Universidade Federal do Rio Grande do Norte
Centro de Ciências Exatas e da Terra
Programa de Pós-Graduação em Ciências Climáticas
Doutorado em Ciências Climáticas

PPGCC

Cálculo das Incertezas Climáticas Sobre América do Sul Utilizando Modelos do CMIP5: Aferição Através das Redes Neurais Artificiais

Thalyta Soares dos Santos

Natal-RN
Setembro de 2015.

Thalyta Soares dos Santos

Cálculo das Incertezas Climáticas Sobre América do Sul Utilizando Modelos do CMIP5: Aferição Através das Redes Neurais Artificiais

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Ciências Climáticas do Centro de Ciências Exatas e da Terra da Universidade Federal do Rio Grande do Norte como parte dos requisitos para obtenção do título de Doutor em Ciências Climáticas.

Orientador:

Prof. Dr. David Mendes - UFRN

Co-orientador:

Prof. Dr. Roger Rodrigues Torres - UNIFEI

UFRN – Universidade Federal do Rio Grande do Norte
CCET – Centro de Ciências Exatas e da Terra
PPGCC – Programa de Pós-Graduação em Ciências Climáticas

Natal-RN

Setembro de 2015

Catalogação da Publicação na Fonte. UFRN / SISBI / Biblioteca Setorial
Centro de Ciências Exatas e da Terra – CCET.

Santos, Thalyta Soares dos.
Cálculo das incertezas climáticas sobre América do Sul utilizando modelos do CMIP5: aferição através das redes neurais artificiais / Thalyta Soares dos Santos. - Natal, 2015.
xiv, 77 f. : il.

Orientador: Prof. Dr. David Mendes.
Coorientador: Prof. Dr. Roger Rodrigues Torres.

Tese (Doutorado) – Universidade Federal do Rio Grande do Norte. Centro de Ciências Exatas e da Terra. Programa de Pós-Graduação em Ciências Climáticas.

1. Mudanças climáticas - Tese. 2. Incertezas climáticas - Tese. 3. Redes neurais artificiais – Tese. 4. Reliability ensemble averaging – Tese. I. Mendes, David. II. Torres, Roger Rodrigues. III. Título.

RN/UF/BSE-CCET CDU: 551.583

À minha avó, Inah Rocha (in memoriam), que é a maior de todas as minhas saudades.
"...enquanto eu respirar, vou me lembrar de você...".

Agradecimentos

Em primeiro lugar a Deus, porque sem Ele nada seria possível e nem nada teria sentido. Por nunca ter me abandonado em todos os desertos que atravessei. Mesmo quando não fui fiel, Ele permaneceu fiel.

Aos meus pais, Tânia Consuêlo e Zorildo José, meu tio Hutson Soares e meu primo Ítalo Soares, que são o alicerce da minha vida. Obrigada por serem a minha referência de tantas maneiras e estarem sempre presentes na minha vida de uma forma indispensável, mesmo separados por tantos quilômetros. As orações de vocês cruzando tantos estados deste país foram essenciais pra mim. Essa vitória é de vocês também.

Ao meu companheiro de uma década, Allan Rodrigues, que representa minha segurança em todos os aspectos, meu parceiro incondicional, o carinho espontâneo e tão necessário. Obrigada por me fazer sentir tão amada, mesmo nos momentos mais difíceis da nossa vida.

À família de Allan (minha segunda família), por toda torcida, confiança e apoio, obrigada: meu sogro e sogra seu Gaspar e Maria do Carmo, minha avó Rosita, tia Alda, meus cunhados Alda, Sheyla e Gabriel.

Ao meu orientador, David Mendes, pela paciência e cumplicidade, fundamentais para o término deste trabalho.

Meu co-orientador, Roger Torres, que mesmo aceitando o desafio de me co-orientar após o início do trabalho, foi sempre muito disponível e atencioso.

Ao querido professor Felipe Pimenta e sua esposa Patrícia Eichler, pelo carinho e preocupação dedicados a mim e ao Allan, que muitas vezes nos fizeram sentir parte da família.

Às minhas amigas amadas Aline Castro e Moane Gusmão sempre disponíveis a me ajudar, desde a programação até as palavras de apoio, vocês são essenciais na minha vida. Às minhas amigas não menos importantes, que entendem a loucura da vida acadêmica e sempre me apoiaram na conclusão de mais essa etapa: Bruna Silveira, Cristina Schultz (Cabeça e Cris, CFMF), Tatiane Felinto, Rita Ricarte. Obrigada por todas vocês

existirem.

Aos amigos queridos conquistados nesta cidade maravilhosa Daniel Évora, Eduardo Catão, Gustavo Rachetti, Kacya Lopes, Michargan Faraday, Nathalia Duarte, Sonally Siqueira, Ulysses Freire, Vanessa Rachetti, que tanto me incentivaram e torceram por mim. Obrigada por entrarem em minha vida, vocês aliviaram horas difíceis, me enchendo de força e alegria.

Às companheiras de doutorado Ana Carla, Micejane Costa e Maytê Duarte, pelo apoio sempre que precisei.

De maneira incomum gostaria de agradecer a dois seres que entendem cada sentimento meu, Pingo e Gunga (meus cachorrinhos de estimação). Quero deixar registrada a importância que vocês tem para mim, vocês alegram os meus dias.

À UFRN e ao programa de Pós-Graduação em Ciências Climáticas, pela oportunidade.

À CAPES pelo apoio recebido através de bolsa de estudo.

À todos os professores que fazem parte da PPGCC, pelo aprendizado.

Aos professores da banca examinadora Profª Drª Maria Helena, Profº Drº Weber Gonçalves e Profº Drº Enio Pereira, pela participação e colaboração.

Enfim, a todos que de qualquer forma contribuíram para a realização deste trabalho.

Cálculo das Incertezas Climáticas Sobre América do Sul Utilizando Modelos do CMIP5: Aferição Através das Redes Neurais Artificiais

Autor(a): Thalyta Soares dos Santos
Orientador(a): Prof. Dr. David Mendes - UFRN
Co-orientador(a): Prof. Dr. Roger Rodrigues Torres - UNIFEI

Resumo

Entender o comportamento do clima é o primeiro passo para classificá-lo, tendo sido motivo de estudos para diversos pesquisadores. Entretanto, os modelos climáticos, tradicionalmente utilizados, ainda não são capazes de representar adequadamente toda a dinâmica e interação do clima com outros fatores, como por exemplo, oceano e o continente. Nesse sentido, o objetivo principal da pesquisa é avaliar as incertezas envolvidas nas projeções de mudanças climáticas na América do Sul (AS) , simuladas por Modelos de Circulação Geral (MCGs), no intuito de identificar essas incertezas e fornecer informações mais confiáveis desses modelos utilizando as Redes Neurais Artificiais. Para isto, foi utilizado o método REA (*Reliability Ensemble Averaging*). O método REA leva em conta "critérios de confiabilidade" para calcular a projeção dos vários MCGs, o intervalo de incerteza e a confiabilidade das mudanças climáticas simuladas por modelos de circulação geral (MCGs). Os critérios considerados são o desempenho do modelo em reproduzir o atual clima ("critério de desempenho do modelo") e a convergência das mudanças simuladas através de modelos ("critério de convergência dos modelos"). Com a aplicação das RNAs, uma técnica de *dowscanlig* estatístico foi possível aferir os resultados do método REA. As avaliações foram realizadas para as simulações de precipitação e temperatura dos modelos pertencentes ao CMIP5 (*Coupled Model Intercomparison Project Phase 5*). Notou–se que houve um decréscimo na média das projeções de mudança de precipitação e temperatura ao comparar as simulações pelo método REA com a média aritmética simples dos MCGs. As mudanças de temperatura são maiores do que os intervalos de incerteza associados para todas as regiões estudadas na América do Sul, indicando uma alta confiabilidade nas projeções. Quanto à precipitação, os intervalos de incerteza possuem magnitudes maiores do que a das mudanças projetadas. Portanto, existe uma menor confiabilidade de uma projeção de mudanças na precipitação sazonal média dos modelos estudados, quando comparados à temperatura na AS. Quando aplicada, verificou–se que as RNAs se mostraram uma metodologia eficaz para aferir as saídas dos modelos climáticos globais. Sua utilização reduziu o intervalo de incerteza associado às projeções de mudanças climáticas e aumentou a confiabilidade do conjunto de modelos calculadas pelo método REA para ambas as variáveis estudadas. A partir dos resultados obtidos, é possível afirmar que as RNAs podem ser usadas para auxiliar a compreensão das mudanças climáticas, tornando as projeções mais confiáveis.

Climate Uncertainties in South America: Measuring the IPCC-AR5 Models Through Artificial Neural Networks

Autor(a): Thalyta Soares dos Santos
Orientador(a): Prof. Dr. David Mendes - UFRN
Co-orientador(a): Prof. Dr. Roger Rodrigues Torres - UNIFEI

Abstract

Understanding the behavior of climate is the first step towards classifying it, and it has been the goad of several studies by many different authors. However, the climate models, traditionally used are not yet capable of adequately representing the dynamics and interaction of climate with other factors, such as ocean and the land. In this sense, the main goal of this research is to evaluate the uncertainties involved in the climate change projections simulated by General Circulation Models (GCM) in South America, with the goal of identifying these uncertainties and supplying more reliable information about these models, using Artificial Neural Networks (ANN). We used the "Reliability Ensemble Averaging" (REA) method, which takes into account "reliability criterias" for calculating average, uncertainty range, and a measure of reliability of simulated climate changes from ensembles of different General Circulation Model simulations. The criteria was the performance of the model in reproducing present-day climate ("model performance criterion") and the convergence of the simulated changes across models ("model convergence criterion"). ANN, a downscaling technique, was applied to verify the results from the REA method. For these tests, simulations of precipitation and temperature from the CMIP5 (Coupled Model Intercomparison Project Phase 5) were used. It was noted that, in general, the average projected changes in precipitation and temperature decreased when using the REA method compared to the simple arithmetic mean from the GCM. The changes in temperature are larger than the uncertainty intervals associated for all the regions studied in South America, indicating high reliability of the projections. For precipitation, however, the magnitudes of the uncertainty intervals are larger than the changes projected. Therefore, there's a smaller reliability for projection of changes in the average seasonal precipitation when compared to temperature in South America. ANN was assessed to be an efficient methodology to assess global climate model outputs, and using this method has decreased the uncertainty interval associated with projected climate changes while increasing the reliability of the model ensemble calculated for both variables studied. From the results, it is possible to state that ANN can be used to help understanding climate changes by making the projections more reliable.

Lista de figuras

1.1 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) apud Torres (2014). . . . . p. 3

2.1 Domínio de estudo. Os retângulos indicam as sub-regiões utilizadas nas análises: Amazônia (AMZ), Nordeste do Brasil (NEB), e Bacia do Prata (LPB). . . . . p. 9

2.2 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 e 8.5). As áreas em cinza representam os percentis 98°(cinza claro) e 90°(cinza escuro) encontrados na literatura. As linhas tracejadas indicam os quatro cenários SRES (A2, A1b, B2 e B1). Fonte: Vuuren et al. (2011). . . . . p. 10

2.3 Modelo um neurônio artificial. Fonte: Haykin (2001). . . . . p. 16

2.4 Estrutura de uma rede neural artificial. . . . . p. 19

2.5 Estrutura da rede neural artificial utilizada no estudo. . . . . p. 20

3.1 Representação dos cenários do IPCC. Fonte: (JAHN; HOLLAND, 2013). . p. 28

3.2 Padrão de precipitação (mm/dia) do conjunto de modelos para os cenários: historical (A-B), RCP2.6 (C-D) e RCP8.5 (E-F), no período de controle no verão (coluna esquerda) e inverno (coluna direita). . . . . p. 30

3.3 Média REA (A-B), intervalo de incerteza (C-D) e confiabilidade do conjunto de modelos (E-F) para a precipitação (mm/dia), no período de controle no verão (coluna esquerda) e inverno (coluna direita) para o período de 1971-2000. . . . . p. 32

3.4 Média REA (A-B), intervalo de incerteza (C-D) e confiabilidade do conjunto de modelos (E-F) para a precipitação (mm/dia), no cenário RCP 2.6, no verão (coluna esquerda) e inverno (coluna direita) austral para o período de 2071-2100. . . . . p. 34

3.5 Média REA (A-B), intervalo de incerteza (C-D) e confiabilidade do conjunto de modelos (E-F) para a precipitação (mm/dia), no cenário RCP 8.5, no verão (coluna esquerda) e inverno (coluna direita) austral para o período de 2071-2100. . . . . p. 35

4.1 Illustration of the study areas of the defined regions. . . . . p. 40

4.2 Structure of the artificial neural network. . . . . p. 41

4.3 Absolute error as a function of the number of iterations, AMZ (green), NEB (red) and LPB (black). Continuous lines represent the summer period for each region and the dashed lines represent winter. . . . . p. 42

4.4 Residuals x Fitted Values and Theoretical Quantiles, for the summer. (a) AMZ, (b) NEB, and (c) LPB. . . . . p. 44

4.5 Residuals x Fitted Values and Theoretical Quantiles, for the winter. (a) AMZ, (b) NEB, and (c) LPB. . . . . p. 45

5.1 Domínio de estudo. Os retângulos indicam as sub-regiões utilizadas nas análises: Amazônia (AMZ), Nordeste do Brasil (NEB), e Bacia do Prata (LPB). . . . . p. 58

5.2 Estrutura da rede neural artificial utilizada no estudo. . . . . p. 61

5.3 Média REA (círculos fechados), média REA aferidas por RNA (quadrados fechados), mudança definida pela média simples dos modelos (círculos abertos), média simples aferidas por RNA (círculos fechados), limites de incerteza da média REA superior e inferior (linhas pontilhadas), limites de incerteza da média REA aferidos por RNA superior e inferior (linhas continuas) para mudança sazonal da precipitação utilizando as projeções dos MCGs do CMIP5 para Amazônia (A e B), Nordeste (C e D) e Bacia do Prata (E e F) no cenário RCP 2.6 (coluna esquerda) e RCP 8.5 (coluna direita). As alterações são definidas como a diferença entre os períodos de 2071-2100 – 1961-1990. Unidades estão em milímetros por dia. p. 63

5.4 Média REA (círculos fechados), média REA aferidas por RNA (quadrados fechados), mudança definida pela média simples dos modelos (círculos abertos), média simples aferidas por RNA (círculos fechados), limites de incerteza da média REA superior e inferior (linhas pontilhadas), seus limites de incerteza da média REA aferidos por RNA superior e inferior (linhas continuas) para mudança sazonal da temperatura utilizando as projeções dos MCGs do CMIP5 para Amazônia (A e B), Nordeste (C e D) e Bacia do Prata (E e F) no cenário RCP 2.6 (coluna esquerda) e RCP 8.5 (coluna direita). As alterações são definidas como a diferença entre os períodos de 2071-2100 – 1961-1990. Unidades estão em °C. . . p. 64

Lista de tabelas

2.1 Resumo das principais características dos RCPs utilizados pelo CMIP5 (RCP 2.6, RCP 4.5, RCP 6.0, RCP 8.5). Fonte: Jones e Carvalho (2013), Vuuren et al. (2011) . . . . . p. 10

2.2 Modelos do CMIP5 utilizados neste estudo com a descrição das resoluções horizontais aproximadas . . . . . p. 11

3.1 Modelos do CMIP5 utilizados e suas respectivas resoluções. . . . . p. 27

4.1 List of models from the CMIP5 dataset used in this study. . . . . p. 39

4.2 Proportion and cumulative proportion of variance for the indicated regions. Left column for summer and right column for winter. . . . . p. 46

4.3 p-value and Pearson's correlation coefficient at the level of significance of 5% between the ANN and observed data from the CRU in all regions under study. . . . . p. 47

4.4 p-value and Pearson's correlation coefficient at the level of significance of 5% between the MLR by PCs and observed data from the CRU in all regions under study. . . . . p. 47

4.5 Change in monthly precipitation in terms of an increase or decrease by the end of this century (2071-2100) in the scenarios RCP 8.5 and 2.6, in relation to the reference period 1971-1999 (observation), in mm.month^{-1} and percentage. . . . . p. 48

5.1 Modelos do CMIP5 utilizados neste estudo com a descrição das resoluções horizontais aproximadas . . . . . p. 57

5.2 Média dos parâmetros de desempenho (R_B), convergência (R_D) e confiabilidade do conjunto (ρ) do método REA com e sem aferição das RNA para as mudanças sazonal de precipitação utilizando as projeções dos MCGs do CMIP5 para 2071–2100 no cenário RCP 8.5. Parâmetros são adimensionais. . . . . p. 66

5.3 Média dos parâmetros de desempenho (R_B), convergência (R_D) e confiabilidade do conjunto (ρ) do método REA com e sem aferição das RNA para as mudanças sazonal de temperatura utilizando as projeções dos MCGs do CMIP5 para 2071–2100 no cenário RCP 8.5. Parâmetros são adimensionais. . . . . p. 67

Lista de abreviaturas e siglas

AMZ - Amazônia

ANN - Artificial Neural Networks

AOGCMs - Atmosphere - ocean general circulation models

AS - América do Sul

CMIP3 - Coupled Model Intercomparison Project Phase 3

CMIP5 - Coupled Model Intercomparison Project Phase 5

CPs - Componentes Principais

CRU - Climatic Research Unit

FDP - Função de Densidade de Probabilidade

FOE - Funções Ortogonais Empíricas

GCM - General Circulation Models

GEE - Gases do Efeito Estufa

IPPC - Painel Intergovernamental de Mudanças Climáticas

IPPC AR4 - Quarto Relatório Científico do Painel Intergovernamental de Mudanças Climáticas

JMA - Japanese Meteorological Agency

LPB - Bacia da Prata

MCGOAs - Modelos Climáticos Globais Oceano-Atmosfera

MCGs - Modelos Climáticos Globais

MCR - Modelos de Clima Regional

NEB - Nordeste do Brasil

NWP - Numerical Weather Prediction

PCMDI - Program for Climate Model Diagnosis and Intercomparison

RCPs - Representative Concentration Pathways

REA - Reliability Ensemble Averaging

RLM - Regressão Linear Múltipla

RNAs - Redes Neurais Artificiais

SRES - Special Report on Emissions Scenarios

TAR - Terceiro Relatório Científico do Painel Intergovernamental de Mudanças Climáticas

UEA - University of East Anglia

Lista de símbolos

$\widetilde{\Delta}\xi$ – Mudança esperada em uma variável climática ξ

R_i – Fator de confiabilidade atribuída a um dado modelo i

$\Delta\xi_i$ – Mudança projetada em uma variável climática ξ por um dado modelo i

ε_ξ – Variabilidade natural apresentada pela variável climática ξ

$R_{B,i}$ – 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 do seu viés $D_{\xi,i}$

$B_{\xi,i}$ – Viés apresentado pelo modelo i na simulação da variável climática ξ

$D_{\xi,i}$ – Distância entre a projeção produzida pelo modelo i para a variável climática ξ e a projeção média do conjunto

$\widetilde{\delta}_{\Delta\xi}$ – Intervalo de incerteza entorno da mudança média REA

$\widetilde{\rho}$ – Parâmetro de confiabilidade do conjunto

$\overline{\Delta\xi}$ – Variação simples da variável climática

N – Número total de modelos

x_j – Parâmetro de entrada da rede neural artificial

j – Sinapses da rede neural artificial

w_{kj} – Pesos sinápticos da rede neural artificial

b_k – Viés da rede neural artificial

Y – Variável dependente da regressão linear múltipla

X_m – Variáveis independentes da regressão linear múltipla

α_0 – Intercepto da regressão linear múltipla

α_m – Coeficientes da regressão linear múltipla

ϵ_i – Erro da regressão linear múltipla

Sumário

Lista de figuras p. ix

Lista de tabelas p. xi

Lista de abreviaturas e siglas p. xii

Lista de símbolos p. xiv

1 Introdução p. 1

1.1 Motivação, problemática e hipótese . . . . . p. 4

1.2 Objetivos . . . . . p. 6

1.2.1 Objetivo Geral . . . . . p. 6

1.2.2 Objetivos específicos . . . . . p. 6

1.3 Estrutura da tese . . . . . p. 6

2 Material e Métodos p. 8

2.1 Região de Estudo . . . . . p. 8

2.2 Base de Dados . . . . . p. 8

2.3 Métodos . . . . . p. 12

2.3.1 *Reliability Ensemble Averaging* (REA) . . . . . p. 12

2.3.2 Redes Neurais Artificiais (RNAs) . . . . . p. 15

2.3.2.1 Modelo de um neurônio . . . . . p. 15

2.3.2.2 Vantagens das RNAs . . . . . p. 16

2.3.2.3 Treinamento das RNAs . . . . . p. 17

2.3.3 Regressão Linear Múltipla . . . . . p. 19

3 Análise das Incertezas das Mudanças Climáticas Simuladas na América Do Sul p. 22

3.1 Resumo . . . . . p. 23

3.2 Abstract . . . . . p. 24

3.3 Introdução . . . . . p. 25
3.4 Material e Métodos . . . . . p. 27
3.5 Resultados . . . . . p. 29
3.6 Conclusões . . . . . p. 33

4 Artificial Neural Networks and Multiple Linear Regression Model using Principal Components to Estimate Rainfall over South America p. 36

4.1 Abstract . . . . . p. 37
4.2 Introduction . . . . . p. 38
4.3 Data and Methods . . . . . p. 39
4.3.1 Data . . . . . p. 39
4.3.2 Artificial Neural Networks (ANN) . . . . . p. 40
4.3.3 Multiple Linear Regression using Principal Components . . . . . p. 41
4.4 Results and Discussion . . . . . p. 42
4.4.1 Validation of the ANN . . . . . p. 42
4.4.2 Validation of the MLR by PC . . . . . p. 43
4.4.3 Downscaling scenarios . . . . . p. 47
4.5 Conclusions . . . . . p. 49

5 Incertezas em Projeções de Mudanças Climáticas na América do Sul Aferidas por Redes Neurais Artificiais p. 50

5.1 Resumo . . . . . p. 51
5.2 Abstract . . . . . p. 52
5.3 Introdução . . . . . p. 53
5.4 Material e Métodos . . . . . p. 55
5.4.1 Reability Ensemble Averaging . . . . . p. 57
5.4.2 Redes Neurais Artificiais . . . . . p. 59
5.5 Resultados . . . . . p. 60
5.5.1 Estimativas do intervalo de mudança e incerteza . . . . . p. 60
5.5.2 Análise de confiabilidade . . . . . p. 65
5.6 Conclusões . . . . . p. 67

6 Considerações Finais p. 69

6.1 Sugestões para trabalhos futuros . . . . . p. 70

Referências p. 71

1 Introdução

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. O sistema climático é caracterizado pela atmosfera, hidrosfera, criosfera, biosfera e litosfera. De acordo com Torres (2014) este sistema modifica–se com o tempo pela influência de sua própria dinâmica interna e por causa de forçantes externas naturais e antropogênicas. Uma mudança climática pode ser identificada como alterações no valor médio do clima e/ou na variabilidade de seus elementos (i.e., 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 a forçantes externas atuando neste este sistema (SOLOMON et al., 2007; HEGERL et al., 2007).

Nos últimos anos, as mudanças climáticas apresentaram-se em um contexto muito debatido, ocupando um espaço nas agendas científico, política e sociais (GUPTA, 2010; BRECHIN; BHANDARI, 2011). Em função disso, grandes evoluções no entendimento sobre o clima e suas mudanças foram alcançadas. O marco desse crescimento ocorreu em 1988 com a criação do Painel Intergovernamental de Mudanças Climáticas (IPCC) . Os frequentes relatórios elaborados pelo IPCC ratificam o aumento da temperatura global pelas emissões antropogênicas de carbono e adverte para os riscos dessa mudança.

Por este motivo, a modelagem computacional têm sido bastante utilizada pelos cientistas para entender as indagações sobre o clima global (MILLER, 2004). Os conhecimentos alcançados sobre o clima e suas mudanças são devidos aos uso desses modelos climáticos. A aceitabilidade desses modelos é tão expressiva que se torna quase inimaginável o estudo das mudanças climáticas sem o auxílio da modelagem climática (SHACKLEY; WYNNE, 1996; SHACKLEY, 1997; MILLER; EDWARDS, 2001; WYNNE, 2010).

Apesar do frequente aprimoramento desses modelos e o enorme poder computacional crescente nos últimos anos, eles ainda são 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, e em outra, devido ao ainda pouco conhecimento sobre os complexos

processos envolvidos (GIORGI, 2005; RÄISÄNEN, 2007; COLLINS, 2007; TEBALDI; KNUTTI, 2007; KNUTTI et al., 2010; ANNAN; HARGREAVES, 2010).

Um outro aspecto é que, ao tentar representar a complexidade do sistema climático, também são introduzidas novas possíveis fontes de erro (i. e., via parâmetros incertos) e novas interações entre componentes do modelo que podem, mesmo que apenas temporariamente, degradar a simulação em outros aspectos do sistema climático. Uma consideração importante é que o desempenho do modelo pode ser avaliado somente em relação às observações passadas, levando em conta a variabilidade natural interna. Para ter confiança nas projeções futuras de tais modelos, o clima passado - e sua variabilidade e mudança - devem ser bem simuladas.

Santos (2007) afirma que no estudo do clima e dos cenários climáticos futuros há várias fontes de incerteza: i) conhecimento deficiente do comportamento passado das variáveis que descrevem o clima; ii) conhecimento limitado dos fenômenos físicos, químicos, biológicos e geológicos que se processam no sistema climático, e; iii) aproximações deficientes para simular o comportamento e as interações das várias componentes do sistema nos modelos climáticos. Há também incertezas significativas nas projeções das concentrações atmosféricas futuras de Gases do Efeito Estufa (GEE) devido a um conhecimento incompleto das fontes e sumidouros destes gases, dentre outros.

Em contrapartida, vale ressaltar que incerteza não é o mesmo que erro, visto que fosse se possível um modelo representar um perfeito sistema climático, com excelente rede de observações e um apurado conhecimento do comportamento das forçantes externas agindo sobre o sistema, parte das incertezas adicionadas ao processo de projeção climática seria eliminada, mas ainda ficariam aquelas incertezas associadas à natureza estocástica e não linear das projeções de mudanças climáticas (GIORGI, 2005).

Giorgi (2005) apud Torres (2014) afirma que, 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. 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, pode-se 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 Modelos Climáticos Globais (MCGs) e consequente cálculo das forçantes radiativas associadas; v) simulações regionais 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 (Figura 1.1).

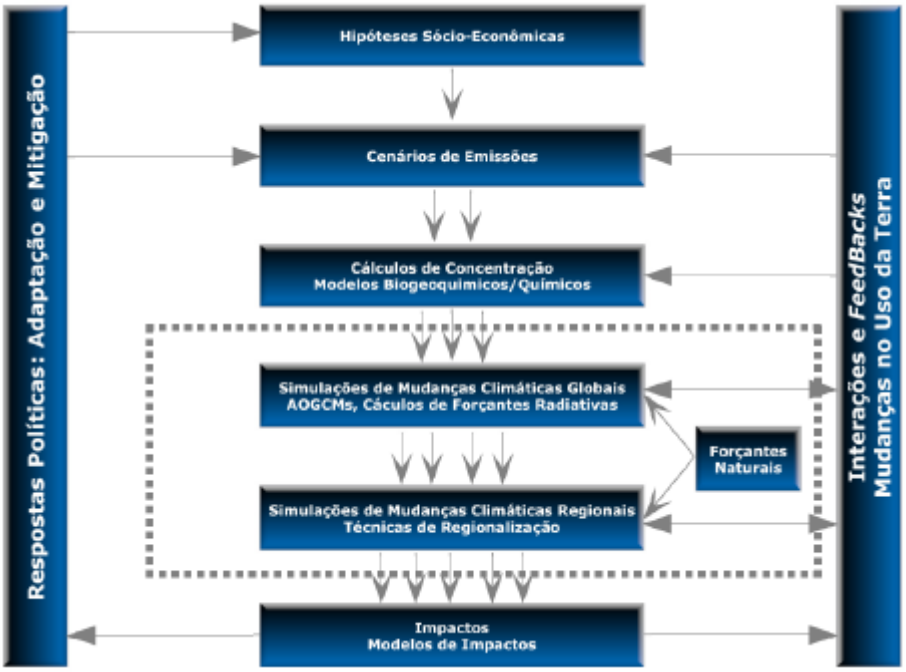

Figura 1.1: Cascata de incertezas em uma projeção de mudanças climáticas. A linha tracejada engloba o segmento de simulação climática da cascata. A sigla *AOGCMs* significa *atmosphere – Ocean General Circulation Models* . Fonte: Adaptada de Mearns et al. (2001) e Giorgi (2005) apud Torres (2014).

Cada etapa citada na Figura 1.1 é caracterizada por uma incerteza que é transmitida para a próxima etapa em um processo de cascata, que ao final determina a incerteza total da projeção (MEARNS et al., 2001; GIORGI, 2005). 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.

As incertezas provenientes da configuração dos modelos relacionam-se com a escolha de uma dada configuração do mesmo (i.e., resolução horizontal e vertical), esquemas de parametrização física (i.e., parametrização de cúmulos), 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, bem como os do Coupled Model Intercomparison Project Phase 3 (CMIP3) e Coupled Model Intercomparison Project Phase 5 (CMIP5) . Com isso, diferentes modelos podem simular respostas climáticas bastante diferentes para uma mesma forçante climática (IPCC) (2001), Solomon et al. (2007). Estas diferenças análogas podem ser também encontradas quando são usadas diferentes parametrizações físicas e/ ou parâmetros dentro de um modelo individual (GIORGI, 2005; MURPHY et al., 2007). Ademais, as incertezas devido à configuração dos modelos aumentam quando se analisa a escala regional.

A contribuição da variabilidade interna dos modelos para as incertezas é atribuída à dependência das simulações climáticas para com à variabilidade natural (i.e., o El Niño Oscilação Sul é o modo de variabilidade não forçada mais bem conhecido) e com relação às condições dos oceanos e continentes. Entretanto, quando se avalia 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. Essas fontes de incertezas mostram que ela podem ser expressivas, embora menos importante do que as incertezas relacionadas com às forçantes antropogênicas (STOTT; KETTLEBOROUGH, 2002; GIORGI, 2005).

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. Vários estudos têm demonstrado que as projeções de modelos climáticos podem divergir, mesmo considerando um conjunto de modelos com elevada acurácia (ARAÚJO et al., 2005; ARAÚJO; NEW, 2007; ALGAR et al., 2009). Giorgi e Mearns (2002) afirmam que diferentes MCGs podem projetar diferentes mudanças regionais, mesmo sob o mesmo cenário de forçante antropogênica (por exemplo, Whetton et al. (1996), Kittel, Giorgi e Meehl (1997), Giorgi e Francisco (2000)). Giorgi e Mearns (2002) afirmam ainda que uma avaliação abrangente das projeções de mudanças regionais precisa ser baseada na informação coletiva de um conjunto de simulações de modelos. Assim, quantificar as incertezas nas projeções de cenários climáticos futuros utilizados para as avaliações de impactos tem sido identificado como uma necessidade de estudos e inspirou diversos trabalhos (por exemplo, Jones (2000a, 2000b), New e Hulme (2000), Katz (2002)).

1.1 Motivação, problemática e hipótese

Na atualidade, os modelos climáticos são instrumentos fundamentais nas ciências climáticas, um vez que, através deles os estudiosos procuram compreender os fenômenos climáticos e prever suas consequências (MORGAN; MORRISON, 1999; LENHARD; KÜPPERS; SHINN, 2007). As projeções de MCGs concebem o conhecimento substancial sobre as mudanças climáticas em escala global. Nesse contexto, os modelos mais complexos possuem emissões antropogênicas de carbono e vinculam processos oceânicos, atmosféricos e da superfície continental para evidenciar o movimento físico de gases (ou massas líquidas), transferência de energia, reflexão e absorção da luz solar, dentre outros fenômenos (WEART, 2008, 2010).

Na ciência do clima, os modelos computacionais não servem apenas para projetar o

clima futuro, mas também para atribuir as causas das mudanças climáticas que ocorreram no passado. Com a utilização de modelos que simulam o que teria acontecido sem os efeitos antropogênicos na atmosfera, seria possível separar as consequências da emissão dos GEEs e a variabilidade natural do clima. Isso permite demonstrar que somente a variabilidade natural inerente às condições do climáticas não explicam o aumento da temperatura observado nas últimas décadas. Através do acoplamento de métodos estatísticos e da modelagem computacional os pesquisadores conseguiram separar e atestar a colaboração antropogênica para o aquecimento do clima global (WEART, 2008).

A despeito da ampla limitação e incerteza dos modelos climáticos, a modelagem é a ferramenta mais utilizada para estudar as mudanças do clima e implementar estratégias de mitigação e adaptação (NORTON; SUPPE, 2001). A utilização de técnicas de regionalização para traduzir as informações fornecidas por modelos climáticos numa escala espacial mais refinada é uma maneira comumente utilizada para diminuir as incertezas projetadas pelos modelos. Entre essas técnicas pode-se citar o uso de funções ortogonais empíricas (FOE) , redes neurais artificiais (RNAs) e as outras técnicas de *downscaling*.

Na literatura existem diversos métodos propostos para combinar as projeções advindas de conjuntos de inúmeros MCGs (tais como o 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).

Neste contexto, a presente pesquisa foi realizada no intuito de responder duas questões principais:

i. É possível confiar nos modelos computacionais para basear nossas ações em relação à questão das mudanças climáticas na América do Sul?

ii. A utilização de uma técnica com as Redes Neurais Artificiais é capaz de diminuir as incertezas nas projeções climáticas provenientes do modelos climáticos?

As hipóteses para responder a essas questões são:

i. Os modelos climáticos globais ainda são considerados a melhor ferramenta para projetar alterações no clima, porém é necessário saber o nível de incerteza associado a tais projeções, principalmente quando se esclarece que os modelos não fazem declarações "verdadeiras" ou "falsas" sobre a natureza.

ii. Visto que comumente técnicas de *dowsncaling* tem sido utilizadas para diminuir as

incertezas projetadas pelos modelos e as redes neurais artificiais podem executar tarefas que um programa linear não pode, a hipótese é de que as RNAs possam ajudar a diminuir as incertezas nas projeções climáticas.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo geral desse estudo é avaliar as incertezas envolvidas nas projeções de mudanças climáticas na América do Sul, simuladas por modelos numéricos presentes no CMIP5, e avaliar a utilização das Redes Neurais Artificiais como método de aferição das incertezas encontradas.

1.2.2 Objetivos específicos

i. Realizar um *downscaling* estatístico para estimar a precipitação sobre à América do Sul, com base nos modelos CMIP5, usando redes neurais artificiais e regressão linear múltipla por componentes principais.

ii. Identificar as incertezas inerentes aos modelos do CMIP5 estudados e utilizar as Redes Neurais Artificiais como método de aferição das mesmas.

1.3 Estrutura da tese

O conceito principal foi apresentar uma tese metodológica que é composta por capítulos, constando em forma geral: introdução, material e métodos, resultados em formato de artigos científicos, considerações finais e referências.

O capítulo 3 (referente ao 1º artigo) apresenta a aplicação do método *Reliability Ensemble Averaging* (RNA) na América do Sul, no intuito de identificar como essas incertezas distribuem-se geograficamente. O capítulo 4 (relativo ao 2º artigo) introduz a aplicação das redes neurais artificiais (RNAs) e da regressão linear múltipla (RLM) por componentes principais (CPs) para estimar precipitação na América do Sul, com o objetivo de comparar a aplicabilidade dos métodos em dados climáticos. No capítulo 5 (3º artigo) aplica-se as RNAs nos resultados obtidos pelo método REA para avaliar a influência deste método de *dowsncaling* na incertezas dos modelos climáticos. Na sequência são apresentados os artigos (resultados):

Capítulo 3 - Santos, T. S.; David, M. **Análise das Incertezas das Mudanças Climáticas Simuladas na América do Sul**. In: Mudanças Climáticas e Impactos nos Ecossistemas. Recife, Editora: Universitária-UFPE.
Publicação prevista para outubro de 2015.

Capítulo 4 - Santos, T. S.; David, M.; Torres, R. R. **Artificial Neural Networks and Multiple Linear Regression Model using Principal Components to Estimate Rainfall over South America**.
Artigo aceito para publicação como um paper de discussão na revista Nonlinear Processes in Geophysics (NPG) em 13 de julho de 2015.
ISSN: 1023–5809
Qualis A2–Geociências

Capítulo 5 - Santos, T. S.; David, M.; Torres, R. R. **Incertezas em Projeções de Mudanças Climáticas na América do Sul Aferidas por Redes Neurais Artificiais**.
Artigo em tradução para a revista Hydrology and Earth System Sciences (HESS)
ISSN: 1027–5606
Qualis A2–Geociências

2 Material e Métodos

2.1 Região de Estudo

A área de estudo é a América do Sul, que está entre as regiões do planeta que mais serão afetadas pelas mudanças climáticas projetadas para o final do século XXI (MARENGO et al., 2010). De acordo com Magrin et al. (2014), tendências significativas na precipitação e temperatura foram observadas na América do Sul. Três sub-regiões foram definidas segundo a importância socio-ambiental: Amazônia (AMZ), Nordeste do Brasil (NEB) e a região da Bacia da Prata (LPB), conforme mostrado na Figura 2.1. Além disso, estas regiões apresentaram diferentes sinais de mudança na projeção da precipitação nas projeções de diferentes modelos até o final do século XXI (MEEHL et al., 2007; TORRES; MARENGO, 2013).

2.2 Base de Dados

As simulações e projeções climáticas analisadas neste estudo advêm dos conjuntos de MCGs integrantes do CMIP5, fornecido pelo *Program for Climate Model Diagnosis and Intercomparison* (PCMDI) (http://pcmdi3.llnl.gov) e disponibilizado pelo *Earth System Grid data portal*. As variáveis utilizadas são médias mensais de precipitação e temperatura do ar próximo à superfície gerados por dez modelos do projeto CMIP5 (Tabela 2.2), simuladas para o clima observado, denominado clima presente ou clima atual (1961 - 1990), e projetadas para o clima do século XXI (2071 - 2100), denominada clima futuro. Essas simulações são oriundas de modelos do CMIP5 (TAYLOR; STOUFFER; MEEHL, 2012).

As simulações do clima presente, denominadas "historical" no conjunto CMIP5, são referentes ao século XX. Torres (2014) afirma que essas simulações 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. Por outro lado, 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

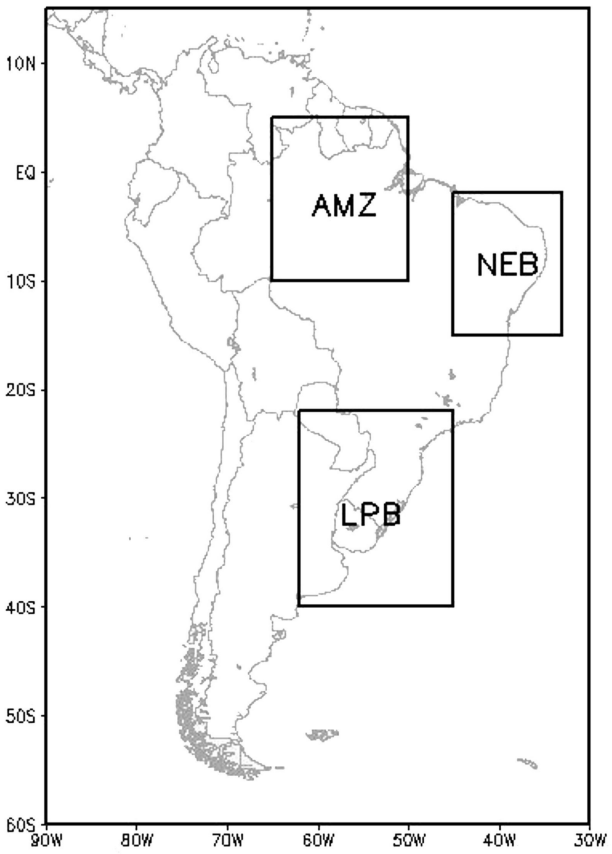

Figura 2.1: Domínio de estudo. Os retângulos indicam as sub-regiões utilizadas nas análises: Amazônia (AMZ), Nordeste do Brasil (NEB), e Bacia do Prata (LPB).

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 $w.m^{-2}$, respectivamente, relativo às condições pré-industriais. Com relação às concentrações de CO_2, os RCPs 2.6, 4.5, 6.0, e 8.5, correspondem aproximadamente a 490, 650, 850 e 1370 ppm, respectivamente, em 2100 (VUUREN et al., 2011).

A Figura 2.2 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 *Special Report on Emissions Scenarios* (SRES) (A2, A1b, B2, e B1) pertencentes ao CMIP3. Como pode-se 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 2.2). Maiores detalhes acerca dos cenários SRES e RCPs podem ser encontrados, por exemplo, em Nakicenovic e Swart (2000), Moss et al. (2010), Vuuren et al. (2011). De maneira geral, as principais características dos cenários de mudanças climáticas estão resumidos na Tabela 2.1.

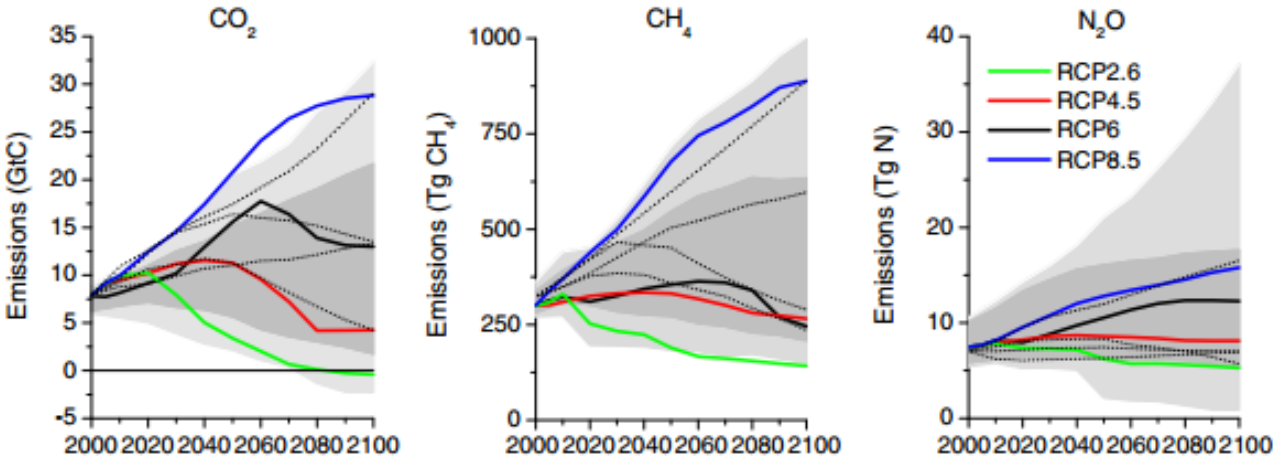

Figura 2.2: Trajetórias das emissões de CO_2 (esquerda), CH_4 (centro) e N_2O (direita) referentes aos quatro cenários RCPs (2.6, 4.5, 6.0 e 8.5). As áreas em cinza representam os percentis 98°(cinza claro) e 90°(cinza escuro) encontrados na literatura. As linhas tracejadas indicam os quatro cenários SRES (A2, A1b, B2 e B1). Fonte: Vuuren et al. (2011).

Tabela 2.1: Resumo das principais características dos RCPs utilizados pelo CMIP5 (RCP 2.6, RCP 4.5, RCP 6.0, RCP 8.5). Fonte: Jones e Carvalho (2013), Vuuren et al. (2011)

Variáveis	**RCP 8.5**	**RCP 6.0**	**RCP 4.5**	**RCP 2.6**
Forçante Radiativa ($w.m^{-2}$)	>8.5 em 2100 e continua subindo	6 em 2100, com uma estabilização após 2100	4.5 em 2100, com uma estabilização após 2100	Um pico de 3 antes de 2100, e após o pico declina
Concentração de CO_2 equivalente (ppm)	>1370 em 2100	850 com uma estabilização após 2100	650 estabilizando após 2100	Pico em 490, antes de 2100 e declina
Poluição do ar	Média – alta	Média	Média	Média–baixa
Emissão de gases do efeito estufa	Alta	Média à alta (Mitigação)	Média à baixa (Mitigação)	Muito baixa
Crescimento Populacional	Alto	Médio	Baixo	Baixo
Área Agrícola	Média – pasto e cultivo	Média – cultivo e muito baixa para pasto (total muito baixo)	Baixa – pasto e cultivo	Média – pasto e cultivo

Tabela 2.2: Modelos do CMIP5 utilizados neste estudo com a descrição das resoluções horizontais aproximadas

Modelo	**Instituição**	**Resolução**	**Referência principal**
ACCESS1.0	Commonwealth Scientific and Industrial Research Organization/Bureau of Meteorology	1.3 ^{o} x 1.9 ^{o}	Bi et al. (2013)
BCC–CSM1–1	Beijing Climate Center	2.8 ^{o} x 2.8 ^{o}	Xiao-Ge, Tong-Wen e Jie (2013)
CCSM4	National Center for Atmospheric Research	1.25^{o} x,0.94^{o}	Craig, Vertenstein e Jacob (2012)
CNRM–CM5	Centre National de Recherches Meteorologiques / Centre Europeen de Recherche et Formation Avancees en Calcul Scientifique (CNRM/CERFACS)	1.4 ^{o} x 1.4 ^{o}	Voldoire et al. (2013)
CSIRO–Mk3.6.0	Commonwealth,Scientific and Industrial Research Organisation in collaboration with the Queensland Climate Change Centre of Excellence	1.875^{o} x1.875^{o}	Collier et al. (2011)
HadGEM2–ES	Met Office Hadley Centre	1.875^{o} x 1.25^{o}	Collins et al. (2011)
INMCM4	Institute for Numerical Mathematics	1.5^{o} x 2.0^{o}	Volodin, Dianskii e Gusev (2010)
MPI–ESM–LR	Max Planck Institute for Meteorology	1.8^{o} x 1.8^{o}	Giorgetta et al. (2013)
MRI–CGCM3	Meteorological Research Institute	1.1^{o} x 1.1 ^{o}	Yukimoto et al. (2012)
NorESM1–M	Norwegian Climate Centre (NCC)	1.9^{o} x 2.5^{o}	Bentsen et al. (2013)

Empregaram-se neste trabalho simulações referentes ao cenário "historical" e projeções climáticas no cenários RCP 2.6 e 8.5, que são os mais extremos dentre os cenários do CMIP5, conforme mostrado anteriormente. As resoluções horizontais dos MCGs do CMIP5 variam em torno de 1 a 3 graus. Com o propósito de comparação, todas as variáveis utilizadas foram interpoladas para uma grade regular comum de 2,5° x 2,5° de

latitude/longitude utilizando uma interpolação bilinear.

As simulações para o século XX foram comparadas com dados de precipitação do CRU TS 3.0 (HARRIS et al., 2014), produzidos por *Climatic Research Unit (CRU) - University of East Anglia (UEA)* . Esses dados cobrem um período de 1901 a 2005 e tem uma resolução espacial de 0.5 °x 0.5 °.

2.3 Métodos

As projeções de mudanças climáticas de cada MCG para os 2071–2100 nos diferentes cenários utilizados foram avaliadas com relação ao período de 1961–1990 (normal climatológica de referência), averiguando-se as regiões de maior ou menor confiabilidade baseada na metodologia denominada *Reliability Ensemble Averaging*. Além disso, foram utilizadas as Redes Neurais Artificiais com a finalidade de aferição em relação aos resultados encontrados pelo REA. Essas metodologias são descritas detalhadamente a seguir.

2.3.1 *Reliability Ensemble Averaging* (REA)

O método REA, desenvolvido por Giorgi e Mearns (2002), aborda a mudança esperada em uma variável climática (ξ) baseando-se em um conjunto de projeções de diferentes modelos. Essa variação média é dada por uma combinação das mudanças projetadas por cada membro do conjunto ($\Delta\xi_i$) e é definido por:

$$\widetilde{\Delta}\xi = \frac{\sum_i R_i \Delta\xi_i}{\sum_i R_i} \tag{2.1}$$

Na qual:

$\widetilde{\Delta}\xi$ = Mudança esperada em uma variável climática ξ;
R_i = Fator de confiabilidade atribuída a um dado modelo i;
$\Delta\xi_i$ = Mudança projetada em uma variável climática ξ por um dado modelo i.

O fator de "confiabilidade" de cada modelo é definido por:

$$R_i = [(R_{B,i})^m \times (R_{D,i})^n]^{[1/(m\times n)]} \tag{2.2}$$

$$R_i = \left\{ \left[\frac{\varepsilon_\xi}{abs(B_{\xi,i})} \right]^m \times \left[\frac{\varepsilon_\xi}{abs(D_{\xi,i})} \right]^m \right\} \tag{2.3}$$

Em que:

ε_ξ = representa a variabilidade natural apresentada pela variável climática ξ
$R_{B,i}$ = 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 do seu viés $D_{\xi,i}$
$B_{\xi,i}$ = Viés apresentado pelo modelo i na simulação da variável ξ
$D_{\xi,i}$ = Distância entre a projeção produzida pelo modelo i para a variável ξ e a projeção média do conjunto
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 como uma função do viés do modelo ($B_{\xi,i}$) em simular a variável, isto é, quanto maior for o viés, menor a confiabilidade do modelo i em projetar a variável ξ. Enquanto, $R_{D,i}$ é um fator que pondera a confiabilidade do modelo em termos da distância ($D_{\xi,i}$) entre a mudança na variável ξ calculada por este modelo e a mudança média REA ($\widetilde{\Delta}\xi$) do conjunto, ou seja, quanto maior a distância menor a confiabilidade do modelo. De maneira geral, para uma projeção de um dado modelo que se afasta demais com relação aos outros membros do conjunto atribui-se um peso menor. Em outras palavras, $R_{B,i}$ é uma medida que mede o critério de desempenho do modelo, enquanto $R_{D,i}$ é uma medida do critério de convergência do modelo. Os parâmetros m e n podem ser utilizados para balancear cada critério. Para os cálculos neste trabalho, m e n são assumidos como sendo igual a 1, o que dá igual peso a ambos os critérios.

Essencialmente, as Equações 2.1 e 2.3 estabelecem que determinada projeção de um modelo é dito 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 e sua distância ao valor médio do conjunto são menores que a variabilidade natural da variável analisada (ε_ξ), de tal forma que $R_B = R_D = 1$. Quando o viés e a distância crescem, a confiabilidade de uma simulação de determinado modelo diminui (GIORGI; MEARNS, 2002).

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), Torres e Marengo (2013), Torres (2014).

Torres (2014) afirma que 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 independentes) 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. Torres (2014) assegura ainda que, 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.

Como proposto por Giorgi e Mearns (2002), e utililizado por Tebaldi et al. (2005), Moise e Hudson (2008) e Xu, Gao e Giorgi (2010), a variabilidade natural (ε_ξ) da precipitação e da temperatura são estimadas pela 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, para cada ponto de grade.

Por meio dos parâmetros mencionados anteriormente, é possível calcular o intervalo de incerteza em torno da mudança média REA ($\pm\widetilde{\delta}_{\Delta\xi}$) e a confiabilidade do conjunto ($\widetilde{\rho}$) :

$$\widetilde{\delta}_{\Delta\xi} = \left[\frac{\sum_i R_i(\Delta\xi_i - \widetilde{\Delta\xi})^2}{\sum_i R_i}\right]^{1/2} \tag{2.4}$$

$$\widetilde{\rho} = \frac{\sum_i R_i^2}{\sum_i R_i} \tag{2.5}$$

Os limites superior e inferior de incerteza da média REA são definidos por:

$$\Delta\xi_+ = \widetilde{\Delta\xi} + \widetilde{\delta}_{\Delta\xi} \tag{2.6}$$

$$\Delta\xi_- = \widetilde{\Delta\xi} - \widetilde{\delta}_{\Delta\xi} \tag{2.7}$$

Segundo Giorgi e Mearns (2002) os fatores de confiabilidade podem ser usados para se estimar a probabilidade das mudanças climáticas futuras projetadas pelo conjunto de MCGs.

Como base de comparação com a variação média do conjunto de modelos do método

REA (descrito na equação 2.1), utilizou-se também uma abordagem mais simples no estudo da variação climática. Nesta abordagem, a variação da variável climática ($\overline{\Delta\xi}$) é dada pela média do conjunto de todas as simulações dos modelos (N), sem fator de confiabilidade atribuído ao modelo, definida por:

$$\overline{\Delta\xi} = \frac{1}{N} \sum_{i=1,N} \Delta\xi_i \tag{2.8}$$

2.3.2 Redes Neurais Artificiais (RNAs)

Uma rede neural artificial (RNA) é um sistema baseado na operação de uma rede neural biológica, que têm a habilidade para armazenar conhecimento e torná-lo disponível para o uso. As redes neurais artificiais fundamentam- se nos estudos sobre a estrutura do cérebro humano para tentar emular sua forma inteligente de processar informações. De acordo com Haykin (2001), as RNAs se assemelham ao cérebro em dois aspectos:

- O conhecimento é adquirido pela rede a partir de seu ambiente, através de um processo de aprendizagem;
- Forças de conexão entre neurônios, conhecidas com pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

O mesmo autor afirma que o procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo de projeto desejado. A modificação de pesos sinápticos é o método tradicional para o projeto de redes neurais. Entretanto, é possível também para uma RNA modificar sua própria topologia, o que é motivado pelo fato dos neurônios no cérebro humano poderem morrer e que novas conexões sinápticas possam crescer.

2.3.2.1 Modelo de um neurônio

Um neurônio é uma unidade de processamento de informação que é fundamental para uma rede neural. A Figura 2.3 mostra o modelo de um neurônio, que forma a base para o projeto de redes neurais artificiais. Um neurônio artificial é formado por três elementos básicos: os pesos sinápticos, a função de soma (somador) e a função de ativação, também conhecida como função de transferência. Mais especificamente:

1. Um conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso

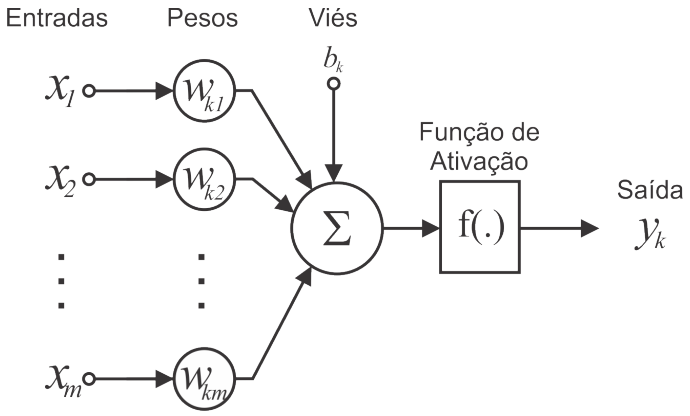

Figura 2.3: Modelo um neurônio artificial. Fonte: Haykin (2001).

ou força própria. Especificamente, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicada pelo peso sináptico w_{kj} ;

2. Somador: soma os sinais de entrada, ponderados pelas respectivas sinapses do neurônio;

3. Função de ativação: para restringir a amplitude da saída do neurônio. Também definida com função restritiva já que limita o intervalo permissível de amplitude do sinal de saída a um valor finito.

O modelo neuronal da Figura 2.3 inclui também um viés aplicado externamente, representado por b_k. Segundo Haykin (2001) o viés (b_k) tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se este é positivo ou negativo, respectivamente.

De maneira geral, a rede neural artificial assemelha- se à rede neural biológica, funcionando como um neurônio humano: as entradas chegam pelos dendritos (elos de conexão), são multiplicadas pelos pesos e somadas dentro do corpo celular. Se o resultado da somatória for maior que um determinado valor limite, haverá uma saída, caso contrário não haverá uma saída, ou melhor, pode-se dizer que a saída estará desligada.

2.3.2.2 Vantagens das RNAs

Uma rede neural possui o poder computacional na sua habilidade de aprender. A rede neural é capaz de produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (aprendizagem). Haykin (2001) aponta que as RNAs oferecem as seguintes propriedades úteis:

1. Não-linearidade: é uma propriedade muito importante, particularmente se o meca-

nismo físico responsável pela geração do sinal de entrada for inerentemente não-linear;

2. Mapeamento de Entrada-Saída: chamado de aprendizagem supervisionada envolve a modificação dos pesos sinápticos de uma rede neural pela aplicação de um conjunto de amostras de treinamento rotuladas ou exemplos da tarefa. Cada exemplo consiste de um sinal de entrada único e de resposta desejada correspondente;

3. Adaptabilidade: As redes neurais têm uma capacidade inata de adaptar seus pesos sinápticos a modificações do meio ambiente. Em particular, uma rede neural treinada para operar em um ambiente específico pode ser facilmente retreinada para lidar com pequenas modificações nas condições operativas do ambiente. Além disso, quando é operado em um ambiente não estacionário (i. e., em que as estatísticas mudam com o tempo), uma rede neural pode ser projetada para modificar seus pesos sinápticos em tempo real.

4. Resposta a Evidências: Uma rede neural pode ser projetada para fornecer informação não somente sobre qual padrão particular selecionar, mas também sobre a confiança na decisão tomada. Essa última informação pode ser utilizada para rejeitar padrões ambíguos, caso eles estejam presentes, e com isso melhorar o desempenho de classificação da rede.

5. Informação Contextual: cada neurônio da rede é potencialmente afetado pela atividade de todos os neurônios da rede. Consequentemente, essa informação contextual é tratada naturalmente pela rede neural.

6. Tolerância a Falhas: Uma rede neural implementada na forma física (em *hardware*), tem o potencial de ser inerentemente tolerante a falhas, ou capaz de realizar computação robusta, no sentido de que seu desempenho se degrada suavemente sob condições de operações adversas.

2.3.2.3 Treinamento das RNAs

Assim como uma rede neural biológica desenvolvida deve possuir a capacidade de armazenar novos conhecimentos, com o intuito de torná-los úteis às tomadas de decisões, uma RNA deve ser treinada com o mesmo objetivo: aprender. É no processo de treinamento que serão ajustados os parâmetros, para que a rede habilite-se a responder o mais corretamente possível a quaisquer outros estímulos que lhe forem apresentados em uma fase posterior ao treinamento, denominada de "teste".

O treinamento inicia quando um exemplo é apresentado à rede e termina quando todas as conexões estão devidamente ajustadas (treinadas) para reconhecer todos os exemplos

mostrados à rede (ou pelo menos uma boa parte dos exemplos). A partir deste momento a rede está pronta para a fase de testes e, a seguir, para o uso. Quanto ao conjunto de dados que serão apresentados à rede, pode-se dizer que, quanto mais completo o conjunto, mais tempo computacional será utilizado para ajustar as conexões e, certamente, melhor será o seu treinamento.

É a fase de treinamento que costuma receber uma atenção especial, pois quanto melhor o conjunto de treinamento, melhor o resultado da atuação da rede. É importante comentar que a eficiência da aplicação depende não só do bom dimensionamento da rede, mas também da forma com que o conjunto de treinamento é mostrado (HAYKIN, 1995). De maneira geral, tudo o que uma rede neural será capaz de fazer depende do que ela for capaz de aprender.

Um algoritmo de aprendizado é um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado, estes algoritmos diferenciam-se entre si principalmente pelo modo como os pesos são modificados. As RNAs baseiam-se nos dados para extrair um modelo geral. Portanto, a fase de aprendizado deve ser rigorosa.

Nas sinapses são armazenados o conhecimento da RNA, ou seja, os pesos atribuídos às conexões entre os neurônios. Parte dos dados deve ser separada para o treinamento da RNA; estes dados devem ser escolhidos aleatoriamente, a fim de que a RNA "aprenda" as regras e não "decore" os exemplos. O restante dos dados será utilizado para a fase de testes, a fim de que se possa "deduzir" corretamente o inter-relacionamento dos dados.

O processo de treinamento de uma RNA pelo algoritmo de retropropagação (tipo supervisionado), consiste basicamente em apresentar pares entrada–saída à rede, calcular as saídas da rede em função das entradas. Em seguida, calcular o erro entre a saída desejada e a saída calculada. Segundo Mendes e Marengo (2010), as informações de erro são usadas como um *feedback* para o sistema e ajusta os parâmetros do sistema de uma forma sistemática. O processo continua realizando a alteração dos valores sinápticos por algum tipo de algoritmo, que neste caso, será o algoritmo de retropropagação, e é repetido até que o desempenho seja aceitável.

Na Figura 2.4 pode-se visualizar a fase *forward* que é um sinal de entrada (estímulo), que estimula a entrada da rede. Neste caso serão usados os dados de precipitação e temperatura dos diversos modelos e os observados. Esses dados de entrada propagam-se para frente (neurônio por neurônio) por meio da rede e segue para a camada de saída da rede como um sinal de saída. Tem-se a fase *backward* que é um sinal de erro que origina-se dos neurônios de saída da rede e propaga-se para trás (camada por camada) através da rede.

O processo de treinamento da RNA pelo algoritmo de retropropagação realiza como

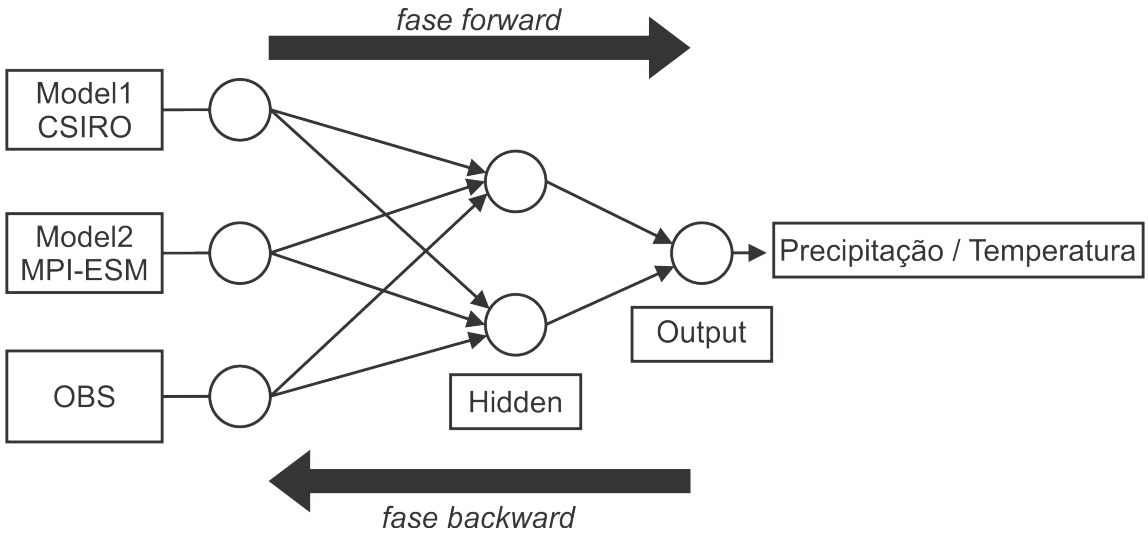

Figura 2.4: Estrutura de uma rede neural artificial.

o próprio nome diz, a retropropagação dos erros calculados das saídas em direção às entradas. O erro calculado na saída de um neurônio é multiplicado pela derivada da função de ativação daquele neurônio e propagado para a sua entrada. Em seguida, este valor é enviado para todos os neurônios da camada anterior e pesados pelas respectivas sinapses, ou seja, na primeira a entrada é propagada pela rede, no sentido da entrada para a saída (fase *forward*), sem que ocorram alterações dos pesos. Já na segunda, a resposta de rede é comparada com a resposta desejada e os pesos são reajustados de maneira a minimizar o erro (fase *backward*).

De acordo com Mendes e Marengo (2010), o objetivo do processo de treinamento é encontrar o conjunto de valores relativos aos pesos que fará com que a saída do RNA corresponda aos valores de *output* mais próximo do real. Assim, espera-se que a rede neural seja capaz de fornecer para os dados dos modelos, os valores mais próximos do real, por meio da análise da incerteza do erro entre os valores simulados e observados, reduzindo assim as incertezas geradas pelos modelos climáticos.

A estrutura da RNA usada aqui envolve o treinamento de 11 preditores (10 saídas dos modelos mais os dados de observação) como entrada para a rede e o melhor desempenho da rede é selecionado, como pode ser visto na Figura 2.5. As análises de incertezas em mudanças climáticas analisadas pelo método REA serão aferidas através das RNAs, para cada período e cenário especificado anteriormente.

2.3.3 Regressão Linear Múltipla

O método de regressão linear múltipla (RLM) é uma técnica estatística que consiste em encontrar uma relação linear entre uma variável dependente (dados observados), e

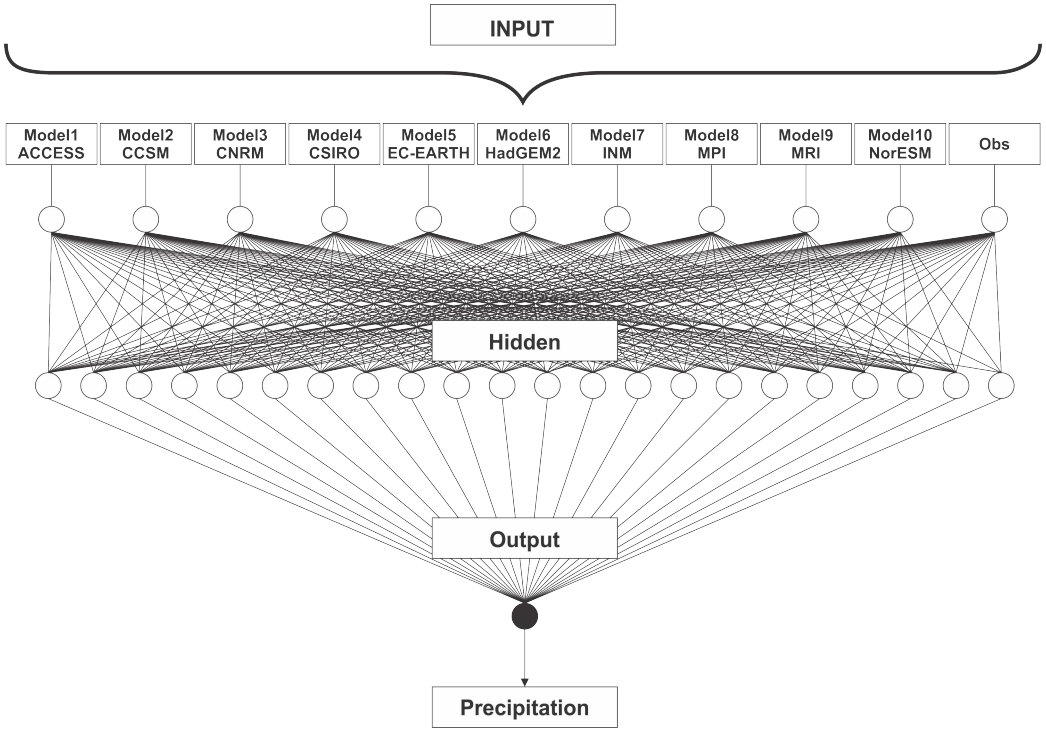

Figura 2.5: Estrutura da rede neural artificial utilizada no estudo.

mais de uma variável independente (saídas dos MCGs). Um modelo de regressão múltipla pode ser apresentado pela seguinte equação:

$$Y_i = \alpha_0 + \alpha_1 X_{1i} + ... + \alpha_m X_{mi} + \epsilon_i \tag{2.9}$$

Sendo:

Y Y é a variável dependente;
X_i, X_2 e X_m variáveis independentes;
α_0 o intercepto;
α_1 e α_m coeficientes da regressão múltipla a serem estimados pelo método dos mínimos quadrados (WILKS, 1995);
ϵ_i é o erro.

O objetivo da regressão linear múltipla é encontrar os coeficientes (α_m) que relacionam as variáveis independente e dependente; esse passo é chamado calibração do modelo de regressão. Em forma matricial, tem-se:

$$Y = \begin{bmatrix} Y_1 \\ : \\ Y_i \end{bmatrix} \tag{2.10}$$

$$A = \begin{bmatrix} \alpha_0 \\ : \\ \alpha_m \end{bmatrix} \tag{2.11}$$

$$X = \begin{bmatrix} 1 & X_{11} & \cdots & X_{m1} \\ : & : & \ddots & : \\ 1 & X_{1i} & \cdots & X_{mi} \end{bmatrix} \tag{2.12}$$

$$\varepsilon = \begin{bmatrix} \epsilon_1 \\ : \\ \epsilon_i \end{bmatrix} \tag{2.13}$$

Sendo:

Matriz – Y = matriz das variáveis dependentes;
Matriz – X = matriz das variáveis independentes;
Matriz – A = matriz com os coeficientes α_m;
Matriz – ε = matriz com os coeficientes ϵ_i;

Reescrevendo o modelo de regressão múltipla em forma matricial, tem–se:

$$\begin{bmatrix} Y_1 \\ : \\ Y_i \end{bmatrix} = \begin{bmatrix} \alpha_0 \\ : \\ \alpha_m \end{bmatrix} \begin{bmatrix} 1 & X_{11} & \cdots & X_{m1} \\ : & : & \ddots & : \\ 1 & X_{1i} & \cdots & X_{mi} \end{bmatrix} \begin{bmatrix} \epsilon_1 \\ : \\ \epsilon_i \end{bmatrix} \tag{2.14}$$

$$Y = XA + \epsilon \tag{2.15}$$

Apesar de seu sucesso evidente em muitas aplicações, a RLM quando utilizada para variáveis climáticas possui multicolinearidade. Diante disto, os erros da estimativa dos parâmetros podem ser erroneamente interpretados (LEAHY, 2000). Para solucionar este problema, utilizaram-se Componentes Principais (CPs). Esta técnica tem como objetivo explicar a estrutura de variância e covariância de um vetor aleatório por meio da construção de combinações lineares das variáveis originais que são, para este problema, as variáveis preditoras de regressão linear múltipla (MINGOTE, 2005). De maneira geral, as CPs visa reduzir por meio de transformações ortogonais o número de variáveis e retirar a multicolinearidade das variáveis independentes. Portanto, as CPs das variáveis explicativas são um novo conjunto de variáveis com as mesmas informações das variáveis originais, mas não correlacionadas.

3 Análise das Incertezas das Mudanças Climáticas Simuladas na América Do Sul

Thalyta Soares dos Santos[1]

David Mendes[2]

[1] Programa de Pós-Graduação em Ciências Climáticas–PPGCC/UFRN, Natal, Brasil

[2] Departamento de Ciências Atmosféricas e Climáticas

(a) Artigo para publicação em capítulo do livro Mudanças Climáticas e Impactos nos Ecossistemas, Editora: Universitária–UFPE. Publicação prevista para outubro de 2015.

3.1 Resumo

Neste trabalho objetivou-se analisar as incertezas envolvidas nas projeções de mudanças climáticas na América do Sul (AS) simuladas por modelos climáticos do *Coupled Model Intercomparison Project 5th Phase* (CMIP5) para a América do Sul. As incertezas nas projeções das mudanças climáticas futuras surgem a partir de fontes diferentes e são introduzidos na sequência de passos no processo de modelagem, produzindo assim uma cascata de incertezas. Essas incertezas projetadas pelos modelos climáticos foram calculadas através do método *Reliability Ensemble Averaging* (REA) que é utilizado para calcular o intervalo de incerteza e uma medida de confiabilidade das mudanças climáticas simuladas por um conjunto de diferentes modelos climáticos. O REA foi aplicado para os séculos XX e XXI em diferentes cenários do IPCC (*Intergovernmental Panel on Climate Change*). Assim sendo, com o estudo proposto espera-se avaliar e quantificar detalhadamente os intervalos de incerteza nas mudanças climáticas apresentadas no CMIP5 para a América do Sul, relacionadas ao uso de diferentes modelos numéricos e futuras emissões de gases de efeito estufa. Os resultados indicaram diferenças consideráveis entre o período de controle e as projeções futuras. O método produz também uma medida quantitativa da confiabilidade que mostra que ambos os critérios devem ser atendidos pelas simulações a fim de aumentar a confiabilidade das mudanças simuladas. A confiabilidade do conjunto de modelos foi satisfatória para toda a América do Sul, indicando boa simulação dos modelos nessa região.

PALAVRAS-CHAVES: *Reliability Ensemble Averaging*, Confiabilidade dos modelos, IPCC.

3.2 Abstract

In this research the objeticve is analyzed the uncertainties involved in projections of climate change in South America (SA) simulated by climate models presented in the Coupled Model Intercomparison Project 5th Phase (CMIP5) in South America. 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. These uncertainties are calculated by the Reliability Ensemble Averanging (REA) method which is used to calculate the uncertainty range and a measure of reliability of simulated climate changes from ensembles of different AOGCM simulations is introduced. The REA will be applied to the 20th and 21st centuries in different IPCC (Intergovernmental Panel on Climate Change) scenarios. Therefore, the proposed study is expected to evaluate and quantify in detail the ranges of uncertainties in climate change presented in CMIP5 for SA, related to the use of different models and future greenhouse gases emissions. The results indicated significant differences between the control and future projections. The method produces also a quantitative measure of reliability that shows that both criteria must be met by the simulations in order to increase the overall reliability of simulated changes. The reliability of the set of models was satisfactory for the whole of South America, indicating good simulation of the models in this region.

KEYWORDS *Reliability Ensemble Averaging*, Reliability of models, IPCC.

3.3 Introdução

Um grande desafio para os cientistas é estimar futuras mudanças climáticas e instrumentos muito úteis para estas estimativas são modelos climáticos. No entanto, não é possível para qualquer modelo simular exatamente a complexidade do mundo real. É por isso que as saídas dos modelos climáticos só podem ser tomadas como projeções de possíveis mudanças climáticas futuras.

Informações sobre as alterações climáticas a nível global, regional e escalas locais são necessárias a fim de desenvolver a adaptação e estratégias de mitigação a nível nacional e internacional. Essa informação ainda é afetada por um alto nível de incerteza, os limites do nosso conhecimento e modelagem do sistema climático (GIORGI, 2005). É, portanto, necessário caracterizar essa incerteza e descrevê-la em uma forma que possa ser utilizada na avaliação do impacto e adaptação de estudos relacionados ao clima futuro.

Nos modelos climáticos as principais incertezas são semelhantes às que se encontram nos modelos de previsão numérica do tempo e têm a sua origem na impossibilidade de simular fielmente os fenômenos à escala de quilômetro. As tentativas de parametrizar tais fenômenos não resolvem inteiramente o problema. Resultados de Murphy et al. (2004), Stainforth et al. (2005) obtidos com modelos climáticos globais (MCGs) permitem concluir que a incerteza no aumento projetado da temperatura média global até o fim do século XXI é ainda considerável, sobretudo à escala regional. Para diminuir a incerteza é necessário que os modelos adquiram a capacidade de descrever os processos atmosféricos em escalas da ordem de 1 km, como por exemplo, a distribuição espacial do vapor de água e das nuvens. Para poder quantificar com menor incerteza as variações projetadas para os vários indicadores do clima, tais como a temperatura média, a distribuição da precipitação ao longo do ano e a frequência dos fenômenos climáticos extremos, é necessário desenvolver a investigação sobre o clima e construir modelos climáticos mais realistas, que incluam os vários subsistemas e descrevam os fenômenos em escalas espaciais menores do que as dos modelos atuais.

A utilização de técnicas de regionalização para traduzir as informações fornecidas por esses modelos numa escala espacial mais refinada é uma maneira comumente utilizada para diminuir as incertezas projetadas pelos modelos. Entre as técnicas comumente utilizadas pode-se citar o uso de funções ortogonais empíricas (FOE), redes neurais artificiais (RNA), entre outras. No entanto, muitas vezes, utilizando o mesmo período e o mesmo cenário de emissões, diferentes modelos climáticos globais oceano-atmosfera (MCGOAs) e/ou técnicas de regionalização fornecem resultados divergentes, o que impede uma afirmação mais contundente dos padrões apresentados pela média simples de seu conjunto.

Giorgi e Mearns (2002) afirmam que um dos principais fatores de incerteza é que

diferentes MCGOAs podem simular diferentes mudanças regionais, mesmo sob o mesmo cenário de forçante antropogênica, (por exemplo, Kittel, Giorgi e Meehl (1997), Giorgi e Francisco (2000), Whetton et al. (1996). É muito difícil saber qual dos MCGOAs é mais responsável por essas diferenças. Giorgi e Mearns (2002) apontam que uma avaliação abrangente das projeções de mudanças regionais precisa ser baseada na informação coletiva de um conjunto de simulações de MCGOAs.

Embora o enorme avanço científico e computacional das últimas décadas tenha possibilitado um maior entendimento do sistema climático e contribuído valiosamente para as análises das possíveis causas e futuros impactos das mudanças climáticas globais, as incertezas que permeiam as projeções de clima, tais como as reportadas pelo IPCC AR4, ainda continuam muito grandes, principalmente em escala regional. Essas projeções têm sido caracterizadas por um baixo nível de confiança e um alto nível de incerteza decorrente de diferentes fontes (VISSER et al., 2000).

Mesmo com toda essa evolução do IPCC AR4 (Quarto Relatório Científico do Painel Intergovernamental de Mudanças Climáticas) com relação ao TAR (Terceiro Relatório do IPCC) , as projeções de mudanças climáticas possuem e sempre possuirão um intrínseco nível de incerteza, de tal forma que considerações probabilísticas devam sempre ser levadas em conta. Além disso, tornou-se amplamente reconhecido pela comunidade científica que políticos e tomadores de decisão, assim como a sociedade em geral, necessitam de informações confiáveis e bem sintetizadas sobre as mudanças climáticas e seus impactos, contudo, sem deixar de considerar as incertezas envolvidas Torres (2014).

Neste estudo, as incertezas foram analisadas através do método REA *(Reliability Ensemble Averaging)*, desenvolvido por Giorgi e Mearns (2002), este método é de maneira geral, baseado numa média ponderada dos diversos MCGs que conta para a confiabilidade de cada modelo. Na abordagem REA, esta confiabilidade é determinada tendo em conta a capacidade de um modelo em simular o clima observado (medindo o viés), e do grau de convergência de suas alterações climáticas projetadas no que diz respeito aos outros modelos do conjunto. O método REA é considerado uma ferramenta flexível que pode ser aplicada em global e escalas regional, e tem sido aplicada em vários estudos Giorgi e Mearns (2003), Moise e Hudson (2008), Xu, Gao e Giorgi (2010), Kim e Lee (2010), Tao et al. (2012), Torres e Marengo (2013).

Diante do exposto, o objetivo do presente trabalho é analisar as incertezas envolvidas nas projeções de precipitação na América do Sul (AS) simuladas por modelos climáticos do *Coupled Model Intercomparison Project 5th Phase* (CMIP5) para a América do Sul.

3.4 Material e Métodos

O estudo foi realizado para a América do Sul, que está entre as regiões do planeta que mais serão afetadas pelas mudanças climáticas projetas para o final deste século, principalmente na porção tropical do seu continente (SOLOMON et al., 2007; BAETTIG; WILD; IMBODEN, 2007). Além disso, a distribuição das terras sul-americanas em diferentes latitudes e com formas de relevo variadas proporcionam a atuação e o desenvolvimento de diferentes sistemas atmosféricos, que contribuem para a não homogeneidade climática desta região (REBOITA et al., 2010).

As variáveis utilizadas são de dados simulados de precipitação gerados por MCGs utilizados no CMIP5, para o século XX (no período 1971 a 2000) e no século XXI (projeção para 2071–2100). Utilizaram-se 3 modelos provenientes do CMIP5, conforme observado na Tabela 3.1.

Tabela 3.1: Modelos do CMIP5 utilizados e suas respectivas resoluções.

Modelo	**Resolução**
CSIRO–Mk3.6.0	1.3 º x 1.9 º
MIROC5	1.39° X 1.40625°
MPI–ESM–LR	1.8497° X 1.875°

Simulações referentes ao século XX (historical) e dois cenários futuros - RCPs (*Representative Concentration Pathways*) 2.6 e 8.5 foram empregados para a análise. Conforme descrito abaixo e detalhado na Figura 3.1, definidos por Moss et al. (2010):

- O cenário historical, período de controle, é rodado com arquivos de emissões não constantes fornecidas pelo IPCC. É uma simulação comparável às observações históricas, de forma a se obter informações sobre o desempenho do modelo para o clima passado/presente;
- O cenário RCP 2.6 representa o nível mais baixo de evolução do CO_2, no qual o máximo é atingido em meados do século XXI, diminuindo até a estabilidade em meados do século XXII. É um cenário mais otimista;
- O cenário RCP 8.5 prevê que o forçamento radiativo continua a aumentar em 2100, e as emissões são ainda elevadas, com aumento indefinido (e concentrações em 2300 de aproximadamente 3000 ppm CO_2). Forçando picos, em 2050, em aproximadamente 3 ($w.m^{-2}$), e diminui para 2,6 ($w.m^{-2}$), em 2100. É um cenário mais pessimista

As simulações para o século XX foram comparadas com dados de precipitação do CRU TS 3.0 (HARRIS et al., 2014), produzidos por *Climatic Research Unit (CRU) - University of*

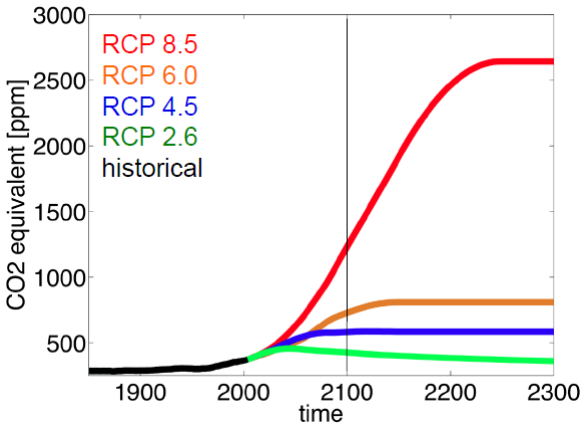

Figura 3.1: Representação dos cenários do IPCC. Fonte: (JAHN; HOLLAND, 2013).

East Anglia (UEA) . Esses dados cobrem um período de 1901 a 2005 e tem uma resolução espacial de 0.5 °x 0.5 °de lat/lon.

As análises de incertezas em mudanças climáticas proposta nesse artigo foram analisadas por meio da aplicação do método *Reliability Ensemble Averaging* (REA) desenvolvido por Giorgi e Mearns (2002), para cada período e cenário especificado anteriormente. A variação esperada ($\widetilde{\Delta}\xi$) em uma variável climática (ξ), é dada por uma combinação das mudanças projetadas por cada modelo do conjunto ($\Delta\xi_i$).

$$\widetilde{\Delta}\xi = \frac{\sum_i R_i \Delta\xi_i}{\sum_i R_i} \tag{3.1}$$

No qual R_i é o fator de confiabilidade do modelo definido como:

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

Na equação 3.2, $R_{B,i}$ é um fator que mede a confiabilidade do modelo como uma função do viés do modelo ($B_{\xi,i}$) em simular a variável, isto é, quanto maior for o viés menor a confiabilidade do modelo. O viés é definido como a diferença entre os dados simulados e observados. $R_{D,i}$ é um fator que mede a confiabilidade do modelo em termos da distância ($D_{\xi,i}$) da mudança calculada por um modelo determinado a partir da média REA, isto é, quanto maior a distância menor a confiabilidade do modelo. Portanto, a distância é uma medida do grau de convergência de um determinado modelo com outros. Em outras palavras, $R_{B,i}$ é uma medida do critério de desempenho do modelo, enquanto $R_{D,i}$ é uma medida do critério de convergência do modelo. Os parâmetros m e n podem ser utilizados para balancear cada critério. Para os cálculos neste trabalho, m e n são assumidos como sendo igual a 1, o que dá igual peso a ambos os critérios. Quanto maior

o viés e a distância à média REA, menor a confiabilidade da projeção.

Com os parâmetros descritos anteriormente, um intervalo de incerteza ($\widetilde{\delta}_{\Delta\xi}$), no entorno da mudança média REA ($\widetilde{\Delta}\xi \pm \widetilde{\delta}_{\Delta\xi}$) e uma medida da confiabilidade coletiva dos modelos ($\widetilde{\rho}$) podem ser estimadas, respectivamente, por:

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

$$\widetilde{\rho} = \frac{\sum_i R_i^2}{\sum_i R_i} \tag{3.4}$$

Como base de comparação com a variação média do conjunto de modelos do método REA (descrito na equação 3.1), utilizou-se também uma abordagem mais simples no estudo da variação climática, que é:

$$\overline{\Delta\xi} = \frac{1}{N} \sum_{i=1,N} \Delta\xi_i \tag{3.5}$$

3.5 Resultados

A Figura 3.2 apresenta a climatologia da precipitação do conjunto de modelos para o verão e o inverno austral. É possível notar que os cenários futuros RCP 2.6 e 8.5 possuem um padrão bastante similar. A precipitação do conjunto de modelos varia de 1 a 5 mm nestes cenários. No período de controle, a chuva mais elevada em DJF na Amazônia e noroeste desta região em JJA. Esta representa uma região muito difícil de simular a precipitação devido à dificuldade de se obter dados observados para esta região, o que influencia na magnitude e localização dos padrões (principalmente para a precipitação).

No cenário historical observa-se ainda um padrão mais elevado da precipitação na região dos Andes, assim como observado por Torres e Marengo (2013). Segundo Seth, Rojas e Rauscher (2010) a média do conjunto apresenta um transporte de umidade mais fraco para o leste da Cordilheira dos Andes, que pode ser um dos fatores que induzem uma superestimação da precipitação sobre a bacia do La Plata para todas as estações, especialmente durante o inverno austral (Figura 3.2 - B).

Na figura 3.3 mostra-se as incertezas das simulações climáticas na América do Sul calculada através do método REA para o período de controle. Quando se comparam os padrões de mudanças da precipitação obtidos pela média simples (isto é, ao atribuir o mesmo peso a todos os membros do conjunto) e o obtido através da aplicação de uma

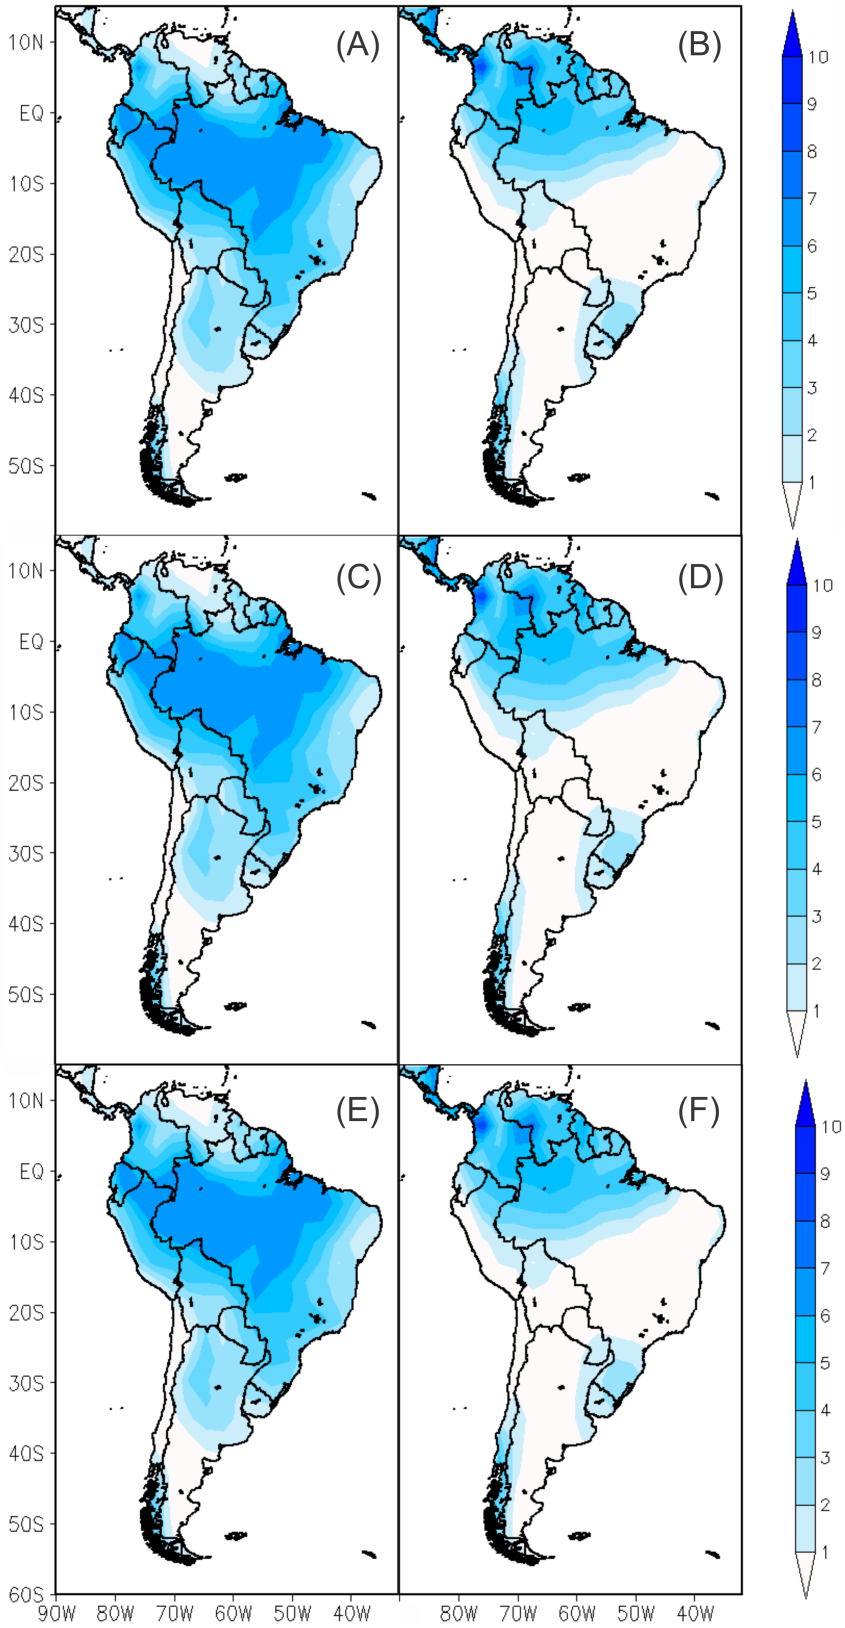

Figura 3.2: Padrão de precipitação (mm/dia) do conjunto de modelos para os cenários: historical (A-B), RCP2.6 (C-D) e RCP8.5 (E-F), no período de controle no verão (coluna esquerda) e inverno (coluna direita).

abordagem REA (Figura 3.2 (A-B) e Figura 3.3 (A-B), respectivamente), é possível notar que quando se leva em conta a confiabilidade dos modelos (medido pelo desempenho e critérios de convergência na abordagem REA), a magnitude da variação da precipitação diminui consideravelmente. Esta variação é mais pronunciada em DJF em quase toda a AS e em JJA no noroeste da Amazônia e no sul da AS.

Grandes faixas de incertezas das simulações são perceptíveis sobre o norte da América do Sul (que atinge uma área ainda maior no verão austral), no NEB, Sul do Brasil e na região dos Andes, nas duas estações. Esta faixa de incerteza é ainda maior do verão austral. A confiabilidade do conjunto de modelos é acima de 0,6, em quase toda a região da AS, o que pode indicar que existe uma alta confiabilidade das simulações. Resultados semelhantes foram encontrados por Giorgi e Mearns (2002), ao aplicar o método REA com um conjunto de 18 diferentes modelos em mais de 22 regiões que cobrem todo o globo.

Os cenários RCP 2.6 e 8.5 que apresentam os padrões de incerteza para as simulações do século XXI são bastantes similares. Observando-se a média dos modelos (figura 3.2- C a F), comparando os parâmetros de confiabilidade de cada um dos modelos (REA) (figura 3.4- C a F) a variação da simulação da precipitação para os meses de dezembro–janeiro–fevereiro é maior quando comparada a junho–julho–agosto, assim como observado no período de controle. Nota-se ainda que a média REA comparada à média simples dos modelos não possui uma diferença tão marcante, como foi observada no período de controle. Isto sugere que os modelos estudados apresentaram padrões similares de precipitação.

Na Figura 3.3 e 3.4 (B-C) vê–se também o intervalo de incerteza das projeções da precipitação para o período de 2071-2100. Percebe–se claramente que um comportamento similar entre o cenário mais otimista e o pessimista (RCP 2.6 e 8.5, respectivamente). Essa incerteza é maior nos meses que compreendem o verão quando comparado ao inverno austral. Este resultado corrobora com a variação REA que também foi maior para os meses de DJF. Esta mesma característica foi encontrada por Torres e Marengo (2012) que analisaram as projeções de precipitação (mm/dia) para o período de 2071–2100 para 24 modelos do CMIP3 no cenário A2 (pessimista).

Com relação à confiabilidade coletiva do conjunto de modelos Figura 3.3 e 3.4 (E-F) é acima de 0,6, em quase toda a região da AS, indicando de maneira geral, alta confiabilidade do conjunto de modelos, assim como observado no período de controle. Nota-se para as projeções (RCP 2.6 e 8.5) no período do inverno austral regiões com baixíssima confiabilidade: região sul da AS, um porção no Nordeste do Brasil (que possui uma alta variabilidade temporal e espacial do regime de precipitação) e a região dos Andes. Seth, Rojas e Rauscher (2010) afirmou que a má representação das condições climáticas

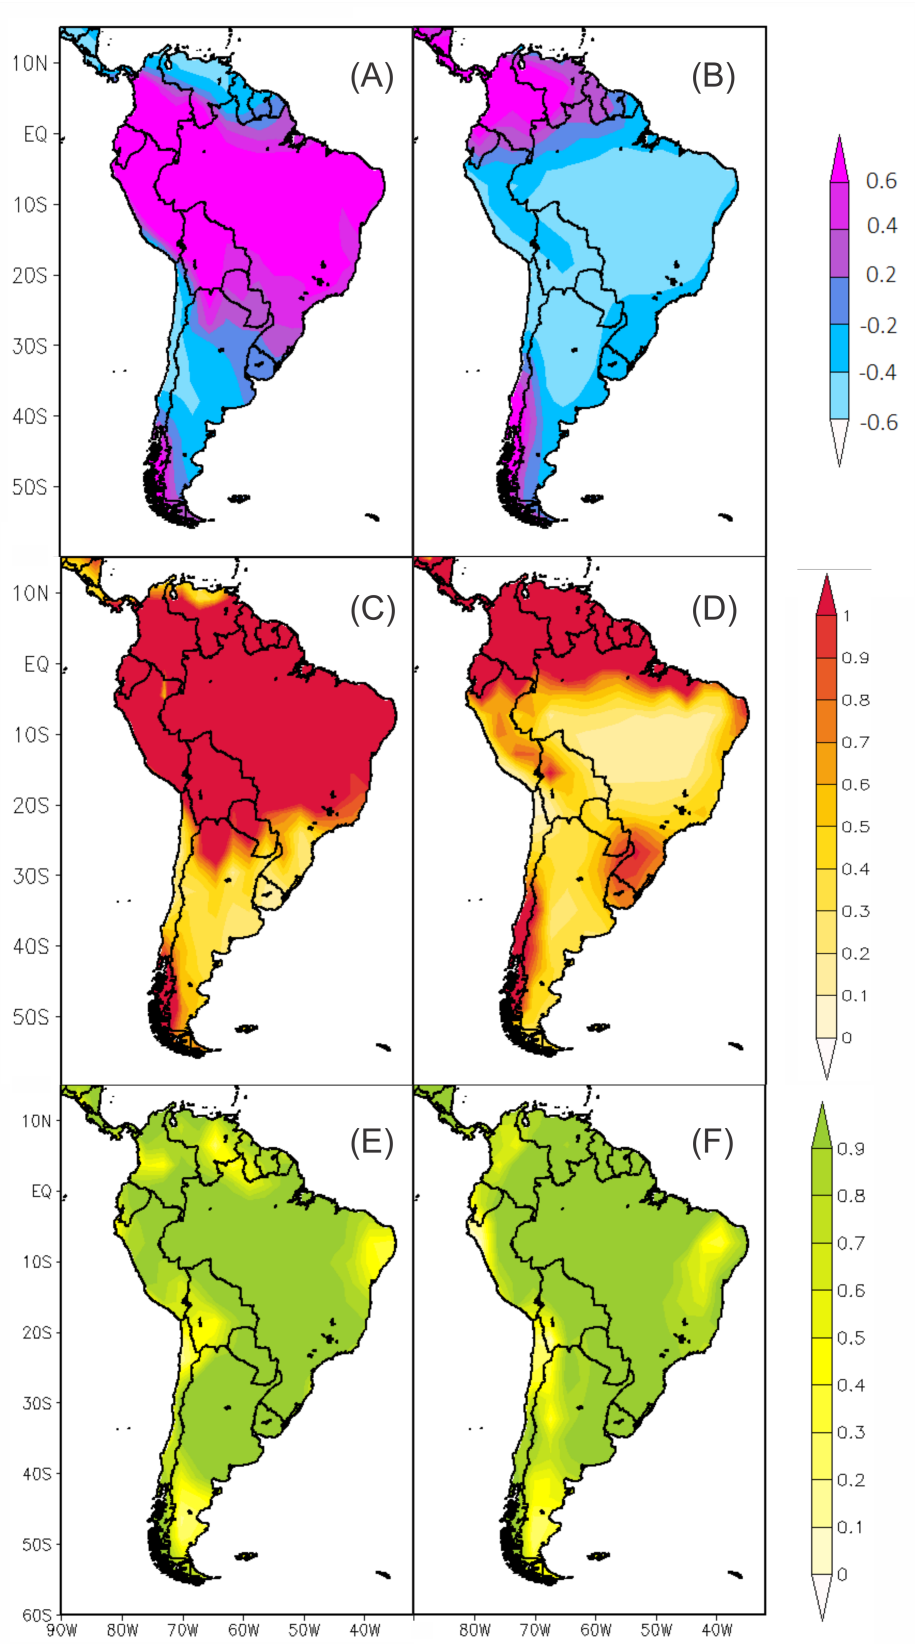

Figura 3.3: Média REA (A-B), intervalo de incerteza (C-D) e confiabilidade do conjunto de modelos (E-F) para a precipitação (mm/dia), no período de controle no verão (coluna esquerda) e inverno (coluna direita) para o período de 1971-2000.

atuais sobre Cordilheira dos Andes pode ser relacionada, entre outras coisas, a baixa resolução do modelo que não permite uma boa representação da topografia complexa desta região.

3.6 Conclusões

O objetivo do método REA é minimizar a contribuição de simulações que tem uma desempenho mais pobre na representação do clima. Portanto, pode-se extrair apenas as informações mais confiáveis de cada modelo. No decorrer deste trabalho analisou-se que para a precipitação não havia nenhum modelo foi melhor ou pior do que todos os outros, ou seja, que apresentou viés mais baixo ou mais alto em todas as regiões.

No período de controle quando se leva em conta o desempenho de cada modelo em representar o clima atual e a convergência de sua projeção para o conjunto, tal como proposto pelo método REA, nota-se que a variação REA é ligeiramente menor ao longo de todo o continente, quando comparado à média simples do conjunto. Enquanto, nas para o século XXI, a variação das projeções foram muito semelhantes. Tanto o a variação média REA, quanto a média simples do modelo, apresentou uma variação maior no período do verão austral, o que pode estar relacionado ao regime de precipitação mais variável nesta época na América do Sul. O intervalo de incerteza foi claramente maior para o período de controle do que para as projeções futuras, corroborando com as maiores variações dos modelos observadas para o mesmo período.

A confiabilidade coletiva do conjunto de modelos foi acima de 0,6 para quase toda a América do Sul em todos os cenários analisados, o que pode indicar que existe uma alta confiabilidade das simulações, sem nenhuma variação.

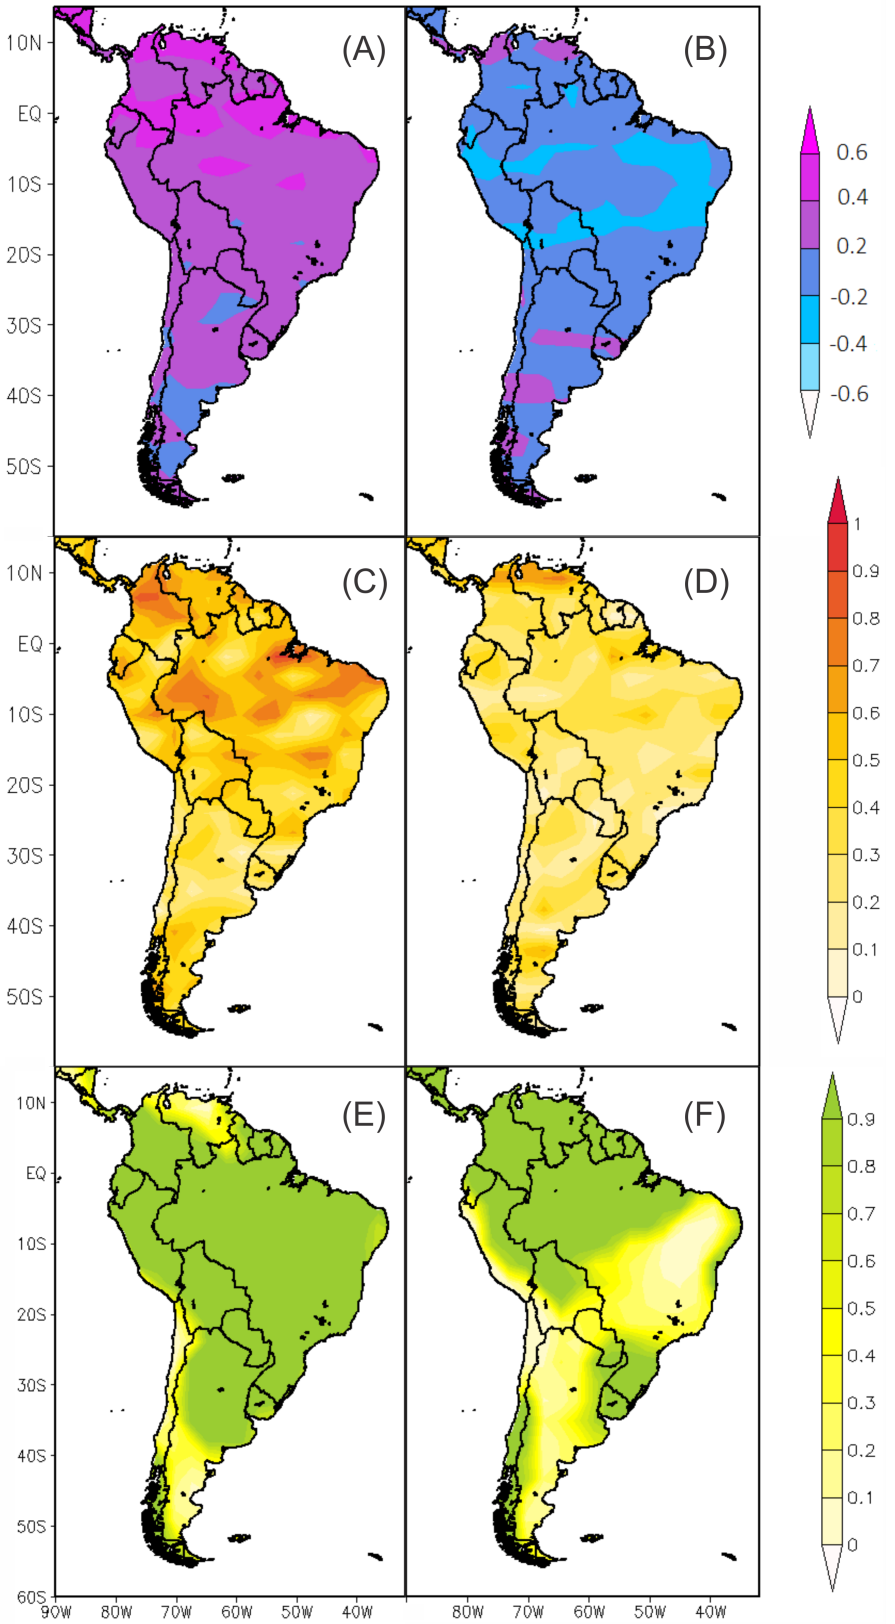

Figura 3.4: Média REA (A-B), intervalo de incerteza (C-D) e confiabilidade do conjunto de modelos (E-F) para a precipitação (mm/dia), no cenário RCP 2.6, no verão (coluna esquerda) e inverno (coluna direita) austral para o período de 2071-2100.

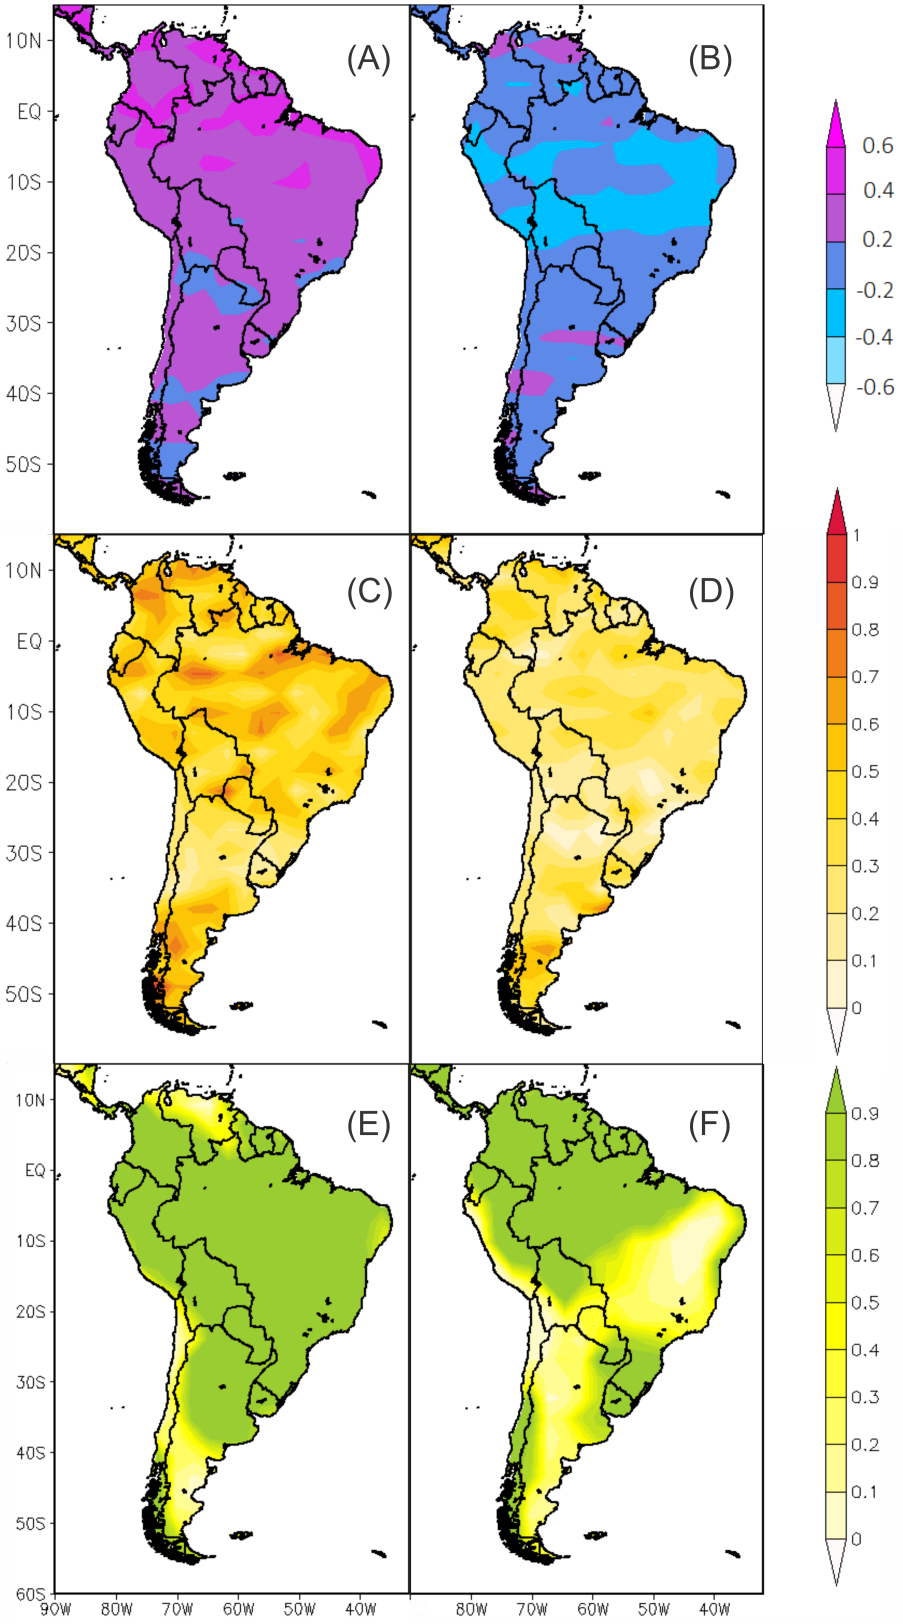

Figura 3.5: Média REA (A-B), intervalo de incerteza (C-D) e confiabilidade do conjunto de modelos (E-F) para a precipitação (mm/dia), no cenário RCP 8.5, no verão (coluna esquerda) e inverno (coluna direita) austral para o período de 2071-2100.

4 Artificial Neural Networks and Multiple Linear Regression Model using Principal Components to Estimate Rainfall over South America

Thalyta Soares dos Santos[1]

David Mendes[1]

Roger Rodrigues Torres[2]

[1] Federal University of Rio Grande do Norte, Campus Universitário Lagoa Nova, Natal, RN, 59078-970, Brazil

[2] Federal University of Itajubá, Instituto de Recursos Naturais. Av. BPS, 1303, Pinheirinho, Itajubá, MG, 37500-903, Brazil

(b) Artigo aceito para publicação como um paper de discussão na revista Nonlinear Processes in Geophysics (NPG) em 13 de julho de 2015.
ISSN: 1023–5809
Qualis A2–Geociências

4.1 Abstract

Several studies have been devoted to dynamic and statistical downscaling for analysis of both climate variability and climate change. This paper introduces an application of artificial neural networks (ANN) and multiple linear regression (MLR) by principal components to estimate rainfall in South America. This method is proposed for downscaling monthly precipitation time series over South America for three regions: the Amazon, Northeastern Brazil and the La Plata Basin, which is one of the regions of the planet that will be most affected by the climate change projected for the end of the 21st century. The downscaling models were developed and validated using CMIP5 model output and observed monthly precipitation. We used GCM experiments for the 20th century (RCP Historical; 1970-1999) and two scenarios (RCP 2.6 and 8.5; 2070-2100). The model test results indicate that the ANN significantly outperforms the MLR downscaling of monthly precipitation variability.

4.2 Introduction

The forecasting of meteorological phenomena is a complex task. The mathematical, statistical, and dynamic methods developed in recent decades help address the problem, but there is still a need to investigate new techniques to improve the results. One of these techniques is statistical downscaling, which involves the reduction of the models spatial scale. Downscaling techniques can be divided into two broad categories: dynamic and statistical. Dynamic techniques focus on numerical models with more detailed resolution, while statistical (or empirical) techniques use transfer functions between scales. Currently, numerical weather prediction (NWP) models can forecast various meteorological variables with acceptable accuracy (RAMÍREZ; FERREIRA; VELHO, 2006).

Specifically, rainfall is of great interest, both for its climatic and meteorological relevance and direct effect on agricultural output, hydropower generation and other important economic factors. However, it is one of the most difficult variables to forecast, because of its inherent spatial and temporal variability (WILSON; VALLÉE, 2002; ANTOLIK, 2000). For this reason, the temporal and spatial scales involved are not yet solved satisfactorily by the available numerical models (OLSON; JUNKER; KORTY, 1995).

Ramos (2000), studying artificial neural networks (ANN) and multiple linear regression (MLR), found that the neural networks method performed better than linear regression, although both showed good performance for monthly and seasonal rainfall. Ramírez, Velho e Ferreira (2005), using observed daily rainfall in the São Paulo region, found that ANN outperformed to MLR, which showed a high bias for days without rain. Ramírez, Ferreira e Velho (2006) analyzed daily rainfall in Southeastern Brazil and concluded that the ANN method tended to predict moderate rainfall with greater accuracy during austral summer compared to ETA model forecasts. Mendes e Marengo (2010) reported that the daily rainfall in the Amazon Basin is better represented by ANN than autocorrelation models.

In this context, the aim of this study is to conduct a statistical downscaling to estimate rainfall over South America, based on some models used in the fifth report of the IPCC (Intergovernmental Panel on Climate Change), by applying artificial neural networks and multiple linear regression using principal components.

4.3 Data and Methods

4.3.1 Data

We used monthly precipitation simulations for the austral summer (December - January - February) and winter (June - July - August) generated by ten models (Table 4.1) from the CMIP5 project (Coupled Model Intercomparison Project 5th Phase), obtained from the Earth System Grid Federation (ESGF) of the German Climate Computing Center (http://ipcc-ar5.dkrz.de) and the Program for Climate Model Diagnosis and Intercomparison (http://pcmdi3.llnl.gov). All model simulations for the 20th century were compared with the precipitation data of the CRU TS 3.0 (MITCHELL; JONES, 2005), produced by the Climatic Research Unit (CRU) - University of East Anglia (UEA). These data cover the period from 1901 to 2005 and have spatial resolution from 0.5° x 0.5°. We used climate simulations for the 20th century (historical) in the 1970-1999 period, and projections for the 21st century (Representative Concentration Pathways - RCP 2.6 and 8.5), for the period 2070-2099, as defined by (MOSS et al., 2010).

Tabela 4.1: List of models from the CMIP5 dataset used in this study.

Acronym	Model	Resolutions
ACCESS	ACCESS1.0	1.3° x 1.9°
CCSM	CCSM4	0.9° x 1.3°
CNRM	CNRM-CM5	1.4° x 1.4°
CSIRO	CSIRO-Mk3-6-0	1.9° x 1.9°
EC-EARTH	EC-EARTH	1.1° x 1.1°
HadGEM-ES	HadGEM2-ES	1.3° x 1.9°
INM	INMCM4	1.5° x 2.0°
MPI	MPI-ESM-LR	1.9° x 1.9°
MRI	MRI-CGCM3	1.1° x 1.1°
NorESM	NorESM1-M	1.9° x 2.5°

Our focus on South America is because is one of the planet's regions that will be most affected by the climate change projected for the end of the 21st century (MARENGO et al., 2010). According to Magrin et al. (2014), significant trends in precipitation and temperature have been observed in South America (SA). In addition, changes in climate variability and in extreme events have severely affected the region. The three sub-regions evaluated in South America were defined according to the precipitation regime: the Amazon (AMZ), Northeastern Brazil (NEB), and the La Plata Basin (LPB) (Figure 4.1).

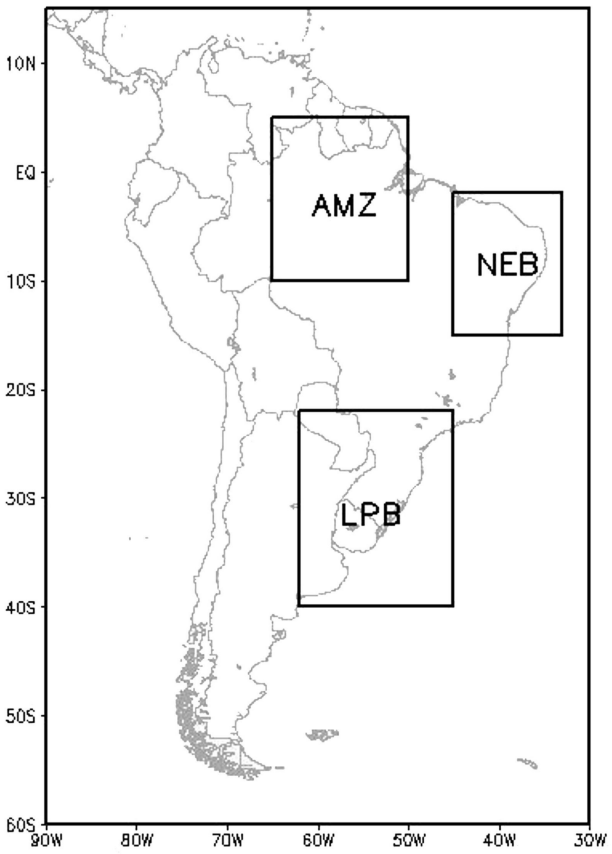

Figura 4.1: Illustration of the study areas of the defined regions.

4.3.2 Artificial Neural Networks (ANN)

An ANN is a system inspired by the operation of biological neurons with the purpose of learning a certain system. The construction of an ANN is achieved by providing a stimulus to the neuronal model, calculating the output and adjusting the weights until the desired output is achieved. An entry is submitted to the ANN along with a desired target, a defined response for the output (when this is the case, the training is regarded as supervised). An error field is built based on the difference between the desired response and the output of the system. The error information is used as feedback for the system, which adjusts its parameters in a systematic way, in other words, the backpropagation error algorythm is used to train the network. According to Alsmadi, Omar e Noah (2009) the backpropagation architecture is the most popular, effective, and easy to learn model for complex, multilayered networks. This network is used more than all others combined. This algorithm has a first phase with a functional propagation signal (feedforward) and a second phase with the backpropagation of the error (backpropagation).

In the first phase, the functional signal based on the inputs propagates through the network until generating an output, with the weights of synapses remaining fixed. In the

second phase, the output is compared with a target, producing an error signal. The error signal propagates from the output to the input and the weights are adjusted in such a way as to minimize the error. The process is repeated until the performance is acceptable. As such, the performance of the ANN is strongly dependent on the data source.

A first part of the data is used for training, the second is used for cross–validation, and the third part is used for testing. The architecture of the ANN used in the present study can be found in Figure 4.2. It consists of an input, a hidden layer and an output layer. The number of intermediate units was obtained through trial and error. During the training, the performance of the ANN is also assessed within the validation set.

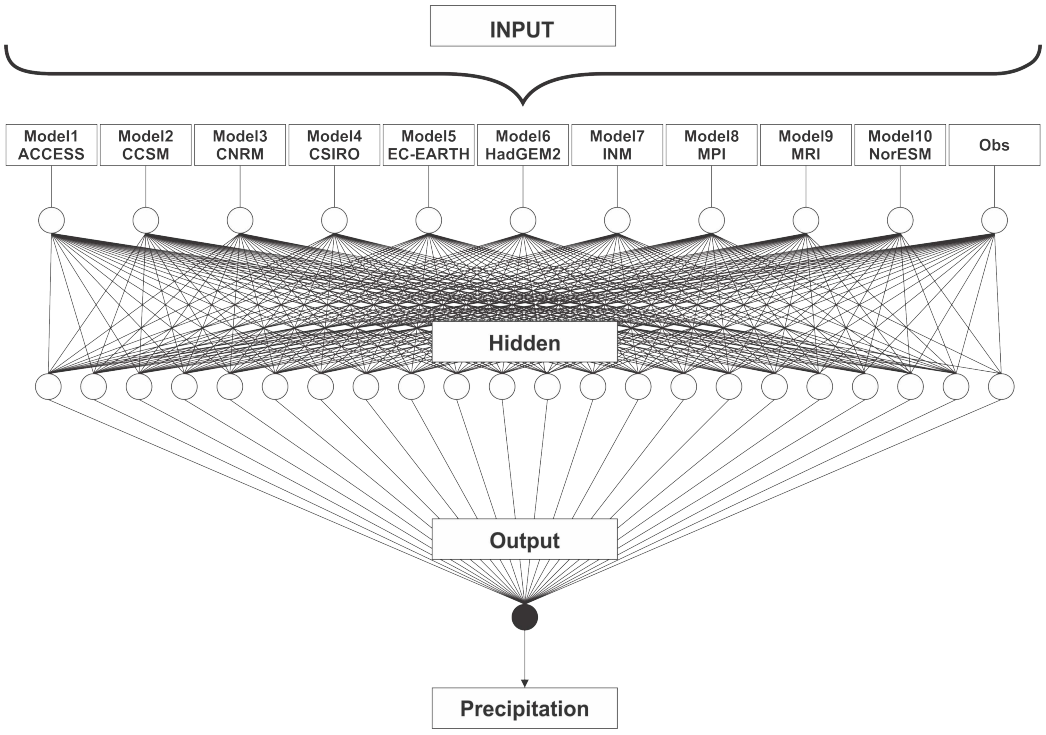

Figura 4.2: Structure of the artificial neural network.

4.3.3 Multiple Linear Regression using Principal Components

Multiple linear regression (MLR) is a statistical technique that consists of finding a linear relationship between a dependent (observed) variable (and more than one independent variable (outputs of the GCM). A multiple regression model can be represented by the following equation:

$$Y_i = a + b_1 X_1 + b_2 X_2 + \cdots + b_m X_m + C, \tag{4.1}$$

Where Y_i is the dependent variable, X_1, X_2, $\cdots$, X_m the independent variables, is the intercept, b_1,b_2 and b_m are the multiple regression coefficients, to be estimated by the

least squares method Wilks (1995), and C is the error term.

In spite of their obvious success in many applications, MLRs present multicollinearity when employed with climatic variables. In this regard, the parameter estimation errors can be incorrectly interpreted (LEAHY, 2000). To resolve this problem, we used principal components (PC). This method seeks to reduce the number of variables through orthogonal transformations and to remove the multicollinearity of the independent variables. The PC of the explanatory variables are therefore a new set of variables with the same information as the original variables, but uncorrelated.

4.4 Results and Discussion

4.4.1 Validation of the ANN

After using the precipitation simulations for the period 1970–1999 with the ANN, we obtained a final error after a number of interactions, which ranged from 1 to 600 (Figure 4.2). One of the difficulties of using ANN consists on identifying the best stopping point for training Haykin (2001), because the training error starts out with a maximum value, decreases rapidly and then levels off, indicating there is no more error to correct. In the summer, the network became stable more rapidly, indicating that the GCM employed converge to the same pattern of precipitation.

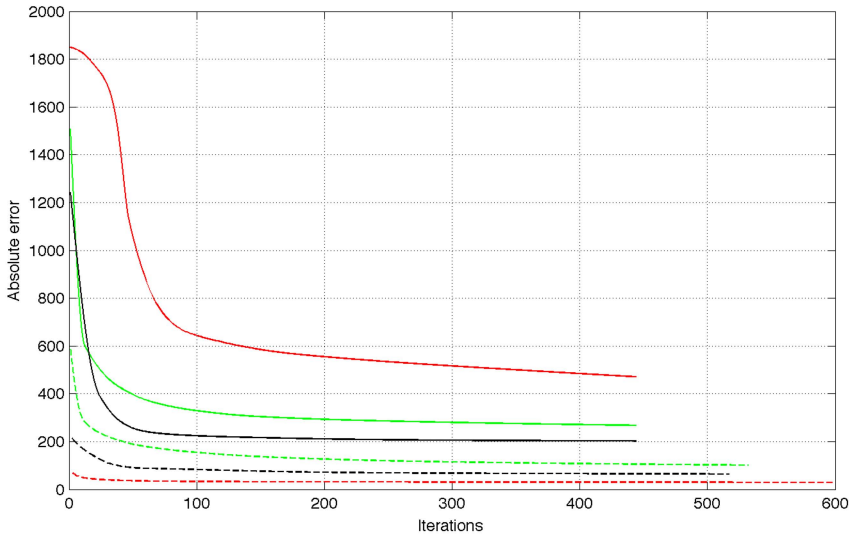

Figura 4.3: Absolute error as a function of the number of iterations, AMZ (green), NEB (red) and LPB (black). Continuous lines represent the summer period for each region and the dashed lines represent winter.

With respect to winter, the networks remained unstable for a longer time before

finding the minimum error. The NEB region should be highlighted, which required the largest number of iterations, around 600. This is possibly related to the greater variability of rainfall in this season (Figure 4.3).

According to Villanueva (2011), it is assumed that the three sets (training, validation and testing) contain independent samples, and that they are well capable of representing the problem being addressed. One should therefore expect that good performance on the validation set will imply good performance of the testing set. In this study, the validation values were closest to the test values in summer.

4.4.2 Validation of the MLR by PC

To validate the MLR, the following assumptions need to be met: i) the residuals must have random distribution around mean zero (homoscedasticity); ii) the residuals should have a normal distribution; and iii) variance must be homogeneous (SILVA et al., 2014).

Figures 4.4 and 4.5 show that the residuals versus adjusted values meet the assumption of homoscedasticity. With respect to the QQ-plot, the quantiles of the residuals versus the normal distribution indicate that all regions present normality in the residuals. Given that the closer the residuals are to the line, the closer they are to having normal distribution. The employed data therefore fit the MLR by the PC model. Based on the PC analysis (Table 4.2), one can see that in summer for the AMZ region, the accumulated proportion explains around 77% in NEB and 80% in PC6, while in winter, the PC1 of the AMZ explained 71% and PC3 explained 72% in NEB, thus representing the greatest variability of precipitation in these regions. In general, one can observe that a smaller number of climate models were required in winter to capture the variance of precipitation in these regions. Similar behavior of PC in both seasons stands out in the LPB region, which may be due to the failure of GCM to capture the variance of precipitation in this region.

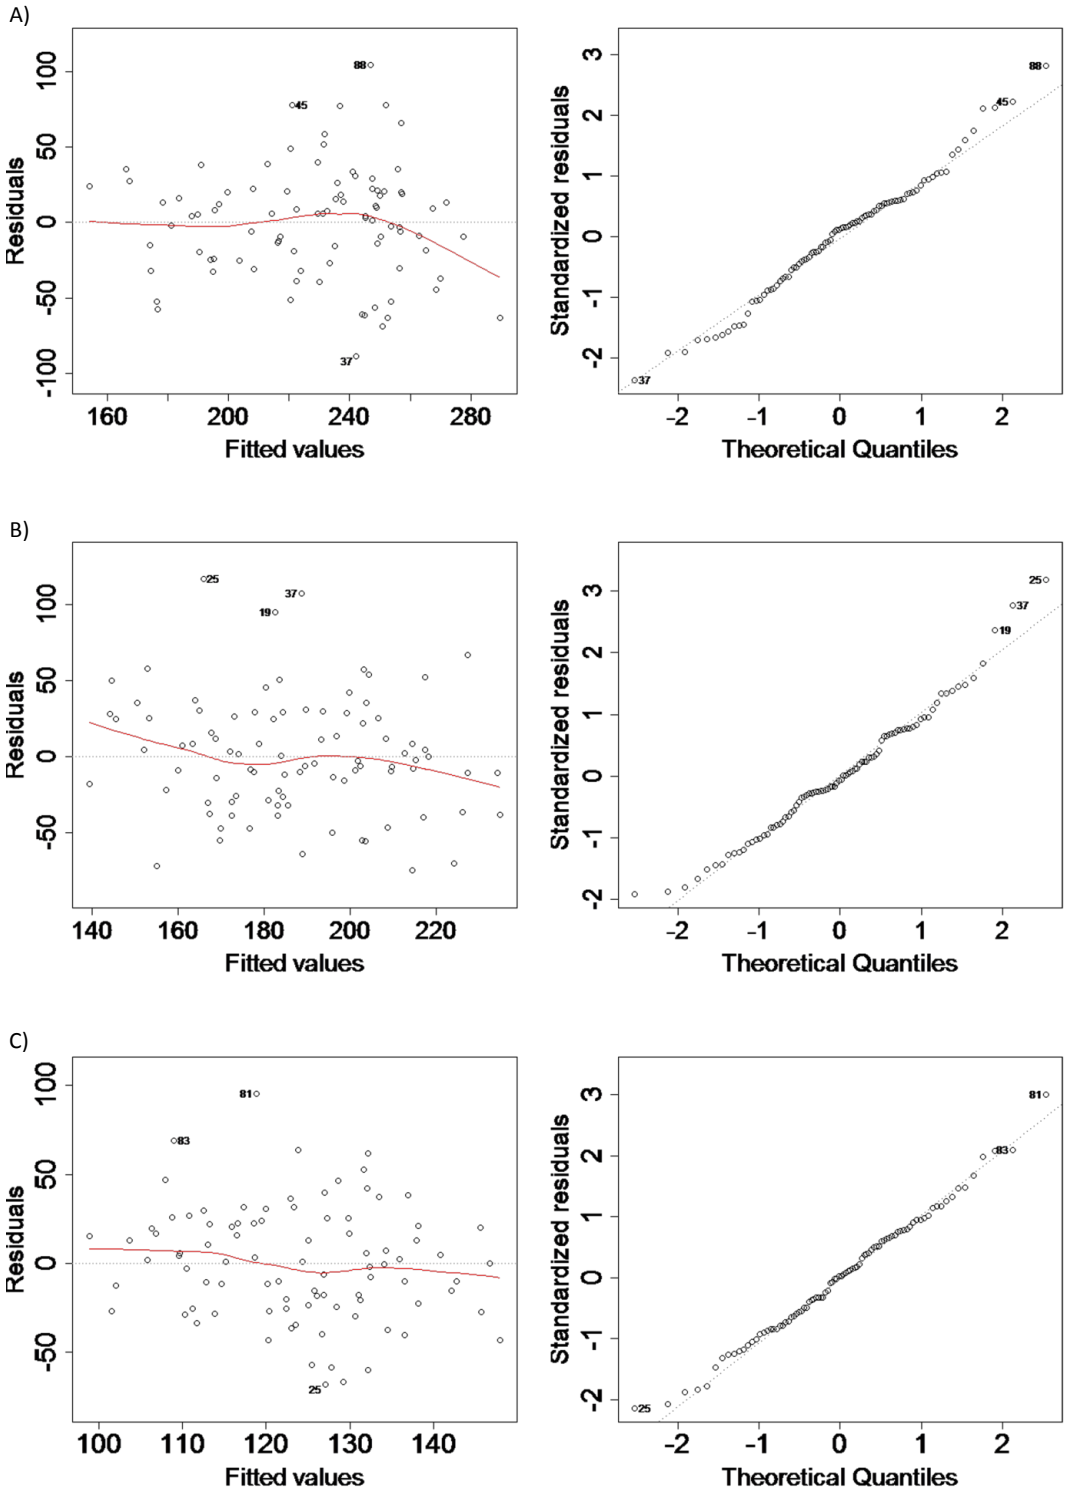

Figura 4.4: Residuals x Fitted Values and Theoretical Quantiles, for the summer. (a) AMZ, (b) NEB, and (c) LPB.

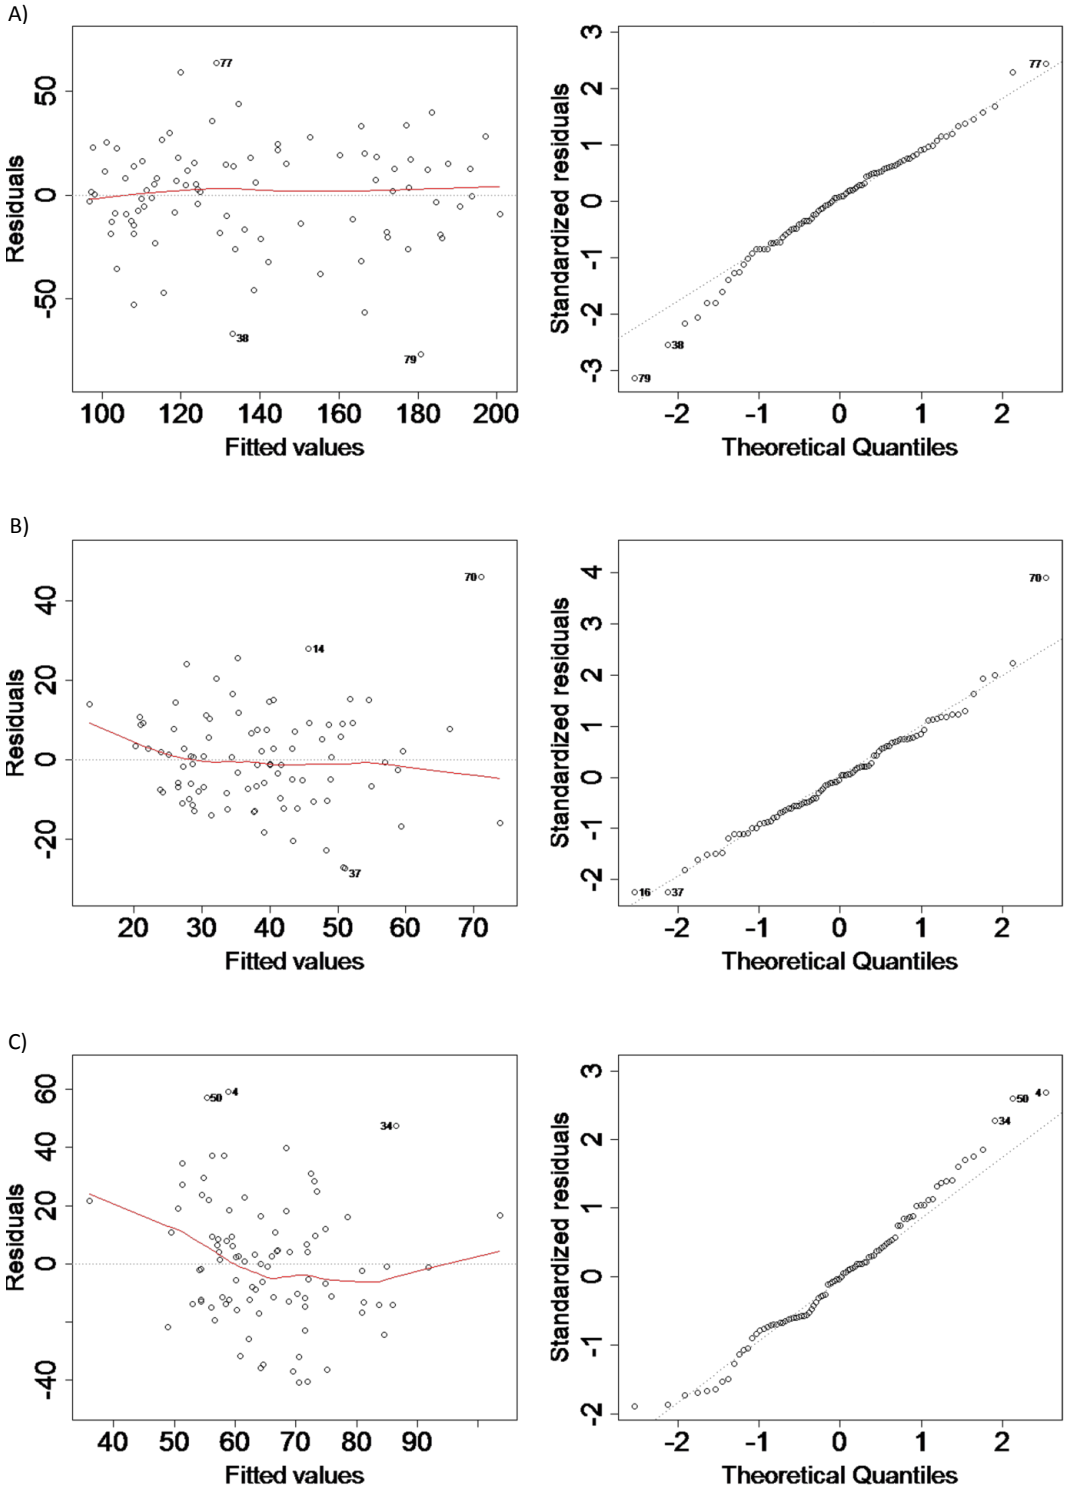

Figura 4.5: Residuals x Fitted Values and Theoretical Quantiles, for the winter. (a) AMZ, (b) NEB, and (c) LPB.

Tabela 4.2: Proportion and cumulative proportion of variance for the indicated regions. Left column for summer and right column for winter.

	SUMMER										WINTER									
	AMZ										AMZ									
	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10
Proportion of variance	0.24	0.12	0.13	0.11	0.09	0.08	0.11	0.06	0.06	0.04	0.71	0.07	0.05	0.04	0.03	0.03	0.02	0.02	0.02	0.01
Cumulative proportion	0.24	0.36	0.49	0.60	0.69	0.77	0.84	0.90	0.96	1.00	0.71	0.78	0.83	0.87	0.90	0.93	0.95	0.97	0.99	1.00
	NEB										NEB									
	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10
Proportion of variance	0.32	0.13	0.10	0.09	0.08	0.08	0.06	0.07	0.04	0.03	0.54	0.10	0.08	0.07	0.06	0.04	0.04	0.03	0.02	0.02
Cumulative proportion	0.32	0.45	0.55	0.64	0.72	0.80	0.86	0.93	0.97	1.00	0.54	0.64	0.72	0.79	0.85	0.89	0.93	0.96	0.98	1.00
	LPB										LPB									
	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10
Proportion of variance	0.16	0.15	0.14	0.10	0.11	0.09	0.07	0.06	0.06	0.06	0.16	0.15	0.12	0.11	0.10	0.09	0.08	0.07	0.06	0.06
Cumulative proportion	0.16	0.31	0.45	0.55	0.66	0.75	0.82	0.88	0.94	1.00	0.16	0.31	0.43	0.54	0.64	0.73	0.81	0.88	0.94	1.00

Tables 4.3 and 4.4 show the Pearson's correlation coefficients at significance level of 5% between the ANN and the observed data, and between the MLR by PC and observed data, respectively. One can see that in both downscaling methods used, the highest correlations occur in winter in all regions under study, indicating that the models are better able to represent the variability of precipitation during this season.

Tabela 4.3: p-value and Pearson's correlation coefficient at the level of significance of 5% between the ANN and observed data from the CRU in all regions under study.

	p-value			Correlation coefficient		
	AMZ	NEB	LPB	AMZ	NEB	LPB
Summer	<0.001	0.08	0.01*	0.61	0.38	0.18
Winter	<0.001	<0.001	<0.001	0.77	0.69	0.49

∗Significance 5%.

Tabela 4.4: p-value and Pearson's correlation coefficient at the level of significance of 5% between the MLR by PCs and observed data from the CRU in all regions under study.

	p-value			Correlation coefficient		
	AMZ	NEB	LPB	AMZ	NEB	LPB
Summer	<0.001	<0.001	0.06	0.52	0.27	0.20
Winter	<0.001	<0.001	0.00*	0.62	0.60	0.33

∗Significance 5%.

Ramírez, Ferreira e Velho (2006) performed statistical downscaling for the precipitation forecast for the Southeast of Brazil, using ANN and MLR with the ETA model. The results suggested that the precipitation forecasts using ANN performed better in winter than in summer, since the synoptic forcing is more pronounced and the deep convective activity is less common. One can also observe that in the regions NEB (ANN x Obs) and LPB (MLR x Obs), the correlations of 38 and 20%, respectively, were not statistically significant. The lowest correlation occurred in the LPB region. Seth, Rojas e Rauscher (2010) stated that the mean of the set of models reveals weaker moisture transport east of the Andes, which may be one of the factors that induce underestimation of precipitation in this region.

4.4.3 Downscaling scenarios

Table 4.5 presents the results of the monthly precipitation simulation for the end of this century (2071-2100) based on the ten GCM described previously in the RCP

scenarios 8.5 and 2.6, in relation to the reference period 1971-1999 (observation) for the two downscaling methods.

In both scenarios, and employing both ANN and MLR, an increase of precipitation in the summer and a decrease in the winter can be observed. These results corroborate the findings of Mendes e Marengo (2010), who used ANN and autocorrelation to study changes in monthly precipitation for the Amazon Basin in scenarios A2, A1B and B1, derived from five models of the CMIP3, used in the IPCC AR4. The authors found an increase in precipitation in the summer months and a reduction in winter.

In the NEB region (Table 4.5), an increase of precipitation in summer of around 30% was observed. With respect to winter, one can see a reduction of 40% in the higher forcing scenario (RCP 8.5), and of 10% (RCP2.6) in the lower climate forcing. The IPCC revealed CMIP5 precipitation projections for end of century (2081–2100) of increase precipitation from October to March over the southern part of Southeast Brazil and the La Plata Basin. From April to September, the CMIP5 ensemble projects precipitation increases over the La Plata Basin and northwestern SA near the coast (STOCKER et al., 2013). According to Magrin et al. (2014) seasonal scales, rainfall reductions during winter and spring in southern Amazonia may indicate a late onset of the rainy season in those regions and a longer dry season. The changes are more intense for the late 21-st century and for the RCP8.5 when compared to scenario RCP 2.6, as can be seen in Table 4.5.

Tabela 4.5: Change in monthly precipitation in terms of an increase or decrease by the end of this century (2071-2100) in the scenarios RCP 8.5 and 2.6, in relation to the reference period 1971-1999 (observation), in mm.month^{-1} and percentage.

		RCP 8.5		RCP 2.6	
		ANN(mm/%)	MLR (mm/%)	ANN(mm/%)	MLR (mm/%)
AMZ	Summer	20.0 / 14.1	23.1 /16.5	18.8 / 13.3	22.4 / 15.8
	Winter	-9.3 / -12.2	-9.9 / -13.9	-0.5 / -0.7	-3.1 / -4.9
NEB	Summer	55.2 / 36.2	47.1 / 30.9	48.0 / 33.1	40.0 / 27.5
	Winter	-6.6 / -42.7	-6.9 / -44.5	-1.81 / -9.41	-2.06 / -10.7
LPB	Summer	7.26 / 5.63	5.7 / 4.42	5.56 / 4.4	4.01 / 3.15
	Winter	-2.79 / -4.17	-3.67 / -5.48	-3.09 / -4.63	-3.09 / -4.56

4.5 Conclusions

This paper investigated the applicability of artificial neural networks and multiple linear regression analysis by principal components, as temporal downscaling methods for the generation of monthly precipitation over South America (for current years and future scenarios). Both the ANN and MLR methods provided good fit with the observed data. This indicates that ANN are a viable alternative for the modeling of precipitation in time series. ANN can be compared with the statistical model, and this indicates that the networks are a potentially competitive tool.

The future scenarios used (RCP 2.6, lower climate forcing, and RCP 8.5, higher climate forcing) indicate an increase in precipitation in summer and a reduction in precipitation during winter according to both the methods used.

In general, the results showed that the use of ANN produced more accurate results than MLR by PC, which can be attributed to the fact that ANN perform tasks that a linear program is unable to do. In addition, one of the advantages of ANN is their capacity for temporal processing, and thus their ability to incorporate not only concurrent, but also several predictive values, as inputs without any additional effort.

5 Incertezas em Projeções de Mudanças Climáticas na América do Sul Aferidas por Redes Neurais Artificiais

Thalyta Soares dos Santos[1]

David Mendes[1]

Roger Rodrigues Torres[2]

[1] Universidade Federal do Rio Grande do Norte, Campus Universitário Lagoa Nova, Natal, RN, 59078-970, Brasil

[2] Universidade Federal de Itajubá, Instituto de Recursos Naturais. Av. BPS, 1303, Pinheirinho, Itajubá, MG, 37500-903, Brasil

Artigo em tradução para a revista Hydrology and Earth System Sciences (HESS)
ISSN: 1027–5606
Qualis A2–Geociências

5.1 Resumo

Embora o enorme avanço científico e computacional das últimas décadas tenha possibilitado um maior entendimento do sistema climático e contribuído para as análises das possíveis causas e futuros impactos das mudanças climáticas globais, as incertezas que permeiam as projeções de clima ainda continuam muito grandes, principalmente em escala regional. Este trabalho realiza uma avaliação das incertezas nas projeções de precipitação e temperatura em três regiões da América do Sul nos cenários (RCP 2.6 e 8.5) usando dez modelos de circulação geral da atmosfera pertencentes ao *Coupled Model Intercomparison Project 5th Phase* (CMIP5) utilizando o método *Reliability Ensemble Averaging* (REA). Além disso, analisa a influência da utilização das Redes Neurais Artificiais (RNA) nos modelos estudados. Os resultados indicaram que 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 de modelos, como proposto pelo método REA, em geral, a média das projeções de mudança de temperatura decresce ligeiramente sobre todas as regiões, comparado à média aritmética simples dos MCGs. Além disso, em todas as análises constatou–se que os intervalos de incertezas das projeções climáticas diminuíram quando aferidas com RNA, indicando uma maior confiabilidade nas projeções.

5.2 Abstract

Although the large scientific and computational advances of the last decades have allowed for a deeper understanding of the climate system and has contributed to the analyses of the possible causes and future impacts of global climate change the uncertainties that permeate the climate projections are still very large, specially in regional scales. This study makes an evaluation of the uncertainties in the temperature and precipitation projections for three regions in South America under the scenarios RCP 2.6 and 8.5 using ten different atmospheric general circulation models in the Coupled Model Intercomparison Project 5th Phase (CMIP5), using the Reliability Ensemble Averaging (REA). It also analyses the influence of using Artificial Neural Networks (ANN) for the models studied. Results indicate that taking into consideration the skill of every GCM in representing the observed climate as well as the convergence of its projection relative to the average of the model ensembles (as proposed by REA), in general leads to a slight decrease in all regions studied when compared to the simple arithmetic mean of the GCM. Also, in all of the analyses it was seen that the uncertainty intervals of the climate projections decreased when assessed with ANN, indicating higher reliability in the projections.

5.3 Introdução

As informações transmitidas, não somente para a população, mas principalmente aos tomadores de decisão, nem sempre tem conseguido discernir as certezas e incertezas com relação às variações do clima presente e, principalmente das projeções climáticas futuras. As ferramentas comumente adotadas para obter e avaliar as projeções climáticas passadas e futuras são os modelos de circulação geral (MCGs). Os modelos climáticos são baseados em princípios físicos bem estabelecidos e são utilizados para tentar reproduzir as observações características do clima presente e alterações do clima passado e futuro. Entretanto, enquanto as incertezas associadas ao clima atual podem ser testadas com os dados observados (HIJMANS; GRAHAM, 2006), as associadas às projeções de mudanças climáticas só podem ser estimadas por métodos indiretos. Vários estudos têm demonstrado que as projeções de modelos climáticos podem divergir, mesmo considerando um conjunto de modelos com elevada acurácia (ARAÚJO et al., 2005; ARAÚJO; NEW, 2007; ALGAR et al., 2009).

New e Hulme (2000) apresentaram uma abordagem para quantificar as incertezas associadas com às mudanças climáticas de maneira probabilística. Um modelo que utiliza simulação Baysiana de Monte Carlo foi desenvolvido para lidar com as incertezas relacionadas com os cenários de emissões de gases do efeito de estufa e com as limitações e imprevisibilidade dos MCGs. Räisänen e Palmer (2001) também utilizaram uma abordagem probabilística para modelar as incertezas inerentes ao clima e sua variabilidade, e ainda expressar as projeções de mudanças climáticas de forma probabilística. Naquele estudo, 17 MCGs (com o mesmo comportamento de aumento do CO_2) foram utilizados como uma projeção probabilística do conjunto de modelos da projeção do clima futuro.

Giorgi e Mearns (2002) propuseram a aplicação de um método baseado na média ponderada de diferentes MCGs, levando 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 observado (viés) e o grau de convergência de sua projeção para o futuro 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. O método foi aplicado para 9 diferentes MCGs em dois diferentes cenários de emissão do IPCC (A2 e B2), e para 22 regiões ao redor do mundo. Os pesos foram atribuídos aos MCGs com base no desempenho do modelo e na convergência. A avaliação foi feita com base na simulação média global obtida para 10 regiões de escala subcontinental. Projeções em escala local e variabilidade temporal das variáveis climáticas não foram consideradas naquele estudo. Os autores sugeriram que em comparação com abordagens mais simples, o método REA permite uma redução da incerteza nas mudan-

ças simuladas por minimizar a influência dos *"outlier"* ou de modelos com desempenho insatisfatório. O método também produz uma medida quantitativa da confiabilidade que mostra que ambos os critérios devem ser cumpridos pelas simulações, a fim de aumentar a confiabilidade das mudanças simuladas. O método REA é considerado uma ferramenta flexível que pode ser aplicado em escala global e regional, e tem sido aplicado em vários estudos, como: (GIORGI; MEARNS, 2003; MOISE; HUDSON, 2008; XU; GAO; GIORGI, 2010; KIM; LEE, 2010; TAO et al., 2012; RAWLINS; BRADLEY; DIAZ, 2012; TORRES; MARENGO, 2013; SENGUPTA; RAJEEVAN, 2013).

Tebaldi et al. (2005) elaboraram uma versão estendida do método REA e quantificaram as incertezas nas projeções de mudanças climáticas utilizando uma abordagem bayesiana, em 22 regiões no cenário de emissão A2, para inverno e verão boreal, a partir de 9 MCGs. A principal característica do método foi a utilização dos dois critérios (viés e convergência) que o método REA introduz como uma forma de avaliar a confiabilidade dos modelos, juntamente com um modelo de estatística robusta que pode otimizar o método proposto por Giorgi e Mearns (2002).

Outra técnica para lidar com as diferentes projeções climáticas dos modelos numéricos é a utilização de aproximações probabilísticas, na qual os resultados de diferentes modelos ou integrações de um mesmo modelo são utilizados para a produção de uma Função de Densidade Probabilística (FDP) (GIORGI, 2005; COLLINS, 2007). A largura ou espalhamento da FDP representa uma medida da incerteza na projeção e a integral entre dois limiares estabelecidos indicam a probabilidade de sua ocorrência.

Além dos estudos expostos acima, a utilização de técnicas de regionalização para traduzir as informações fornecidas por modelos climáticos numa escala espacial mais refinada é uma maneira comumente utilizada para diminuir as incertezas projetadas pelos modelos. Entre essas técnicas pode-se citar o uso de Funções Ortogonais Empíricas, redes neurais artificiais (RNA) e as técnicas de *downscaling*, que possuem duas abordagens principais, a dinâmica e a empírica (estatística). O *downscaling* dinâmico é um método de extração de informações de escala local, desenvolvendo modelos de clima regional (MCR) com resolução de GCM, utilizando dados de GCMs como condições de fronteira. Por outro lado, o *downscaling* empírico, começa com a premissa de que o clima regional é o resultado da interação da circulação geral atmosférica e dos oceanos, bem como da topografia regional (MENDES; MARENGO, 2010).

Boulanger, Martinez e Segura (2007) avaliaram a evolução dos padrões de temperatura utilizando redes neurais artificiais, cujos parâmetros foram otimizados por Estatística Bayesiana. Eles concluíram que a abordagem da rede neural, quando aplicada à temperatura, usando uma estatística Bayesiana para otimização, torna possível calcular o peso ideal para uma combinação linear dos modelos do AR4 (IPCC Fourth Assessment Report,

quarto relatório do IPCC).

Na América do Sul, Blázquez, Kusunoki et al. (2012) estudaram as projeções climáticas e incertezas sobre a América do Sul usando simulações do modelo MRI/JMA (Japanese Meteorological Agency) com resoluções de 20 e 60 km. A análise de incertezas de projeções climáticas revelou que as projeções de temperatura são mais confiáveis do que as projeções de precipitação.

Torres e Marengo (2013) avaliaram as incertezas envolvidas nas projeções de mudanças sazonais da temperatura e precipitação ao longo da América do Sul no século XXI, utilizando simulações climáticas geradas por 24 MCGs do CMIP3 pelo método REA. Os autores encontraram uma maior confiabilidade nas projeções de temperatura na região da Bacia do Prata e uma maior incerteza na Amazônia. Para a precipitação, as alterações projetadas tiveram a mesma magnitude que o intervalo de incerteza associado, sendo comparáveis a variabilidade natural.

Blázquez e Nuñez (2013) avaliaram duas fontes de incertezas nos modelos de projeções de temperatura e precipitação: variabilidade interna e variabilidade inter–modelos. Oito modelos do CMIP3 e CMIP5, nos cenários SRES A1B e RCP 4.5, respectivamente, foram comparados afim de identificar melhorias na confiabilidade das projeções nos modelos da nova geração sobre a América do Sul. Os autores identificaram algumas melhorias no novo conjunto de modelos (CMIP5) 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 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 tenha sido menor sobre o norte e leste do Brasil na estação de verão.

Dessa forma, com base na complexidade dos problemas acima sobre as projeções dos modelos climáticos para a América do Sul, este trabalho realiza uma avaliação das incertezas nas projeções de mudanças climáticas para esta região em um cenário forçante e dez modelos do CMIP5, usando o método REA (devido aos vários tipos de informações geradas). Além disso, será analisada a influência da aplicação das Redes Neurais Artificiais nos resultados dos modelos avaliados.

5.4 Material e Métodos

Utilizaram-se simulações mensais de precipitação e temperatura do ar próximo a superfície gerados por dez modelos (Tabela 5.1) do projeto CMIP5 (*Coupled Model Inter-*

comparison Project 5th Phase), obtidos a partir do *Program for Climate Model Diagnosis and Intercomparison* (http://pcmdi3.llnl.gov). Simulações climáticas para o século XX (historical) e projeções para o século XXI para dois diferentes forçantes intitulados *Representative Concentration Pathways* (RCP2.6 e 8.5), usados nas médias sazonais para os períodos 1961-1990 (tempo presente) e 2071-2100 (tempo futuro). Os *Representative Concentration Pathways* são definidos por Moss et al. (2010).

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; FRANCISCO, 2000; KNUTTI, 2008; TORRES, 2014). A resolução espacial dos MCGs varia de cerca de 1°a 3°lat/lon, e para fins de intercomparação, as rodadas dos modelos e os dados observados são interpolados em uma grade comum de 2.5°$\times$ 2.5°.

Todas as simulações do modelo para o século 20 foram comparados com os dados de precipitação do CRU TS 3.0 (HARRIS et al., 2014), produzido pelo Climatic Research Unit (CRU) - University of East Anglia (UEA). Estes dados abrangem o período 1901 a 2005 e têm resolução espacial de 0.5°$\times$ 0.5°. O foco deste trabalho é na América do Sul, porque é uma das regiões do planeta onde as previsões apontam que mais serão afetadas pela mudança climática projetada para o final do século 21 (MARENGO et al., 2010). De acordo com Magrin et al. (2014), tendências significativas na precipitação e temperatura foram observadas na América do Sul. Além disso, as mudanças na variabilidade climática e eventos extremos tem afetado a região severamente. As três sub-regiões avaliadas na América do Sul foram definidas de acordo com o regime de precipitação: Amazônia (AMZ), Nordeste do Brasil (NEB) e da Bacia do Prata (LPB) (Figura 5.1).

Tabela 5.1: Modelos do CMIP5 utilizados neste estudo com a descrição das resoluções horizontais aproximadas

Modelo	**Instituição**	**Resolução**	**Referência**
ACCESS1.0	Commonwealth Scientific and Industrial Research Organization/Bureau of Meteorology	1.3 º x 1.9 º	Bi et al. (2013)
BCC–CSM1–1	Beijing Climate Center	2.8 º x 2.8 º	Xiao-Ge, Tong-Wen e Jie (2013)
CCSM4	National Center for Atmospheric Research	1.25º x,0.94º	Craig, Vertenstein e Jacob (2012)
CNRM–CM5	Centre National de Recherches Meteorologiques / Centre Europeen de Recherche et Formation Avancees en Calcul Scientifique (CNRM/CERFACS)	1.4 º x 1.4 º	Voldoire et al. (2013)
CSIRO–Mk3.6.0	Commonwealth,Scientific and Industrial Research Organisation in collaboration with the Queensland Climate Change Centre of Excellence	1.875º x1.875º	Collier et al. (2011)
HadGEM2–ES	Met Office Hadley Centre	1.875º x 1.25º	Collins et al. (2011)
INMCM4	Institute for Numerical Mathematics	1.5º x 2.0º	Volodin, Dianskii e Gusev (2010)
MPI–ESM–LR	Max Planck Institute for Meteorology	1.8º x 1.8º	Giorgetta et al. (2013)
MRI–CGCM3	Meteorological Research Institute	1.1º x 1.1 º	Yukimoto et al. (2012)
NorESM1–M	Norwegian Climate Centre (NCC)	1.9º x 2.5º	Bentsen et al. (2013)

5.4.1 Reability Ensemble Averaging

No método REA desenvolvido por Giorgi e Mearns (2002), a variação esperada ($\Delta\xi$) em uma variável climática (ξ) é dada por uma combinação das mudanças projetadas por cada membro do conjunto ($\Delta\xi_i$) e é definido por:

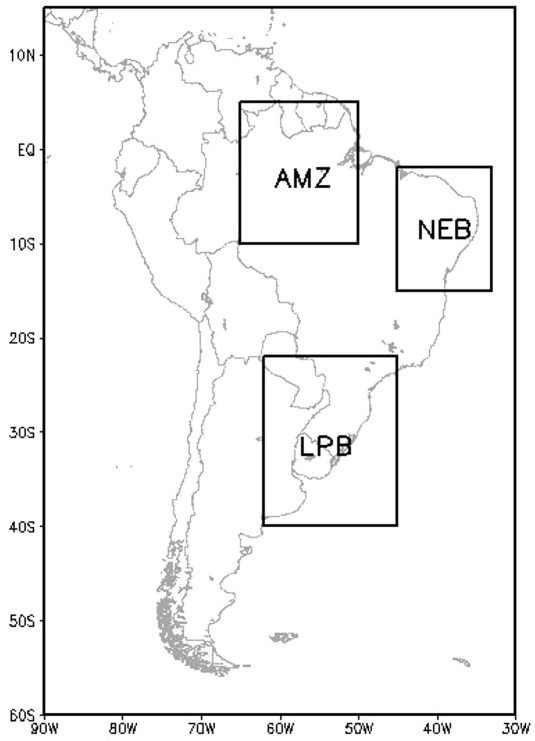

Figura 5.1: Domínio de estudo. Os retângulos indicam as sub-regiões utilizadas nas análises: Amazônia (AMZ), Nordeste do Brasil (NEB), e Bacia do Prata (LPB).

$$\widetilde{\Delta}\xi = \frac{\sum_i R_i \Delta\xi_i}{\sum_i R_i} \tag{5.1}$$

No qual R_i é o fator de confiabilidade do modelo definido como:

$$R_i = [(R_{B,i})^m \times (R_{D,i})^n]^{[1/(m\times n)]} = \left\{ \left[\frac{\varepsilon_\xi}{abs(B_{\xi,i})} \right]^m \times \left[\frac{\varepsilon_\xi}{abs(D_{\xi,i})} \right]^m \right\}^{[1/(m\times n)]} \tag{5.2}$$

Na equação 5.2, $R_{B,i}$ é um fator que mede a confiabilidade do modelo como uma função do viés do modelo ($B_{\xi,i}$) em simular a variável, isto é, quanto maior for o viés menor a confiabilidade do modelo. O viés é definido como a diferença entre os dados simulados e observados. $R_{D,i}$ é um fator que mede a confiabilidade do modelo em termos da distância ($D_{\xi,i}$) da mudança calculada por um modelo determinado a partir da média REA, isto é, quanto maior a distância menor a confiabilidade do modelo. Portanto, a distância é uma medida do grau de convergência de um determinado modelo com outros. Em outras palavras, $R_{B,i}$ é uma medida do critério de desempenho do modelo enquanto $R_{D,i}$ é uma medida do critério de convergência do modelo. Os parâmetros m e n podem ser utilizados para balancear cada critério. Para os cálculos neste trabalho, m e n são

assumidos como sendo igual a 1, o que dá igual peso a ambos os critérios. Quanto maior o viés e a distância à média REA, menor a confiabilidade da projeção.

Torres e Marengo (2013)afirmam que os critérios de convergência do método REA baseiam-se na hipótese de que, para determinado cenário de emissão, se os sinais de mudanças climáticas produzidos por diferentes modelos não são muito sensíveis às diferenças entre os modelos, esses sinais são ditos mais confiáveis e a média do conjunto dos modelos pode convergir para as condições do clima futuro.

Como proposto por Giorgi e Mearns (2002), o parâmetro ε_ξ é a medida da variabilidade natural da variável utilizada. A variabilidade natural é estimada para cada ponto de grade tomando–se a diferença entre o maior e o menor valor da série temporal observada (1901-2000), após remover a tendência linear dos dados e aplicar um filtro média-móvel para eliminar flutuações com período menor do que 30 anos.

Com os parâmetros descritos anteriormente, um intervalo de incerteza ($\widetilde{\delta}_{\Delta\xi}$), no entorno da mudança média REA ($\widetilde{\Delta}\xi \pm \widetilde{\delta}_{\Delta\xi}$), e uma medida da confiabilidade coletiva dos modelos ($\widetilde{\rho}$) podem ser estimadas, respectivamente, por:

$$\widetilde{\delta}_{\Delta\xi} = \left[\frac{\sum_i R_i (\Delta\xi_i - \widetilde{\Delta\xi})^2}{\sum_i R_i} \right]^{1/2} \tag{5.3}$$

$$\widetilde{\rho} = \frac{\sum_i R_i^2}{\sum_i R_i} \tag{5.4}$$

Como base de comparação com a variação média do conjunto de modelos do método REA (descrito na equação 5.1), utilizou-se também uma abordagem mais simples no estudo da variação climática, que é:

$$\overline{\Delta\xi} = \frac{1}{N} \sum_{i=1,N} \Delta\xi_i \tag{5.5}$$

5.4.2 Redes Neurais Artificiais

Uma rede neural artificial é um sistema fundamentado na operação de um neurônio biológico com o propósito de aprender um determinado sistema. A construção de uma RNA é baseada proporcionando um estímulo para o modelo neuronal, calculando as saídas e ajustando os pesos até que o resultado desejado seja alcançado. Uma entrada é submetida à RNA juntamente com um alvo desejado, uma resposta definida para a saída (quando este for o caso, o treinamento é considerado supervisionado). Um campo de erro é construído com base na diferença entre a resposta desejada e a saída do sistema. As

informações do erro são utilizadas como realimentação para o sistema, que ajusta os parâmetros de uma forma sistemática. Em outras palavras, o algoritmo de retropropagação do erro é usado para treinar a rede. De acordo com Alsmadi, Omar e Noah (2009) a arquitetura *backpropagation* é o modelo mais popular, eficaz e fácil de aprender nas redes complexas. Esta rede é mais utilizada do que todos os outros juntos. Este algoritmo tem uma primeira fase com um sinal funcional propagação (*feedforward*) e uma segunda fase com o retropropagação do erro (*backpropagation*).

Na primeira fase, o sinal funcional com base nas entradas propaga através da rede até a geração de uma saída, com os pesos de sinapses permanecendo fixa. Na segunda fase, a saída é comparada com um alvo, produzindo um sinal de erro. O sinal de erro se propaga a partir da saída para a entrada e as ponderações são ajustadas com o intuito de minimizar o erro. O processo é repetido até que o desempenho seja aceitável. Dessa maneira, o desempenho da RNA é fortemente dependente da fonte de dados.

A primeira parte dos dados é usada para o treinamento, a segunda é usado para validação e a terceira parte é usada para testes. A arquitetura da RNA usada no presente estudo pode ser encontrada na Figura 5.2, em que 60% dos dados foram usados para treinamento, 20% para validação e 20% para os testes. É constituída por uma entrada, uma camada oculta e uma camada de saída. O número de unidades intermediarias foi obtido por meio de tentativa e erro. Durante o treinamento, o desempenho da RNA também é avaliado dentro do conjunto de validação.

A estrutura da RNA usada neste estudo envolve o treinamento de 11 preditores (10 saídas dos modelos e os dados de observação) como entrada para a rede, e o melhor desempenho da rede é selecionado. Espera–se, portanto, que a RNA seja capaz de fornecer valores mais confiáveis (por meio da análise de erro entre os valores simulados) do que ao usar apenas modelos climáticos.

5.5 Resultados

5.5.1 Estimativas do intervalo de mudança e incerteza

As Figuras 5.3 e 5.4 mostram as projeções de mudanças climáticas de precipitação e temperatura nos cenários RCP 2.6 e 8.5 para a média simples dos modelos e a variação média REA [Eq. 5.1], juntamente com os correspondentes limites de incerteza superior e inferior [Eq. 5.3]. Todos os parâmetros são apresentados para os casos com e sem aplicação das RNAs.

Para as projeções de precipitação do CMIP5 (Figura 5.3), os padrões de mudança obtidos pela média aritmética simples (i.e., quando assumimos o mesmo peso para todos

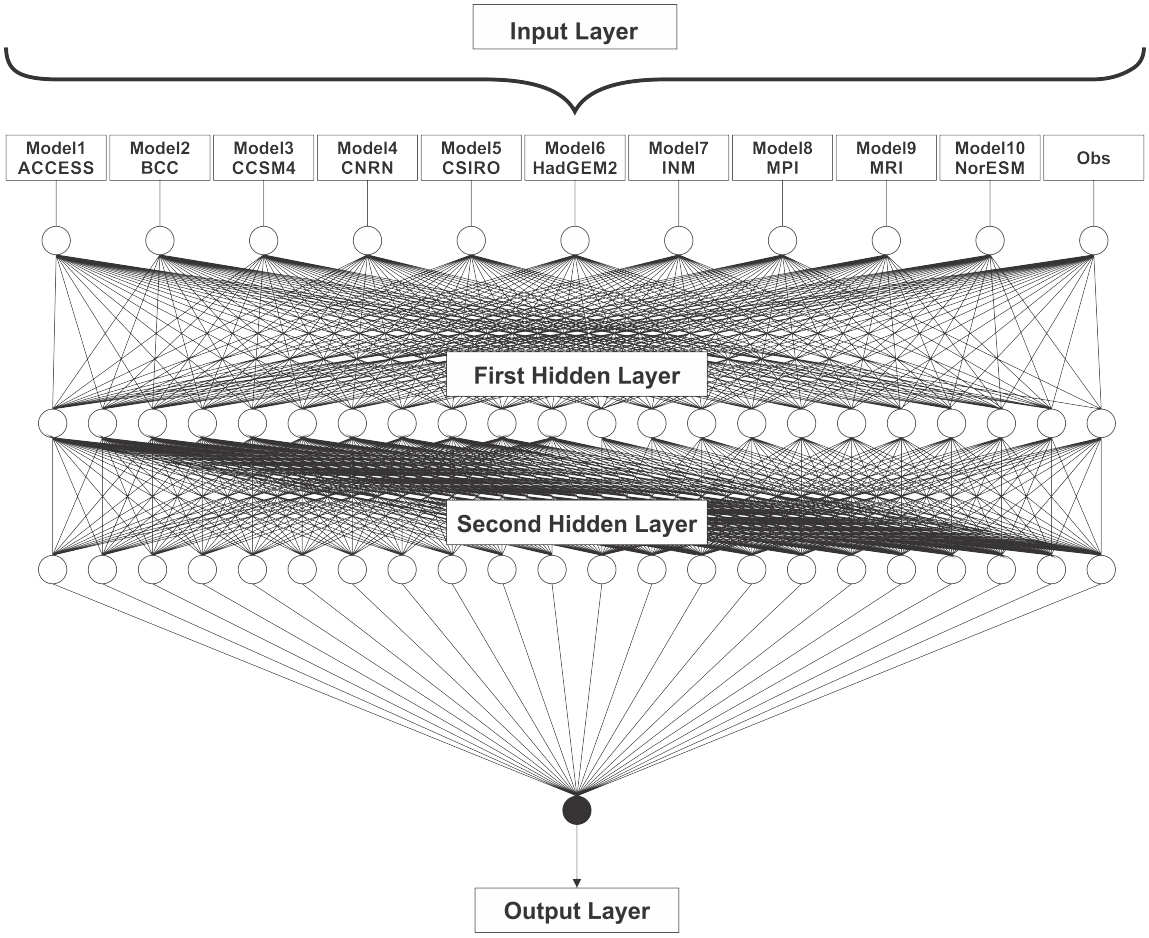

Figura 5.2: Estrutura da rede neural artificial utilizada no estudo.

os membros do conjunto) são maiores do que aqueles obtidos pela aplicação do método REA, corroborando com os estudos de Torres (2014). Isso indica que quando leva-se em consideração a confiabilidade dos MCGs (medidas pelos critérios de desempenho e convergência no método REA), as projeções possuem um mesmo padrão, porém a magnitude das mudanças de precipitação diminuem sutilmente em todas as regiões estudadas e em ambos cenários avaliados. Essa diferença entre a mudança média REA e a mudança da média do conjunto é da ordem de alguns décimos de mm.dia^{-}1. Comparando os dois cenários utilizados, observa-se que no cenário RCP 8.5 (Figura 5.3 – B, C, F) as projeções indicam maiores valores de mudança de precipitação quando comparadas ao RCP 2.6 (Figura 5.3 – A, C, E) corroborando com Magrin et al. (2014) que apresentaram os mesmo resultados, em que as mudanças de precipitação mais intensas ocorrem para o final do século XXI.

Analisando a influência da RNA nos resultados obtidos é possível notar que, tanto para a média simples do modelo quanto para a média REA, a RNA reproduziu o mesmo padrão apresentado de mudança nas estimativas de precipitação. Além disso, nota-se uma redução nas magnitudes de projeção de mudança de precipitação para ambos os casos

quando se utiliza a RNA (aproximadamente 43% para a média simples do modelo e 32% para a abordagem REA). Essa diminuição é ainda mais pronunciada na região Nordeste do Brasil.

Ainda na figura 5.3, as mudanças projetadas para a precipitação possuem um mesmo padrão tanto pela média simples do modelo como pela média REA aferidas ou não pelas redes neurais. Nota-se uma redução da precipitação no outono e inverno da região AMZ, no inverno e na primavera do NEB, e na LPB apenas no período do inverno austral (JJA). Resultados semelhantes foram encontrados por Torres e Marengo (2013).

Em relação aos intervalos de incerteza das projeções de precipitação observam-se maiores valores no verão do AMZ e NEB, enquanto na região LPB eles são mais evidentes no período do inverno para ambos os cenários analisados. Apesar de apresentarem um padrão semelhante, a intervalo de incerteza observada no cenário RCP 8.5 é ligeiramente maior que no cenário RCP 2.6. Além disso, esses são consideravelmente menores quando aferidos pela RNA, com uma redução de cerca de 35% na AMZ, 22% no NEB e 35% na LPB. Isto é uma consequência do treinamento realizado na aplicação da RNA até que a rede chegue a um estado estável, diminuindo o erro e tornando os valores aferidos pela RNA mais próximos do real.

De maneira análoga a precipitação, a média REA para as mudanças de temperatura são menores que a média aritmética simples do conjunto de modelos (Figura 5.4), com uma redução sutil de aproximadamente 0,4°C. Torres (2014), estudando as projeções da temperatura obtidos a partir do método REA verificou uma diminuição mais pronunciada sobre a região oeste da Amazônia quando comparou a média REA com a média simples do modelo (cerca de 1°C para as projeções no final deste século tanto com dados do CMIP3 como com dados do CMIP5).

As projeções de temperatura no cenário RCP 8.5 são maiores quando comparada ao RCP2.6 (em torno de 0,3°C na AMZ, 0,4°C no NEB e 0,2°C na LPB). Symon (2013) afirma que, dependendo da quantidade de redução das emissões, existem dois terços de garantia que o aumento da temperatura média da superfície global na terra ao final do século XXI será entre 2.6–4.8°C (RCP8.5) e 0.3–1.7°C (RCP2.6).

Observa-se também que a RNA diminui a projeção de temperatura tanto para a média simples (Figura 5.4– A, C e E) quanto para a média REA (Figura 5.4 – B, D e F) para todas as regiões analisadas. Com relação ao intervalo de incerteza das projeções de temperatura, a região da AMZ é a que apresenta maior magnitude, principalmente no período do inverno. Além disso, a faixa de incerteza quando os dados de temperatura são aferidos pela RNA são notavelmente menores. Essa redução é ainda mais acentuada na região da LPB, na qual este decréscimo atinge aproximadamente 0,33 e 0,43°C nos cenários RCP 2.6 e 8.5, respectivamente.

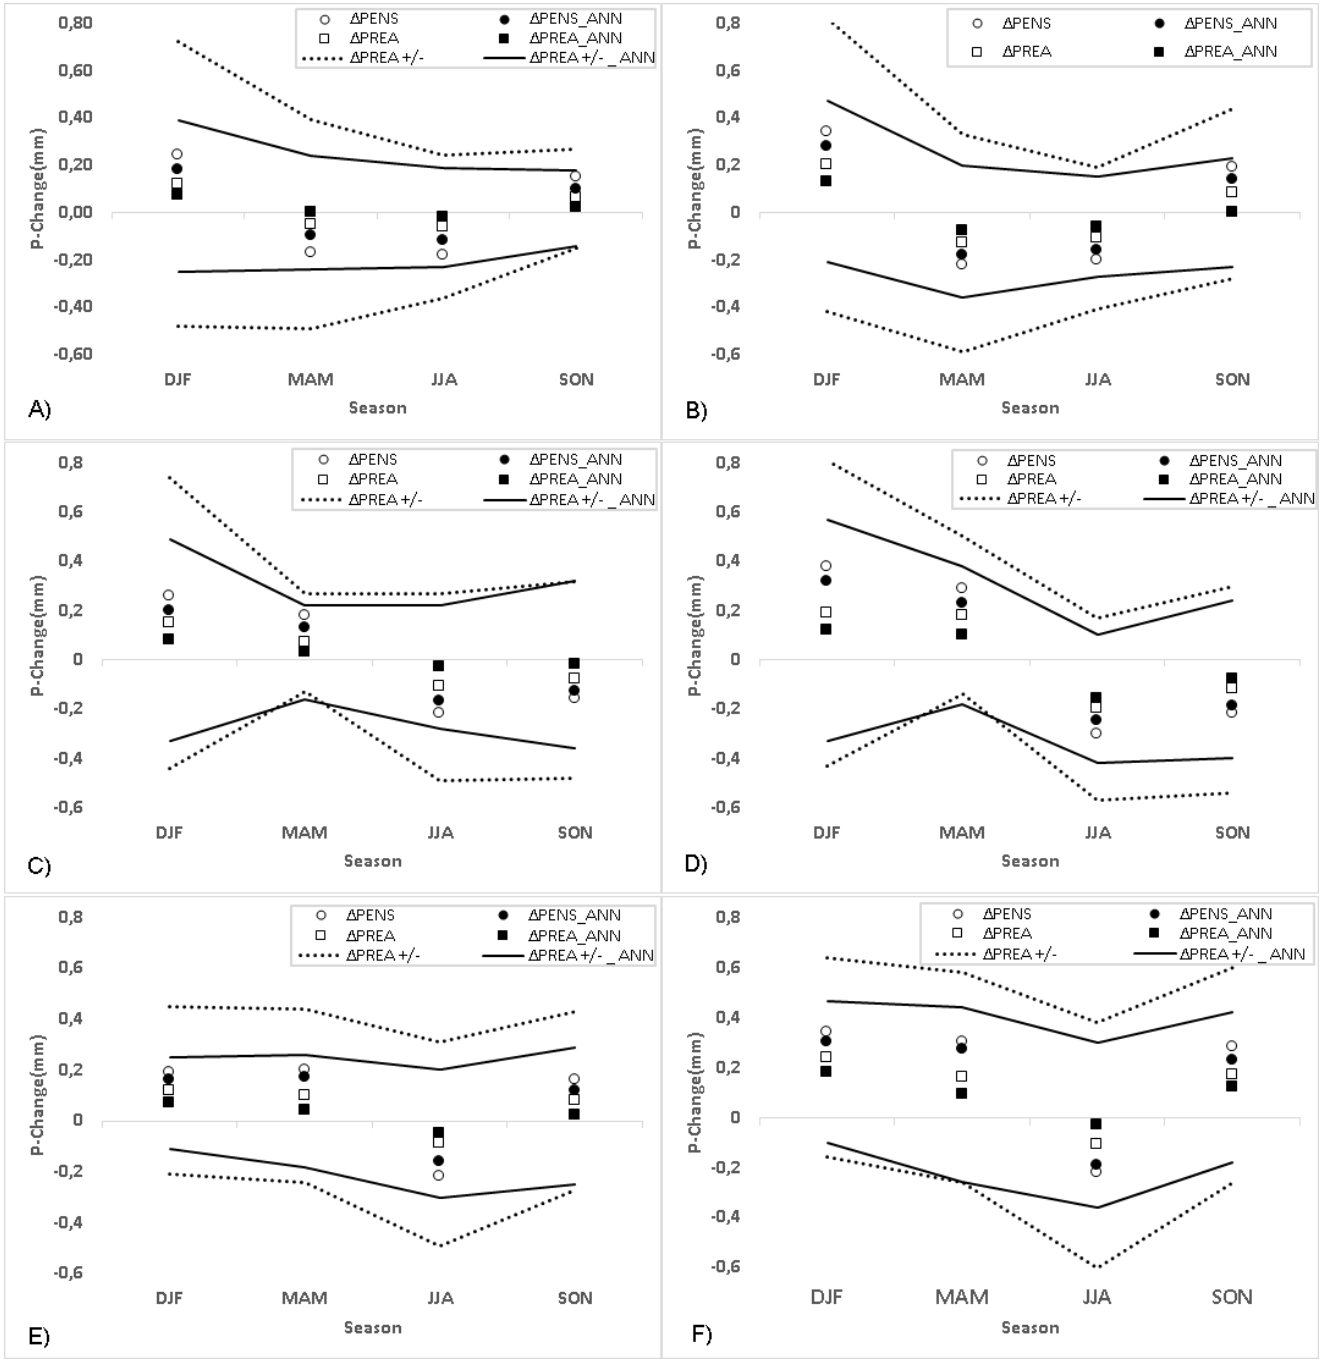

Figura 5.3: Média REA (círculos fechados), média REA aferidas por RNA (quadrados fechados), mudança definida pela média simples dos modelos (círculos abertos), média simples aferidas por RNA (círculos fechados), limites de incerteza da média REA superior e inferior (linhas pontilhadas), limites de incerteza da média REA aferidos por RNA superior e inferior (linhas continuas) para mudança sazonal da precipitação utilizando as projeções dos MCGs do CMIP5 para Amazônia (A e B), Nordeste (C e D) e Bacia do Prata (E e F) no cenário RCP 2.6 (coluna esquerda) e RCP 8.5 (coluna direita). As alterações são definidas como a diferença entre os períodos de 2071-2100 – 1961-1990. Unidades estão em milímetros por dia.

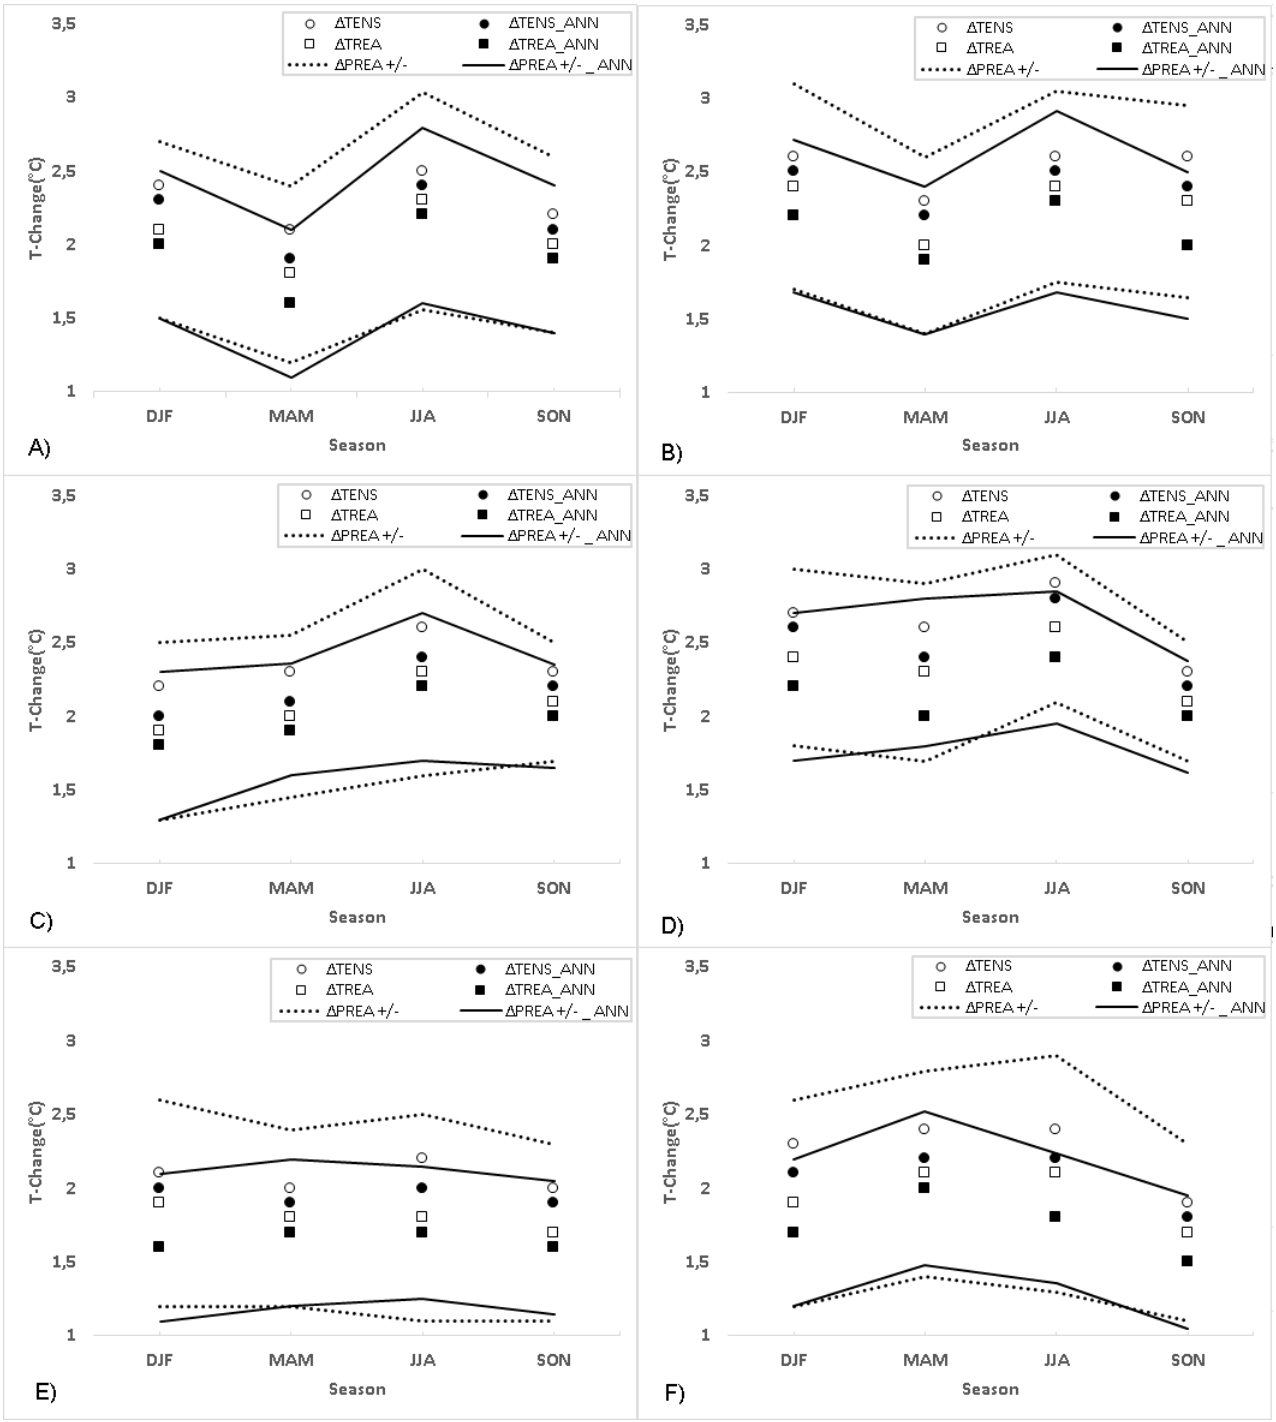

Figura 5.4: Média REA (círculos fechados), média REA aferidas por RNA (quadrados fechados), mudança definida pela média simples dos modelos (círculos abertos), média simples aferidas por RNA (círculos fechados), limites de incerteza da média REA superior e inferior (linhas pontilhadas), seus limites de incerteza da média REA aferidos por RNA superior e inferior (linhas continuas) para mudança sazonal da temperatura utilizando as projeções dos MCGs do CMIP5 para Amazônia (A e B), Nordeste (C e D) e Bacia do Prata (E e F) no cenário RCP 2.6 (coluna esquerda) e RCP 8.5 (coluna direita). As alterações são definidas como a diferença entre os períodos de 2071-2100 – 1961-1990. Unidades estão em °C.

5.5.2 Análise de confiabilidade

As Tabelas 5.2 e 5.3 mostram a confiabilidade do conjunto de modelos para o cenário RCP 8.5, juntamente com os parâmetros de confiabilidade de desempenho (R_B) e convergência (R_D) dos modelos. No geral, os parâmetros de confiabilidade para os cenários RCP 2.6 foram similares àqueles para os RCP 8.5, assim, esses não são discutidos aqui.

Analisando os dois critérios separadamente para a variável precipitação (Tabela 5.2), o valor médio do parâmetro relativo ao critério de convergência (R_D) é maior do que o parâmetro de desempenho (R_B) para todos as regiões estudadas. Isto indica que a convergência dos modelos na simulação de mudanças de precipitação é melhor que o desempenho dos modelos em reproduzir o clima atual. Na maioria dos casos o valor da confiabilidade do conjunto está entre aqueles de R_B e R_D. Em geral, R_D é aproximadamente entre 0,8 e 1, enquanto R_B é na sua maioria inferior a 0,6. Segundo Giorgi e Mearns (2002) isto se deve ao fato de que os vieses dos modelos são maiores do que a magnitude das mudanças de precipitação projetada.

A confiabilidade do conjunto é acima de 0,5 em todas as regiões estudadas e, uma vez que as projeções de mudanças são pequenas ($<$ 1 mm.dia^{-}1), isto pode indicar que existe uma alta confiabilidade em uma projeção de nenhuma mudança expressiva na precipitação média sazonal. Estes resultados são condizentes com Torres e Marengo (2013) que encontraram uma confiabilidade acima de 0,5 em quase toda a AS. A RNA aumentou em torno de 5% o R_B da projeção de precipitação, sugerindo que a utilização da RNA para a aferição de projeções climáticas pode melhorar o desempenho dos modelos em reproduzir o clima atual. Além disso, as RNAs também aumentam a confiabilidade no conjunto de modelos em um valor médio de 5% para a Amazônia e 6% para o NEB e LPB. Essa melhoria da confiabilidade é ainda mais pronunciada no período do verão. O valor da convergência do modelo (R_D) não sofreu mudanças expressivas porque estes já eram próximos à unidade mesmo sem aferição por RNA.

Com relação à temperatura (Tabela 5.3), os valores referentes a R_B são maiores quando comparados a R_D, ou seja, o valor médio do parâmetro relativo ao critério de desempenho (R_B) 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. Torres e Marengo (2013) afirmaram que um maior valor de R_B para a temperatura pode ser explicado, uma vez que o viés nas simulações de temperatura tem magnitude próxima da variabilidade natural sobre praticamente toda a AS. Dessa maneira, valores relativamente altos de R_B podem ser encontrados sobre quase todo o domínio de estudo.

Para esta variável, os valores de R_B, R_D e ρ são menores do que aqueles encontrados

para a precipitação. Entretanto, de maneira semelhante à precipitação, a RNA aumenta os parâmetros de desempenho do modelo em torno de 12% na AMZ e no NEB, e 8% na LPB. A convergência e a confiabilidade aumentam cerca de 8% e 17% em todas as regiões estudadas, respectivamente.

Tabela 5.2: Média dos parâmetros de desempenho (R_B), convergência (R_D) e confiabilidade do conjunto (ρ) do método REA com e sem aferição das RNA para as mudanças sazonal de precipitação utilizando as projeções dos MCGs do CMIP5 para 2071–2100 no cenário RCP 8.5. Parâmetros são adimensionais.

REGION	**SEASON**	R_B	R_D	ρ	R_B_RNA	R_D_RNA	ρ_RNA
AMZ	DJF	0.58	0.88	0.64	0.60	0.90	0.69
	MAM	0.60	0.92	0.69	0.62	0.93	0.73
	JJA	0.58	0.93	0.66	0.61	0.93	0.68
	SON	0.59	0.87	0.65	0.63	0.89	0.69
NEB	DJF	0.58	0.84	0.65	0.60	0.85	0.72
	MAM	0.50	0.93	0.57	0.54	0.94	0.63
	JJA	0.54	1.00	0.61	0.57	1.00	0.64
	SON	0.60	0.90	0.67	0.63	0.91	0.70
LPB	DJF	0.54	0.92	0.67	0.57	0.92	0.74
	MAM	0.59	0.99	0.72	0.63	1.00	0.75
	JJA	0.60	1.00	0.73	0.62	1.00	0.78
	SON	0.60	0.95	0.73	0.64	0.95	0.79

Tabela 5.3: Média dos parâmetros de desempenho (R_B), convergência (R_D) e confiabilidade do conjunto (ρ) do método REA com e sem aferição das RNA para as mudanças sazonal de temperatura utilizando as projeções dos MCGs do CMIP5 para 2071–2100 no cenário RCP 8.5. Parâmetros são adimensionais.

REGION	SEASON	R_B	R_D	ρ	R_B_RNA	R_D_RNA	ρ_RNA
AMZ	DJF	0.38	0.22	0.12	0.44	0.24	0.15
	MAM	0.36	0.25	0.18	0.43	0.27	0.22
	JJA	0.43	0.28	0.22	0.46	0.30	0.25
	SON	0.42	0.26	0.17	0.47	0.29	0.20
NEB	DJF	0.36	0.26	0.18	0.41	0.28	0.22
	MAM	0.34	0.22	0.15	0.40	0.25	0.18
	JJA	0.44	0.32	0.22	0.48	0.34	0.25
	SON	0.40	0.28	0.16	0.45	0.30	0.20
LPB	DJF	0.49	0.39	0.35	0.52	0.42	0.38
	MAM	0.52	0.46	0.30	0.60	0.53	0.39
	JJA	0.58	0.52	0.42	0.63	0.54	0.50
	SON	0.54	0.50	0.40	0.58	0.53	0.52

5.6 Conclusões

Neste artigo utilizou-se o método "Reliability Ensemble Averaging" (REA) para avaliar a magnitude das incertezas envolvidas nas projeções de mudanças climáticas em três regiões da América do Sul geradas por dez modelos climáticos. Além disso, compararam-se os resultados do método REA original com o resultados quando os modelos são aferidos por RNA. O objetivo do método REA é minimizar a contribuição de simulações que tem uma performance mais pobre na representação do clima, podendo dessa forma extrair apenas as informações mais confiáveis de cada modelo. A RNA é comumente utilizada com uma ferramenta de *downscaling* estatístico, que pode minimizar as deficiências dos modelos. Especificamente, projeções de mudança de precipitação e temperatura sazonal sobre três regiões da América do Sul foram analisadas por meio da utilização de dez MCGs pertencentes ao CMIP5 em dois cenários forçantes distintos: RCP 2.6 e 8.5. O foco deste trabalho foi as projeções de mudanças para o final do século (2071–2100), com relação ao período de referência 1961–1990.

A variação da média REA difere significativamente da média simples do conjunto em alguns décimos de mm para a precipitação e de alguns décimos de °C para a temperatura. Quando leva-se em consideração o desempenho de cada modelo em representar o clima observado e a consistência de sua projeção com relação à média do conjunto, como proposto pelo método REA, nota-se que a projeção de mudança diminui para ambas as variáveis nas três regiões estudadas (Amazônia, Nordeste do Brasil e região da Bacia do Prata) nos dois cenários analisados. Isto aponta 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) resultados similares foram obtidos por Torres (2014).

Baseando-se nos conjuntos de MCGs do CMIP5, existe uma alta confiabilidade de uma projeção de mudanças na temperatura sobre toda a América do Sul. Com relação a precipitação, os maiores valores de confiabilidade do modelo foram observados apenas na LPB.

O intervalo de incerteza calculado usando o método REA aferido com as RNAs foi inferior ao intervalo correspondente calculado usando apenas o REA, tanto para temperatura e precipitação. Além disso, a confiabilidade do conjunto de modelos foi superior em torno de 6% para a precipitação e 17% para a temperatura. Isto é por causa da minimização da contribuição de *outliers* ou de uma má simulação dos modelos climáticos.

Os resultados obtidos utilizando o método de RNA indicam que as redes são técnicas promissoras para avaliar as projeções de precipitação e temperatura. As principais vantagens deste método *downscaling* (RNA) é sua capacidade de processamento temporal e sua capacidade de incorporar não apenas um valor efetivo, mas também valores preditores como entrada sem qualquer esforço adicional. Dessa maneira, enfatiza-se a importância das RNAs e a utilidade destas como uma ferramenta útil no processamento de saída de modelos climáticos.

6 Considerações Finais

A presente tese avaliou a magnitude das incertezas envolvidas nas projeções de mudanças climáticas na América do Sul geradas por inúmeros modelos climáticos, no intuito de fornecer subsídios importantes para os estudos da mudanças climáticas na América do Sul.

A partir dos resultados expostos nos artigos, foi possível constatar o grau incerteza no clima da AS, ainda que utilizando modelos mais complexos e mais realísticos quando comparado às versões anteriores (mais realísticos, porque muitos incluíram importantes processos e/ ou *feedbacks* não abordados nas versões anteriores, como ciclo de carbono, processos biogeoquímicos, vegetação dinâmica). Além disso, foi avaliado como uma técnica estatística para *downscaling* (redes neurais artificiais) pode influenciar nas incertezas inerentes aos modelos climáticos.

A compreensão e quantificação das incertezas envolvidas nas projeções de mudanças climáticas são vitais para o delineamento de estratégias de mitigação e adaptação, assim como o diagnóstico de futuros impactos e vulnerabilidades. Nesse sentido, acredita-se que o objetivo geral foi alcançado, uma vez que a metodologia proposta permitiu ponderar os intervalos de incerteza nas projeções de mudanças climáticas apresentadas no CMIP5 para a América do Sul, relacionadas ao uso de diferentes modelos numéricos e futuras emissões de gases de efeito estufa.

O método *Reliability Ensemble Averaging* apontou que, no conjunto de MCGs avaliados, as mudanças na magnitude de temperatura são maiores do que os intervalos de incerteza associados para as regiões estudadas da América do Sul, 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. Por outro lado, quando empregado à precipitação, os intervalos de incerteza possuem magnitudes maiores do que a das mudanças projetadas. Portanto, existe uma menor confiabilidade de uma projeção de mudanças na precipitação sazonal média dos modelos estudados, quando comparados à temperatura na América do Sul, exceto na região da Bacia do Prata, que apresentou uma maior confiabilidade dentre todas as regiões estudadas.

A possível redução das incertezas associadas às projeções de mudanças climáticas é uma forte motivação para utilizar técnicas como as redes neurais artificiais e a regressão linear múltipla por componentes principais. O uso das RNAs mostrou-se mais consistente quando comparada a Regressão Linear Múltipla. Essa metodologia apresenta, como vantagem o fato de que o ajuste das RNAs são capazes de simular não-linearidades e reconhecer padrões específicos ligados à quantidade e qualidade dos exemplos apresentados. Os resultados apresentados têm como finalidade confirmar que as RNAs são métodos proficientes no estudo de simulações climáticas.

A partir da utilização das redes neurais artificiais aplicadas ao método *Reliability Ensemble Averaging*, verificou-se que as RNAs se mostraram uma metodologia eficaz para aferir as saídas dos modelos climáticos globais, simulados com diferentes concentrações de gases de efeito estufa. Sua utilização reduziu o intervalo de incerteza associado às projeções de mudanças climáticas e aumentou a confiabilidade do conjunto de modelos, calculadas pelo método REA. As RNAs possuem a capacidade de explorar as não-linearidades presentes nas análises realizadas e tirar informações dos diferentes parâmetros de entrada que são fornecidos à mesma pelas variáveis aleatórias utilizadas (precipitação e temperatura), diminuindo, dessa maneira, as incertezas intrínsecas dos modelos.

6.1 Sugestões para trabalhos futuros

As perspectivas futuras incluem tópicos que não foram abordados ao longo da pesquisa. Como sugestão para trabalhos futuros:

- Identificar o comportamento das incertezas dos modelos quando as redes neurais artificias forem aplicadas espacialmente.
- Avaliar como outras técnicas de *downscaling* (estatístico e/ou dinâmico) podem influenciar nas incertezas dos modelos climáticos.
- Averiguar as incertezas referentes a extremos climáticos.

Referências

ALGAR, A. C. et al. Predicting the future of species diversity: macroecological theory, climate change, and direct tests of alternative forecasting methods. *Ecography*, Blackwell Publishing Ltd, v. 32, n. 1, p. 22–33, 2009. ISSN 1600-0587.

ALSMADI, M. K. S.; OMAR, K. B.; NOAH, S. A. Back propagation algorithm: the best algorithm among the multi-layer perceptron algorithm. *International Journal of Computer Science and Network Security*, v. 9, n. 4, p. 378–383, 2009.

ANNAN, J. D.; HARGREAVES, J. C. Reliability of the cmip3 ensemble. *Geophysical Research Letters*, v. 37, n. 2, p. n/a–n/a, 2010. ISSN 1944-8007. L02703.

ANTOLIK, M. S. An overview of the national weather service's centralized statistical quantitative precipitation forecasts. *Journal of Hydrology*, Elsevier, v. 239, n. 1, p. 306–337, 2000.

ARAÚJO, M. B.; NEW, M. Ensemble forecasting of species distributions. *Trends in ecology & evolution*, Elsevier, v. 22, n. 1, p. 42–47, 2007.

ARAÚJO, M. B. et al. Reducing uncertainty in projections of extinction risk from climate change. *Global Ecology and Biogeography*, Blackwell Science Ltd, v. 14, n. 6, p. 529–538, 2005. ISSN 1466-8238.

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, n. 1, 2007. ISSN 1944-8007.

BENTSEN, M. et al. The norwegian earth system model, noresm1–m – part 1: Description and basic evaluation of the physical climate. *Geoscientific Model Development*, v. 6, n. 3, p. 687–720, 2013.

BI, D. et al. The access coupled model: description, control climate and evaluation. *Aust. Meteorol. Oceanogr. J*, v. 63, n. 1, p. 41–64, 2013.

BLÁZQUEZ, J.; KUSUNOKI, S. et al. Climate projections and uncertainties over south america from mri/jma global model experiments. *Atmospheric and Climate Sciences*, Scientific Research Publishing, v. 2, n. 04, p. 381, 2012.

BLÁZQUEZ, J.; NUÑEZ, M. N. Analysis of uncertainties in future climate projections for south america: comparison of wcrp-cmip3 and wcrp-cmip5 models. *Climate dynamics*, Springer, v. 41, n. 3-4, p. 1039–1056, 2013.

BOULANGER, J.-P.; MARTINEZ, F.; SEGURA, E. 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*, Springer-Verlag, v. 28, n. 2-3, p. 255–271, 2007. ISSN 0930-7575.

BRECHIN, S. R.; BHANDARI, M. Perceptions of climate change worldwide. *Wiley Interdisciplinary Reviews: Climate Change*, v. 2, n. 6, p. 871–885, 2011. ISSN 1757-7799.

COLLIER, M. et al. The csiro-mk3. 6.0 atmosphere-ocean gcm: participation in cmip5 and data publication. In: *International Congress on Modelling and Simulation–MODSIM*. [S.l.: s.n.], 2011.

COLLINS, M. Ensembles and probabilities: a new era in the prediction of climate change. *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, The Royal Society, v. 365, n. 1857, p. 1957–1970, 2007. ISSN 1364-503X.

COLLINS, W. J. et al. Development and evaluation of an earth-system model hadgem2. *Geoscientific Model Development*, v. 4, n. 4, p. 1051–1075, 2011.

CRAIG, A. P.; VERTENSTEIN, M.; JACOB, R. A new flexible coupler for earth system modeling developed for ccsm4 and cesm1. *International Journal of High Performance Computing Applications*, v. 26, n. 1, p. 31–42, 2012.

GIORGETTA, M. A. et al. Climate and carbon cycle changes from 1850 to 2100 in mpi-esm simulations for the coupled model intercomparison project phase 5. *Journal of Advances in Modeling Earth Systems*, v. 5, n. 3, p. 572–597, 2013. ISSN 1942-2466.

GIORGI, F. Climate change prediction. *Climatic Change*, Springer, v. 73, n. 3, p. 239–265, 2005.

GIORGI, F.; FRANCISCO, R. Evaluating uncertainties in the prediction of regional climate change. *Geophysical Research Letters*, v. 27, n. 9, p. 1295–1298, 2000. ISSN 1944-8007.

GIORGI, F.; MEARNS, 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, n. 10, p. 1141–1158, 2002.

GIORGI, F.; MEARNS, L. O. Probability of regional climate change based on the reliability ensemble averaging (rea) method. *Geophysical Research Letters*, v. 30, n. 12, p. n/a–n/a, 2003. ISSN 1944-8007.

GUPTA, J. A history of international climate change policy. *Wiley Interdisciplinary Reviews: Climate Change*, v. 1, n. 5, p. 636–653, 2010. ISSN 1757-7799.

HARRIS, I. et al. Updated high–resolution grids of monthly climatic observations–the cru ts3.10 dataset. *International Journal of Climatology*, v. 34, n. 3, p. 623–642, 2014. ISSN 1097-0088.

HAYKIN, S. *Redes Neurais artificiais : introdução e princípios de neurocomputação*. [S.l.]: Porto Alegre: Bookman, 1995.

HAYKIN, S. *Redes Neurais–Princípios e Prática*. [S.l.]: Porto Alegre: Bookman, 2001.

HEGERL, G. C. et al. Understanding and attributing climate change. 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*. [S.l.]: Cambridge University Press, 2007.

HIJMANS, R. J.; GRAHAM, C. H. The ability of climate envelope models to predict the effect of climate change on species distributions. *Global Change Biology*, Blackwell Publishing Ltd, v. 12, n. 12, p. 2272–2281, 2006. ISSN 1365-2486.

(IPCC), I. P. on C. C. Climate scenario development. Cambridge university Press, 2001.

JAHN, A.; HOLLAND, M. M. Implications of arctic sea ice changes for north atlantic deep convection and the meridional overturning circulation in ccsm4–cmip5 simulations. *Geophysical Research Letters*, v. 40, n. 6, p. 1206–1211, 2013. ISSN 1944-8007.

JONES, C.; CARVALHO, L. M. Climate change in the south american monsoon system: present climate and cmip5 projections. *Journal of Climate*, v. 26, n. 17, p. 6660–6678, 2013.

JONES, R. N. Analysing the risk of climate change using an irrigation demand model. *Climate Research*, INTER-RESEARCH NORDBUNTE 23, D-21385 OLDENDORF LUHE, GERMANY, v. 14, n. 2, p. 89–100, 2000.

JONES, R. N. Managing uncertainty in climate change projections–issues for impact assessment. *Climatic change*, Springer, v. 45, n. 3-4, p. 403–419, 2000.

KATZ, R. W. Techniques for estimating uncertainty in climate change scenarios and impact studies. *Climate Research*, v. 20, n. 2, p. 167–185, 2002.

KIM, Y.-O.; LEE, J.-K. Addressing heterogeneities in climate change studies for water resources in korea. *Current Science*, Current Science Assoc//Indian Academy of Sciences, v. 98, n. 8, 2010.

KITTEL, T. G. F.; GIORGI, F.; MEEHL, G. A. Intercomparsion of regional biases and doubled CO_2 – sensitivity of coupled atmosphere-ocean general circulation model experiments. *Climate Dynamics*, Springer-Verlag, v. 14, n. 1, p. 1–15, 1997. ISSN 0930-7575.

KNUTTI, R. Should we believe model predictions of future climate change? *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, The Royal Society, v. 366, n. 1885, p. 4647–4664, 2008. ISSN 1364-503X.

KNUTTI, R. et al. Challenges in combining projections from multiple climate models. *Journal of Climate*, v. 23, n. 10, p. 2739–2758, 2010.

LEAHY, K. Multicollinearity: When the solution is the problem. *Data Mining Cookbook: Modelling data for marketing, risk and costumer relationship management. New York: John Wiley & Sons*, 2000.

LENHARD, J.; KÜPPERS, G.; SHINN, T. *Simulation: Pragmatic constructions of reality*. [S.l.]: Springer Science & Business Media, 2007.

MAGRIN, G. O. et al. Central and south america. in: Climate change 2014: Impacts, adaptation, and vulnerability. part b: Regional aspects. contribution of working group ii to the fifth assessment report of the intergovernmental panel on climate change. In: _____. *In: Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part B: Regional Aspects. Contribution of Working Group II to the Fifth Assessment Report of*

the Intergovernmental Panel on Climate Change. [S.l.]: Cambridge University Press, 2014. p. 1499–1566.

MARENGO, J. et al. Future change of climate in south america in the late twenty-first century: intercomparison of scenarios from three regional climate models. *Climate Dynamics*, Springer-Verlag, v. 35, n. 6, p. 1073–1097, 2010. ISSN 0930-7575.

MEARNS, L. et al. Climate scenario development. Cambridge university Press, p. 739–768, 2001.

MEEHL, G. A. et al. Global climate projections. *Climate change*, v. 283, 2007.

MENDES, D.; MARENGO, J. Temporal downscaling: a comparison between artificial neural network and autocorrelation techniques over the amazon basin in present and future climate change scenarios. *Theoretical and Applied Climatology*, Springer Vienna, v. 100, n. 3-4, p. 413–421, 2010. ISSN 0177-798X.

MILLER, C. A. Climate science and the making of a global political order. *States of knowledge: The coproduction of science and social order*, p. 46–66, 2004.

MILLER, C. A.; EDWARDS, P. N. *Changing the atmosphere: expert knowledge and environmental governance*. [S.l.]: MIT Press, 2001.

MINGOTE, S. A. *Análise de dados através de métodos de estatística multivariada – Uma abordagem aplicada*. [S.l.]: Editora UFMG, 2005.

MITCHELL, T. D.; JONES, P. D. An improved method of constructing a database of monthly climate observations and associated high–resolution grids. *International journal of climatology*, v. 25, n. 6, p. 693–712, 2005.

MOISE, A. F.; HUDSON, D. A. Probabilistic predictions of climate change for australia and southern africa using the reliability ensemble average of ipcc cmip3 model simulations. *Journal of Geophysical Research: Atmospheres*, v. 113, n. D15, 2008. ISSN 2156-2202.

MORGAN, M. S.; MORRISON, M. *Models as mediators: Perspectives on natural and social science*. [S.l.]: Cambridge University Press, 1999.

MOSS, R. H. et al. The next generation of scenarios for climate change research and assessment. *Nature*, Nature Publishing Group, v. 463, n. 7282, p. 747–756, 2010.

MURPHY, J. et al. A methodology for probabilistic predictions of regional climate change from perturbed physics ensembles. *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, The Royal Society, v. 365, n. 1857, p. 1993–2028, 2007. ISSN 1364-503X.

MURPHY, J. M. et al. Quantification of modelling uncertainties in a large ensemble of climate change simulations. *Nature*, v. 430, n. 7001, p. 768–772, 2004.

NAKICENOVIC, N.; SWART, R. Special report on emissions scenarios. *Special Report on Emissions Scenarios, Edited by Nebojsa Nakicenovic and Robert Swart, pp. 612. ISBN 0521804930. Cambridge, UK: Cambridge University Press, July 2000.*, v. 1, 2000.

NEW, M.; HULME, M. Representing uncertainty in climate change scenarios: a monte–carlo approach. *Integrated Assessment*, Kluwer Academic Publishers, v. 1, n. 3, p. 203–213, 2000. ISSN 1389-5176.

NORTON, S. D.; SUPPE, F. Why atmospheric modeling is good science. *Changing the atmosphere: Expert knowledge and environmental governance*, Cambridge, MA: MIT Press, p. 67–105, 2001.

OLSON, D. A.; JUNKER, N. W.; KORTY, B. Evaluation of 33 years of quantitative precipitation forecasting at the nmc. *Weather and Forecasting*, v. 10, n. 3, p. 498–511, 1995.

RÄISÄNEN, J. How reliable are climate models? *Tellus A*, Blackwell Publishing Ltd, v. 59, n. 1, p. 2–29, 2007. ISSN 1600-0870.

RÄISÄNEN, J.; PALMER, T. A probability and decision-model analysis of a multimodel ensemble of climate change simulations. *Journal of Climate*, v. 14, n. 15, p. 3212–3226, 2001.

RAMÍREZ, M. C. V.; FERREIRA, N. J.; VELHO, H. F. d. C. Linear and nonlinear statistical downscaling for rainfall forecasting over southeastern brazil. *Weather and Forecasting*, v. 21, n. 6, p. 969–989, 2006.

RAMÍREZ, M. C. V.; VELHO, H. F. de C.; FERREIRA, N. J. Artificial neural network technique for rainfall forecasting applied to the sao paulo region. *Journal of Hydrology*, Elsevier, v. 301, n. 1, p. 146–162, 2005.

RAMOS, A. M. *Desagregação espacial da precipitação simulada por modelos atmosféricos no Nordeste do Brasil*. Master's thesis, 2000.

RAWLINS, M. A.; BRADLEY, R. S.; DIAZ, H. F. Assessment of regional climate model simulation estimates over the northeast united states. *Journal of Geophysical Research: Atmospheres*, v. 117, n. D23, p. n/a–n/a, 2012. ISSN 2156-2202.

REBOITA, M. S. et al. Regimes de precipitação na ámerica do Sul: Uma revião bibliogáfica. *Revista Brasileira de Meteorologia*, SciELO Brasil, v. 25, n. 2, p. 185–204, 2010.

SANTOS, F. D. A física das alterações climáticas. *Gazeta de Física*, v. 30, p. 48–57, 2007.

SENGUPTA, A.; RAJEEVAN, M. Uncertainty quantification and reliability analysis of cmip5 projections for the indian summer monsoon. *CURRENT SCIENCE*, v. 105, n. 12, p. 1692, 2013.

SETH, A.; ROJAS, M.; RAUSCHER, S. Cmip3 projected changes in the annual cycle of the south american monsoon. *Climatic Change*, Springer Netherlands, v. 98, n. 3–4, p. 331–357, 2010. ISSN 0165-0009.

SHACKLEY, S. Trust in models? the mediating and transformative role of computer models in environmental discourse. In: _____. *The International Handbook of Environmental Sociology*. [S.l.]: Edward Elgar Publishing Ltd., Cheltenham, 1997. p. 237–260.

SHACKLEY, S.; WYNNE, B. Representing uncertainty in global climate change science and policy: Boundary-ordering devices and authority. *Science, Technology & Human Values*, Sage Publications, v. 21, n. 3, p. 275–302, 1996.

SILVA, A. G. da et al. Improving regional dynamic downscaling with multiple linear regression model using components principal analysis: Precipitation over amazon and northeast brazil. *Advances in Meteorology*, Hindawi Publishing Corporation, v. 2014, 2014.

SOLOMON, S. et al. *Climate change 2007-the physical science basis: Working group I contribution to the fourth assessment report of the IPCC*. [S.l.]: Cambridge University Press, 2007.

STAINFORTH, D. A. et al. Uncertainty in predictions of the climate response to rising levels of greenhouse gases. *Nature*, v. 433, n. 7024, p. 403–406, 2005.

STOCKER, T. F. et al. Climate change 2013: The physical science basis. *Intergovernmental Panel on Climate Change, Working Group I Contribution to the IPCC Fifth Assessment Report (AR5)(Cambridge Univ Press, New York)*, 2013.

STOTT, P. A.; KETTLEBOROUGH, J. Origins and estimates of uncertainty in predictions of twenty-first century temperature rise. *Nature*, Nature Publishing Group, v. 416, n. 6882, p. 723–726, 2002.

SYMON, C. Science Report Briefing, *Climate change: action, trends and implications for business. The IPCC's Fifth Assessment Report, Working Group 1.* 2013.

TAO, H. et al. Assessment of cmip3 climate models and projected changes of precipitation and temperature in the yangtze river basin, china. *Climatic Change*, Springer Netherlands, v. 111, n. 3-4, p. 737–751, 2012. ISSN 0165-0009.

TAYLOR, K. E.; STOUFFER, R. J.; MEEHL, G. A. An overview of cmip5 and the experiment design. *Bulletin of the American Meteorological Society*, American Meteorological Society, v. 93, n. 4, p. 485–498, 2012.

TEBALDI, C.; KNUTTI, R. The use of the multi-model ensemble in probabilistic climate projections. *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, The Royal Society, v. 365, n. 1857, p. 2053–2075, 2007. ISSN 1364-503X.

TEBALDI, C. et al. Quantifying uncertainty in projections of regional climate change: A bayesian approach to the analysis of multimodel ensembles. *Journal of Climate*, v. 18, n. 10, p. 1524–1540, 2005.

TORRES, R. R. *Análise de incertezas em projeções de mudanças climáticas na América do Sul*. 271 p. Tese (Doutorado) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014-02-03 2014.

TORRES, R. R.; MARENGO, J. A. Uncertainty assessments of climate change projections over south america. *Theoretical and Applied Climatology*, Springer Vienna, v. 112, n. 1-2, p. 253–272, 2013. ISSN 0177-798X.

VILLANUEVA, W. J. P. *Síntese automática de redes neurais artificiais com conexões à frente arbitrárias*. Doctoral thesis, 2011.

VISSER, H. et al. Identifying key sources of uncertainty in climate change projections. *Climatic Change*, Kluwer Academic Publishers, v. 45, n. 3-4, p. 421–457, 2000. ISSN 0165–0009.

VOLDOIRE, A. et al. The cnrm–cm5.1 global climate model: description and basic evaluation. *Climate Dynamics*, Springer-Verlag, v. 40, n. 9-10, p. 2091–2121, 2013. ISSN 0930-7575.

VOLODIN, E.; DIANSKII, N.; GUSEV, A. Simulating present–day climate with the inmcm4.0 coupled model of the atmospheric and oceanic general circulations. *Izvestiya, Atmospheric and Oceanic Physics*, v. 46, n. 4, p. 414–431, 2010. ISSN 0001-4338.

VUUREN, D. V. et al. The representative concentration pathways: an overview. *Climatic Change*, Springer Netherlands, v. 109, n. 1-2, p. 5–31, 2011. ISSN 0165-0009.

WEART, S. The development of general circulation models of climate. *Studies in History and Philosophy of Science Part B: Studies in History and Philosophy of Modern Physics*, Elsevier, v. 41, n. 3, p. 208–217, 2010.

WEART, S. R. *The discovery of global warming: revised and expanded edition*. [S.l.]: Harvard University Press, 2008.

WHETTON, P. H. et al. Global comparison of the regional rainfall results of enhanced greenhouse coupled and mixed layer ocean experiments: Implications for climate change scenario development. *Climatic Change*, Kluwer Academic Publishers, v. 33, n. 4, p. 497–519, 1996. ISSN 0165-0009.

WILKS, D. S. *Statistical Methods in the Atmospheric Sciences: An Introduction*. [S.l.]: Academic press, 1995.

WILSON, L. J.; VALLÉE, M. The Canadian Updateable Model Output Statistics (UMOS) system: Design and development tests. *Weather and Forecasting*, v. 17, n. 2, p. 206–222, 2002.

WYNNE, B. Strange weather, again climate science as political art. *Theory, Culture & Society*, SAGE Publications, v. 27, n. 2-3, p. 289–305, 2010.

XIAO-GE, X.; TONG-WEN, W.; JIE, Z. Introduction of {CMIP5} experiments carried out with the climate system models of beijing climate center. *Advances in Climate Change Research*, v. 4, n. 1, p. 41 – 49, 2013. ISSN 1674-9278.

XU, Y.; GAO, X.; GIORGI, F. Upgrades to the reliability ensemble averaging method for producing probabilistic climate-change projections. *Climate Research*, v. 41, n. 10, p. 61–81, 2010.

YUKIMOTO, S. et al. A new global climate model of the meteorological research institute: Mri–cgcm3–model description and basic performance–. *Journal of the Meteorological Society of Japan*, v. 90, n. 0, p. 23–64, 2012.