thereby producing a cascade of uncertainties (Knutti et al. 2010; Giorgi 2005). Several factors contribute to uncertainties in climate simulations or projections: stochastic and nonlinear behavior of the climate system processes (that includes the natural variations in climate or internal variability), random aspects of the natural and anthropogenic forcings (e.g., volcanic eruptions and man-made greenhouse and aerosol emissions), feedback of the climate system to the external forcings, insufficient knowledge of the initial and boundary conditions of the complete system, and the model uncertainty, commonly subdivided into parameter uncertainty (uncertainty in the parameters that control the parameterized physical processes in climate models) and structural uncertainty (uncertainties in choices made when coding the resolved processes) (Giorgi 2005; Collins 2007; Tebaldi and Knutti 2007; Knutti et al. 2010).

To attempt to cover the range of uncertainties mentioned above, two approaches are usually employed: the use of multimodel ensembles with different initial and boundary conditions (Collins 2007; Tebaldi and Knutti 2007) and perturbed physics ensembles (Murphy et al. 2007). Additionally, those ensembles can also use several greenhouse gases (GHG) and aerosol emissions scenarios, such as those developed in the Intergovernmental Panel on Climate Change (IPCC) Special Report on Emissions Scenarios

R. R. Torres (✉)
Center for Weather Forecast and Climate Studies (CPTEC),
National Institute for Space Research (INPE),
Rodovia Presidente Dutra km 40,
12630-000 Cachoeira Paulista, São Paulo, Brazil
e-mail: roger.torres@cptec.inpe.br

R. R. Torres
Natural Resources Institute (IRN),
Federal University of Itajubá (UNIFEL),
Av. BPS, 1303,
37500-903 Itajubá, Minas Gerais, Brazil

J. A. Marengo
Earth System Science Center (CCST),
National Institute for Space Research (INPE),
Rodovia Presidente Dutra km 40,
12630-000 Cachoeira Paulista, São Paulo, Brazil

Published online: 01 August 2012

 Springer

(SRES), based on four storylines, which essentially attempt to cover the range of the possible future emissions under different nonintervention scenarios (Nakicenovic et al. 2000).

Because climate change projections possess an intrinsic level of uncertainty (Giorgi 2005), probabilistic considerations should be taken into account when analyzing future climate outcomes. However, the degree of uncertainty depends on the variables and spatial/temporal scales investigated. Many components of the climate system are chaotic but are believed to be predictable on large spatial scales and on decadal or longer time scales (Knutti 2008).

South America is one of the regions of the planet that is currently affected by extreme climate events and can be most affected by the projected future climate change (IPCC 2007; Meehl 2007a; Baettig et al. 2007; Torres et al. 2012). The region is vulnerable to current climate variability and extremes, mainly in the form of intense rain and floods or dry spells, and may be affected by more frequent extremes in a warmer climate (Marengo et al. 2010a, b; Rusticucci et al. 2010 and references therein). With an economy that is strongly based on agricultural production, highly dependent on hydroelectric generation and subject to the numerous social and environmental problems associated with development patterns and urbanization, this continent constantly suffers from temperature and precipitation extremes that cause enormous economic damage and casualties.

In recent years, several studies analyzed climate change projections over South America, which were mainly based on the general circulation models (GCMs) from the Coupled Model Intercomparison Project Phase 3 (CMIP3, Meehl 2007b; Boulanger et al. 2006, 2007; Vera et al. 2006; Vera and Silvestri 2009; Bombardi and Carvalho 2009; Marengo et al. 2010a; Rusticucci et al. 2010; Seth et al. 2010). Various studies also analyzed the climate projections in this region using downscaling methods (Nuñez et al. 2008; Urrutia and Vuille 2009; Boulanger et al. 2010; Marengo et al. 2009, 2010b, 2012 and references therein; Chou et al. 2012). Among these studies, none of the models have a superior performance in representing the current climate. The performance of the models varies according to the region, time scale, and variables analyzed. Furthermore, few of these studies analyzed the uncertainties in the climate change projections over the region in a systematic and probabilistic way, and sometimes, they used only a small subset of all the GCMs available in the CMIP3.

A common method to synthesize the results of an ensemble prediction (or projection) is to produce a simple average of its members, where each member is assigned an equal probability of occurrence. This approach has been shown to be useful in producing results closer to the actual observations that are better than any single member of the ensemble

model (Ebert 2001). Other techniques proposed to cope with different climate projections are to subselect the models with the best performance over a region (and consequently throwing out the models with the worst performance), model weighting of the entire ensemble (e.g., assigning different weights to models according to its performance in simulating the present climate), and the use of a probabilistic approach, in which the results of several models are employed to produce a probability or cumulative density function (PDF or CDF, respectively) (Giorgi 2005; Collins 2007). Several methodologies have been proposed to generate these functions based on the statistical processing of large- or medium-sized ensemble simulations performed with models of varying complexity (Wigley and Raper 2001; Giorgi and Mearns 2002, 2003; Greene et al. 2006; Murphy et al. 2007; Tebaldi et al. 2005; Tebaldi and Knutti 2007; Xu et al. 2010; and citations quoted therein).

Giorgi and Mearns (2002) proposed a method, based on a weighted mean of the different GCMs that account for the “reliability” of each model, which is called reliability ensemble averaging (REA). In the REA approach, this reliability is determined by taking into account the ability of a particular model to simulate the observed climate (by measuring the bias) and the degree of convergence of its projected climate change with respect to the other models in the ensemble. This method allows an assessment of the credibility of the ensemble mean climate change, the calculation of an uncertainty range, and the production of probabilistic outcomes (Giorgi and Mearns 2002, 2003). The REA method is considered to be a flexible tool that can be applied on both global and regional scales, and has been applied in several studies (Giorgi and Mearns 2003; Moise and Hudson 2008; Xu et al. 2010; Kim and Lee 2010; Tao et al. 2012). Because of the various types of information generated and the simplicity of its implementation, this method was chosen for this study as a first assessment of the uncertainties in the climate change projections for South America.

Therefore, based on the complexity of the problems outlined above and the remaining need for detailed information on the climate change uncertainties in the model projections for South America, this paper performs an assessment of the uncertainties in climate change projections for this part of the world using the REA approach to analyze 24 GCMs from the CMIP3 dataset in three different nonintervention emissions scenarios. This paper focuses on the uncertainties due to intermodel variability and, to some extent, due to uncertainties in the future GHG and aerosol emissions. Furthermore, this study aims to produce mean and probabilistic projections for the changes in the mean surface air temperature and precipitation over the entire South American continent while coping with the involved uncertainties.

2 Data and methods

2.1 Data

This study uses simulations and projections of the mean precipitation and surface air temperature generated by 24 GCMs from the CMIP3 dataset used in the IPCC Fourth Assessment Report (IPCC AR4, Solomon et al. 2007). More details about the models and simulations can be found in Randall et al. (2007, Table 8.1) and Meehl et al. (2007a, b) and on the Program for Climate Models Diagnosis and Intercomparison website (http://www-pcmdi.llnl.gov/ipcc/about_ipcc.php).

Climate simulations for the twentieth century (20C3M) and projections for the twenty-first century for three different GHG and aerosol emissions scenarios, SRES B1, A1B, and A2 (Nakicenovic et al. 2000), are used in the seasonal averages for the periods 1961–1990 (present time), 2041–2070, and 2071–2100 (future time slices). These scenarios correspond to an equivalent CO₂ concentration in 2100 of approximately 550 (B1), 700 (A1B), and 850 ppm (A2). Throughout this work, the changes are referenced to the averaged 1961–1990 period. When more than one model run per experiment is available, the mean of all the analyzed model runs is used. This is possible because the averages over time slices of more than 10 years do not differ substantially between different runs of the same model experiment, and because these differences are much smaller than the comparison between different models (Giorgi and Francisco 2000; Knutti 2008). All of the model simulations for the twentieth century are compared against the observed surface air temperature and precipitation from the CRU TS 3.0 dataset (Mitchell and Jones 2005) produced by the University of East Anglia Climate Research Unit.

The spatial resolution of the GCMs varies from approximately 1° to 5° (Randall et al. 2007, Table 8.1), and for intercomparison purposes, the model runs and the observed data are interpolated to a common 2.5°×2.5° grid. REA calculations are performed using all of the simulations and projections for each South American land grid point, but some area averages of the results are taken into account in four key subregions: the eastern and western Amazon Basin (EAMZ and WAMZ, respectively), Northeast Brazil (NEB), and the La Plata Basin (LPB, Fig. 1). These regions were chosen because they represent different climatic conditions during El Niño and La Niña events, as well as sea surface temperature anomalies in the tropical Atlantic (Ambrizzi et al. 2004; Nobre et al. 2006). Moreover, these regions have presented different signals of precipitation change among the climate models projected by the end of the twenty-first century (Meehl et al. 2007a; Marengo et al. 2010b).

2.2 Reliability ensemble averaging

In the REA approach (Giorgi and Mearns 2002), the mean change for a climate variable ξ ($\tilde{\Delta}\xi$) projected by a set of models is given by the weighted average of each ensemble member projected change ($\Delta\xi_i$) as:

$$\tilde{\Delta}\xi = \frac{\sum_i R_i \Delta\xi_i}{\sum_i R_i}, \quad (1)$$

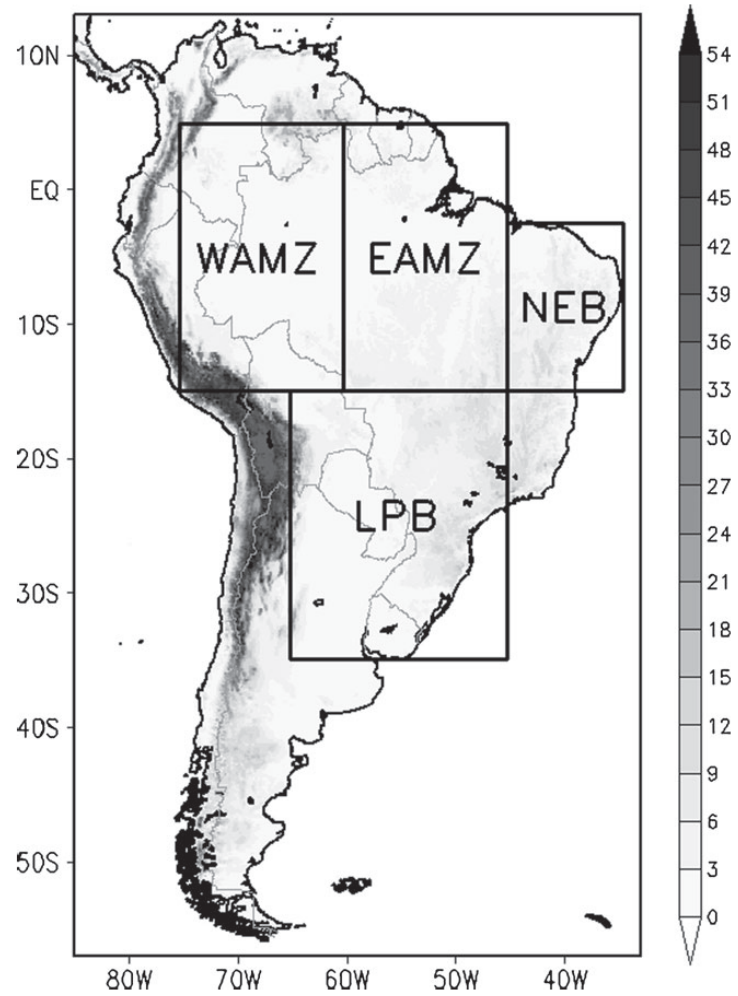
where R_i is the reliability factor of the model defined by

$$R_i = \left[(R_{B,i})^m \times (R_{D,i})^n \right]^{1/(m \times n)} \\ = \left\{ \left[\frac{\varepsilon_\xi}{\text{abs}(B_{\xi,i})} \right]^m \left[\frac{\varepsilon_\xi}{\text{abs}(D_{\xi,i})} \right]^n \right\}^{1/(m \times n)}. \quad (2)$$

$R_{B,i}$ is a factor that measures the model reliability as a function of its bias ($B_{\xi,i}$) when simulating the variable ξ in the current climate, that is, the higher the bias, the lower the model reliability. $R_{D,i}$ evaluates the model reliability in terms of the distance ($D_{\xi,i}$) between its projected change and the ensemble REA mean, that is, an outlier model result is downweighted. In other words, $R_{B,i}$ and $R_{D,i}$ represents the model's performance and convergence criteria, respectively. Equations (1) and (2) establish that a given model projection is said to be more reliable when its bias and distance to the REA mean are within the natural variability of the analyzed variable (ε_ξ), such that $R_B = R_D = 1$. Parameters m and n were introduced by Giorgi and Mearns (2002) to balance both criteria differently, but for simplicity, in this work, it was assumed that $m=n=1$.

The convergence criteria is based on the hypothesis that, for a given emission scenario, if the climate change signals produced by the different climate models are not very sensitive to the differences among the models, these signals are said to be more reliable, and the ensemble model average could converge to the future climate conditions. However, as emphasized by Giorgi and Mearns (2002), the distance to the REA mean is only an estimate of the convergence criteria because the future conditions are not known. Moreover, the REA mean is not intended to be the true climate response to a given forcing scenario, but rather a better estimate of it. In this study, just as in Giorgi and Mearns (2002), the natural variability of the surface air temperature and precipitation are estimated for each grid point by taking the difference between the highest and minimum values of the observed time series (1901–2000), after removing the linear tendency of the data and applying a running mean filter to average-over fluctuations shorter than 30 years.

Fig. 1 The topography ($\times 10^2$ m) and domain of the study. Boxes indicate the key subregions used in the analysis: the eastern and western Amazon Basin (*EAMZ* and *WAMZ*, respectively), Northeast Brazil (*NEB*) and the La Plata Basin (*LPB*)



Through the parameters defined above, the uncertainty range around the REA mean change ($\tilde{\delta}_{\Delta\xi}$) and the ensemble reliability ($\tilde{\rho}$) can be estimated by

$$\tilde{\delta}_{\Delta\xi} = \left[\frac{\sum_i R_i (\Delta\xi_i - \tilde{\Delta\xi})^2}{\sum_i R_i} \right]^{1/2} \tag{3}$$

and

$$\tilde{\rho} = \frac{\sum_i R_i^2}{\sum_i R_i} \tag{4}$$

Additionally, the reliability factors can also be used to estimate the probability of future climate change based on a GCM ensemble (Giorgi and Meams 2003). However, Giorgi and Meams (2003) emphasized that the probability of occurrence

of a certain climate change is unknown, and therefore, the model performance in predicting climate change cannot be evaluated. Moreover, the PDF of the simulated changes is also unknown because this would require a larger set of model simulations. Therefore, some hypotheses must be made during the construction of these functions (e.g., assuming that the models can predict the future climate, that the available model results encompass the total related uncertainty range, and that all models are independent) and the results must be carefully analyzed. For example, the hypothesis of the independence of the models in ensembles, such as the CMIP3 dataset, is one of the main caveats of model weighting studies, such as the one discussed here. Most of the models exhibit strong similarities due to factors that included their being developed at the same institution, their sharing versions of the same atmospheric or oceanic components, and/or their being successive versions of the same model (Masson and Knutti 2011). This model

dependency reduces the effective sample size in the ensemble averaging process.

According to Giorgi and Mearns (2003), the probability of occurrence of a climate change projection simulated by a model i (P_{m_i}) can be considered to be proportional to the normalized reliability parameter defined in Eq. (2), i.e.,

$$P_{m_i} = \frac{R_i}{\sum_{j=1}^N R_j}, \quad (5)$$

where N represents the number of different GCMs. In other words, it is assumed that a climate change simulated by a model with a higher reliability parameter value is more likely to occur.

The construction and validation of a PDF (or CDF) are far from being a trivial task. First, to evaluate the PDFs generated from model ensembles, an observed and well-representative distribution of the present climate variability must be created, which is not easy to accomplish because of the geographically sparse data and the lack of extended and continuous observational climate data information, especially for South America. Due to this basic restriction, the validation of any model-based PDF is compromised, when a real PDF distribution of the current climate is not known. Second, a good model-based PDF should be constructed (ideally) from a very large sample of hundreds of simulations of the same model at a high spatial resolution, and this large number of simulations should be performed for each of several different models, a task that is very computationally expensive and not feasible. Because of this, it is difficult to establish one methodology to construct the PDFs or to determine the PDF results as being more suitable or reliable. All of the studies (including the present study) are limited to a relatively small sample size of simulations and observations. However, although REA is a very simple methodology, the PDFs generated by this method are in agreement with and are quite comparable to more sophisticated methodologies presented in the literature (Tebaldi et al. 2005; Tebaldi and Knutti 2007; Greene et al. 2006; Furrer et al. 2007).

3 Results

Before analyzing the climate change projections, a spatial analysis of the GCM ensemble mean's representation of the present time seasonal climatology (1961–1990) was performed for the surface air temperature and precipitation. In general, the ensemble mean well represents the South American monsoon system and the associated South Atlantic Convergence Zone, characterized by the north-west/southeast migration of the maximum rainfall amounts from the Amazon Basin to the southeast Atlantic (Fig. 2a–h). However, overestimation of the rainfall is observed for

almost all seasons (except for JJA) over the central Andes (with values larger than 4 mm day^{-1} in the DJF and the SON) and in the DJF over Northeast Brazil ($\sim 1\text{--}3 \text{ mm day}^{-1}$), and an underestimation is observed for all seasons in the central portion of the La Plata basin ($\sim 1\text{--}3 \text{ mm day}^{-1}$) and nearly all of the Amazon, eastern Colombia, Venezuela, Guyana, French Guyana, and Suriname ($\sim 1\text{--}4 \text{ mm day}^{-1}$; Fig. 2i–l). Regarding the simulation of the surface air temperature climatology, the ensemble average is very similar to the observed data, in which the temperature bias does not exceed 1°C over nearly the entire continent (Fig. 3a–h). Nevertheless, colder than observed temperatures are identified over the NEB and Center West Brazil (except for the SON) and the Andes, and higher temperatures are observed over Northeast Argentina (except for JJA) and over the Amazon Basin in the SON (Fig. 3i–l).

Poor representation of the current climate conditions over the Andes can be related to, among other things, the coarse model resolution that does not allow a good representation of the complex topography of this region. Furthermore, as shown by Seth et al. (2010), the ensemble mean exhibits a weaker moisture transport to the east of the Andes, which can be one of the factors inducing an underestimation of the rainfall over the La Plata basin for all seasons, especially during the austral winter (Fig. 2i–l). In fact, over the Amazon Basin, the systematic rainfall underestimation by the models can be related to many factors, such as the poor representation of cumulus convection, the biosphere–atmosphere interactions in the rainforest, soil moisture, and land surface processes. On the other hand, there is poor data observation coverage in some portions of South America, mainly in the Amazon Basin, in which few meteorological stations are available, which slightly influences the magnitude and location of the bias patterns (mainly for precipitation).

Kim et al. (2008), when analyzing the spatial and temporal variability of the global monsoon simulated by the CMIP3 models, grouped the models into three sets according to their spatial resolution (low-, medium-, and high-resolution group, corresponding to a horizontal resolution of $4\text{--}5^\circ$, $2\text{--}3^\circ$, and less than 2° , respectively), attempting to analyze the impact of this parameter in representing the global monsoon climate. Those authors concluded that although a slight improvement of the rainfall simulation over high topography was provided by the higher resolution models, any set performed better in representing the current climate conditions as a whole. Even those sets with coarser resolution exhibited results comparable to those with higher resolution. Therefore, it was decided to use all of the available models in our analysis, instead of using only those with higher resolution.

Analyzing the climate change projections, all of the CMIP3 models project a temperature increase in all of South America that is more intense in its tropical continental

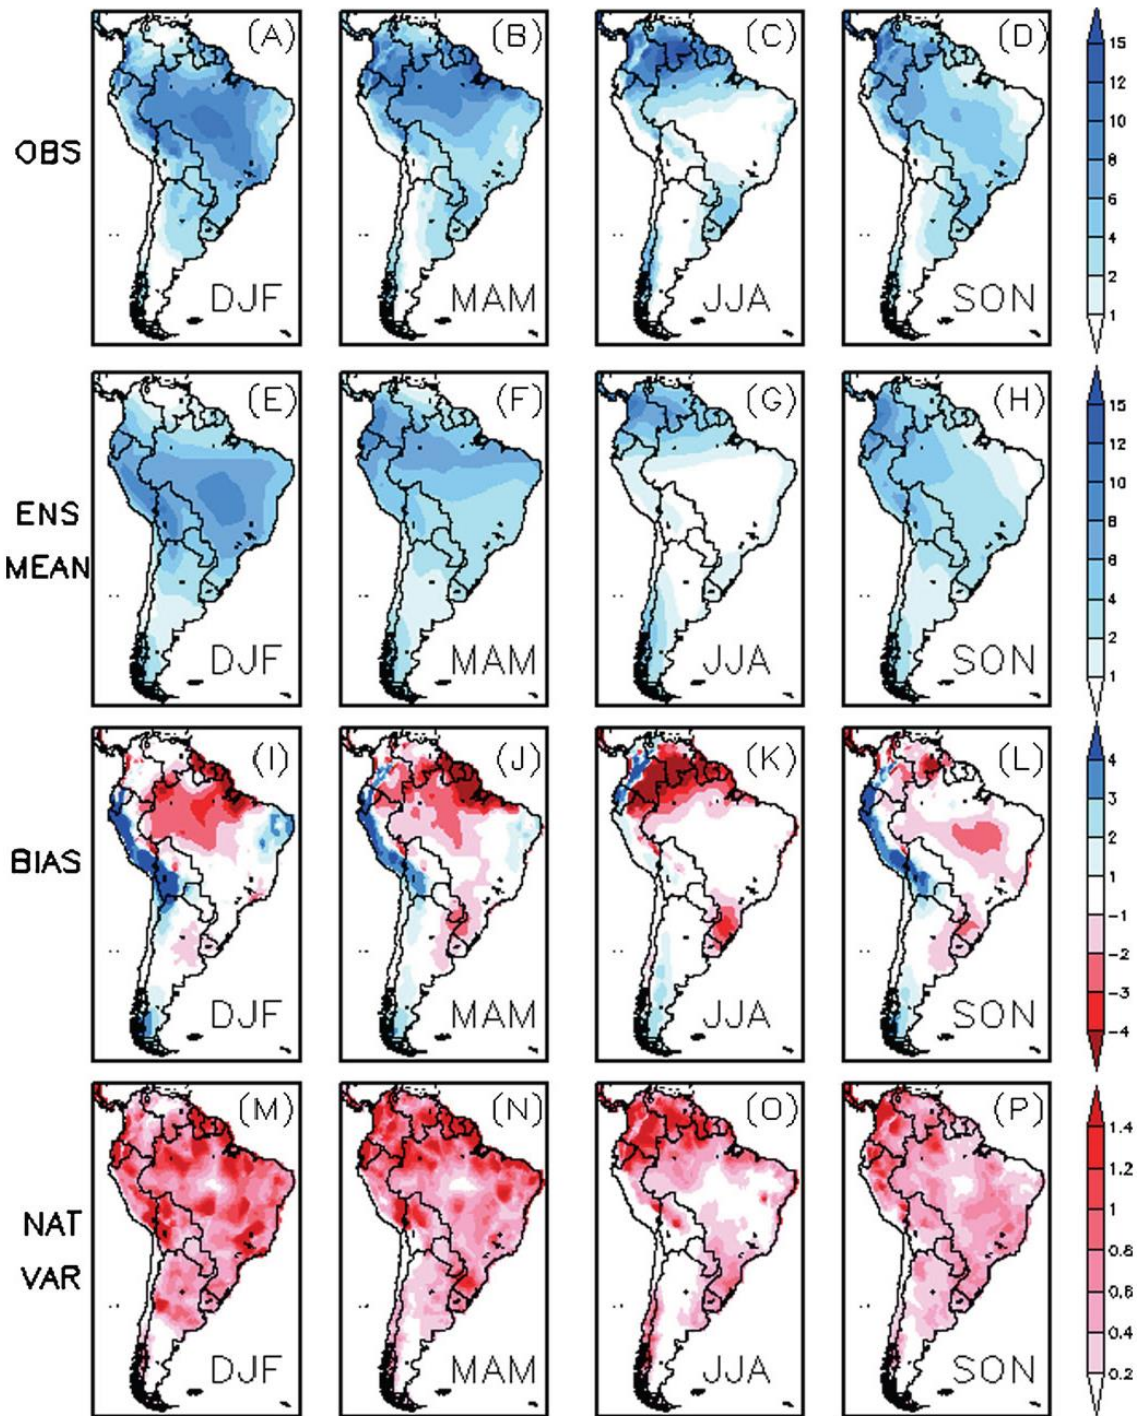


Fig. 2 Observed (a–d) and ensemble mean (e–h) patterns of seasonal precipitation and bias (i–l) for 1961–1990. The natural variability of precipitation (m–p) was calculated for the period from 1901 to 2000. Units are in millimeters per day

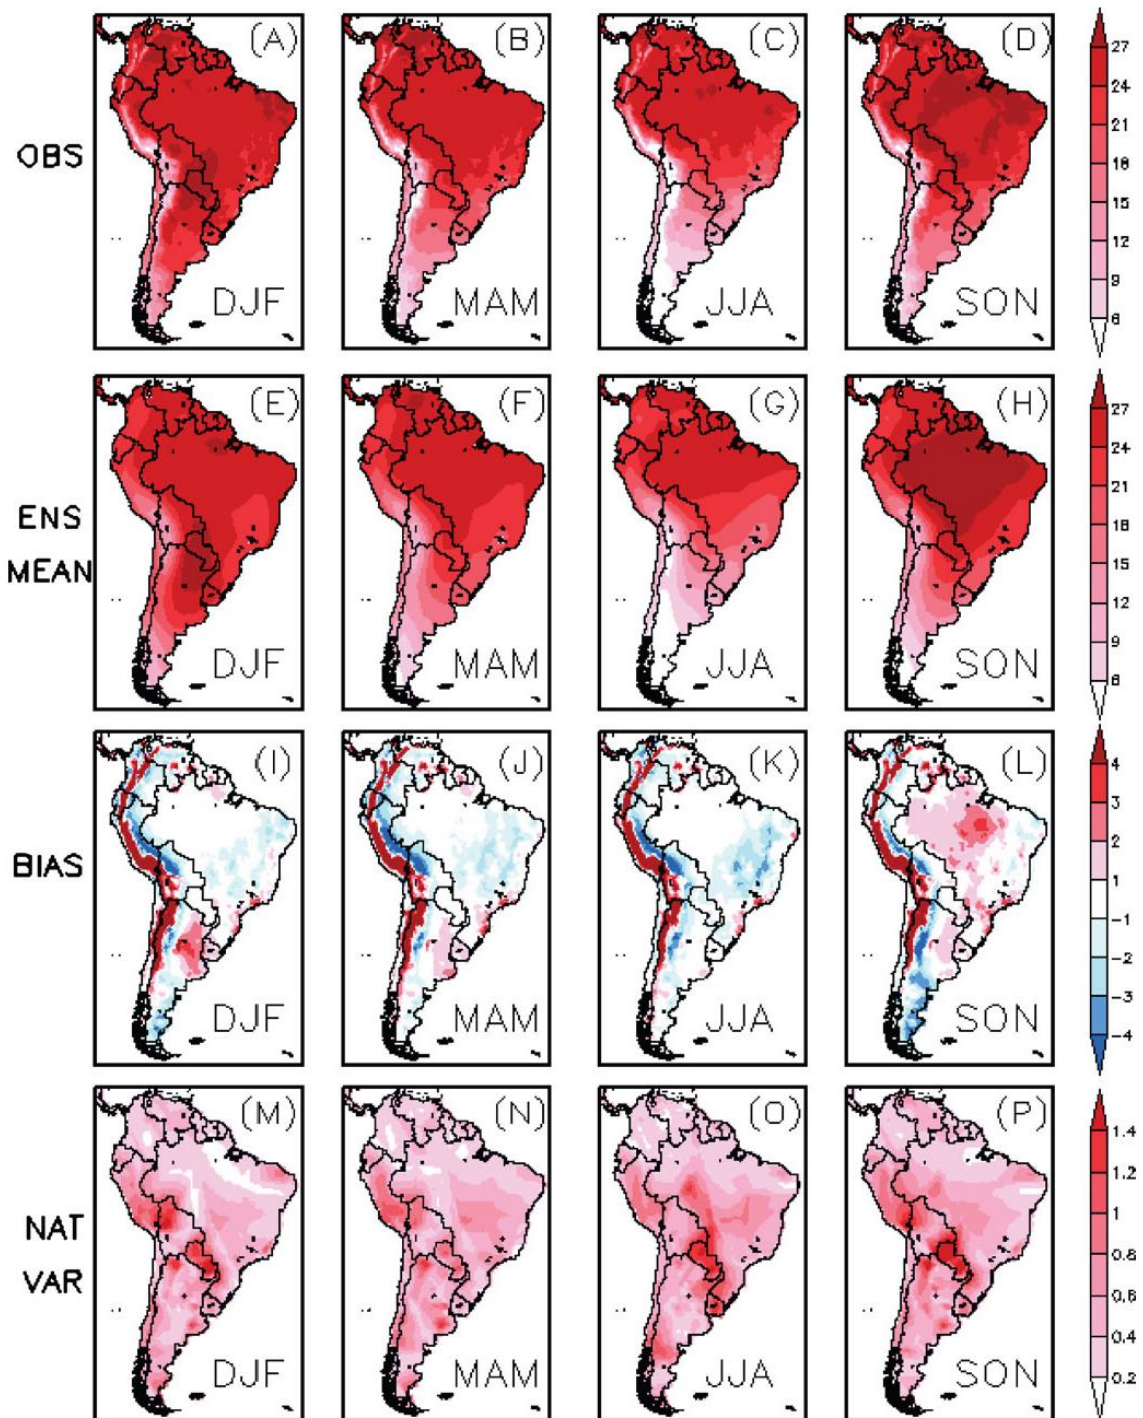


Fig. 3 a–p The same as in Fig. 2, but for seasonal surface air temperature (in degrees Celsius)

portion and by the end of the century in higher emissions scenarios. According to the ensemble mean, the temperature change could reach above 4 °C in the Amazon Basin from June to August by 2071–2100 in the SRES A2 scenario (Fig. 4c, d). For the South American continent as a whole, the range of temperature change is between 1.3, 1 and 4, and 2 and 5 °C for the SRES B1, A1B, and A2 emissions scenarios, respectively (Fig. 4). Similar results can be found in Meehl et al. (2007a).

Regarding the projected changes in precipitation, the ensemble mean indicates an increase of rainfall in the austral summer in nearly all of South America by 2071–2100, except for the eastern NEB, Patagonia, and the northern tip of South America, where rainfall is projected to decrease

for all seasons (Fig. 5). The ensemble mean also indicates an increase of rainfall for the LPB, the western Amazon (WAMZ), Peru, Ecuador, and southern Colombia in the MAM, and marked reductions over the eastern Amazon (EAMZ) and the NEB in the SON. The patterns of change are quite similar for the other emissions scenarios, differing only in the magnitude of the changes (Fig. 5). However, unlike the temperature projections, the uncertainty of the rainfall changes in a warmer climate is very high. As indicated by Meehl et al. (2007a) in the IPCC AR4, areas where the magnitude of the precipitation change is larger than the standard deviation among the CMIP3 models (a first approximation of the ensemble reliability) represent only a small portion of the world's domain and are virtually

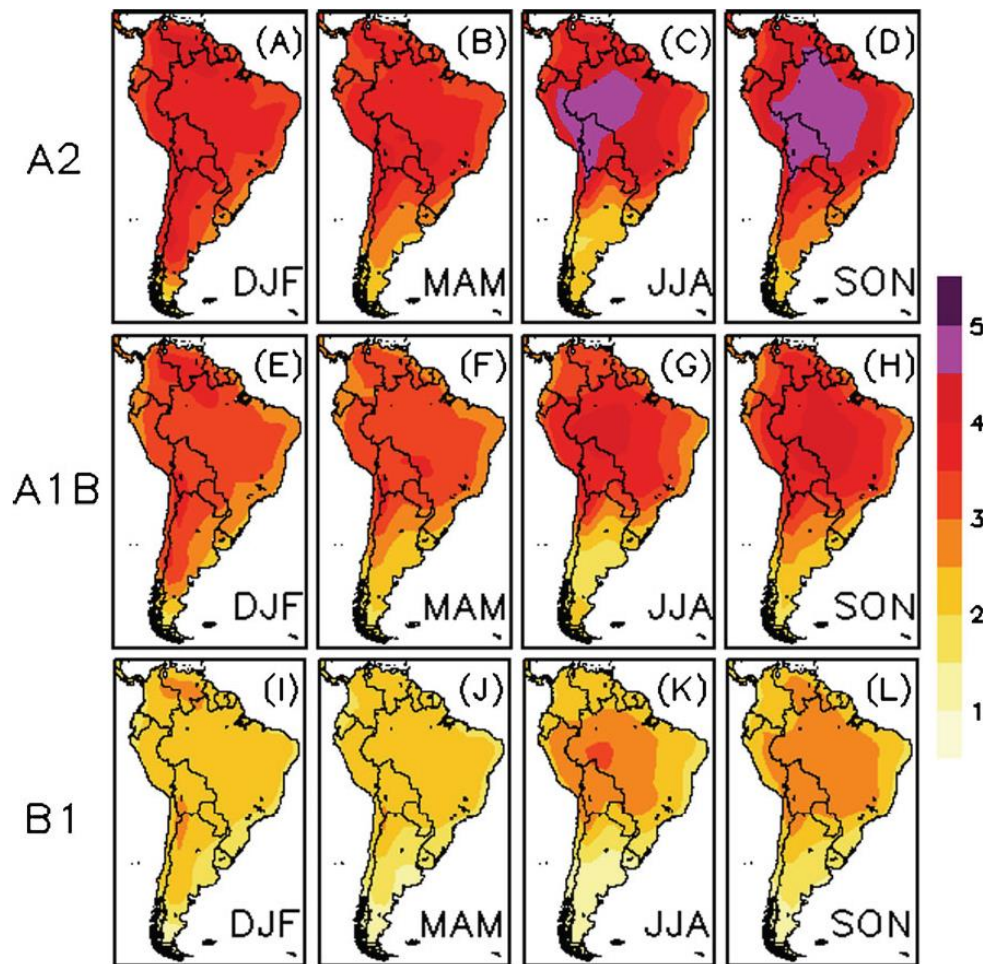


Fig. 4 Seasonal surface air temperature change (in degrees Celsius) projected by the end of the twenty-first century (2071–2100) in the SRES A2 (a–d, top), A1B (e–h, middle), and B1 (i–l, bottom)

emissions scenarios. The changes are defined as the difference between the periods from 2071–2100 to 1961–1990

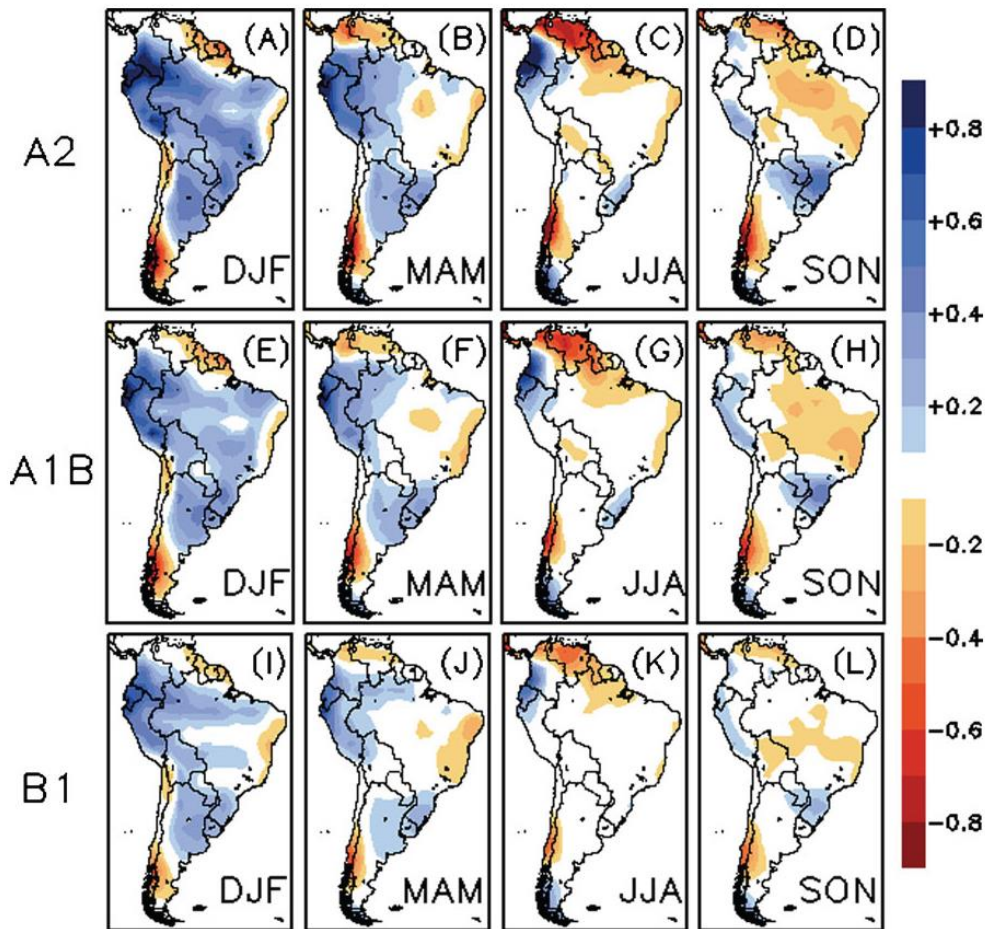


Fig. 5 a–l The same as in Fig. 4, but for the seasonal precipitation change (in millimeters per day)

nonexistent over the South American continent (except for some portions of southern South America in the DJF and for Northeast Brazil in the JJA).

As mentioned earlier, to account for the uncertainties involved in the climate change projections over South America, the REA method was applied to the surface air temperature and precipitation variables in the time slices 2041–2070 and 2071–2100, and the emissions scenarios SRES B1, A1B, and A2. To simplify the analysis, and based on the fact that the patterns of change differ only in their magnitude among the scenarios and time slices, we focus on the analysis of the period between 2071 and 2100 in the A2 emission scenario (higher emissions scenario).

When comparing the patterns of temperature change obtained by the simple average (i.e., when assigning the same weight to all of the ensemble members) and that obtained by the application of REA approach (Figs. 4 and 6), it is possible to notice that when taking into account the

reliability of models (measured by the performance and convergence criteria in the REA approach, as mentioned earlier), the magnitude of the temperature change projections decreases in nearly the entire domain and is more pronounced over the western Amazon Basin, where this decrease reaches approximately 0.5 °C by the end of this century. The Amazon Basin is the region that exhibits the largest discrepancies among the CMIP3 models regarding the magnitude of the expected temperature change pattern, as evidenced when analyzing the uncertainty range parameter ($\tilde{\delta}_{\Delta T}$, Fig. 6e h). High ensemble reliability ($\tilde{\rho}$) is found over the LPB region for all seasons and in Patagonia in the JJA (Fig. 6i l). Analyzing the two model reliability criteria separately, the convergence parameter (R_D) is found to be the dominant factor in determining the region of highest confidence in the studied domain (Fig. 6). Because the temperature bias has the same order of magnitude as the natural variability over nearly the entire South American

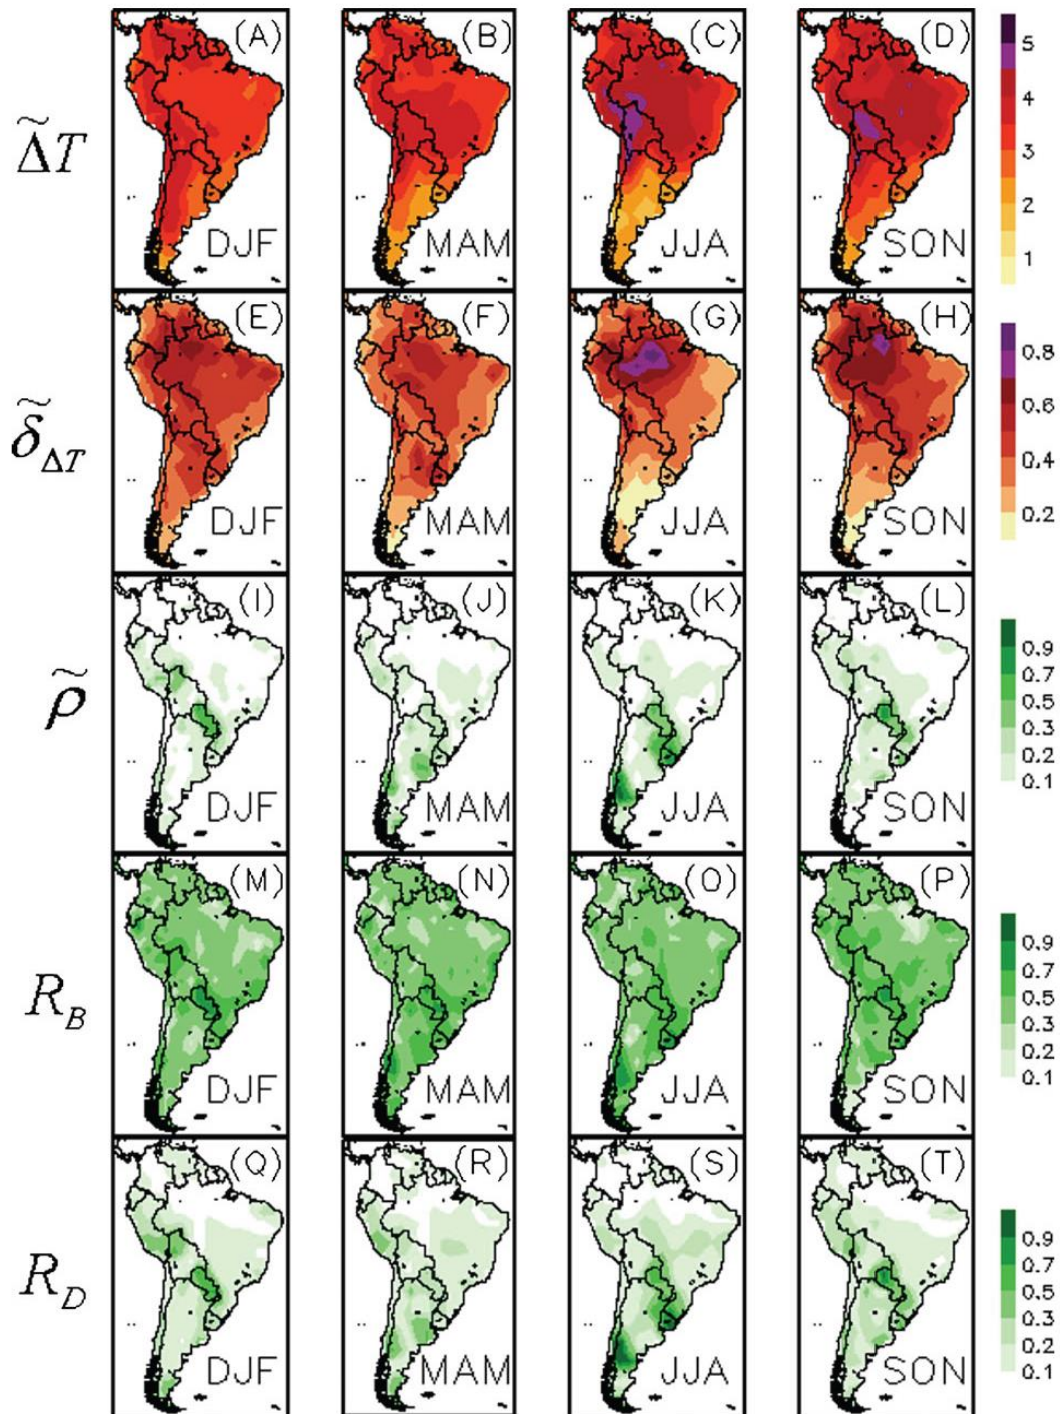


Fig. 6 REA mean (a–d), uncertainty range (e–h), ensemble reliability (i–l), and model performance and convergence parameters (m–p and q–t, respectively) for the seasonal surface air temperature projected for

2071–2100 in the A2 scenario. The REA mean and the uncertainty range are in degrees Celsius

region (Fig. 3i–p and m–p, respectively), high R_B values are found throughout the studied domain. As the range of the projected temperature change is large among the models and the natural variability is small (Fig. 3m–p), R_D is small, except in some seasons over Paraguay, Northwest Bolivia/southern Peru, southern Brazil, Uruguay, and southern Argentina, which possess high natural variability, as shown in Fig. 3m–p.

The REA average changes for precipitation (Fig. 7a–d) show no marked difference when compared with the simple ensemble mean (Fig. 5), except in northern Peru/southern Colombia in the DJF and eastern Amazonia in the SON, in which the magnitude of the projected precipitation change is reduced (approximately 0.4 and 0.2 mm day⁻¹, respectively). Large uncertainty ranges are noticeable over northern South America in all seasons, and over the Amazon Basin, NEB, and Center West Brazil in the DJF and the SON. The convergence parameter is greater than the performance parameter ($R_D > R_B$) because the model bias is larger than the magnitude of the projected rainfall changes, and the magnitude of the changes is small and comparable to the natural variability (Fig. 2m–p). The ensemble reliability is above 0.5 in nearly the entire South American continent, which may indicate that there is high reliability in a projection of no significant change. Similar results were found by Giorgi and Mearns (2002), when applying the REA method to a set of 18 different GCMs averaged over 22 continental regions covering the entire globe.

Tables 1 and 2 show the REA results for the rainfall and surface air temperature averaged in the key regions indicated in Fig. 1 for the periods 2041–2070 and 2071–2100, and in the SRES B1, A1B, and A2 scenarios, for the austral summer and winter. The REA approach, when applied to the temperature variable, in all regions, time slices, and scenarios, reduces the magnitude of change (by approximately 8 %) when compared with the simple ensemble mean. Furthermore, all REA mean temperature changes are larger than its associated uncertainty range and, as expected, the ensemble reliability decreases when analyzing higher emissions scenarios and more distant periods. Therefore, for 2071–2100 (2041–2070) in the A2 scenario, higher reliability is found over the LPB, as previously analyzed, where temperature increases can reach 3.1 ± 0.8 °C (1.9 ± 0.5 °C) in the austral summer and 3.3 ± 0.6 °C (1.9 ± 0.4 °C) in the austral winter. On the other hand, a higher uncertainty range is found in the Amazon Basin, where the results show a temperature increase of 3.3 ± 0.9 °C (3.9 ± 0.9 °C) in the austral summer (winter) over the eastern Amazon, and 3.5 ± 1.1 °C (4.2 ± 1.1 °C) in the austral summer (winter) for the western Amazon, for 2071–2100 (2041–2070) in the A2 scenario. For projections of the precipitation change, the uncertainty range, as derived by the REA approach, has the same order of magnitude as the projected change in all of the analyzed regions, scenarios, and time slices, indicating no significant change.

Based on the reliability factor, and as calculated through Eq. (5), Figs. 8, 9, and 10 show the probabilities of temperature and precipitation change. Figure 8 shows the seasonal probabilities of exceeding some temperature thresholds (2, 3, 4, and 5 °C) for 2071–2100 in the A2 scenario. There is a very likely (>90 %) probability that the temperature increase will be greater than 2 °C for the whole continent in all seasons. A more likely than not (>50 %) probability of exceeding 4 °C is found over northwest South America, the Amazon Basin, Bolivia, Peru, and NEB from June to November. Due to both the high uncertainty and lack of significant change, as highlighted in the previous results, the spatial probability maps of exceeding some rainfall thresholds are omitted here.

CDFs of the temperature and precipitation change in the SRES B1, A1B, and A2 scenarios for key regions are displayed in Figs. 9 and 10. Note, however, that for positive precipitation changes, the value in the curves yields the probability of being greater than a given threshold, and for negative precipitation, the changes are given by 1 minus the value in the curve. Steeper curves indicate regions with larger agreement among the GCM results.

From the CDFs for temperature, as all models project a positive temperature change over South America in all seasons, time scale and emission scenarios, the probability of warming is equal to 1. The probabilities of exceeding larger temperature change thresholds increase (and the agreement between the models diminish) from lower to higher emissions scenarios, and from 2041–2070 to 2071–2100. For the Amazon Basin, the probability of larger temperature increases over its western portion is larger than over its eastern one, and is larger for austral winter compared to summer. Except for the Amazon Basin, no significant difference was found between summer and winter in the other analyzed regions. The maximum temperature increase projected by a GCM inside the ensemble (indicated when the probability approach zero) by the end of this century is of the order of 4.0–5.5 °C in EAMZ, 4.5–5.5 °C in WAMZ, 3.5–4.5 °C in NEB, and 3.5–5.0 °C in LPB, in which the lower and higher values represent the B1 and A2 scenarios, respectively.

Investigating the CDF curves for rainfall, most of the models are distributed over zero change, except for the LPB and the WAMZ region, where the curves shift slightly toward positive values. Larger spread among the model results is observed over the NEB in the DJF. Moreover, there is a large disagreement in the signal of change among those models that indicate some precipitation change. However, changes in the amounts of precipitation appear to be more likely to occur in summer than in winter, in accordance with the patterns presented in Figs. 5 and 7. In general, the CDF curves indicate a high probability of no significant change in rainfall amounts in the two time slices and regions analyzed.

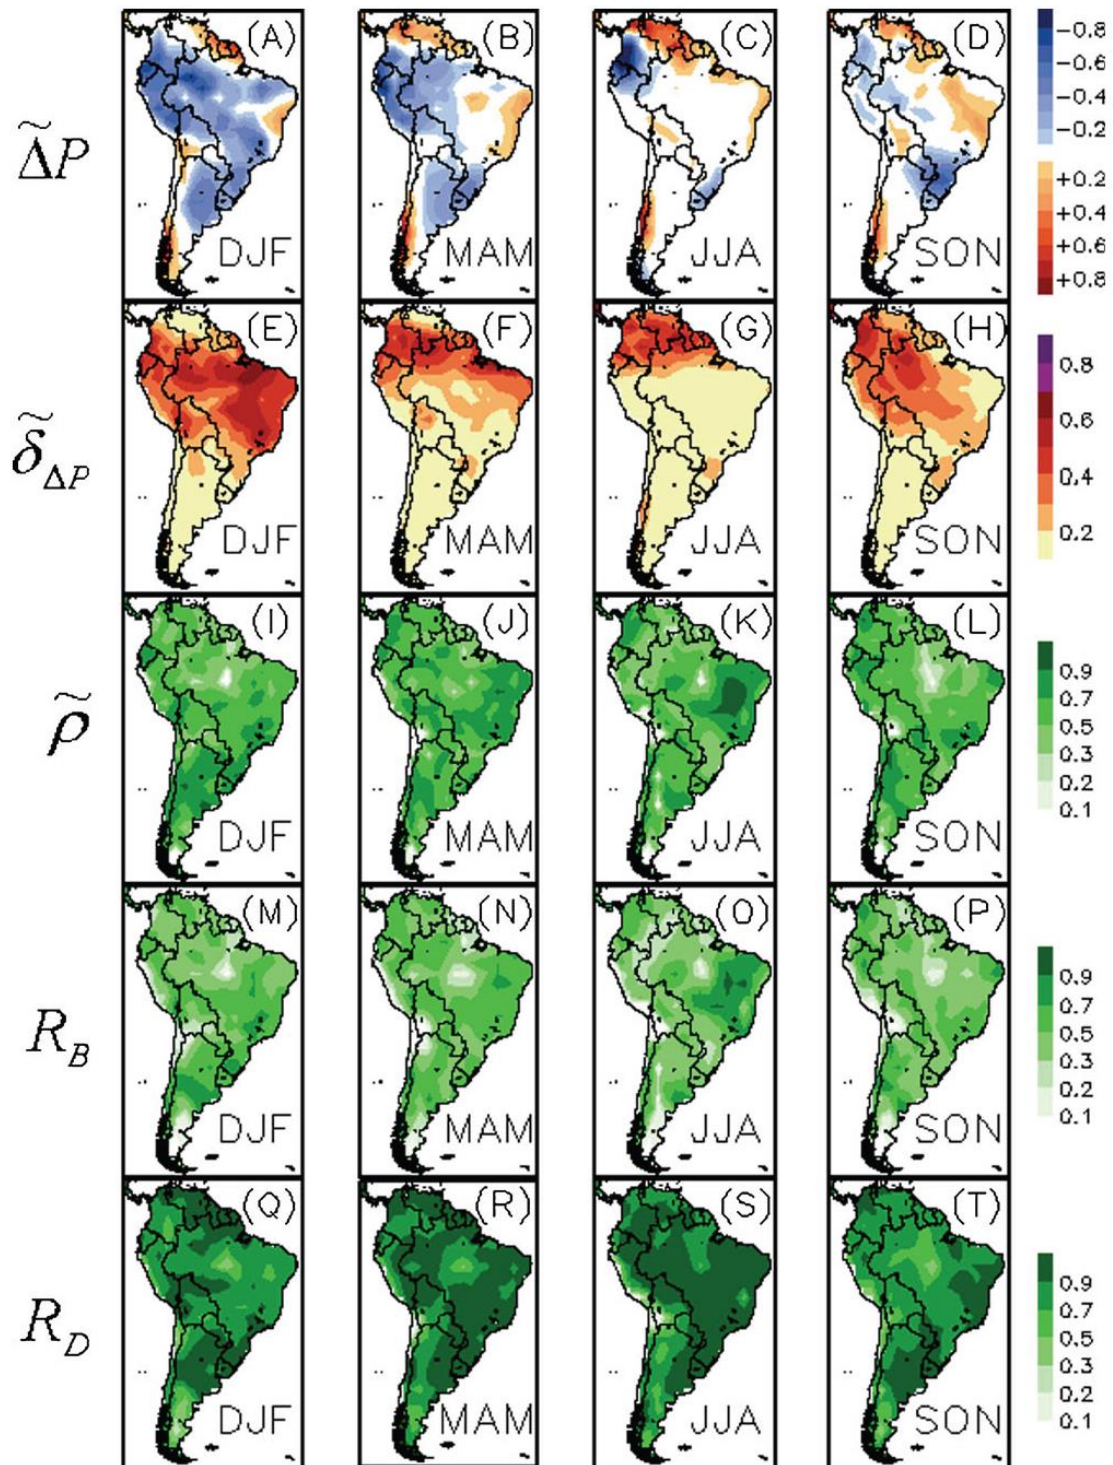


Fig. 7 a–t The same as in Fig. 6, but for the seasonal precipitation (in millimeters per day)

Table 1 Ensemble mean (ΔT_{ENS}), REA mean (ΔT_{REA}), uncertainty range (δ), ensemble reliability (ρ), and collective model convergence criteria (R_D) for the austral summer and the winter surface air temperature projected for 2041–2070 and 2071–2100 in the SRES A2, A1B and B1 scenarios

Region	Time scale		SRES	ΔT_{ENS}	ΔT_{REA}	δ	ρ	R_D
EAMZ	2041–2070	DJF	A2	2.2	2.0	0.5	0.10	0.16
			A1B	2.2	2.0	0.6	0.10	0.16
			B1	1.7	1.4	0.5	0.15	0.22
		JJA	A2	2.4	2.4	0.6	0.15	0.23
			A1B	2.5	2.3	0.6	0.17	0.22
			B1	1.9	1.7	0.5	0.26	0.32
	2071–2100	DJF	A2	3.6	3.3	0.9	0.06	0.09
			A1B	3.1	2.8	0.8	0.07	0.11
			B1	2.2	1.9	0.7	0.12	0.17
		JJA	A2	4.0	3.9	0.9	0.08	0.13
			A1B	3.5	3.3	0.9	0.11	0.15
			B1	2.5	2.2	0.7	0.19	0.24
WAMZ	2041–2070	DJF	A2	2.3	2.1	0.6	0.22	0.30
			A1B	2.3	2.1	0.6	0.22	0.30
			B1	1.8	1.6	0.5	0.28	0.39
		JJA	A2	2.6	2.5	0.6	0.15	0.22
			A1B	2.7	2.3	0.8	0.19	0.22
			B1	2.1	1.7	0.7	0.27	0.30
	2071–2100	DJF	A2	3.8	3.5	1.1	0.13	0.16
			A1B	3.3	3.0	1.0	0.15	0.20
			B1	2.3	2.0	0.7	0.24	0.30
		JJA	A2	4.4	4.2	1.1	0.08	0.12
			A1B	3.8	3.4	1.1	0.12	0.15
			B1	2.7	2.3	0.9	0.20	0.22
NEB	2041–2070	DJF	A2	2.0	1.8	0.6	0.16	0.23
			A1B	2.0	1.9	0.6	0.14	0.23
			B1	1.5	1.4	0.5	0.20	0.32
		JJA	A2	2.0	2.0	0.3	0.18	0.29
			A1B	2.0	1.9	0.4	0.21	0.30
			B1	1.5	1.4	0.4	0.28	0.32
	2071–2100	DJF	A2	3.3	3.0	0.8	0.09	0.13
			A1B	2.8	2.6	0.8	0.10	0.16
			B1	2.0	1.8	0.7	0.16	0.24
		JJA	A2	3.2	3.3	0.5	0.10	0.16
			A1B	2.8	2.7	0.5	0.13	0.20
			B1	1.9	1.8	0.5	0.21	0.32
LPB	2041–2070	DJF	A2	2.0	1.9	0.5	0.31	0.39
			A1B	2.0	1.8	0.6	0.32	0.39
			B1	1.5	1.3	0.5	0.42	0.52
		JJA	A2	2.0	1.9	0.4	0.42	0.56
			A1B	2.0	1.9	0.6	0.42	0.53
			B1	1.5	1.4	0.6	0.48	0.65
	2071–2100	DJF	A2	3.3	3.1	0.8	0.18	0.22
			A1B	2.9	2.6	0.8	0.22	0.27
			B1	2.0	1.8	0.7	0.35	0.40
		JJA	A2	3.3	3.3	0.6	0.25	0.32
			A1B	2.9	2.7	0.8	0.31	0.37
			B1	2.1	1.9	0.7	0.41	0.53

The ensemble, REA means and the uncertainty range are in degrees Celcius

Table 2 The same as in Table 1, but for the precipitation (in millimeters per day)

Region	Time scale		SRES	ΔP_{ENS}	ΔP_{REA}	δ	ρ	R_D	
EAMZ	2041–2070	DJF	A2	0.0	0.0	0.6	0.52	0.92	
			A1B	0.0	0.0	0.7	0.54	0.91	
			B1	0.0	0.0	0.5	0.56	0.94	
		JJA	A2	-0.1	-0.1	0.2	0.62	0.96	
			A1B	-0.1	-0.1	0.2	0.64	0.96	
			B1	-0.1	-0.1	0.2	0.63	0.97	
		2071–2100	DJF	A2	0.1	0.1	0.9	0.47	0.83
				A1B	0.1	0.1	0.9	0.51	0.85
				B1	0.1	0.1	0.6	0.54	0.90
	JJA		A2	-0.2	-0.1	0.3	0.60	0.91	
			A1B	-0.1	-0.1	0.3	0.64	0.93	
			B1	-0.1	-0.1	0.2	0.62	0.95	
	WAMZ	2041–2070	DJF	A2	0.2	0.2	0.6	0.57	0.93
				A1B	0.3	0.2	0.5	0.57	0.93
				B1	0.2	0.2	0.4	0.58	0.98
JJA			A2	0.0	0.0	0.3	0.49	0.97	
			A1B	-0.1	-0.1	0.3	0.49	0.96	
			B1	-0.1	-0.1	0.3	0.45	0.97	
2071–2100			DJF	A2	0.5	0.4	0.7	0.54	0.85
				A1B	0.3	0.3	0.7	0.54	0.87
				B1	0.3	0.2	0.5	0.56	0.94
		JJA	A2	0.0	0.0	0.5	0.48	0.92	
			A1B	0.0	0.0	0.4	0.49	0.94	
			B1	0.0	-0.1	0.4	0.45	0.96	
NEB		2041–2070	DJF	A2	0.0	0.0	0.7	0.65	0.87
				A1B	-0.2	-0.1	0.7	0.65	0.88
				B1	-0.1	-0.1	0.6	0.67	0.91
	JJA		A2	-0.1	-0.1	0.1	0.77	0.99	
			A1B	-0.1	-0.1	0.1	0.76	0.97	
			B1	-0.1	-0.1	0.1	0.76	0.99	
	2071–2100		DJF	A2	0.1	0.0	0.9	0.61	0.79
				A1B	0.1	0.0	0.8	0.62	0.82
				B1	0.0	-0.1	0.7	0.65	0.87
		JJA	A2	-0.1	-0.1	0.2	0.76	0.97	
			A1B	-0.1	-0.1	0.2	0.76	0.96	
			B1	-0.1	-0.1	0.1	0.76	0.97	
	LPB	2041–2070	DJF	A2	0.2	0.2	0.4	0.70	0.95
				A1B	0.2	0.2	0.4	0.70	0.93
				B1	0.1	0.1	0.3	0.71	0.96
JJA			A2	0.0	0.0	0.1	0.60	0.96	
			A1B	0.0	0.0	0.2	0.61	0.95	
			B1	0.0	0.0	0.1	0.60	0.97	
2071–2100			DJF	A2	0.3	0.3	0.5	0.67	0.88
				A1B	0.3	0.2	0.5	0.67	0.89
				B1	0.2	0.2	0.4	0.70	0.94
		JJA	A2	0.0	0.0	0.2	0.58	0.92	
			A1B	0.0	0.0	0.2	0.60	0.94	
			B1	0.0	0.0	0.1	0.60	0.97	

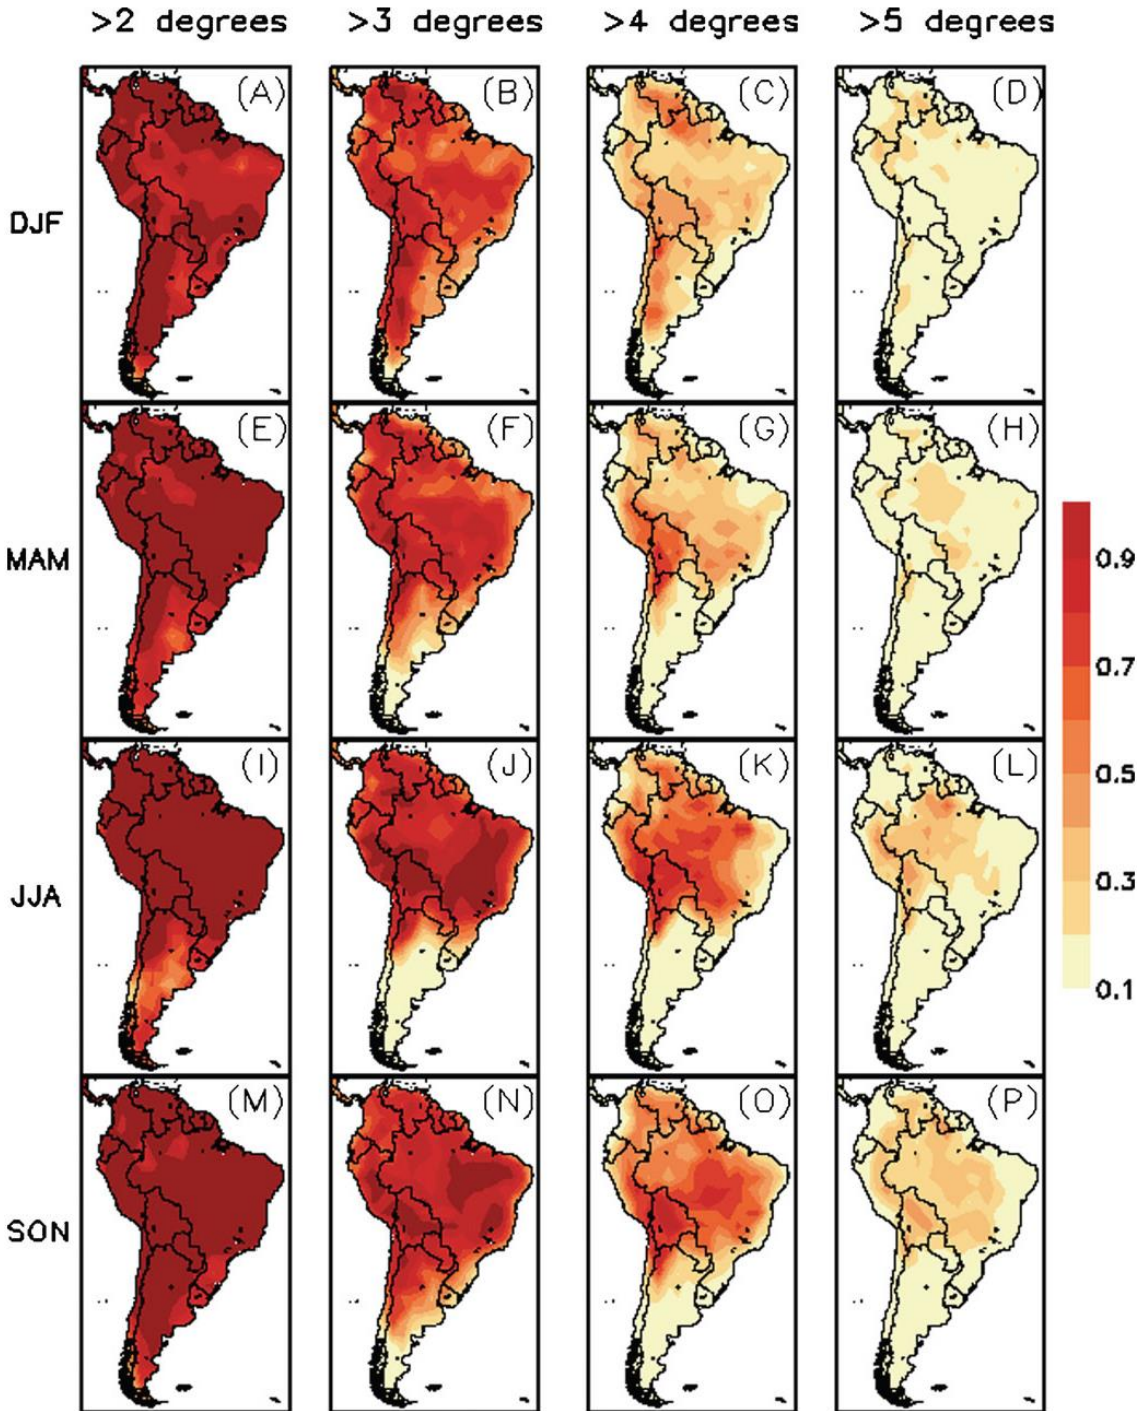


Fig. 8 a–p Seasonal probabilities of exceeding some temperature thresholds (2, 3, 4, and 5 °C) for 2071–2100 in the A2 scenario




Fig. 9 Cumulative density functions of the temperature change (in degrees Celsius) in the A2 (left), A1B (center), and B1 (right) scenarios for the eastern and western Amazon Basin (a–c and d–f, respectively), Northeast Brazil (g–i), and the La Plata Basin (j–l).

Black lines represent the period from 2041 to 2070 and gray lines represent 2071–2100. Filled circles are for the DJF and empty circles for the JJA.




Fig. 10 a-l The same as in Fig. 9, but for the precipitation change (in millimeters per day)

4 Summary and conclusion

Due to the increasing need for a detailed and probabilistic analysis of the uncertainties in climate change projections over South America, this study analyzes the projected temperature and precipitation changes from all the GCMs available in the CMIP3 dataset over different time slices (2041–2070 and 2071–2100) and emissions scenarios (SRES B1, A1B, and A2), relative to the present climate (1961–1990). The REA approach is applied to the seasonal mean surface air temperature and the precipitation changes for both time slices and for all the analyzed emissions scenarios.

When taking into account the performance of each model in representing the current climate and the convergence of its projection to the ensemble mean in the ensemble averaging, as proposed by the REA method, it is noted that the REA mean temperature change projection is slightly smaller (approximately 8 %) over the entire continent when compared with the simple ensemble mean. This indicates that outlier results are downweighted in the ensemble mean. The temperature change is larger than the corresponding uncertainty range for the entire South American domain and for the investigated time slices, showing a high reliability of the projected REA mean change for this variable. Higher reliability is found over the La Plata Basin, where the REA mean temperature change is 3.1 ± 0.8 °C in the austral summer and 3.3 ± 0.6 °C in the austral winter by 2071–2100 for the A2 scenario. On the other hand, higher uncertainty ranges are found in the Amazon Basin, where the results show a temperature increase of 3.3 ± 0.9 °C (3.9 ± 0.9 °C) in the austral summer (winter) over the eastern Amazon and 3.5 ± 1.1 °C (4.2 ± 1.1 °C) in the austral summer (winter) for its western portion, for the same period and scenario.

The probability of a temperature increase exceeding the 2 °C threshold is found to be very likely (>90 %) for all seasons in the entire South America region and a more likely than not (>50 %) probability of exceeding 4 °C is found over northwest South America, the Amazon Basin, Bolivia, Peru, and NEB from June to November by the end of the twenty-first century in the A2 scenario. These are the same areas indicated by Fung et al. (2011) that could experience an increase in water stress with a global temperature that is +2 or +4 °C warmer than the 1961–1990 average for the 2060s. Betts et al. (2011) explains that the IPCC AR4 projections clearly suggest that much greater levels of warming are possible by the end of the twenty-first century in the absence of mitigation. The central value of the range of AR4-projected global warming is approximately 4 °C. The higher end of the projected warming is associated with the higher emissions scenarios and models which included stronger carbon cycle feedbacks.

When applied to precipitation, the REA mean shows no marked differences when compared with the simple

ensemble mean. In general, the uncertainty range has the same order of magnitude as the projected change. Therefore, based on this set of global climate models and on the applied methodology, there is high reliability in a projection of no significant rainfall change (in magnitude) in the two future time slices analyzed over the entire South American region. However, these results do not apply to the projections of climate extremes. South America had experienced an increase of extreme temperature and precipitation events in the last half of the twentieth century (Marengo et al. 2010a; Rusticucci et al. 2010), and many climate models project an even further increase of such events by the end of twenty-first century (Tebaldi et al. 2006; Marengo et al. 2009).

In the literature, there are several proposed methods for combining projections from ensembles of climate models and estimating an uncertainty range, but none of them have been shown to be the most suitable or reliable. Moreover, this subject is far from being trivial, as indicated by Knutti et al. (2010).

Model weighting, as in the case of the REA approach, imposes a strong assumption in the climate change analysis when explicitly assuming that performance in the past climate is a certain guarantee for performance into the future climate projections. This issue is widely debated in the scientific community, and no consensus has been reached. Additionally, the impact of model dependency into the ensemble mean reliability imposes some restrictions on the interpretation of our results, so that the results must be carefully analyzed. The REA method was chosen for its simplicity and the various types of information that it can provide. Other methodologies must be applied to compare these results. In addition, regional climate model ensembles and the next generation of global climate models that have been prepared for the IPCC AR5 may be used to increase the reliability in future climate change projections. Finally, the two main contributions of this study are as follows: (1) being the first spatially explicit and deep assessment of the climate change projections uncertainties in South America and (2) producing summarized and probabilistic information on the possible climate change outcomes, which is more suitable for impact, adaptation, and vulnerabilities studies.

Acknowledgments We thank the modeling groups, the Program for Climate Model Diagnosis and Intercomparison and the WCRP's Working Group on Coupled Modeling, for their roles in making the WCRP CMIP3 multimodel dataset available. The first author was supported by the Coordination for Improvement of Higher Education Personnel (CAPES) and by the Brazilian National Council for Scientific and Technological Development (CNPq). Additional funding was provided by Rede-CLIMA, the National Institute of Science and Technology for Climate Change (INCT-CC), and the FAPESP-Assessment of Impacts and Vulnerability to Climate Change in Brazil and strategies for Adaptation options project (Ref. 2008/58161-1).

References

- Ambrizzi T, Souza EB, Pulwarty RS (2004) The Hadley and Walker regional circulations and associated ENSO impacts on the South American seasonal rainfall. In: Diaz HF, Bradley RS (eds) *The Hadley circulation: present, past and future*. Kluwer, Dordrecht, 21, pp 203–235
- Baettig MB, Wild M, Imboden DM (2007) A climate change index: where climate change may be most prominent in the 21st century. *Geophys Res Lett* 34:L01705. doi:10.1029/2006GL028159
- Betts RA, Collins M, Hemming D, Jones CD, Lowe JA, Snderson MG (2011) When could global warming reach 4 °C? *Phil Trans R Soc A* 369:67–84. doi:10.1098/rsta.2010.0292
- Bombardi RJ, Carvalho LMV (2009) IPCC Global coupled climate model simulations of the South America Monsoon System. *Clim Dyn* 33:893–916. doi:10.1007/s00382-008-0488-1
- Boulanger JP, Martinez F, Segura EC (2006) Projection of future climate change conditions using IPCC simulations, neural networks and Bayesian statistics. Part 1: temperature mean state and seasonal cycle in South America. *Clim Dyn* 27:233–259. doi:10.1007/s00382-006-0134-8
- Boulanger JP, Martinez F, Segura EC (2007) Projection of future climate change conditions using IPCC simulations, neural networks and Bayesian statistics. Part 2: precipitation mean state and seasonal cycle in South America. *Clim Dyn* 28:255–271. doi:10.1007/s00382-006-0182-0
- Boulanger JP, Brasseur G, Carril AF, Castro M, Degallier N, Ereño C, Treut HL, Marengo JA, Menendez G, Nuñez MN, Penalba OC, Rolla AL, Rusticucci M, Terra RA (2010) Europe–South America network for climate change assessment and impact studies. *Clim Chang* 98:307–329. doi:10.1007/s10584-009-9734-8
- Chou SC, Marengo JA, Lyra A, Sueiro G, Pesquero J, Alves LM, Kay G, Betts R, Chagas D, Gomes J, Bustamante J (2012) Downscaling of South America present climate driven by 4-member HadCM3 runs. *Clim Dyn* 38(3–4):635–653. doi:10.1007/s00382-011-1002-8
- Collins M (2007) Ensembles and probabilities: a new era in the prediction of climate change. *Phil Trans R Soc A* 365:1957–1970. doi:10.1098/rsta.2007.2068
- Ebert EE (2001) Ability of a poor man's ensemble to predict the probability and distribution of precipitation. *Mon Wea Rev* 129:2461–2480. doi:10.1175/1520-0493(2001)129<2461:AOAPMS>2.0.CO;2
- Fung F, Lopez A, New M (2011) Water availability in +2 °C and +4 °C worlds. *Phil Trans R Soc A* 369:99–116. doi:10.1098/rsta.2010.0293
- Furrer R, Sain SR, Nychka D, Meehl GA (2007) Multivariate Bayesian analysis of atmosphere–ocean general circulation models. *Environ Ecol Stat* 14:249–266. doi:10.1007/s10651-007-0018-z
- Giorgi F (2005) Climate change prediction. *Clim Change* 73:239–265. doi:10.1007/s10584-005-6857-4
- Giorgi F, Francisco R (2000) Uncertainties in regional climate change prediction: a regional analysis of ensemble simulations with the HadCM2 coupled AOGCM. *Clim Dyn* 16:169–182. doi:10.1007/PL00013733
- Giorgi F, Mearns LO (2002) Calculation of average, uncertainty range and reliability of regional climate changes from AOGCM simulations via the “Reliability Ensemble Averaging (REA)” method. *J Clim* 15:1141–1158
- Giorgi F, Mearns LO (2003) Probability of regional climate change calculated using the Reliability Ensemble Averaging (REA) method. *Geophys Res Lett* 30:1629. doi:10.1029/2003GL017130
- Greene AM, Goddard L, Upmanu L (2006) Probabilistic multi-model regional temperature change projections. *J Clim* 19:4326–4343. doi:10.1175/JCLI3864.1
- IPCC (2007) Summary for policymakers. In Solomon S, Qin D, Mammig M, Chen Z, Marquis M, Averyt KB, Tignor M, Miller HL (eds) *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 University Press, Cambridge
- Kim Y-O, Lee J-K (2010) Addressing heterogeneities in climate change studies for water resources in Korea. *Curr Sci* 98:1077–1083
- Kim H-J, Wang B, Ding Q (2008) The global monsoon variability simulated by CMIP3 coupled climate models. *J Clim* 20:4497–4525. doi:10.1175/2008JCLI2041.1
- Knutti R (2008) Should we believe model predictions of future climate change? *Phil Trans R Soc* 366:4647–4664. doi:10.1098/rsta.2008.0169
- Knutti R, Furrer R, Tebaldi C, Cermak J, Meehl GA (2010) Challenges in combining projections from multiple climate models. *J Clim* 23:2739–2758. doi:10.1175/2009JCLI3361.1
- Marengo JA, Jones R, Alves LM, Valverde M (2009) Future change of temperature and precipitation extremes in South America as derived from the PRECIS regional climate modeling system. *Int J Climatol* 30:1–15. doi:10.1002/joc.1863
- Marengo JA, Rusticucci M, Penalba O, Renom M (2010a) An inter-comparison of observed and simulated extreme rainfall and temperature events during the last half of the twentieth century. Part 2: historical trends. *Clim Chang* 98:509–529. doi:10.1007/s10584-009-9743-7
- Marengo JA, Ambrizzi T, Rocha RP, Alves LM, Cuadra SV, Valverde M, Ferraz SET, Torres RR, Santos DC (2010b) Future change of climate in South America in the late XXI century: intercomparison of scenarios from three regional climate models. *Clim Dyn* 35:1073–1097. doi:10.1007/s00382-009-0721-6
- Marengo JA, Chou SC, Kay G, Alves LM, Pesquero JF, Soares WR, Santos DC, Lyra AA, Sueiro G, Betts R, Chagas DJ, Gomes JL, Bustamante JF, Tavares P (2012) Development of regional future climate change scenarios in South America using the Eta CPTEC/HadCM3 climate change projections: climatology and regional analyses for the Amazon. São Francisco and the Parana River Basins. *Clim Dyn* 38(9–10):1829–1848. doi:10.1007/s00382-011-1155-5
- Masson D, Knutti R (2011) Climate model genealogy. *Geophys Res Lett* 38:L08703. doi:10.1029/2011GL046864
- Meehl GA, Stocker TF, Collins WD, Friedlingstein P, Gaye AT, Gregory JM, Kitoh A, Knutti R, Murphy JM, Noda A, Raper SCB, Watterson IG, Weaver AJ, Zhao Z-C (2007a) Global climate projections. In Solomon S, Qin D, Mammig M, Chen Z, Marquis M, Averyt KB, Tignor M, Miller HL (eds) *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 University Press, Cambridge
- Meehl GA, Covey C, Delworth T, Mojbib L, McAvaney B, Mitchell JFB, Stouffer RJ, Taylor KE (2007b) The WCRP CMIP3 multimodel dataset: a new era in climate change research. *Bull Am Meteorol Soc* 88:1383–1394. doi:10.1175/BAMS-88-9-1383
- Mitchell TD, Jones PD (2005) An improved method of constructing a database of monthly climate observations and associated high-resolution grids. *Int J Climatol* 25:693–712. doi:10.1002/joc.1181
- Moise AF, Hudson DA (2008) Probabilistic predictions of climate change for Australia and southern Africa using the reliability ensemble average of IPCC CMIP3 model simulations. *J Geophys Res* 113:D15113. doi:10.1029/2007JD009250
- Murphy JM, Booth BBB, Collins M, Harris GR, Sexton DMH, Webb MJ (2007) A methodology for probabilistic predictions of regional climate change from perturbed physics ensembles. *Phil Trans R Soc A* 365:1993–2028. doi:10.1098/rsta.2007.2077
- Nakicenovic N, Alcamo J, Davis G, De Vries B, Fenhann J, Gaffin S, Gregory K, Grubler A, Jung TY, Kram T, La Rovere EL, Michaelis L, Mori S, Morita T, Pepper W, Pitcher H, Price L, Riahi K, Roehrl A, Rogner HH, Sankovski A, Schlesinger M,

- Shukla P, Smith S, Swart R, Van Rooijen S, Victor N, Dadi Z (2000) Special report on emissions scenarios. Cambridge University Press, Cambridge
- Nobre P, Marengo JA, Cavalcanti IFA, Obregon G (2006) Seasonal-to-decadal predictability and prediction of South American climate. *J Clim* 19:5988–6004. doi:10.1175/JCLI3946.1
- Nuñez MN, Solman SA, Cabré MF (2008) Regional climate change experiments over southern South America. II: climate change scenarios in the late twenty-first century. *Clim Dyn* 32:1081–1095. doi:10.1007/s00382-008-0449-8
- Randall DA, Wood RA, Bony S, Colman R, Fichefet T, Fyfe J, Kattsov V, Pitman A, Shukla J, Srinivasan J, Stouffer RJ, Sumi A, Taylor KE (2007) Climate models and their evaluation. In Solomon S, Qin D, Manning M, Chen Z, Marquis M, Averyt KB, Tignor M, Miller HL (eds.) *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 University Press, Cambridge
- Rusticucci M, Marengo JA, Penalba O, Renom M (2010) An inter-comparison of observed and simulated extreme rainfall and temperature events during the last half of the twentieth century: part 1: mean values and variability. *Clim Chang* 98:493–508. doi:10.1007/s10584-009-9742-8
- Seth A, Rojas M, Rauscher SA (2010) CMIP3 projected changes in the annual cycle of the South American monsoon. *Clim Change* 98:331–357. doi:10.1007/s10584-009-9736-6
- Solomon S, Qin D, Manning M, Chen Z, Marquis M, Averyt KB, Tignor M, Miller HL (2007) *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 University Press, Cambridge
- Tao H, Gemmer M, Jiang J, Lai X, Zhang Z (2012) Assessment of CMIP3 climate models and projected changes of precipitation and temperature in the Yangtze River Basin. *China Clim Change* 111 (3–4):737–751. doi:10.1007/s10584-011-0144-3
- Tebaldi C, Knutti R (2007) The use of the multi-model ensemble in probabilistic climate projections. *Phil Trans R Soc A* 365:2053–2075. doi:10.1098/rsta.2007.2076
- Tebaldi C, Smith RL, Nychka D, Mearns LO (2005) Quantifying uncertainty in projections of regional climate change: a Bayesian approach to the analysis of multimodel ensembles. *J Clim* 18:1524–1540
- Tebaldi C, Hayhoe K, Arblaster JM, Meehl G (2006) Going to the extremes. An intercomparison of model-simulated historical and future changes in extremes events. *Clim Change* 79:185–211. doi:10.1007/s10584-006-9051-4
- Torres RR, Lapola DM, Marengo JA, Lombardo MA (2012) Socio-climatic hotspots in Brazil. *Clim Change*. doi:10.1007/s10584-012-0461-1
- Urrutia R, Vuille M (2009) Climate change projections for the tropical Andes using a regional climate model: temperature and precipitation simulations for the end of the 21st century. *J Geophys Res* 114:D02108. doi:10.1029/2008JD011021
- Vera C, Silvestri G (2009) Precipitation interannual variability in South America from the WCRP-CMIP3 multi-model dataset. *Clim Dyn* 32:1003–1014. doi:10.1007/s00382-009-0534-7
- Vera C, Silvestri G, Liebmann B, González P (2006) Climate change scenarios for seasonal precipitation in South America from IPCC-AR4 models. *Geophys Res Lett* 33:L13707. doi:10.1029/2006GL025759
- Wigley TM, Raper SC (2001) Interpretation of high projections for global-mean warming. *Science* 293:451–454. doi:10.1126/science.1061604
- Xu Y, Xuejie G, Giorgi F (2010) Upgrades to the reliability ensemble averaging method for producing probabilistic climate change projections. *Clim Res* 41:61–81. doi:10.3354/cr00835

ANEXO B – SEGUNDO ARTIGO PUBLICADO NO PERIÓDICO *CLIMATIC CHANGE*

SOCIO - CLIMATIC HOTSPOTS IN BRAZIL

RESUMO

Brasil sofre anualmente com eventos extremos de tempo e clima, os quais podem ser exacerbados em um clima mais quente. Embora diversos estudos tenham analisado as projeções de mudanças climáticas no Brasil, pouca atenção tem sido dada para definir as localidades que podem ser mais afetadas, e conseqüentemente possuem uma população mais vulnerável, de forma espacialmente explícita. Este estudo apresenta uma análise espacial sumarizada dos dados de mudanças climáticas, e uma investigação conjunta que combina estas possíveis mudanças climáticas com indicadores de vulnerabilidade social no Brasil. O *Regional Climate Change Index (RCCI)*, o qual pode sintetizar um grande número de projeções de modelos climáticos, é utilizado para a análise climática, e o *Socio-Climatic Vulnerability Index (SCVI)* é proposto para agregar as vulnerabilidades da população local às informações de mudanças climáticas. Os resultados referentes ao *RCCI* indicam alguns *hotspots* climáticos emergindo no Brasil, cobrindo a porção oeste do Nordeste Brasileiro, noroeste do estado de Minas Gerais, e regiões centro-oeste e norte, exceto no nordeste do Pará e Amapá. A análise do *SCVI* revela que os principais *hotspots* sócio-climáticos situam-se na região Nordeste e nas principais regiões metropolitanas do Brasil, principalmente Manaus, Belo Horizonte, Brasília, Salvador, Rio de Janeiro, e São Paulo. As duas principais contribuições deste estudo são uma análise espacialmente detalhada do *RCCI* no Brasil, e o desenvolvimento de um índice que pode sintetizar um grande número de informações atualmente disponíveis de modelos climáticos com indicadores de vulnerabilidade social. Ambos os índices podem ser ferramentas importantes para melhorar o diálogo entre cientistas climáticos e sociais, e para comunicar mudanças climáticas para tomadores de decisão em uma forma mais sintética e socialmente relevante.

Socio-climatic hotspots in Brazil

Roger R. Torres · David M. Lapola · Jose A. Marengo · Magda A. Lombardo

Received: 16 September 2011 / Accepted: 23 March 2012
© Springer Science+Business Media B.V. 2012

Abstract Brazil suffers yearly from extreme weather and climate events, which can be exacerbated in a warmer climate. Although several studies have analyzed the projections of climate change in Brazil, little attention has been paid to defining the locations that can be most affected, and consequently have a more vulnerable population, in a spatially-explicit form. This study presents a spatial analysis of summarized climate change data and a joint investigation combining these possible climate changes and social vulnerability indicators in Brazil. The Regional Climate Change Index (*RCCI*), which can synthesize a large number of climate model projections, is used for the climate analysis, and the Socio-Climatic Vulnerability Index (*SCVI*) is proposed to aggregate local population vulnerabilities to the climate change information. The *RCCI* results show climatic hotspots emerging in Brazil, covering the western portion of the Northeast (NE), northwestern Minas Gerais state and center-western (CW) and northern regions (N), except northeast Pará and Amapá states. The *SCVI* analysis reveals major socio-climatic hotspots in the NE and several localized hotspots in some of the major Brazilian metropolitan regions, namely Manaus, Belo Horizonte, Brasília,

R. R. Torres (✉)
Center for Weather Forecast and Climate Studies (CPTEC), National Institute for Space Research (INPE),
Cachoeira Paulista, SP, Brazil
e-mail: roger.torres@cptec.inpe.br

D. M. Lapola
Earth System Science Lab (LabTerra), Department of Ecology, São Paulo State University (UNESP),
Rio Claro, SP, Brazil

J. A. Marengo
Center for Earth System Science, National Institute for Space Research (INPE), Cachoeira Paulista,
SP, Brazil

M. A. Lombardo
Center for Environmental Planning and Analysis (CEAPLA), São Paulo State University (UNESP),
Rio Claro, SP, Brazil



Salvador, Rio de Janeiro and São Paulo. The two novelties of this study are a spatially detailed analysis of the *RCCI* in Brazil and the development of an index that can summarize the large amount of climate model information available today with social vulnerability indicators. Both indices may be important tools for improving the dialogue between climate and social scientists and for communicating climate change to policymakers in a more synthetic and socially relevant form.

1 Introduction

Projections indicate a considerable change in Brazil's climate within this century (Baettig et al. 2007; Marengo et al. 2009, 2010a), and there are several reasons to believe Brazil will be highly impacted by such climatic change: its economy depends heavily on exports of agricultural commodities (IPEA 2011); the provision of staple foods is strongly reliant on smallholder agriculture (responsible, for example, for 87 % of the national production of cassava, 70 % of dry beans, 46 % of maize, and 58 % of milk) (IBGE 2009); it has an energy matrix dominated by renewable energy, which is highly susceptible to climate variations (Lucena et al. 2009); and it still suffers widespread poverty, significant social inequality and epidemic outbreaks (IPEA 2003; Magrin et al. 2007; Confalonieri et al. 2009). The floods in São Paulo city in the summer of 2010 (Folha de São Paulo 2010), the landslides in the state of Rio de Janeiro in the summer of 2011 (Folha de São Paulo 2011), the annual dengue fever epidemics throughout the entire country, and the succession of intense droughts and floods events in Amazonia and Northeast (NE) Brazil (Marengo et al. 2011c, d; Ponce 1995) reveal how unprepared Brazil is for climate change.

Several studies have examined the effects of climate change in Brazil using different general circulation models (GCMs) and dynamical downscaling methods (e.g., Vera et al. 2006; Bombardi and Carvalho 2009; Marengo et al. 2010a, b, 2011a; Rusticucci et al. 2010). Despite the contribution of these studies to our knowledge of climate change, uncertainties about the regional climate impacts still remain. Moreover, the intrinsic uncertainties of climate change projections (Giorgi 2005; Knutti 2008) make the interactions between climate scientists and social scientists and, importantly, between scientists and policymakers, very difficult (Pidgeon and Fischhoff 2011). One possibility to improve the communication between climate scientists and others is the creation of climate change indices that aggregate various information and measures of uncertainty concisely and reliably (Giorgi 2006; Baettig et al. 2007; Xu et al. 2009). However, there is currently no scientific study showing where climate change hotspots (the word "hotspots" is used in this study to indicate areas with large regional climate changes and/or a highly vulnerable population) are located in Brazil and how these climate hotspots relate to population density and social conditions, such as poverty, education and health, in a country-wide perspective.

Therefore, this study addresses the need for straightforward and synthesized assessments of climate change and its probable social impacts in Brazil by presenting a spatially explicit analysis of Brazil's socio-climatic hotspots by relating more than one hundred climate projections with indicators of social vulnerability to climate change. The Regional Climate Change Index (*RCCI*) developed by Giorgi (2006) is applied specifically to Brazil and is incremented with social vulnerability proxies to compose what is defined here as the Socio-Climatic Vulnerability Index (*SCVI*). The *SCVI* is a timely approach to identifying the areas for which climate change projections have the most human/social relevance. This information can then be used to target areas where actions towards adaptation should be prioritized.

2 Methods

2.1 Climate simulation dataset

This study uses monthly precipitation and surface air temperature data simulated for the present climate (1961–1990) and projected to the end of this century (2071–2100) from 24 GCMs of the Coupled Model Inter-comparison Project Phase 3 (CMIP3) employed in the Intergovernmental Panel on Climate Change (IPCC) Fourth Assessment Report (IPCC 2007) (Table 1). Hereafter, the word change(s) refers to the difference between the mean values of the climate variables for the periods 2071–2100 and 1961–1990. Three sets of IPCC emission scenarios were used for the future period: SRES B1, A1B and A2, corresponding to equivalent CO₂ concentrations of approximately 550, 700 and 850 ppm, respectively, in the year 2100 (Nakicenovic et al. 2000). The models and simulations are described in more detail in Meehl et al. (2007).

The GCMs spatial resolutions vary from roughly 1–5 ° of latitude/longitude (Table 1). All GCMs were interpolated to a common 1 ° grid, using the conservative remapping scheme (Jones 1999; Giorgi and Bi 2005; Giorgi 2006; Xu et al. 2009), for inter-comparison

Table 1 List of models, approximate model spatial resolutions, emissions scenarios and number of runs in the CMIP3 dataset used in this study. Models are ranked by their spatial resolution

Models	Resolution (lat/lon)	20C3M	A2	A1B	B1
INM-CM3.0	5 °×4 °	1	1	1	1
GISS-EH	5 °×4 °	5	-	3	-
GISS-ER	5 °×4 °	9	1	2	1
GISS-AOM	4 °×3 °	2	-	2	2
CGCM3.1(T47)	3.8 °×3.8 °	5	5	5	5
ECHO-G	3.8 °×3.8 °	5	3	3	3
UKMO-HadCM3	3.8 °×2.5 °	2	1	1	1
IPSL-CM4	3.8 °×2.5 °	1	1	1	1
FGOALS-g1.0	2.8 °×3 °	3	-	2	3
MRI-CGCM2.3.2	2.8 °×2.8 °	5	5	5	5
CGCM3.1(T63)	2.8 °×2.8 °	1	-	1	1
CNRM-CM3	2.8 °×2.8 °	1	1	1	1
MIROC3.2(medres)	2.8 °×2.8 °	2	3	3	3
PCM	2.8 °×2.8 °	4	4	4	2
GFDL-CM2.0	2.5 °×2 °	3	1	1	1
GFDL-CM2.1	2.5 °×2 °	3	1	1	1
BCCR-BCM2.0	1.9 °×1.9 °	1	1	1	1
CSIRO-MK3.0	1.9 °×1.9 °	3	1	1	1
CSIRO-MK3.5	1.9 °×1.9 °	3	1	1	1
ECHAM5	1.9 °×1.9 °	4	3	4	3
UKMO-HadGEM1	1.9 °×1.3 °	2	1	1	-
CCSM3	1.4 °×1.4 °	7	4	7	9
ECHAM4	1.1 °×1.1 °	1	1	1	-
MIROC3.2(hires)	1.1 °×1.1 °	1	-	1	1

purposes and to properly relate them with social datasets in a reasonable grid size. However, one might argue that the interpolation of models from the coarsest to the highest resolution in an ensemble is not ideal. An appropriate technique to downscale the results of climate models would be statistical downscaling or dynamical downscaling (Boulanger et al. 2006; Christensen et al. 2007). Nevertheless, these two techniques are too time-consuming and/or computationally expensive and their application is highly non-trivial. Because this study aims to present a new approach to combine climate and social information, a more suitable interpolation or downscaling technique for the climate change dataset can be applied in future studies.

For the *RCCI* calculation described in Section 2.2, all climate variables and statistics were computed as follows: 1) the change was calculated for each model simulation; 2) different runs using the same model (when available) were averaged; 3) the results were interpolated to a 1° latitude/longitude spatial resolution; 4) the ensemble average over the different available models was obtained; and 5) the three emission scenarios were averaged.

2.2 Regional climate change index

The *RCCI* is a qualitative index proposed by Giorgi (2006) to identify the regions in which climate change may be more prominent. This index is based on the temperature change in a specific region relative to the change in mean global temperature (or regional warming amplification factor, *RWAF*), change in mean regional precipitation (ΔP , %) and change in the interannual variability of temperature ($\Delta\sigma_T$, %) and precipitation ($\Delta\sigma_P$, %), all of which are calculated separately for austral summer and winter. The *RCCI* is not affected by small changes below certain thresholds, while more intense changes receive heavier weights (Giorgi 2006).

In the *RCCI* formulation, the σ_T and σ_P indexes can represent a proxy for extreme climate conditions, such as excessively rainy or dry seasons, that could seriously affect human welfare and the environment. The interannual standard deviation of temperature was used as a measure of σ_T and the coefficient of variation (i.e., the standard deviation divided by the mean) was used as a measure of σ_P . Both σ_T and σ_P were calculated for the selected 30 year periods after detrending the data to obtain unbiased variability estimates. The coefficient of variation was used as a measure of interannual precipitation variability because it removes the dependency of the standard deviation on the mean for zero-bounded variables such as rainfall (Räsänen 2002; Giorgi 2006).

However, it is worth mentioning that the process of estimating the occurrence of extreme events is non-trivial, especially for projections of the future climate (Frich et al. 2002; Meehl et al. 2005; Tebaldi et al. 2006 and citations quoted therein). The interannual variability calculated using the standard deviation and coefficient of variation are used only as a first approximation for such events (Räsänen 2002; Giorgi 2006 and Xu et al. 2009). A more suitable extreme climate calculation could be derived, for example, from a robust statistical estimate of the probability density function of daily temperature and precipitation data (Alexander et al. 2006) generated by an ensemble of higher-resolution models.

The *RCCI* was chosen for this study because it is a well accepted index in the literature to show where climate change could be, on a relative basis, more pronounced in a warmer climate based in a large set of climate models. Moreover, its results compare quite well with another well accepted index, the Climate Change Index, developed by Baettig et al. (2007), as will be discussed in Section 3.1.

2.3 Socio-climatic vulnerability index

This paper introduces an index that combines information about the magnitude of climate change in a specific region and social factors that could affect the vulnerability of the local population. We call this index the Socio-Climatic Vulnerability Index (*SCVI*) and define it as

$$SCVI = CI * \sqrt[n]{\prod_{i=1}^n F_i},$$

where *CI* represents any climate change index suitable for the region, whereas the second element on the right-hand side of the equation represents the geometric mean of the normalized social vulnerability factors (F_i) that characterize the local social conditions.

The definition of vulnerability used here is based on that used by the IPCC: vulnerability is the degree to which a system (in this study, the Brazilian population) is susceptible to, and unable to cope with, adverse effects of climate change, including climate variability and extremes. Additionally, vulnerability is a function of the character, magnitude, and rate of climate change and the variation to which a system is exposed, its sensitivity and its adaptive capacity (glossary of IPCC AR4, [IPCC 2007]).

Similar to the *RCCI*, the *SCVI* is intended to be a relative index of vulnerability to climate change in which the most important is not the value itself, but how it compares from one region to another, ranking locations in which vulnerability is high or low in a comparative basis. Moreover, the *SCVI* can be applied on any spatial scale (assuming sufficient available data and a reasonable spatial scale for characterizing the analyzed region) and can incorporate as many distinct social variables as needed in the right-hand side of the equation above. Therefore, the *SCVI* can merge several indicators of a population's vulnerability (e.g., water resources and agricultural vulnerabilities) and climate change indexes based on a broad array of models.

The specialized literature includes dozens of indexes for identifying a population's vulnerability to climate change on a country (e.g., Yohe et al. 2006; Diffenbaugh et al. 2007; Eriksen and Kelly 2007) or regional scale (e.g., Confalonieri et al. 2009 and Yusuf and Francisco 2009). For example, Preston et al. (2011) identified and reviewed 45 vulnerability mapping studies appearing in the literature until 2010. These studies differ from the present study in the following ways: several of the previous studies used observed climatology rather than climate change projections, nearly all of the previous studies were based on climate projections from solely one climate model and Brazil was always depicted using coarse spatial scales.

The *SCVI* was calculated for all of Brazil using a spatial resolution of 1° of latitude/longitude. The climate change index used here is the *RCCI* described in the previous section, but the use of other climate change indexes in addition to or instead of the *RCCI* could strengthen the reliability of the determination of climate change hotspots. The demographic density (ρ) (Goldewijk 2005) and the inverse of the Human Development Index (*HDI*) for all Brazilian municipalities (IPEA 2003) are used as the social vulnerability indicators (Fig. 1). Both social variables are normalized to the Brazilian domain and are representative of the year 2000. The original resolution of ρ is 5 arc-minutes, whereas the *HDI* data are available at the municipal level. The transformation of these data to a 1° basis followed the procedures using the ArcGIS® software: first, the *HDI* data are transformed from a polygon shape into a 5 arc-min raster; second, both *HDI* and ρ are converted into 1° latitude/longitude rasters using the “mean” neighborhood block statistics.

The employed *SCVI* formulation implies that the social vulnerability to climate change will be more pronounced in regions with higher ρ and lower *HDI*, in agreement with several studies on social vulnerability to climate change (Adger 1999; Füssel and Klein 2006;

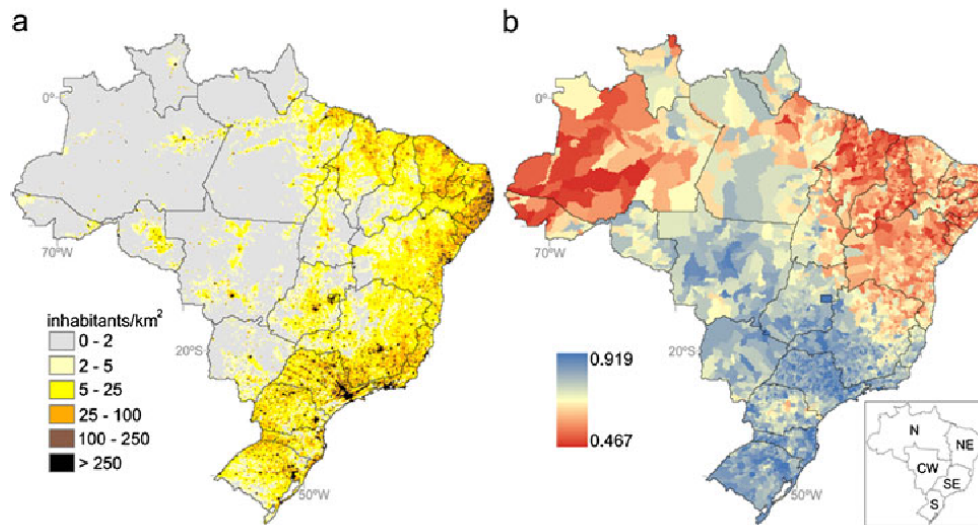


Fig. 1 Year 2000 (a) Brazilian population density (inhabitants per km²) and (b) Human Development Index (dimensionless). The bottom right-hand panel shows Brazil's 5 macro regions: North (N), Northeast (NE), Centre-West (CW), South (S) and Southeast (SE)

Eriksen and Kelly 2007; Magrin et al. 2007; Ionescu et al. 2009; Confalonieri et al. 2009). In general, these studies agree that social vulnerability is more pronounced in more heavily populated areas (justifying the use of ρ), and that sanitation/health, economic wealth and literacy levels influence exposure and sensitivity to climate change, and modulate the population's adaptive capacity for climate change. The *HDI* conveniently combines these three social indicators – health, income and education – into a single measure.

The most recent *HDI* information at the municipality level for Brazil was published in 2000 by the Brazilian office of the United Nations Development Programme in conjunction with the Ministry of Planning's Applied Economic Research Institute (IPEA) and the João Pinheiro Foundation (<http://hdr.undp.org/en/reports/national/latinamericathecaribbean/brazil/name,3212,en.html>). Unfortunately, more recent information at this level of detail is not available for either *HDI* or population density. However, although the values of *HDI* have changed from 2000 to 2011 (e.g., from 0.665 to 0.718 on the national level), it is reasonable to assume that the broad regional development patterns have not changed considerably. We assume the same for population density in terms of 2000–2011 changes in the spatial distribution pattern.

3 Results and discussion

3.1 *RCCI*

The analysis of the *RCCI* for Brazil (Fig. 2a) evidences the occurrence of climatic hotspots covering the western part of the NE region, the northwestern part of Minas Gerais state and the center-west (CW) and northern (N) regions of the country (except in northeast Pará and Amapá states).

In western NE and northwestern Minas Gerais state, the main factors that contribute to the higher values of the *RCCI* are the projected decrease of rainfall amounts during the austral




Fig. 2 (a) Regional Climate Change Index (*RCCI*) and (b) Socio-Climatic Vulnerability Index (*SCVI*) for Brazil (both dimensionless)

winter and changes in the interannual variability of temperature and precipitation in both seasons (Table 2). In the CW region, high values of the *RCCI* are primarily caused by changes in both the mean and interannual precipitation variability in the austral winter and in the interannual temperature variability in the austral summer (Table 2). In N region the main contributors to high values of the *RCCI* are the changes in the interannual temperature variability in both the austral summer and winter and the interannual variability of rainfall and the *RWAF* during the austral winter (Table 2).

In general, the *RCCI* results agree with previous studies that use regional and GCM models to project climate change in South America (Boulanger et al. 2006, 2010; Vera et al. 2006; IPCC 2007; Bombardi and Carvalho 2009; Marengo et al. 2010a, 2011a). Moreover, the spatial pattern of the *RCCI* in Brazil compares well to the Climate Change Index

Table 2 Mean values for the 5 Brazilian macro regions (see Fig. 1 for geographic reference) of the Regional Climate Change Index (*RCCI*) and its four components of climatic change: mean precipitation (ΔP , % of present-day value), interannual variability of precipitation ($\Delta\sigma_P$, % of present-day value), mean surface air temperature relative to the global average temperature change (or Regional Warming Amplification Factor, *RWAF*) and change in regional surface air temperature interannual variability ($\Delta\sigma_T$, % of present-day value). Results are shown for the austral summer and winter (DJF and JJA, respectively), except for the *RCCI*

	North	Northeast	Centre-West	Southeast	South
<i>RCCI</i>	15.99	13.01	17.71	12.86	4.81
ΔP (DJF)	5.97	0.99	2.43	1.32	7.70
ΔP (JJA)	-5.82	-17.45	-18.01	-13.11	4.48
$\Delta\sigma_P$ (DJF)	5.00	10.10	8.39	10.01	1.06
$\Delta\sigma_P$ (JJA)	17.35	14.74	26.42	17.20	10.06
<i>RWAF</i> (DJF)	1.14	1.04	1.10	1.02	0.92
<i>RWAF</i> (JJA)	1.48	1.15	1.44	1.23	1.06
$\Delta\sigma_T$ (DJF)	16.11	12.40	21.15	18.10	6.11
$\Delta\sigma_T$ (JJA)	16.73	12.67	13.73	9.55	3.23

developed by Baettig et al. (2007), although the two indexes are calculated by different ensemble models and methodologies. Additionally, all areas indicated as hotspots by the *RCCI* were also predicted to suffer soil moisture deficits and an increase in the frequency of short-term (4–6 month duration) droughts by the end of the twenty-first century by Sheffield and Wood (2008). In the Amazon basin, the *RCCI* results are coherent with the well documented potential of climate change to enhance intense drought events in this region, such as the droughts of 2005 and 2010 (Malhi et al. 2008; Nobre and Borma 2009; Lewis et al. 2011; Marengo et al. 2011b, c, d; Davidson et al. 2012), which caused serious hydrological, agricultural and transportation problems, strongly affecting residents.

The lowest values of the climate index were found for Southern Brazil (S), in the states of São Paulo and Mato Grosso do Sul, and throughout the Brazilian coast. However, these low *RCCI* values should not be interpreted as indicating “no-change” or “no-impact” but rather as a smaller change relative to other regions of Brazil. For example, some studies indicate an increase in the frequency of extreme precipitation events in S during the last half of the twentieth century (e.g., Tebaldi et al. 2006; Rusticucci et al. 2010; Marengo et al. 2010b) and indicate a further increase in these events towards the end of the twenty-first century in a warmer climate (Tebaldi et al. 2006; Marengo et al. 2009). Thus, as mentioned in Section 2.2, future studies must improve the *RCCI* index calculation (i.e., using higher-resolution models and more advanced statistical techniques) to explicitly capture climate extreme events.

South America has the lowest *RCCI* values among the 26 averaged land regions of the world analyzed by Giorgi (2006). However, our study reveals that different climate change patterns are found inside each of the 3 (out of 26) boxes established to represent the South America climate change behavior in Giorgi’s study [“Amazon Basin” (20 S–10 N; 78.5–34.5 W), “Central South America” (40–20 S; 78.5–34.5 W) and “Southern South America” (56–40 S; 78.5–34.5 W)]. For example, the “Amazon Basin” box includes NE and Peru/Ecuador, regions with different predictions regarding precipitation change (Vera et al. 2006; Meehl et al. 2005). Differently, the results from the spatial analysis of the *RCCI* performed here emphasize the different projected climate change pattern when comparing N and NE regions.

3.2 *SCVI*

The *SCVI* analysis reveals major socio-climatic hotspots in NE Brazil and several widespread punctual hotspots in many of the major Brazilian metropolitan regions (Fig. 2b). The spatial pattern of the *SCVI* is quite different from that of the *RCCI*; it reveals an east–west gradient related to the historical occupation of the coastal lands and its vicinities in Brazil, which indicates that population density has a considerable weight in *SCVI* calculations. Therefore, the *SCVI* analysis shows that the designation of the most impacted areas by climate change can be quite different when translated into a social-vulnerability relevant form.

The large socio-climatic hotspots in NE result from a combination of low-to-medium *RCCI* values, relatively high ρ , and the lowest *HDI* levels in Brazil (Table 3). This result is in agreement with those shown of Confalonieri et al. (2009), who found that the NE region is the most vulnerable to public health impacts of climate change in Brazil, although those authors employed only past climatological observations in their analysis and presented their results on a state-level basis. However, the inclusion of the epidemiological vulnerability index presented by Confalonieri et al. (2009) in the *SCVI* calculation (making our results more comparable to those of Confalonieri et al.’s) did not change the relative socio-climatic vulnerability among the regions: NE remained as the most vulnerable area in the country, followed by SE, CW, S and N. This epidemiological vulnerability index was constructed by Confalonieri et al. (2009) using morbidity, mortality and health cost data related to seven

Table 3 Mean values for the 5 Brazilian macro regions (see Fig. 1 for geographic reference) of the Socio-Climatic Vulnerability Index (*SCVI*, dimensionless), Human Development Index (*HDI*, dimensionless) and population density (ρ , inhabitants per km²)

	North	Northeast	Centre-West	Southeast	South
SCVI	0.30	0.93	0.43	0.85	0.31
HDI	0.651	0.612	0.741	0.738	0.766
ρ	3.82	33.48	7.52	80.45	45.18

climate-sensitive endemic infectious diseases occurring in Brazil (e.g., dengue fever, cholera and malaria).

The other punctual socio-climatic hotspots covering some of the major Brazilian cities are Manaus (*SCVI*=3.2), Belo Horizonte (3.2), Brasília (3.1), Salvador (2.8), Rio de Janeiro (2.6) and São Paulo (1.7), as well as nearly all the NE capitals. Some of the values found for these cities are the result of high or very high *RCCI* values, as is the case for Manaus, Belo Horizonte and Brasília. For the other cities, even the relatively low *RCCI* values are not sufficient to avoid the high *SCVI* values, meaning that even a moderate climate change might bring serious consequences to these cities because of their high population densities. High ρ values in Brazil indicate metropolitan areas, for which the *SCVI* formulation is able to correctly capture the effect of the pronounced social heterogeneity typical of the country's largest cities. As an example, let us consider the metropolitan area of São Paulo city, which in 2000 had an *HDI* of 0.828, suggesting a high human development level. However, a finer-scale analysis reveals that the São Paulo metropolitan region has several districts (especially in the city outskirts) with *HDI* values lower than 0.750, considered "moderate" human development, similar to many N and NE municipalities. A recent assessment of the overall vulnerability of the São Paulo metropolitan area to climate change shows that the residents of such districts would be affected most strongly by climate change through floods, landslides, and spreading diseases (Nobre et al. 2010). It is reasonable to apply the same conclusion to the other Brazilian metropolitan regions unveiled here as socio-climatic hotspots, as suggested by the neighborhood-level *HDI* analysis performed for other cities (e.g., SEPLAN et al. 2006 for Manaus; PNUD et al. 2006 for Salvador; IPP et al. 2003 for Rio de Janeiro).

In fact, the above-mentioned social impacts of climate change can vary dramatically by region and livelihood. For the NE, the major climatic constraint has always been linked to rainfall shortage and limited water availability for human consumption and subsistence agriculture (Kabat et al. 2003; Sahota 1968). The decomposition of the *RCCI* into separate components, given in Table 2, reveals that the future impacts of climate change on the NE population will be tied to aggravations of rainfall shortage and limited water availability. For metropolitan areas, these impacts will certainly be expressed by floods, landslides, heat waves, and possibly other events, which are closely linked to the urbanization pattern. It is important to note that some indirect impacts of climate change have not been included in this vulnerability assessment. Climate-driven agricultural losses can, for example, increase the vulnerability of a given population, even if the croplands are located in depopulated areas far from consuming centers. This issue is not addressed by this spatial analysis using only the *HDI* and ρ as social vulnerability indicators, and will be tackled in future studies.

Finally, low *SCVI* values should not be interpreted as "no action needed". The *SCVI* index must be used as an auxiliary index in climate change debates rather than a substitutive to other specific vulnerability or impact indexes, such as the *RCCI*. Although it is reasonable to focus adaptation policies on regions where more people are affected, some adaptation measures are needed to strengthen the adaptive capacity of less dense, but no less important,

areas. Let us take as an example the Brazilian Legal Amazon population of 23 million people, which is scattered over an area of more than 5 million km². If impacted by climate change, we may expect a south/eastward population migration, which would increase ρ in already dense areas, thereby worsening the *SCVI* values in South/East Brazil, similar to the results of past dry spell events in Northeast Brazil (Yap 1976).

3.3 Final remarks

This study is a first-order spatially explicit evaluation of the social vulnerability to climate change in Brazil. Refinements should include the use of regional climate models (with spatial resolutions of 50 km or higher) or advanced statistical downscaling techniques and the consideration of other indicators of social vulnerability (such as fine-scale epidemiological information, data on susceptibility to landslides and floods, water availability, and agricultural risks).

That being said, the two major contributions of this study are the presentation of a more detailed analysis of the *RCCI* in Brazil (compared to the study by Giorgi 2006) and the development of a new index (*SCVI*) that merges the extensive number of IPCC global model projections on climate change with social vulnerability indicators. Moreover, this proposed index could be applied to other countries and regions. Both the *RCCI* and *SCVI* indexes have a simplistic and exploratory nature but can be useful for improving the dialogue between climate and social scientists and communicating climate change to policymakers in a more synthetic and socially relevant form.

Acknowledgments We are thankful to M. D. Oyama and C. A. Nobre for their helpful comments on the early drafts of this manuscript. Three anonymous reviewers provided suggestions that considerably improved the quality of the manuscript. The first author was supported by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) and by Brazil's Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Additional support was provided by FAPESP through the "Assessment of impacts and vulnerability to climate change in Brazil and strategies for adaptation options" project (Proc. # 2008/58161-1). We also thank the Program for Climate Model Diagnosis and Intercomparison (PCMDI) and the WCRP's Working Group on Coupled Modelling (WGCM) for making the CMIP3 multi-model dataset available.

References

- Adger WN (1999) Social vulnerability to climate change and extremes in coastal Vietnam. *World Develop* 27:249–269
- Alexander LV, Zhang X, Peterson TC, Caesar J, Gleason B, Tank AMGK, Haylock M, Collins D, Trewin B, Rahimzadeh F, Tagipour A, Kumar KR, Revadekar J, Griffiths G, Vincent L, Stephenson DB, Burn J, Aguilar E, Brunet M, Taylor M, New M, Zhai P, Rusticucci M, Vazquez-Aguirre JL (2006) Global observed changes in daily climate extremes of temperature and precipitation. *J Geophys Res* 111:D05109
- SEPLAN (Secretaria de Estado Planejamento e Desenvolvimento Econômico do Amazonas), Prefeitura de Manaus, Programa das Nações Unidas para Desenvolvimento Brasil, Fundação João Pinheiro. 2006. Atlas do Desenvolvimento Humano em Manaus. Manaus, SEPLAN/Prefeitura de Manaus/PNUD-Brasil/Fundação João Pinheiro. 24p. Available at: http://www.pnud.org.br/publicacoes/atlas_manauas/Release_Atlas.pdf. Accessed in 01/Feb/2012
- Baettig MB, Wild M, Imboden DM (2007) A climate change index: Where climate change may be most prominent in the 21st century. *Geophys Res Lett* 34:L01705
- Bombardi RJ, Carvalho LMV (2009) IPCC Global coupled climate model simulations of the South America Monsoon System. *Clim Dyn* 33:893–916
- Boullanger JP, Martinez F, Segura EC (2006) Projection of future climate change conditions using IPCC simulations, neural networks and Bayesian statistics. Part I: temperature mean state and seasonal cycle in South America. *Clim Dyn* 27:233–259

- Boulanger JP, Brasseur G, Carril AF, Castro M, Degallier N, Ereño C, Le Treut H, Marengo JA, Menendez CG, Nuñez MN, Penalba OC, Rolla AL, Rusticucci M, Terra R (2010) A Europe–South America network for climate change assessment and impact studies. *Clim Change* 98:307–329
- Christensen JH, Carter TR, Rummukainen M, Amanatidis G (2007) Evaluating the performance and utility of regional climate models: the PRUDENCE project. *Clim Change* 81:1–6
- Confalonieri UEC, Marinho DP, Rodriguez RE (2009) Public health vulnerability to climate change in Brazil. *Clim Res* 40:175–186
- Davidson EA, Araujo AC, Artaxo P, Balch JK, Brown IF, Bustamante MMC, Coel MT, DeFries RS, Keller M, Longo M, Munger JW, Schroeder W, Soares-Filho BS, Souza CM Jr, Wofsy SC (2012) The Amazon basin in transition. *Nature* 481:321–328
- Folha de São Paulo (2010) Reféns da chuva. *Folha de São Paulo*, 22. Jan.2010, p. C1
- Folha de São Paulo (2011) Estado do Rio enfrenta a pior chuva em mais de 4 décadas. *Folha de São Paulo*, 13. Jan.2011, p. A1
- IPP (Instituto Municipal de Urbanismo Pereira Passos), Instituto Universitário de Pesquisas do Rio de Janeiro, Instituto de Pesquisa Economica Aplicada, Fundação João Pinheiro. 2003. IDH dos bairros do Rio de Janeiro. Available at: http://www.pnud.org.br/pdf/Tabela%206.2.22%20IDH%20bairro%2091_00-15_12_03.xls, Accessed in 01/Feb/2012
- PNUD (Programa das Nações Unidas para Desenvolvimento Brasil), Companhia de Desenvolvimento Urbano do Estado da Bahia, Fundação João Pinheiro, Instituto Brasileiro de Geografia e Estatística. 2006. Atlas de Desenvolvimento da Região Metropolitana de Salvador. PNUD/CONDER/Fundação João Pinheiro/IBGE. Available at: http://www.pnud.org.br/publicacoes/atlas_salvador/index.php. Accessed in: 01/Feb/2012
- Diffenbaugh NS, Giorgi F, Raymond L, Bi X (2007) Indicators of 21st century socioclimatic exposure. *Proc Natl Acad Sci USA* 104:20195–20198
- Eriksen SH, Kelly PM (2007) Developing credible vulnerability indicators for climate adaptation policy assessment. *Mitig Adapt Strategies Glob Chang* 12:495–524
- Frich P, Alexander LV, Della-Marta P, Gleason B, Haylock M, Tank AMGK, Peterson T (2002) Observed coherent changes in climatic extremes during the second half of the twentieth century. *Clim Res* 19:193–212
- Füssel HM, Klein RJT (2006) Climate change vulnerability assessments: an evolution of conceptual thinking. *Clim Change* 75:301–329
- Giorgi F (2005) Climate change prediction. *Clim Change* 73:239–265
- Giorgi F (2006) Climate change hot-spots. *Geophys Res Lett* 33:L08707
- Giorgi F, Bi XQ (2005) Updated regional precipitation and temperature changes for the 21st century from ensembles of recent AOGCM simulations. *Geophys Res Lett* 32:L21715
- Goldewijk KK (2005) Three centuries of global population growth: a spatial referenced population (density) database for 1700–2000. *Popul Environ* 26:343–367
- IBGE (Brazilian Institute of Geography and Statistics) (2009) Censo agropecuário 2006. Primeiros resultados: Agricultura Familiar Brasil, grandes regiões e unidades da federação. Instituto Brasileiro de Geografia e Estatística Rep., 267pp. Available at: http://www.ibge.gov.br/home/estatistica/economia/agropecuaria/censoagro/agri_familiar_2006/familia_censoagro2006.pdf
- Ionescu C, Klein RJT, Hinkel J, Kumar KSK, Klein R (2009) Towards a formal framework of vulnerability to climate change. *Environ Model Assess* 14:1–16
- IPCC (2007) Summary for policymakers. In: Solomon S, Qin D, Manning M, Chen Z, Marquis M, Averyt KB, Tignor M, Miller HL (eds) *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 University Press, Cambridge, United Kingdom and New York, NY, USA
- IPEA (Institute for Applied Economic Research) (2011) O comércio internacional e a sustentabilidade socioambiental no Brasil. Available at: http://www.ipea.gov.br/portal/images/stories/PDFs/comunicado/110222_comunicadoipea79.pdf, access in 03.05.2011
- IPEA (Institute for Applied Economic Research), United Nations Development Programme Brazil, Joao Pinheiro Foundation (2003) Atlas do Desenvolvimento Humano no Brasil. Available at: www.pnud.org.br/atlas, access in 13.04.2011
- Jones PW (1999) First- and second-order conservative remapping schemes for grids in spherical coordinates. *Mon Wea Rev* 127:2204–2210
- Kabat P, van Schaik, Appleton B, Eds (2003) Climate changes the water rules: how water managers can cope with today's climate variability and tomorrow's climate change. *Dialogue on Water and Climate*, NL, 106p
- Knutti R (2008) Should we believe model predictions of future climate change? *Phil Trans R Soc* 366:4647–4664

- Lewis SL, Brando PM, Phillips OL, Geertje MF, van der Heijden ND (2011) The 2010 Amazon drought. *Science* 331:554
- Lucena AFP, Szklo AS, Schaeffer R, Souza RR, Borba BSMC, Costa IVL, Pereira Júnior AO, Cunha SHF (2009) The vulnerability of renewable energy to climate change in Brazil. *Energy Policy* 37:879–889
- Magrin G, Gay García C, Cruz Choque D, Giménez JC, Moreno AR, Nagy GJ, Nobre C, Villamizar A (2007) Latin America. *Climate Change 2007: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*, Parry ML, Canziani OF, Palutikof JP, van der Linden PJ, Hanson CE, Eds., Cambridge University Press, Cambridge, UK, 581–615
- Malhi Y, Roberts JT, Betts RA, Killeen TJ, Li W, Nobre CA (2008) Climate change, deforestation and the fate of the Amazon. *Science* 319:169–172
- Marengo JA, Jones R, Alves L, Valverde M (2009) Future change of temperature and precipitation extremes in South America as derived from the PRECIS regional climate modeling system. *Int J Climatol* 29:2241–2255
- Marengo JA, Ambrizzi T, Rocha RP, Alves LM, Cuadra SV, Valverde M, Ferraz SET, Torres RR, Santos DC (2010a) Future change of climate in South America in the late XXI century: intercomparison of scenarios from three regional climate models. *Clim Dyn* 35:1073–1097
- Marengo JA, Rusticucci M, Penalba O, Renom M (2010b) An intercomparison of observed and simulated extreme rainfall and temperature events during the last half of the twentieth century. Part 2: historical trends. *Clim Change* 98:509–529
- Marengo JA, Chou SC, Kay G, Alves LM, Pesquero JF, Soares WR, Santos DC, Lyra AA, Sueiro G, Betts R, Chagas DJ, Gomes JL, Bustamante JF, Tavares P (2011a) Development of regional future climate change scenarios in South America using the Eta CPTec/HadCM3 climate change projections: climatology and regional analyses for the Amazon, São Francisco and the Parana River Basins. *Clim Dyn*: on line first
- Marengo JA, Nobre CA, Chou SH, Tomasella J, Sampaio G, Alves LM, Obregón GO, Soares WR, Betts R, Kay G (2011b) Dangerous Climate Change. A Brazil-UK analysis of climate change and deforestation impacts in the Amazon. 55pp. Available at: http://mudancasclimaticas.cptec.inpe.br/~mclima/pdfs/destaques/relatorio_ingl.pdf
- Marengo JA, Tomasella J, Alves LM, Soares W, Rodriguez DA (2011c) The drought of 2010 in the context of historical droughts in the Amazon region. *Geophys Res Lett* 38:L12703
- Marengo JA, Tomasella J, Soares W, Alves LM, Nobre C (2011d) Extreme climatic events in the Amazon basin: climatological and hydrological context of recent floods. *Theor Appl Climatol* 107:73–85
- Meehl GA, Arblaster JM, Tebaldi C (2005) Understanding future patterns of increased precipitation intensity in climate model simulations. *Geophys Res Lett* 32:L18719
- Meehl GA, Covey C, Delworth T, Mojić L, McAvaney B, Mitchell JFB, Stouffer RJ, Taylor KE (2007) The WCRP CMIP3 multimodel dataset: a new era in climate change research. *Bull Am Meteorol Soc* 88:1383–1394
- Nakicenovic N, Alcamo J, Davis G, De Vries B, Fenham J, Gaffin S, Gregory K, Grubler A, Jung TY, Kram T, La Rovere EL, Michaelis L, Mori S, Morita T, Pepper W, Pitcher H, Price L, Riahi K, Roehrl A, Rogner HH, Sankovski A, Schlesinger M, Shukla P, Smith S, Swart R, Van Rooijen S, Victor N, Dadi Z (2000) Special report on emissions scenarios. Cambridge University Press, UK
- Nobre CA, Borma LS (2009) 'Tipping points' for the Amazon forest. *Curr Opin Environ Sustain* 1:28–36
- Nobre CA, Young AF, Saldiva P, Marengo JA, Nobre AD, Alves Júnior SP, Silva GCM, Lombardo M (2010) Vulnerabilidades das megacidades brasileiras às mudanças climáticas: região metropolitana de São Paulo. Available at: <http://www.inpe.br/noticias/arquivos/pdf/megacidades.pdf>, access in 04.05.2011
- Pidgeon N, Fischhoff B (2011) The role of social and decision sciences in communicating uncertain climate risks. *Nature Clim Change* 1:35–41
- Ponce VM (1995) Management of droughts and floods in the semiarid Brazilian Northeast – the case for conservation. *J Soil Water Conservat* 50:422–431
- Preston BL, Yuen EJ, Westaway RM (2011) Putting vulnerability to climate change on the map: a review of approaches, benefits, and risks. *Sustain Sci* 6:177–202
- Räisänen J (2002) CO₂-induced changes in interannual temperature and precipitation variability in 19 CMIP2 experiments. *J Clim* 15:2395–2411
- Rusticucci M, Marengo JA, Penalba O, Renom M (2010) 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. *Clim Change* 98:493–508
- Sahota GS (1968) An economic analysis of internal migration in Brazil. *J Polit Econ* 2:218–245
- Sheffield J, Wood EF (2008) Projected changes in drought occurrence under future global warming from multi-model, multi-scenario, IPCC AR4 simulations. *Clim Dyn* 31:79–105
- Tebaldi C, Hayhoe K, Arblaster JM, Meehl G (2006) Going to the extremes. An intercomparison of model-simulated historical and future changes in extreme events. *Clim Change* 79:185–211

- Vera C, Silvestri G, Liebmann B, González P (2006) Climate change scenarios for seasonal precipitation in South America from IPCC-AR4 models. *Geophys Res Lett* 33:L13707
- Xu Y, Xuejie G, Giorgi F (2009) Regional variability of climate change hot-spots in East Asia. *Adv Atmos Sci* 26(4):783–792
- Yap L (1976) Internal migration and economic development in Brazil. *Q J Econ* 90(1):119–137
- Yohe G, Malone E, Brenkert A, Schlesinger M, Meij H, Xing X (2006) Global distributions of vulnerability to climate change. *Integ Assess J* 6:35–44
- Yusuf AA, Francisco H (2009) Climate change vulnerability mapping for Southeast Asia. *Economy and Environment Program for Southeast Asia*, Singapore

- Vera C, Silvestri G, Liebmann B, González P (2006) Climate change scenarios for seasonal precipitation in South America from IPCC-AR4 models. *Geophys Res Lett* 33:L13707
- Xu Y, Xuejie G, Giorgi F (2009) Regional variability of climate change hot-spots in East Asia. *Adv Atmos Sci* 26(4):783–792
- Yap L (1976) Internal migration and economic development in Brazil. *Q J Econ* 90(1):119–137
- Yohe G, Malone E, Brenkert A, Schlesinger M, Meij H, Xing X (2006) Global distributions of vulnerability to climate change. *Integ Assess J* 6:35–44
- Yusuf AA, Francisco H (2009) Climate change vulnerability mapping for Southeast Asia. *Economy and Environment Program for Southeast Asia*, Singapore

ANEXO C – TERCEIRO ARTIGO PUBLICADO NO PERIÓDICO *THEORETICAL AND APPLIED CLIMATOLOGY*

CLIMATE CHANGE HOTSPOTS OVER SOUTH AMERICA: FROM CMIP3 TO CMIP5 MULTI-MODEL DATASETS

RESUMO

Este estudo identifica possíveis *hotspots* de mudanças climáticas na América do Sul através da análise do padrão espacial do índice *Regional Climate Change Index* (RCCI) sobre a região para o final do século XXI. O RCCI é um índice qualitativo que pode sintetizar um grande número de projeções de modelos climáticos, e é útil para identificar aquelas regiões aonde as mudanças climáticas podem ser mais pronunciadas em um clima mais quente. A confiabilidade e as incertezas dos resultados são avaliados ao utilizarmos inúmeros Modelos de Circulação Geral (MCGs) e cenários forçantes provenientes do *Coupled Model Intercomparison Project Phases 3 and 5*. Os resultados mostram que o sul da Amazônia, centro-oeste e porção oeste de Minas Gerais são persistentes *hotspots* de mudanças climáticas para todos os diferentes cenários forçantes e conjuntos de MCGs. Em geral, a medida em que os cenários variam do mais baixo ao mais alto nível de forçante, a área contendo altos valores de RCCI aumenta e a magnitude intensifica-se do centro-oeste e sudeste do Brasil em direção ao noroeste da América do Sul. Os *hotspots* climáticos identificados neste estudo são caracterizados, em geral, por um aumento na temperatura do ar próximo a superfície, principalmente no inverno, por um aumento na variabilidade interanual de temperatura, predominantemente no verão austral, e por uma mudança na média e variabilidade interanual de precipitação durante o inverno austral.

Climate change hotspots over South America: from CMIP3 to CMIP5 multi-model datasets

Roger Rodrigues Torres · Jose Antonio Marengo

Received: 17 June 2013 / Accepted: 3 October 2013
© Springer-Verlag Wien 2013

Abstract This study identifies possible hotspots of climate change in South America through an examination of the spatial pattern of the Regional Climate Change Index (RCCI) over the region by the end of the twenty-first century. The RCCI is a qualitative index that can synthesize a large number of climate model projections, and it is suitable for identifying those regions where climate change could be more pronounced in a warmer climate. The reliability and uncertainties of the results are evaluated by using numerous state-of-the-art general circulation models (GCMs) and forcing scenarios from the Coupled Model Intercomparison Project phases 3 and 5. The results show that southern Amazonia and the central-western region and western portion of Minas Gerais state in Brazil are persistent climate change hotspots through different forcing scenarios and GCM datasets. In general, as the scenarios vary from low- to high-level forcing, the area of high values of RCCI increase and the magnitude intensify from central-western and southeast Brazil to north-west South America. In general, the climatic hotspots identified in this study are characterized by an increase of mean surface air temperature, mainly in the austral winter; by an increase of interannual temperature variability, predominantly in the austral summer; and by a change in the mean and

interannual variability of precipitation during the austral winter.

1 Introduction

In recent decades, it has become widely recognized by the scientific community that politicians and stakeholders require reliable and concise information about climate change and its impacts, together with reliable estimates of uncertainties. Climate change projections are of a completely different nature to weather and climate prediction, and it is important that the end user of this information be aware of its uncertainties and limitations (Giorgi 2005; Xu et al. 2009; Torres and Marengo 2013).

One possibility to address the need for a brief overview of the scientific facts is the creation of climate change indexes that aggregate several information and estimates of uncertainties (e.g., Giorgi 2006; Baettig et al. 2007; Diffenbaugh et al. 2007, 2008; Xu et al. 2009; Preston et al. 2011; Diffenbaugh and Giorgi 2012; Torres et al. 2012). As emphasized by Diffenbaugh and Giorgi (2012), the impacts of climate change are likely to be determined by local physical, biological, and human characteristics. On the other hand, the quantification of integrated change across a suite of physical climate indicators could help to identify climate change hotspots¹ for studies of impact, adaptation, and vulnerability (Diffenbaugh and Giorgi 2012; Torres et al. 2012). In this way, some climate change indexes can be found in the literature, such as the Regional Climate Change Index (Giorgi 2006), the Climate Change Index (Baettig et al. 2007), and the Squared Chord Distance

R. R. Torres
Center for Weather Forecast and Climate Studies, National Institute for Space Research (CPTEC/INPE), Rodovia Presidente Dutra km 40, Cachoeira Paulista, São Paulo 12630-000, Brazil

R. R. Torres (✉)
Natural Resources Institute, Federal University of Itajubá (IRN/UNIFEI), Av. BPS, 1303, Itajubá, Minas Gerais 37500-903, Brazil
e-mail: roger.torres@unifei.edu.br

J. A. Marengo
Earth System Science Center, National Institute for Space Research (CCST/INPE), Rodovia Presidente Dutra km 40, Cachoeira Paulista, São Paulo 12630-000, Brazil

Published online: 18 October 2013

 Springer

¹ The word “hotspots” is used in this study to indicate areas with large regional climate changes.

and Standard Euclidean Distance (Diffenbaugh et al. 2008; Diffenbaugh and Giorgi 2012).

Several studies have identified Central and South America as regions with high vulnerability to future climate change, mainly in their tropical area (e.g., Baettig et al. 2007; IPCC 2007; Diffenbaugh and Giorgi 2012). These regions are vulnerable to current climate extremes and could be affected greatly by a warmer climate (Marengo et al. 2010a, b, 2011; Rusticucci et al. 2010; Torres et al. 2012; Donat et al. 2013; Sillmann et al. 2013a, b; Torres and Marengo 2013). With an economy based strongly on agricultural commodities, numerous social and environmental problems, and further problems associated with development patterns and urbanization, South America suffers constantly with temperature and precipitation extremes that cause significant economic damage and casualties.

Torres et al. (2012) combined the Regional Climate Change Index (RCCI) developed by Giorgi (2006) and some possible indicators of Brazilian population vulnerability into the Socio-Climatic Vulnerability Index (SCVI) proposed by the authors. Torres et al. (2012) calculated the RCCI over Brazil using numerous general circulation models (GCMs) from the Coupled Model Intercomparison Project phase 3 (CMIP3) (Meehl et al. 2007) employed in the Intergovernmental Panel on Climate Change (IPCC) Fourth Assessment Report (AR4) (IPCC 2007). They showed that the RCCI can be a suitable tool for communicating climate change and that it could be used in combination with social data in a relevant form.

In light of this, the aims of this work are to analyze thoroughly the RCCI index over the whole South America and to investigate the reliability of the results by using different climate change simulation inputs. Specifically, the RCCI is computed for 24 GCMs from CMIP3 and for 24 state-of-the-art GCMs participating in the Coupled Model Intercomparison Project phase 5 (CMIP5) (Taylor et al. 2012). Therefore, the uncertainties regarding the use of different GCM structures and forcing scenarios are analyzed, and the primary persistent climate change hotspots over South America are identified.

2 Methods and data

2.1 Brief climate simulation dataset description

The climate simulations analyzed in this study come from the CMIP3 and CMIP5 state-of-the-art GCM datasets, provided by the Program for Climate Model Diagnosis and Intercomparison (PCMDI) and downloaded from the Earth System Grid data portal. The variables used are monthly precipitation and surface air temperature data simulated for the present climate (1961–1990) and projected to the end of this century (2071–2100) by 24 GCMs from CMIP3 (Meehl et al. 2007) (Table 1) and 24

Table 1 List of models, approximate model horizontal resolutions, emission scenarios, and number of runs in the CMIP3 dataset used in this study

Models	Resolution (lat/lon)	20C3M	A2	A1B	B1
INM-CM3.0	5°×4°	1	1	1	1
GISS-EH	5°×4°	5	–	3	–
GISS-ER	5°×4°	9	1	2	1
GISS-AOM	4°×3°	2	–	2	2
CGCM3.1(T47)	3.8°×3.8°	5	5	5	5
ECHO-G	3.8°×3.8°	5	3	3	3
UKMO-HadCM3	3.8°×2.5°	2	1	1	1
IPSL-CM4	3.8°×2.5°	1	1	1	1
FGOALS-g1.0	2.8°×3°	3	–	2	3
MRI-CGCM2.3.2	2.8°×2.8°	5	5	5	5
CGCM3.1(T63)	2.8°×2.8°	1	–	1	1
CNRM-CM3	2.8°×2.8°	1	1	1	1
MIROC3.2(medres)	2.8°×2.8°	2	3	3	3
PCM	2.8°×2.8°	4	4	4	2
GFDL-CM2.0	2.5°×2°	3	1	1	1
GFDL-CM2.1	2.5°×2°	3	1	1	1
BCCR-BCM2.0	1.9°×1.9°	1	1	1	1
CSIRO-MK3.0	1.9°×1.9°	3	1	1	1
CSIRO-MK3.5	1.9°×1.9°	3	1	1	1
ECHAM5	1.9°×1.9°	4	3	4	3
UKMO-HadGEM1	1.9°×1.3°	2	1	1	–
CCSM3	1.4°×1.4°	7	4	7	9
ECHAM4	1.1°×1.1°	1	1	1	–
MIROC3.2(hires)	1.1°×1.1°	1	–	1	1

Models are ranked by their spatial resolution

GCMs from CMIP5 (Taylor et al. 2012) (Table 2), representing nearly 450 runs. Hereafter, changes refer to the difference between the mean values of the climate variables simulated for the periods 2071–2100 (“future climate”) and 1961–1990 (“present-day” climate).

The forcing scenarios employed in the climate simulations for the future period in the CMIP3 dataset are based on the storylines B1, A1B, and A2 of the Special Report on Emission Scenarios (SRES) (Nakicenovic et al. 2000), which correspond to equivalent CO₂ concentrations in the atmosphere in 2100 of approximately 550, 700, and 850 ppm, respectively. On the other hand, CMIP5 future climate simulations are performed using the new generation of forcing scenarios called Representative Concentration Pathways (RCP) (Moss et al. 2010) and denominated as RCP 2.6, 4.5, 6.0, and 8.5, corresponding to an approximate radiative forcing by the end of the century of 2.6, 4.5, 6.0, and 8.5 W m⁻², respectively, relative to pre-industrial conditions (Moss et al. 2010). With regard to the equivalent CO₂ concentrations, the 2.6, 4.5, 6.0, and 8.5 RCPs correspond roughly to 490, 650, 850, and 1,370 ppm, respectively, in 2100 (van Vuuren et al. 2011).

Table 2 List of models, approximate model horizontal resolutions, future (RCPs 2.6, 4.5, 6.0, 8.5) and historical simulations, and number of runs in the CMIP5 dataset used in this study

Models	Resolution (lat/lon)	Historical	RCP			
			2.6	4.5	6.0	8.5
FGOALS-g2	3.1°×2.8°	4	1	1	–	1
BCC-CSM1-1	2.8°×2.8°	3	1	1	1	1
CanESM2	2.8°×2.8°	5	5	5	–	5
MIROC-ESM	2.8°×2.8°	3	1	1	1	1
FIO-ESM	2.8°×2.8°	1	1	1	1	1
MIROC-ESM-CHEM	2.8°×2.8°	1	1	1	1	1
GFDL-CM3	2.0°×2.5°	5	1	1	1	1
GFDL-ESM2G	2.0°×2.5°	1	1	1	1	–
Giss-E2-R	2.0°×2.5°	5	1	5	1	1
GFDL-ESM2M	2.0°×2.5°	1	1	1	1	1
IPSL-CM5A-LR	1.9°×3.8°	4	1	3	1	3
NorESM1-M	1.9°×2.5°	3	1	1	1	1
CSIRO-Mk3-6-0	1.9°×1.9°	10	10	10	10	10
MPI-ESM-LR	1.9°×1.9°	3	3	3	–	3
INMCM4	1.5°×2.0°	1	–	1	–	1
CNRM-CM5	1.4°×1.4°	1	1	1	–	1
MIROC5	1.4°×1.4°	1	1	1	1	1
IPSL-CM5A-MR	1.3°×2.5°	1	1	1	–	1
HadGEM2-CC	1.3°×1.9°	1	–	1	–	1
HadGEM2-ES	1.3°×1.9°	4	1	1	1	4
ACCESS1.0	1.3°×1.9°	1	–	1	–	1
EC-EARTH	1.1°×1.1°	1	1	1	–	1
MRI-CGCM3	1.1°×1.1°	5	1	1	1	1
CCSM4	0.9°×1.3°	6	5	5	5	5

As in Table 1, models are ranked by their spatial resolution

Further details about the scenarios SRES and RCPs can be found, for example, in Nakicenovic et al. (2000), Moss et al. (2010), and van Vuuren et al. (2011).

The CMIP3 GCM horizontal resolutions vary from about 1° to 5° of latitude/longitude (Table 1), and those from the CMIP5 GCMs vary from approximately 1° to 3°. For intercomparison purposes and to relate them properly with some high-resolution data (such as social and economic datasets) in a reasonable grid size in future studies, all GCMs were interpolated to a common 1° grid by using the conservative remapping scheme (Jones 1999), following some authors in the literature (Giorgi and Bi 2005; Giorgi 2006; Xu et al. 2009; Diffenbaugh and Giorgi 2012; Torres et al. 2012).

In addition to slightly higher horizontal resolutions, CMIP5 also includes GCMs and experiments that are more comprehensive (e.g., including carbon cycle or decadal climate predictability experiments) compared with those of CMIP3, which allows scientists to explore a broader spectrum of scientific questions (Taylor et al. 2012; Knutti and Sedláček 2013; Sillmann et al. 2013a). Some of the main improvements in the CMIP5 GCMs are the addition of interactive ocean and land carbon cycles of varying degrees of complexity and the

more complete radiative forcings due to, among other things, the inclusion of more comprehensive modeling of the indirect effect of aerosols and the use of time-evolving volcanic and solar forcing in most models (Taylor et al. 2012; Knutti and Sedláček 2013; Sillmann et al. 2013a).

2.2 Regional Climate Change Index

The RCCI is a qualitative index proposed by Giorgi (2006), which is well accepted in the literature as a simple way in which to identify those regions where climate change could be, on a relative basis, more pronounced in a warmer climate (e.g., Xu et al. 2009; May 2012; Torres et al. 2012; Li et al. 2013). This index is based on some representative climate change quantities: temperature change in a specific region relative to the mean global temperature change (or regional warming amplification factor, RWF, dimensionless), the change in mean regional precipitation (ΔP , percentage of present-day value), and the change in the interannual variability of temperature ($\Delta\sigma_T$, percentage of present-day value) and precipitation ($\Delta\sigma_p$, percentage of present-day value).

Originally, as proposed by Giorgi (2006), all quantities mentioned above are calculated separately for wet and dry seasons. However, in this study, those quantities are calculated for austral summer (DJF) and winter (JJA) seasons, following Xu et al. (2009) and Torres et al. (2012). Nevertheless, in almost all of South America, the wet and dry seasons occur during the austral summer and winter seasons, respectively, except for some regions, such as over eastern Northeast Brazil and in the north and northwest of South America (e.g., Liebmann and Marengo 2001; Rao et al. 1993).

Thus, the RCCI is finally defined as

$$\text{RCCI} = [n(\Delta P) + n(\Delta\sigma_P) + n(\text{RWF}) + n(\Delta\sigma_T)]_{\text{DJF}} + [n(\Delta P) + n(\Delta\sigma_P) + n(\text{RWF}) + n(\Delta\sigma_T)]_{\text{JJA}}$$

where n is an empirical factor that assumes the value 0, 1, 2, or 4, depending on the magnitude of the change involved (Table 3). For example, assuming a hypothetical location that presents for austral summer, $\Delta P=2\%$, $\Delta\sigma_P=18\%$, $\text{RWF}=1.2$, and $\Delta\sigma_T=16\%$; and for austral winter, $\Delta P=14\%$, $\Delta\sigma_P=8\%$, $\text{RWF}=1.4$, and $\Delta\sigma_T=20\%$. Therefore, consulting Table 3, the RCCI assumes the dimensionless value

$$\text{RCCI} = [0 + 2 + 1 + 4]_{\text{DJF}} + [2 + 1 + 2 + 4]_{\text{JJA}} = 16.$$

The same procedure is carried out over all locations (or grid points) in the domain of the study, and the RCCI values are compared among locations to identify, in a relative basis, the regions in which climate change may be more prominent.

The interannual standard deviation of temperature is used as a measure of σ_T , and the coefficient of variation is used as a measure of σ_P . Both σ_T and σ_P are calculated for the selected 30-year periods following the detrending of the data, in order to obtain unbiased variability estimates (Giorgi 2006). The coefficient of variation is used as a measure of interannual precipitation variability because it removes the dependency of the standard deviation on the mean for zero-bounded variables such as rainfall (Räisänen 2002; Giorgi 2006).

For the RCCI calculation, all climate variables and statistics were computed as follows: (1) the change was calculated for each model simulation; (2) when available, different runs using the same model were averaged; (3) the results were interpolated to a 1° latitude/longitude spatial resolution; (4) the ensemble average over the different available models was obtained; and (5) the different forcing scenarios were averaged. However, when analyzing the uncertainties regarding the different forcing scenarios, step 5 is excluded.

As emphasized in Torres et al. (2012), RCCI has a simplistic and exploratory nature, allowing a summarization of climate projection datasets comprising a large number of climate models, but it can be useful as an indicator of the intensity of climate change. Moreover, indexes like the RCCI can be used for improving the dialogue between climate and social

Table 3 Values of the factors n in the definition of the RCCI

n	ΔP (%)	$\Delta\sigma_P$ (%)	RWF	$\Delta\sigma_T$ (%)
0	<5	<5	<1.1	<5
1	5–10	5–10	1.1–1.3	5–10
2	10–15	10–20	1.3–1.5	10–15
4	>15	>20	>1.5	>15

scientists and for communicating climate change to policymakers in a more concise and socially relevant form.

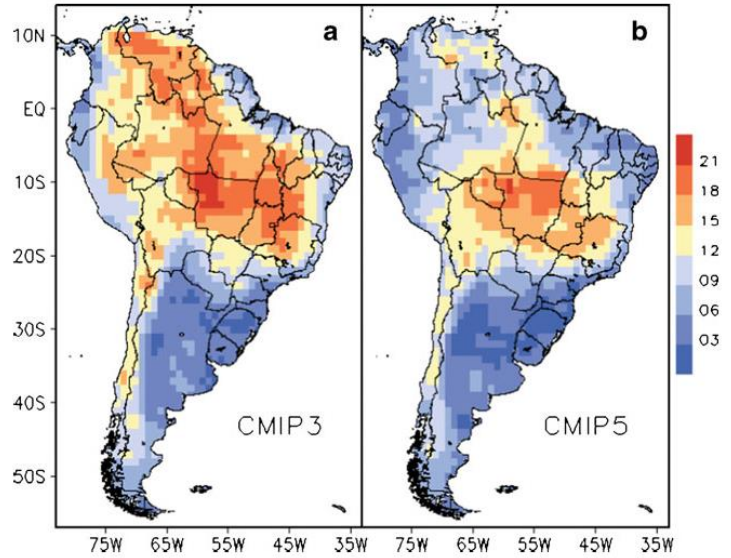
3 Results and discussion

The RCCI map generated with the CMIP3 climate projections by the end of the twenty-first century over South America is shown in Fig. 1a. It is possible to identify the occurrence of climatic hotspots covering all of the Amazon Basin, north-western South America, and central-western Brazil and to the west of the Brazilian Northeast. Moreover, the highest values are found over the Brazilian northwestern Mato Grosso state (Fig. 1a). Intermediate values can be seen over Bolivia and Chile and in the Brazilian states of Mato Grosso do Sul and northern São Paulo. On the other hand, low values are displayed in western Peru, Ecuador, Suriname, French Guiana, Paraguay, Uruguay, throughout Argentina, in the Brazilian states of Amapá, northeastern Pará, southern São Paulo, and in parts of the Brazilian Northeast (northern and eastern portion) and the entire southern Brazil region (Fig. 1a).

In general, high values indicated on the CMIP3 RCCI map are due to an increase of mean surface air temperature during the austral summer, but mainly the austral winter, as shown by the RWF (Fig. 2a, b) and also due to an increase of interannual temperature variability in both seasons (Fig. 2c, d) and a change in the mean and interannual variability of precipitation during the austral winter (Fig. 2f, h).

In order to evaluate the uncertainties involved in the climatic hotspots extracted from the CMIP3 RCCI map due to the choice of the GCM dataset, the RCCI index was recalculated for the new GCM dataset belonging to CMIP5 (Figs. 3 and 4). However, it is worth noting that, as can be seen in Tables 1 and 2, the CMIP5 dataset does not provide a new independent source of information about climate change compared with CMIP3 (Knutti et al. 2013). Indeed, the majority of GCMs that are integrated in CMIP3 are present in CMIP5, but of course, in a new and more climate-comprehensive version (Taylor et al. 2012) and using more realistic scenarios of climate forcings (Moss et al. 2010). Therefore, in this study, it is possible to explore the uncertainties regarding the model structures and climate forcings.

Fig. 1 RCCI for South America using climate projections of the a CMIP3 and b CMIP5 dataset by the end of the twenty-first century. Units are dimensionless



The RCCI map generated with the CMIP5 dataset (Fig. 1b) shows a noticeable difference in northwestern South America and in the Brazilian states of Maranhão, Piauí, and northwestern Pará, when compared with the CMIP3 results (Fig. 1a). On

Fig. 2 The four components of climatic change used in the RCCI calculation through climate projections of the CMIP3 dataset by the end of the twenty-first century. a, b Regional Warming Amplification Factor (RWAf, dimensionless). c, d Change in surface air temperature interannual variability ($\Delta\sigma_T$ %). e, f Change in mean precipitation (ΔP , percentage of present-day value). g, h Change in interannual variability of precipitation ($\Delta\sigma_P$, percentage of present-day value). Results are shown for the austral summer and winter (DJF and JJA, respectively). Percentages are related to ‘present-day mean values’ (1961–1990) taken as reference

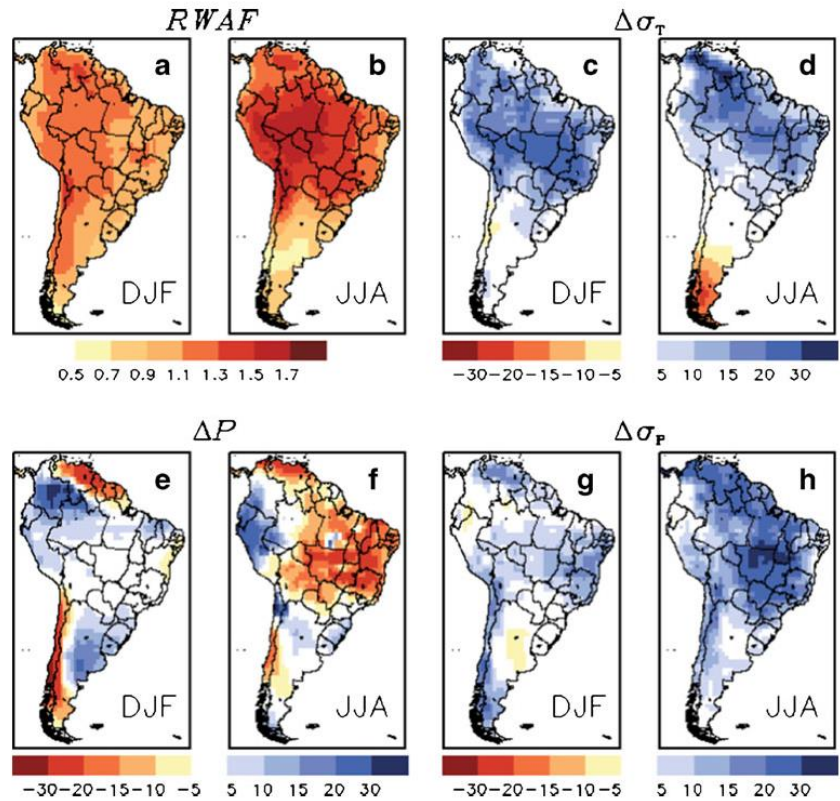
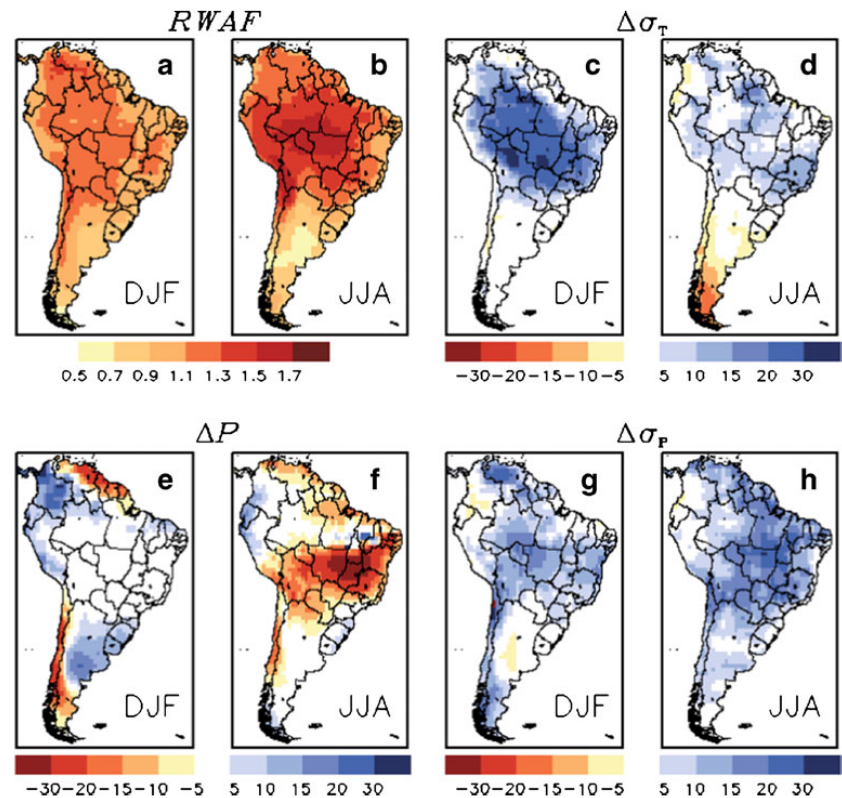


Fig. 3 As in Fig. 2, but for CMIP5 dataset



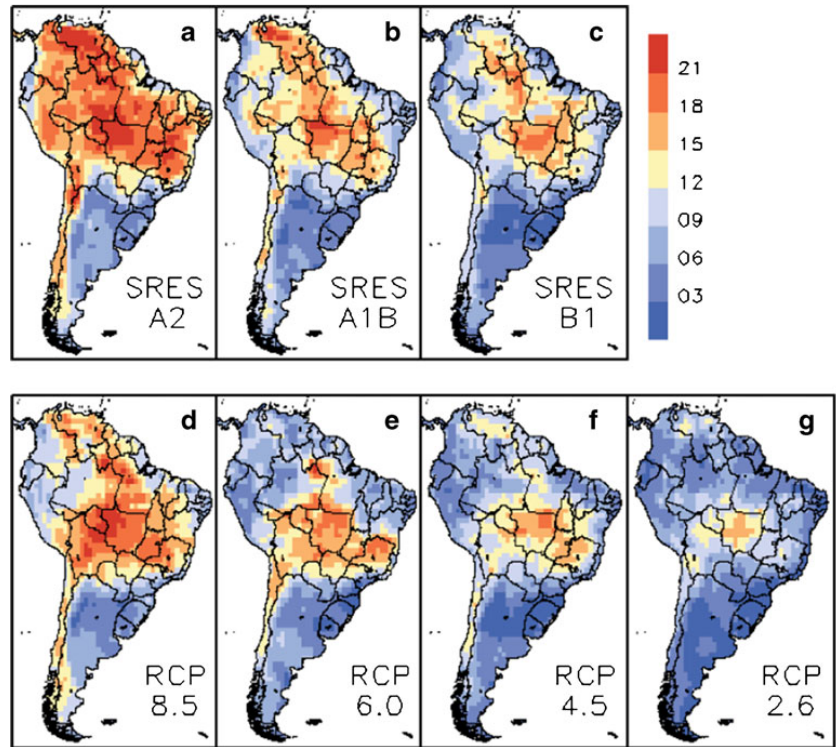
the other hand, beyond the abovementioned regions, the RCCI pattern is quite comparable between the two datasets (Fig. 1), demonstrating consistency between CMIP3 and CMIP5 results. Since some studies have identified a slight improvement in the representation of the South America climate in CMIP5 (Blázquez and Nuñez 2013; Jones and Carvalho 2013), this consistency among two different generations of GCMs together with a better representation of the current climate conditions in CMIP5 increases the reliability of the results. The RCCI CMIP5 map shows Bolivia and Brazil as those South American countries exhibiting climatic hotspots that are more intense. In Brazil, the highest RCCI values are concentrated in the southern Amazon, northern Mato Grosso do Sul, and in the western portion of Minas Gerais state.

A comparison between the four components of climatic change obtained with CMIP3 (Fig. 2) and CMIP5 (Fig. 3) indicates that the spatial distributions of changes is quite similar between the two datasets. In CMIP5, the magnitude of these changes reduces across almost the entire South America, most noticeably in the northwestern region, when compared to those changes projected by CMIP3. An exception can be made for the changes in the interannual variability of temperature and precipitation in the austral summer, in which

a slight increase in the magnitude of changes can be observed in the CMIP5 dataset (Fig. 3c, g). Moreover, another important aspect observed in the new set of GCM simulations is the intensification of temperature changes (increase of RWAF) in the southern Amazon basin (Fig. 3b) and the precipitation changes (projected more intense rainfall reduction) in central-western Brazil (Fig. 3f), when compared with the previous model generation.

The dependence of hotspots on the scenario of climate forcing can be evaluated in Fig. 4. As can be seen, southern Amazonia and the central-western region and western portion of Minas Gerais state in Brazil are persistent climate change hotspots throughout the different forcing scenarios and GCM datasets, providing high reliability on this projected pattern. In general, as the scenarios vary from low- to high-level forcing (e.g., from SRES B1 to A2 or from RCP 2.6 to 8.5), the area of high values of RCCI increase and the magnitude intensify from central-western and southeast Brazil to northwest South America (Fig. 4). Furthermore, Fig. 4a c shows that the intense values projected in the CMIP3 RCCI map over northwestern South America (Fig. 1a) are influenced highly by the SRES A2 scenarios (Fig. 4a). In the RCPs (Fig. 4d g), the only scenario in which some parts of northwestern South

Fig. 4 RCCI calculated for South America discriminating each forcing scenarios separately. The *top row* shows the RCCI computed for the Special Report on Emission Scenarios (SRES) A2 (a), A1B (b), and B1 (c) from CMIP3. The *bottom row* shows the RCCI for the Representative Concentration Pathways (RCP) 8.5 (d), 6.0 (e), 4.5 (f), and 2.6 (g) from CMIP5. *Units* are dimensionless



America appear as climatic hotspots is RCP 8.5. Interestingly, the similarity of the RCCI patterns between the forcing scenarios SRES A1B and RCP 8.5 (Fig. 4b, d) is remarkable.

In the construction of the forcing scenarios SRES and RCPs, no probabilities are assigned to them (Nakicenovic et al. 2000; Moss et al. 2010); thus, all patterns presented in Figs. 1 and 4 can be understood as plausible. Nevertheless, special attention should be given to the CMIP5 results because, in general, CMIP5 GCMs possess higher horizontal resolutions and are more comprehensive compared with those of CMIP3 (Taylor et al. 2012; Sillmann et al. 2013a), which can result in more reliable climate simulations. For example, northwestern South America shows large bias in the simulations of the mean and annual cycle of monthly precipitation in the CMIP3 GCMs when compared with observations (e.g., Bombardi and Carvalho 2009; Torres and Marengo 2013). Those biases are reduced slightly in the CMIP5 simulations (Jones and Carvalho 2013), and this might contribute to the differences between RCCI CMIP3 and CMIP5 maps over northwestern South America, although the different forcing scenarios employed in the CMIP3 and CMIP5 datasets must contribute largely to the differences in the climate projections (Knutti and Sedláček 2013).

Over the regions identified as climate change hotspots in this study, namely southern Amazonia and the central-western and western portion of Minas Gerais state in Brazil, both precipitation- and temperature-related changes contribute almost equally to the high values of RCCI. Despite the inherent uncertainty associated with climate change projections (Giorgi 2005; Knutti et al. 2008), particularly with respect to precipitation, almost all GCMs analyzed in this study present good performance in simulating the current climate over those regions (e.g., Torres and Marengo 2013; Jones and Carvalho 2013), and they agree reasonably well with the sign and magnitude of the projected changes in this part of South America, which increases the reliability of the results.

Finally, the climatic hotspots identified in this study are in agreement with some studies found in the literature. For example, the RCCI CMIP3 map is comparable with the Climate Change Index developed by Baettig et al. (2007), although using different sets of GCMs and forcing scenarios. Furthermore, the RCCI CMIP5 results are quite comparable with the index produced by Diffenbaugh and Giorgi (2012) based on the Standard Euclidean Distance and computed with a smaller set of CMIP5 GCMs and scenarios. Moreover, the RCCI results are coherent with previous studies of climate

change in South America (e.g., Marengo et al. 2010a,b, 2011, 2012; Blázquez and Nuñez 2013; Carvalho and Jones 2013; Jones and Carvalho 2013; Torres and Marengo 2013).

4 Summary and concluding remarks

This study aims to identify possible climate change hotspots in South America through the examination of the spatial pattern of the RCCI index over the region by the end of the twenty-first century. The reliability and uncertainties of the results are evaluated by using numerous state-of-the-art GCMs and forcing scenarios from the CMIP3 and CMIP5 datasets prepared for the IPCC AR4 and IPCC AR5, respectively.

Southern Amazonia and the central-western and western portion of Minas Gerais state in Brazil are persistent climate change hotspots throughout the different forcing scenarios and GCM datasets, which provides high reliability on this projected pattern. Additionally, as the scenarios vary from low- to high-level forcing, the area of high values of RCCI increase and the magnitude intensify from central-western and southeast Brazil to northwest South America. In general, the hotspots are characterized by an increase of mean surface air temperature, mainly in the austral winter; by an increase of interannual temperature variability, predominantly in the austral summer; and by a change in the mean and interannual variability of precipitation during the austral winter.

However, regions not classified as climatic hotspots in this study cannot be neglected. Areas that exhibit relatively low values in the RCCI index, such as southern South America, could still be vulnerable to other climate stressors not included here, such as climate extremes (Tebaldi et al. 2006; IPCC 2012; Donat et al. 2013; Sillmann et al. 2013a, b). Moreover, GCMs' performance on complex terrains such as the Andes is still low. The Andes is already experiencing shifts in temperature and rainfall regimes and is certainly vulnerable to future climate change (Herzog et al. 2011), although RCCI cannot properly identify this region as a climatic hotspot. Furthermore, when aggregating the climatic information with local population vulnerability information in a form that is more relevant to social vulnerability analysis, the designation of those areas potentially most impacted by climate change can be quite different (Torres et al. 2012). Therefore, the RCCI maps discussed here must be used and interpreted as auxiliary information in climate change debates among scientist and policymakers.

Acknowledgments We are thankful to two anonymous reviewers that provided suggestions that considerably improved the quality of the manuscript. The first author was supported by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) and by Brazil's Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Additional support was provided by the Amazonia Security Agenda Project led by CIAT and GCP and funded by the Climate and

Development Knowledge Network, by the projects Rede-CLIMA, the National Institute of Science and Technology for Climate Change (INCT-CC), from the FAPESP-Assessment of Impacts and Vulnerability to Climate Change in Brazil and Strategies for Adaptation Options project (Ref. 2008/581611). We also thank the Program for Climate Model Diagnosis and Intercomparison (PCMDI) and the WCRP's Working Group on Coupled Modelling (WGCM) for making the CMIP3 and CMIP5 multi-model dataset available.

References

- Baettig MB, Wild M, Imboden DM (2007) A climate change index: where climate change may be most prominent in the 21st century. *Geophys Res Lett* 34, L01705
- Blázquez J, Nuñez MN (2013) Analysis of uncertainties in future climate projections for South America: comparison of WCRP-CMIP3 and WCRP-CMIP5 models. *Clim Dyn* 41:1039–1056
- Bombardi RJ, Carvalho LMV (2009) IPCC global coupled climate model simulations of the South America monsoon system. *Clim Dyn* 33: 893–916
- Carvalho LMV, Jones C (2013) CMIP5 simulations of low-level tropospheric temperature and moisture over tropical Americas. *J Clim* 26: 6257–6286
- Diffenbaugh NS, Giorgi F, Raymond L, Bi X (2007) Indicators of 21st century socioclimatic exposure. *Proc Natl Acad Sci U S A* 104: 20195–20198
- Diffenbaugh NS, Giorgi F, Pal JS (2008) Climate change hotspots in the United States. *Geophys Res Lett* 35, L16709
- Diffenbaugh NS, Giorgi F (2012) Climate change hotspots in the CMIP5 global climate model ensemble. *Clim Chang* 114:813–822
- Donat MG, Alexander LV, Yang H, Durre I, Vose R, Dunn RJH, Willett KM, Aguilar E, Brunet M, Caesar J, Hewitson B, Jack C, Klein Tank AMG, Kruger AC, Marengo JA, Peterson TC, Renom M, Oria Rojas C, Rusticucci M, Salinger J, Elrayah AS, Sekele SS, Srivastava AK, Trewin B, Villarreal C, Vincent LA, Zhai P, Zhang X, Kitching S (2013) Updated analyses of temperature and precipitation extreme indices since the beginning of the twentieth century: The HadEX2 dataset. *J Geophys Res Atmos* 118(5):2098–2118
- Giorgi F (2005) Climate change prediction. *Clim Chang* 73:239–265
- Giorgi F, Bi XQ (2005) Updated regional precipitation and temperature changes for the 21st century from ensembles of recent AOGCM simulations. *Geophys Res Lett* 32, L21715
- Giorgi F (2006) Climate change hot-spots. *Geophys Res Lett* 33, L08707
- Herzog SK, Martínez R, Jorgensen PM, Tiessen H (2011). Climate change and biodiversity in the tropical Andes. Inter-American Institute for Global Change Research (IAI) and Scientific Committee on Problems of the Environment (SCOPE), 348 pp. http://www.iai.int/index.php?option=com_content&view=article&id=118&Itemid=73. Accessed 15 June 2013
- IPCC (2007) Summary for policymakers. In: Solomon S, Qin D, Manning M, Chen Z, Marquis M, Averyt KB, Tignor M, Miller HL (eds) *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 University Press, Cambridge
- IPCC (2012) 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 CB, Barros V, Stocker TF, Qin D, Dokken DJ, Ebi KL, Mastrandrea MD, K.J. Mach, G.-K. Plattner, S.K. Allen, M. Tignor, and P.M. Midgley (eds.)]. Cambridge University Press, Cambridge, 582 pp.

- Jones PW (1999) First- and second-order conservative remapping schemes for grids in spherical coordinates. *Mon Weather Rev* 127: 2204–2210
- Jones C, Carvalho LMV (2013) Climate change in the South American monsoon system: present climate and CMIP5 projections. *J Clim* 26(17):6660–6678
- Knutti R, Allen MR, Friedlingstein P, Gregory JM, Hegerl GC, Meehl GA, Meinshausen M, Murphy JM, Plattner GK, Raper SCB, Stocker TF, Stott PA, Teng H, Wigley TLM (2008) A review of uncertainties in global temperature projections over the twenty first century. *J Clim* 21:2651–2663
- Knutti R, Sedláček J (2013) Robustness and uncertainties in the new CMIP5 climate model projections. *Nat Clim Chang* 3:369–373
- Knutti R, Masson D, Gettelman A (2013) Climate model genealogy: generation CMIP5 and how we got there. *Geophys Res Lett* 40: 1194–1199
- Li J, Lin X, Chen A, Peterson T, Ma K, Bertzky M, Ciais P, Kapos V, Peng C, Poulter B (2013) Global priority conservation areas in the face of 21st century climate change. *PLoS ONE* 8(1):e54839. doi: 10.1371/journal.pone.0054839
- Liebmann B, Marengo JA (2001) Interannual variability of the rainy season and rainfall in the Brazilian Amazon Basin. *J Clim* 14(22): 4308–4318
- Rao VB, Lima MC, Franchito SH (1993) Seasonal and interannual variations of rainfall over eastern northeast Brazil. *J Clim* 6(9): 1754–1763
- May W (2012) Assessing the strength of regional changes in near-surface climate associated with a global warming of 2°C. *Clim Chang* 110(3–4):619–644
- Marengo JA, Ambrizzi T, Rocha RP, Alves LM, Cuadra SV, Valverde M, Ferraz SET, Torres RR, Santos DC (2010a) Future change of climate in South America in the late XXI century: intercomparison of scenarios from three regional climate models. *Clim Dyn* 35:1073–1097
- Marengo JA, Rusticucci M, Penalba O, Renom M (2010b) An intercomparison of observed and simulated extreme rainfall and temperature events during the last half of the twentieth century. Part 2: historical trends. *Clim Chang* 98:509–529
- Marengo JA, Nobre CA, Chou SH, Tomasella J, Sampaio G, Alves LM, Obregón GO, Soares WR, Betts R, Kay G (2011) Dangerous climate change. A Brazil–UK analysis of climate change and deforestation impacts in the Amazon. 55 pp. Available at http://mudancasclimaticas.cptec.inpe.br/~mclima/pdfs/destaques/relatorio_ingl.pdf Accessed 13 April 2013
- Marengo JA, Chou SC, Kay G, Alves LM, Pesquero JF, Soares WR, Santos DC, Lyra AA, Suenro G, Betts R, Chagas DJ, Gomes JL, Bustamante JF, Tavares P (2012) Development of regional future climate change scenarios in South America using the Eta CPTEC/HadCM3 climate change projections: climatology and regional analyses for the Amazon, São Francisco and the Parana River Basins. *Clim Dyn* 38(9–10):1829–1848
- Meehl GA, Covey C, Delworth T, Latif M, McAvaney B, Mitchell JFB, Stouffer RJ, Taylor KE (2007) The WCRP CMIP3 multi-model dataset: a new era in climate change research. *Bull Am Meteorol Soc* 88:1383–1394
- Moss RH, Edmonds JA, Hibbard KA, Manning MR, Rose SK, van Vuuren DP, Carter TR, Emori S, Kainuma M, Kram T, Meehl GA, Mitchell JFB, Nakicenovic N, Riahi K, Smith SJ, Stouffer RJ, Thomson AM, Weyant JP, Willbanks TJ (2010) The next generation of scenarios for climate change research and assessment. *Nature* 463:747–756
- Nakicenovic N, Alcamo J, Davis G, De Vries B, Fenhann J, Gaffin S, Gregory K, Grubler A, Jung TY, Kram T, La Rovere EL, Michaelis L, Mori S, Morita T, Pepper W, Pitcher H, Price L, Riahi K, Roehrl A, Rogner HH, Sankovski A, Schlesinger M, Shukla P, Smith S, Swart R, Van Rooijen S, Victor N, Dadi Z (2000) Special report on emissions scenarios. Cambridge University Press, Cambridge
- Preston BL, Yuen EJ, Westaway RM (2011) Putting vulnerability to climate change on the map: a review of approaches, benefits, and risks. *Sustain Sci* 6:177–202
- Räisänen J (2002) CO₂-induced changes in interannual temperature and precipitation variability in 19 CMIP2 experiments. *J Clim* 15:2395–2411
- Rusticucci M, Marengo JA, Penalba O, Renom M (2010) 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. *Clim Chang* 98:493–508
- Sillmann J, Kharin VV, Zhang X, Zwiers FW, Bronaugh D (2013a) Climate extremes indices in the CMIP5 multimodel ensemble: part 1. Model evaluation in the present climate. *J Geophys Res* 118:1716–1733
- Sillmann J, Kharin VV, Zwiers FW, Zhang X, Bronaugh D (2013b) Climate extremes indices in the CMIP5 multimodel ensemble: part 2 Future climate projections. *J Geophys Res* 118:2473–2493
- Taylor KE, Stouffer RJ, Meehl GA (2012) An overview of CMIP5 and the experiment design. *Bull Am Meteorol Soc* 93:485–498
- Tebaldi C, Hayhoe K, Arblaster JM, Meehl G (2006) Going to the extremes. An intercomparison of model-simulated historical and future changes in extreme events. *Clim Chang* 79:185–211
- Torres RR, Lapola DM, Marengo JA, Lombardo MA (2012) Socio-climatic hotspots in Brazil. *Clim Chang* 115:597–609
- Torres RR, Marengo JA (2013) Uncertainty assessments of climate change projections over South America. *Theor Appl Climatol* 112:253–272
- van Vuuren DP, Edmonds J, Kainuma M, Riahi K, Thomson A, Hibbard K, Hurtt GC, Kram T, Krey V, Lamarque JF, Masui T, Meinshausen M, Nakicenovic N, Smith SJ, Rose SK (2011) The representative concentration pathways: an overview. *Clim Chang* 109:5–31
- Xu Y, Xuejie G, Giorgi F (2009) Regional variability of climate change hot-spots in East Asia. *Adv Atmos Sci* 26(4):783–792