

UNIVERSIDADE FEDERAL DE ALAGOAS
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS
CURSO DE PÓS-GRADUAÇÃO EM METEOROLOGIA

THAYWANNE NOVAES DE ALMEIDA

**IMPACTOS NA PRODUTIVIDADE DO FEIJÃO NA REGIÃO NORDESTE DO
BRASIL SOB CONDIÇÕES DO CENÁRIO CLIMÁTICO RCP 4.5**

MACEIÓ-AL

2021

THAYWANNE NOVAES DE ALMEIDA

**IMPACTOS NA PRODUTIVIDADE DO FEIJÃO NA REGIÃO NORDESTE DO
BRASIL SOB CONDIÇÕES DO CENÁRIO CLIMÁTICO RCP 4.5**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Meteorologia do Instituto de Ciências Atmosféricas da Universidade Federal de Alagoas, como requisito parcial para obtenção do Título de Mestre em Meteorologia, área de concentração Processos de Superfície Terrestre.
Orientador: Prof. Dr. Fabrício Daniel dos Santos Silva.

MACEIÓ-AL

2021

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central

Bibliotecária Responsável: Betânia Almeida dos Santos

A447i Almeida, Thaywanne Novaes de
Impactos na produtividade do feijão na região Nordeste do Brasil
sob condições do cenário climático RCP 4.5 / Thaywanne Novaes de
Almeida. – 2021.

76 f. : il. color.

Orientador: Prof. Dr. Fabrício Daniel dos Santos Silva
Dissertação (mestrado em Meteorologia) – Universidade Federal
de Alagoas. Instituto de Ciências Atmosféricas. Programa de Pós-
graduação em Meteorologia. Maceió, 2021.

Bibliografia: f. 67-76

1. Modelo agrometeorológico. – cultura do feijão. 2 Condições
climáticas - cultura do feijão. 3. Variáveis meteorológicas – feijão –
desenvolvimento. 4. Downscaling Estatístico. I. Título.

CDU: 551.5:635.652(812/813)



UNIVERSIDADE FEDERAL DE ALAGOAS
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM METEOROLOGIA

CERTIFICADO DE APRESENTAÇÃO

N.º de ordem: MET-UFAL-MS-181.

***"IMPACTOS NA PRODUTIVIDADE DO FEIJÃO NA REGIÃO NORDESTE DO BRASIL
SOB CONDIÇÕES DO CENÁRIO CLIMÁTICO RCP 4.5"***

Thaywanne Novaes de Almeida

Dissertação submetida ao colegiado do Curso de Pós-Graduação em Meteorologia da Universidade Federal de Alagoas - UFAL, como parte dos requisitos necessários à obtenção do grau de Mestre em Meteorologia.

Aprovado pela Banca Examinadora composta por:

Prof. Dr. Fabricio Daniel dos Santos Silva
(Orientador)

Prof.ª. Dra. Maria Luciene Dias de Melo
(Membro Interno)

Prof. Dr. João Hugo Baracuy da Cunha Campos
(Membro Externo)

Agosto /2021

À minha família, em especial, ao meu filho.

AGRADECIMENTOS

Primeiramente, a Deus, pelo dom da vida e a graça da fé, que não me permitiu fraquejar e desistir, e honrou-me com a bênção alcançada.

Aos meus amigos de curso, que por diversos momentos, compartilharam seus conhecimentos e sempre estiveram solícitos em ajudar.

Aos professores do PPGMET que fizeram parte dessa caminhada, incentivaram e contribuíram para meu aprendizado, em especial, ao meu orientador Fabrício, que se fez presente e contribuiu para essa conquista, meus agradecimentos, de maneira especial, por me apresentar a agrometeorologia e repassar parte da sua experiência.

A Fundação de Amparo à Pesquisa do Estado de Alagoas – FAPEAL, que apoiou e potencializou o resultado da nossa pesquisa, com processo de nº E:600.30.0000000756/2019. A essa instituição, deixo aqui registrado meus agradecimentos, por contribuir com a ciência e acreditar na educação.

E por fim, a minha família, que sempre me apoiou e acreditou nas minhas escolhas, sem dúvidas, é o alicerce mais importante da vida.

RESUMO

O feijão é uma leguminosa com variabilidade agrônômica, rica em nutrientes e exigentes em condições climáticas - os índices pluviométricos e as temperaturas, em geral, são as principais variáveis meteorológicas que afetam o seu desenvolvimento e produtividade. Na Região Nordeste do Brasil (NEB), a cultura do feijão é uma das mais praticadas e importantes do ponto de vista socioeconômico, sendo que maior parte do território do NEB insere-se no clima semiárido, característico de seca e estiagens prolongadas, fatores que influenciam diretamente o rendimento de safras agrícolas. O Painel Intergovernamental sobre Mudanças Climáticas (IPCC) aponta uma predominância positiva do aumento da temperatura média global ao longo dos próximos anos, que pode ser analisado com base nos cenários de mudanças climáticas. Contudo, para analisar o impacto das mudanças climáticas na produtividade do feijão no NEB, foram utilizados dados da produtividade do feijão disponibilizado pelo IBGE de 1817 municípios entre 1974 a 2018. Destes municípios, foi possível calibrar e validar o modelo agrometeorológico em 73, por apresentarem dados meteorológicos e de produtividade confiáveis, classificados em três grupos homogêneos (baixa, média e alta produtividade). Para geração de cenários futuros regionalizados e avaliação dos impactos das mudanças climáticas na produtividade do feijão foi empregada a técnica de *downscaling* estatístico, para o cenário RCP4.5. Foram utilizados seis modelos climáticos globais que compuseram o quinto relatório do IPCC: o canadense CANESM2, os franceses CNRM-CM5 e IPSL-CM5A-MR, o americano GFDL-ESM2M, o alemão MPI-ESMMR, e o modelo norueguês NORESM1-MS. Por meio dos modelos, observaram-se as áreas do NEB que terão impacto na produtividade, com base no período climatológico de simulações, para os anos de 2011-2040, 2041-2070 e 2071-2100. As simulações indicaram que a maior parte dos municípios produtores do NEB terá sua produtividade reduzida, como consequência direta da tendência de redução significativa da precipitação acumulada, e de aumento das temperaturas que, por conseguinte, aumentarão a evapotranspiração potencial.

Palavras-chave: Modelo agrometeorológico. Modelos Climáticos Globais. *Downscaling* Estatístico.

ABSTRACT

Beans are a legume with agronomic variability, rich in nutrients and demanding in climatic conditions - rainfall and temperatures, in general, are the main meteorological variables that affect its development and productivity. In the Northeast Region of Brazil (NEB), the bean crop is one of the most practiced and important from a socioeconomic point of view, and most of the NEB territory is part of the semi-arid climate, characteristic of drought and prolonged droughts, factors that directly influence the yield of agricultural crops. The Intergovernmental Panel on Climate Change (IPCC) points to a positive predominance of the increase in global average temperature over the next few years, which can be analyzed based on climate change scenarios. However, to analyze the impact of climate change on bean productivity in NEB, bean productivity data provided by IBGE from 1817 municipalities between 1974 and 2018 were used. Of these municipalities, it was possible to calibrate and validate the agrometeorological model in 73, as they presented reliable meteorological and productivity data, classified into three homogeneous groups (low, medium and high productivity). To generate regionalized future scenarios and assess the impacts of climate change on edible beans productivity, the statistical downscaling technique was used for the RCP4.5 scenario. Six global climate models that made up the fifth IPCC report were used: the Canadian CANESM2, the French CNRM-CM5 and IPSL-CM5A-MR, the American GFDL-ESM2M, the German MPI-ESMMR, and the Norwegian model NORESM1-MS. Through the models, the NEB areas that will have an impact on productivity were observed, based on the climatological period of simulations, for the years 2011-2040, 2041-2070 and 2071-2100. The simulations indicated that most of the NEB producing municipalities will have their productivity reduced, as a direct consequence of the tendency of a significant reduction in accumulated precipitation, and of an increase in temperatures, which, therefore, will increase the potential evapotranspiration.

Keywords: Agrometeorological model. Global Climate Models. Statistical Downscaling.

LISTA DE FIGURAS

Figura 1: Forçante radiativa dos RCPs	22
Figura 2: (a) Distribuição espacial dos 97 municípios do NEB com estações meteorológicas convencionais do INMET e (b) distribuição espacial dos 73 municípios utilizadas na pesquisa.	27
Figura 3: Análise de agrupamento para três áreas: (a) Distribuição espacial dos municípios, grupo G1 destacado em vermelho, grupo G2 em azul e grupo G3 em verde; (b) dendograma dos grupos e (c) grupos selecionados em três diferentes níveis.....	38
Figura 4: Distribuição dos municípios com estações meteorológicas utilizadas para aplicação do modelo agrometeorológico, identificados a cada grupo homogêneo de produtividade do feijão ao qual pertencem: G1, G2 e G3.	38
Figura 5: Produtividades observadas e simuladas do feijão nas cidades de (a) São João do Piauí (G1), (b) Campina Grande (G2) e (c) Cabrobó (G3). Respectivos parâmetros de calibração do modelo indicados em destaque nos gráficos.	42
Figura 6: Da esquerda para a direita: climatologia a partir de dados observados da precipitação acumulada anual, do trimestre dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera).	45
Figura 7: Similar a Figura 6, mas para o modelo CANESM2.....	45
Figura 8: Similar a Figura 6, mas para o modelo CNRM-CM5.....	46
Figura 9: Similar a Figura 6, mas para o modelo GFDL-ESM2M	46
Figura 10: Similar a Figura 6, mas para o modelo IPSL-CM5A-MR.....	46
Figura 11: Similar a Figura 6, mas para o modelo MPI-ESM-MR.....	46
Figura 12: Similar a Figura 6, mas para o modelo NORESM1-M.	47
Figura 13: Similar a Figura 6, mas para o modelo ENSEMBLE.....	47
Figura 14: Diferença entre climatologias simuladas pela média de todos os modelos (ensemble) e obtida das observações no período 1979-2000.	47
Figura 15: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para São Luís (MA).	48
Figura 16: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Teresina (PI).	48
Figura 17: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Fortaleza (CE).....	48

Figura 18: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Natal (RN).	49
Figura 19: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para João Pessoa (PB).	49
Figura 20: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Recife (PE).	49
Figura 21: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Maceió (AL).	49
Figura 22: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Aracajú (SE).	50
Figura 23: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Salvador (BA).	50
Figura 24: Da esquerda para a direita: climatologia a partir de dados observados da temperatura máxima anual, do trimestre dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera).	52
Figura 25: Da esquerda para a direita: climatologia a partir do ensemble dos MCGs da temperatura máxima anual, do trimestre dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera).	52
Figura 26: Diferença entre climatologias simuladas pela média de todos os modelos (ensemble) para a temperatura mínima e obtida das observações no período 1979-2000.	52
Figura 27: Da esquerda para a direita: climatologia a partir de dados observados da temperatura mínima anual, do trimestre dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera).	52
Figura 28: Da esquerda para a direita: climatologia a partir do ensemble dos MCGs da temperatura máxima anual, do trimestre dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera).	53
Figura 29: Diferença entre climatologias simuladas pela média de todos os modelos (ensemble) para a temperatura mínima e obtida das observações no período 1979-2000.	53

Figura 30: Correlação r entre simulações e observações, para dados agregados em decênios, (a) precipitação, (b) temperaturas máximas e (c) temperaturas mínimas.....	55
Figura 31: Viés entre simulações e observações, para dados agregados em decênios, (a) precipitação (mm), (b) temperaturas máximas (°C) e (c) temperaturas mínimas (°C).	55
Figura 32: RMSE entre simulações e observações, para dados agregados em decênios, (a) precipitação (mm), (b) temperaturas máximas (°C) e (c) temperaturas mínimas (°C).	55
Figura 33: Diferenças médias anuais da precipitação acumulado do ensemble dos modelos para (a) 2011-2040, (b) 2041-2070 e (c) 2071-2100, com as médias 1979-2000.	58
Figura 34: Diferenças médias anuais das temperaturas máximas do ensemble dos modelos para (a) 2011-2040, (b) 2041-2070 e (c) 2071-2100, com as médias 1979-2000.	58
Figura 35: Diferenças médias anuais das temperaturas mínimas do ensemble dos modelos para (a) 2011-2040, (b) 2041-2070 e (c) 2071-2100, com as médias 1979-2000.	59
Figura 36: Estimativa média da produtividade do feijão, para o cenário RCP 4.5, para o calendário 1 e 3, entre o período de 2011 a 2100.	61
Figura 37: Similar à figura 36, mas para os calendários 2 e 10.	62
Figura 38: Similar à figura 36, mas para o calendário 4.	63
Figura 39: Similar à figura 36, mas para o calendário 5.	64
Figura 40: Similar à figura 36, mas para os calendários 6, 7, 8 e 9.	65

LISTA DE TABELAS

Tabela 1: Escala fenológica para o feijão.....	19
Tabela 2: Vantagens e limitações dos principais métodos de downscaling estatístico.	24
Tabela 3: Valores de Kc e Ky para o Feijão.....	31
Tabela 4: Descrição dos modelos de circulação geral (MCG) usados neste estudo.	35
Tabela 5: Metadados das estações meteorológicas do Grupo 1: Município, unidade da federação, longitude, latitude, altitude, e respectivas produtividades médias, mínima e máxima observada relativa ao período 1974-2018.....	39
Tabela 6: Mesmo da Tabela 5, mas para estações meteorológicas do Grupo 2.	40
Tabela 7: Mesmo da Tabela 5, mas para estações meteorológicas do Grupo 3.	40
Tabela 8: Calendário de plantio por Estados.	59

LISTA DE SIGLAS

ARM – Armazenamento de Água no Solo
CAD – Capacidade de campo
EMA – Erro Médio Absoluto
ETP – Evapotranspiração Potencial
ETPc – Evapotranspiração Potencial da Cultura
ETPr – Evapotranspiração Real da Cultura
GS – Programa Garantia Safra
IBGE – Instituto Brasileiro de Geografia e Estatística
INMET – Instituto Nacional de Meteorologia
IPCC – Painel Intergovernamental de Mudanças Climáticas
MAPA – Ministério da Agricultura Pecuária e Abastecimento
MCG – Modelos Climáticos Globais
MDE – Modelo de *Downscaling* Estatístico
NEB – Região Nordeste do Brasil
PDFoi- Densidade de Probabilidade das Observações
PDFpi- Densidade de Probabilidade das Previsões
Pei – Produtividade Final Estimada
Poi – Produtividade Real Observada
PR – Produtividade Real
PREC – Precipitação
PRO – Produtividades Reais Observadas
PRT – Produção Máxima Tecnológica
RCP – Caminho de Concentração Representativa
RMSE – Regressão é o Coeficiente de Determinação
RV – Razão das Variâncias
S – Desvio Padrão
SD – *Downscaling* Estatístico
SEAF – Seguro da Agricultura Familiar
TN – Temperatura Mínima
TX – Temperatura Máxima

SUMÁRIO

1. INTRODUÇÃO	15
1.1. Objetivos	17
1.1.1. Geral	17
1.1.1.2. Específicos.....	17
2. REVISÃO BIBLIOGRÁFICA	18
2.1 Clima e cultivo do feijão	18
2.2 Modelos Agrometeorológicos	20
2.3 Modelos Climáticos Globais e cenários de mudanças climáticas	21
2.3.1 Cenário RCP4.5	22
2.4 Downscaling Estatístico	23
3. MATERIAIS E MÉTODOS	27
3.1 Dados e Área de Estudo	27
3.2 Classes de Produtividade via Análise de Agrupamento	28
3.3 Modelo agrometeorológico de penalização por déficit hídrico	29
3.4 Calibração do modelo agrometeorológico	31
3.5 Downscaling Estatístico: métodos	33
3.5.1 Dados de reanálise e construção da relação preditor-preditando	34
3.5.2 Dados de cenários RCP	34
3.6 Descrição do MDE	35
4. RESULTADOS E DISCUSSÃO	37
4.1 Determinação de áreas homogêneas de produtividade	37
4.2 Calibração e validação do modelo agrometeorológico	41
4.3 Calibração e validação do modelo de downscaling estatístico	43
4.3.1. Simulação do clima presente	44
4.3.2. Validação da simulação do clima presente	53
4.4. Cenários futuros da precipitação, temperaturas máximas e mínimas	56
4.5. Cenários futuros de produtividade	59
5. CONCLUSÃO	67
6. REFERÊNCIA BIBLIOGRÁFICA	68

1. INTRODUÇÃO

O feijão é uma leguminosa muito exigente em condições climáticas, os índices pluviométricos e as temperaturas afetam diretamente seu desenvolvimento e produção. Em virtude da capacidade baixa de recuperação após a deficiência hídrica e com sistema radicular pouco desenvolvido, o feijoeiro é considerado uma planta sensível ao estresse hídrico (Fernandes e Turco, 2003).

O rendimento da produtividade de safras agrícolas, incluindo-se o feijão, está fortemente relacionado às condições climáticas. A mudança na temperatura média global provoca perturbações no ciclo da água, ocasionando uma redistribuição do recurso, aumentando a intensidade e frequência das chuvas e da temperatura de uma determinada região (Faria, 2012; Xiang Li et. Al, 2014).

Os modelos agrometeorológicos são fundamentais para representar a interação do clima com a agricultura. De acordo com Greatrex (2012) são realizados experimentos para o aprimoramento desses modelos, em virtude da tendência das mudanças climáticas. O principal objetivo desses experimentos é assegurar as representações com maior confiabilidade, e assim antever o desenvolvimento das plantas, as melhores datas para semeadura e aplicação de técnicas de manejo agrícola e previsibilidade das safras em resposta ao clima (Hanks e Rasmussen, 1982).

O Painel Intergovernamental sobre Mudanças Climáticas realizou observações experimentais de vários parâmetros ambientais para determinar a influência antrópica no clima atual. As variações na temperatura média, nos padrões de precipitação pluvial, na área coberta por neve, no nível do mar e muitas outras variáveis foram analisadas detalhadamente. Segundo o IPCC (2013), o clima global vem sofrendo um aumento da temperatura significativo nas últimas décadas, o Relatório de Avaliação Científica (AR5), afirmou que a temperatura média da superfície global aumentou 0,85 °C durante o período de 1800 a 2012, e acredita-se que um aumento adicional ocorrerá durante o século XXI dependendo do cenário climático ao qual poderá estar submetida a humanidade.

O IPCC projeta as condições médias do clima futuro usando modelos climáticos em escala global que representam o planeta em milhões de quadrículas, ou grade, que resolvem complexas equações matemáticas a fim de calcular como a energia é transferida entre os pontos de grade usando as leis da termodinâmica. Se feito corretamente, esses modelos são capazes de representar como se dá a circulação de energia no planeta, podendo ser utilizados para estimar variáveis ambientais (vento,

temperatura, umidade, etc). Esses modelos simulam condições passadas que são comparadas a registros observacionais, e no caso de recriarem adequadamente as condições passadas, pode-se avançar no tempo e projetar o que pode acontecer no futuro (Chou et al., 2007; Gidey et al., 2018).

Para “guiar” os modelos climáticos nas projeções futuras, os mesmos realizam seus cálculos baseados em cenários climáticos. O quinto relatório do IPCC (AR5, de sua sigla em inglês), lançado em 2014, trouxe a definição de novos cenários climáticos futuros, os RCPs, ou Representative Concentration Pathways (Caminhos representativos de concentração), que são um conjunto consistente de projeções baseados apenas nos componentes que afetam o forçamento radiativo, como entrada para a modelagem climática. Esses parâmetros que afetam a forçante radiativa estão relacionados a diferentes projeções populacionais, econômicas, de uso de recursos energéticos do planeta, e principalmente, das possíveis formas que essas atividades, entre outras, influenciarão nas concentrações de gases de efeito estufa, incluindo CO₂, CH₄, N₂O, VOCs, CO, SO₂, aerossóis carbonosos, HFCs, PFCs e SF₆ (Brenkert et al., 2003; Kim et al., 2006; Clarke et al., 2007; van Vuuren et al., 2011).

Os RCPs são nomeados de acordo com o nível de forçamento radiativo até o ano de 2100. Há quatro RCPs, o RCP2.6 que inclui um nível muito baixo de forçamento baseado em um cenário futuro de mitigação da concentração de gases de efeito estufa e outros agentes forçantes, o RCP4.5 e RCP6.0, de estabilização média, e um cenário representativo na continuidade e aumento de emissões de gases de efeito estufa, atingindo valores muito altos, o RCP8.5. Cada valor após a sigla RCP indica o nível de energia adicionado ao sistema climático terrestre, em W/m².

A maior parte da Região Nordeste do Brasil (NEB) insere-se no clima semiárido, característico de estiagens e secas prolongadas. Estudos recentes apontam que existe uma predominância positiva para aumento das temperaturas, o que, conseqüentemente, deve provocar aumento da evapotranspiração potencial (ETP). O aumento na ETP associado à alta variabilidade espaço-temporal da precipitação, pode incrementar efeitos de secas mais duradouras e prejudicar ainda mais as atividades agrícolas (Marengo et al., 2009; Silva, 2014a; Cunha et al., 2018).

A agricultura praticada no NEB é em sua maior parte de subsistência e de sequeiro (Silva e Silva, 2016). Os produtores, em sua maioria, são de baixa renda e não possuem condições de mecanizar o cultivo para aperfeiçoar a produtividade. O relatório do IPCC (2014), intitulado *Impactos, Adaptação e Vulnerabilidade*, alerta para os riscos

aos qual este tipo de atividade agrícola está fadado. Segundo o documento, os riscos da mudança climática provem da vulnerabilidade (falta de preparo), exposição (pessoas ou bens em perigo) e sobreposição com os riscos (tendências ou eventos climáticos desencadeantes).

1.1. OBJETIVOS

1.1.1. Geral

Analisar o impacto de mudanças climáticas na produtividade do feijão no NEB, por meio de um modelo agrometeorológico de penalização por déficit hídrico e sob condições do cenário futuro regionalizado RCP4.5 aplicado a MCGs do CMIP5 (Coupled Model Intercomparison Project Phase 5).

1.1.1.2. Específicos

- **Validar** um modelo agrometeorológico de penalização por déficit hídrico aplicado a cultura do feijão no NEB;
- **Validar** uma técnica de *downscaling* estatístico da precipitação e ETP para estações meteorológicas do NEB, a partir de previsões de MCGs para o cenário futuro de forçante radiativa RCP4.5;
- **Estimar** a produtividade da cultura do feijão no NEB, para o cenário futuro de forçante radiativa RCP4.5;
- **Quantificar** os resultados da produtividade real observada com a gerada a partir do cenário de mudanças climáticas RCP4.5.

2. REVISÃO BIBLIOGRÁFICA

2.1 CLIMA E CULTIVO DO FEIJÃO

O Brasil é o principal consumidor e maior produtor de feijão do mundo, sendo os estados do Paraná, Minas Gerais, Bahia, São Paulo e Goiás os que mais produzem essa leguminosa. De acordo com os dados disponibilizados pelo CONAB (2020) a produtividade estimada para a primeira safra do ano é de 1,05 milhão de toneladas, 6,1% superior à última safra que sofreu com adversidades climáticas, para a segunda e terceira safra estima-se um aumento de 2,5%. O calendário de colheita é organizado da seguinte forma:

- 1ª Safra – colheita de novembro a março – concentração nas Regiões Sul, Sudeste, Goiás, Piauí e Bahia.
- 2ª Safra – colheita de abril a junho – concentrações nas Regiões Nordeste, Sul, Sudeste, Mato Grosso, Rondônia e Goiás.
- 3ª Safra – colheita de agosto a outubro – concentração em Minas Gerais, Goiás, São Paulo, Bahia, Pará, Pernambuco e Alagoas.

A cultura do feijão assume grande importância socioeconômica, além de ser uma excelente fonte de proteínas, carboidratos, vitaminas e minerais, e possuir grande quantidade de fibras dietéticas, baixa quantidade de gordura (2% de óleo em média) e não conter colesterol, o feijoeiro é alimento básico, principalmente da classe populacional de renda mais baixa, tornando-se assim, alimento indispensável nas refeições da maioria dos brasileiros (Arf et al. 1996; Arf et al. 2004).

O feijoeiro é cultivado em quase todas as regiões do Brasil, principalmente em lavouras de pequeno e médio porte onde, de modo geral, é a cultura de maior destaque, responsável pela maior fonte de renda das propriedades, como é o caso da NEB, que a prática agrícola do feijão é de subsistência, e sequeiro.

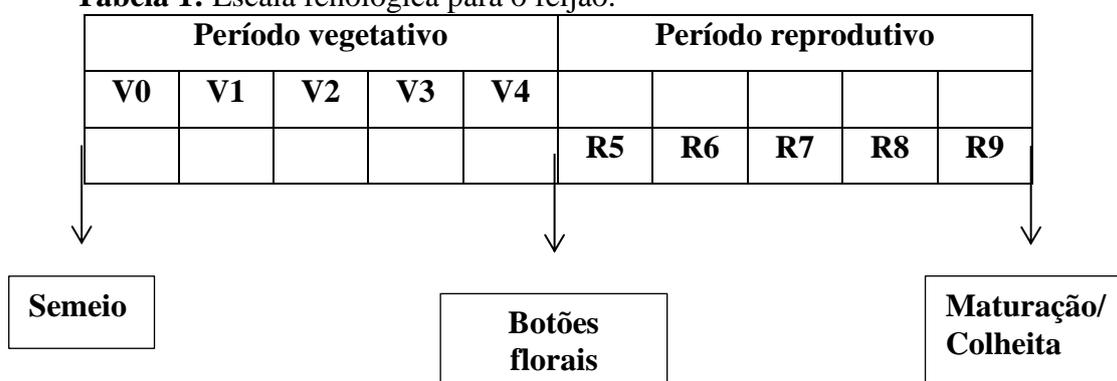
O feijão-comum é cultivado em grande diversidade de ambientes, e em muitos países, por essa razão, é uma espécie com variabilidade agrônômica, uma leguminosa muito exigente em condições climáticas, os índices pluviométricos e as temperaturas afetam diretamente seu desenvolvimento e produção. Em virtude da capacidade baixa de recuperação após a deficiência hídrica e com sistema radicular pouco desenvolvido, o feijoeiro é considerado uma planta sensível ao estresse hídrico (Campos, 2010).

As exigências do feijoeiro quanto à disponibilidade hídrica e clima são responsáveis pela grande oscilação da oferta do produto no decorrer dos anos, no Brasil,

aproximadamente 90% da produtividade é proveniente de cultivos das “águas” e da “seca”, ambos de elevado risco. Outros elementos do clima que exercem influência no crescimento e desenvolvimento dessa cultura são o fotoperíodo, vento e radiação solar (Maia, 1996).

O ciclo médio para a produtividade do feijão é de 90 dias. As fases vegetativa (V) e reprodutiva R são subdivididas em dez etapas. A germinação inicia-se na fase V0, corresponde ao dia da sementeira em solo úmido, ou em caso de solo seco, corresponde ao dia da primeira chuva ou irrigação, ou seja, no dia que há umidade para germinar. A tabela 1 representa a escala fenológica para o feijão.

Tabela 1: Escala fenológica para o feijão.



Fonte: Fernández e Guepts, 1986.

A etapa de germinação (V0) dura entorno de cinco dias e termina quando os cotilédones atinge o solo. A etapa V1 corresponde aos cotilédones fora do solo e a V2 as folhas encontram-se na posição horizontal. As etapas V3 e V4 iniciam-se quando as folhas trifoliadas estão totalmente abertas, sendo um de uma a três folhas, respectivamente. Por conseguinte, a fase reprodutiva inicia-se em R5 que é a prefloração, e se estende até a abertura da primeira flor, sendo a vagem aberta nas etapas R6 e R7. Na R8 a vagem atinge sem comprimento máximo e a R9 maturação para colheita.

Trabalhos relevantes na literatura tentam demonstrar que a temperatura é uma das condições mais importantes para o desenvolvimento do feijoeiro, muito embora existam outras condições edafoclimáticas que estejam associadas a grau de produtividade, tais como a precipitação, umidade do solo, umidade relativa do ar, ventos, etc. Martins (2017) faz uma abordagem das condições edafoclimáticas no NEB e seu impacto em safras agrícolas.

Faria (2012) analisa em sua pesquisa a influência da temperatura sobre a ramificação e o florescimento padrão da vagem. Contudo, o autor observa à produção

nas mais diversas condições climáticas. Dickson e Petzoldt (1987), faz um trabalho semelhante, no entanto, observa a germinação das sementes e as lesões provocadas em temperaturas mais baixas e solos mais úmidos.

Filgueira (2008), por sua vez, afirma que o feijão amplamente adaptável à temperatura ambiente e que se desenvolve positivamente de uma faixa de 18 a 30°C. Quando a temperatura torna-se 35°C, a produtividade diminui significativamente, pois o pólen é prejudicado, acarretando vagens deformadas.

Para definir a melhor época de plantio o zoneamento agroclimático é uma alternativa necessária de acordo com as limitações de cada região. As simulações com modelos agros meteorológicos também possibilitam avaliar a viabilidade da produtividade futura.

2.2 MODELOS AGROMETEOROLOGICOS

A agricultura é umas das atividades mais importantes do Brasil, e umas das mais afetadas por condições climáticas. Os modelos agrometeorológicos são ferramentas de grande potencial, que permite simulações para diferentes áreas e situações. Além de permitir o estudo do comportamento da interação dos fatores naturais com a agricultura.

O conceito de modelo é bem definido por Witt (1978), mas antes é necessário que se faça a separação dos termos sistemas, modelos e simulações, conforme Parizi (2010, p. 46):

Sistema é o conjunto de componentes e suas inter-relações, que são agrupados com o objetivo de estudar alguma parte do mundo real, sendo que a seleção desses componentes depende dos objetivos do estudo; O modelo é a representação matemática de um sistema ou um processo, enquanto que modelagem é o processo de desenvolvimento dessa representação; Simulação inclui os processos necessários para a operacionalização do modelo ou a solução do modelo visando simular o que acontece no sistema.

Sob essa perspectiva, os modelos devem aproximar-se ao máximo do sistema real e conter maior parte dos aspectos importantes nos processos envolvidos.

Os modelos agrometeorológicos são equações matemáticas, empíricas ou mecánísticas, que visam simular a realidade e representar o desenvolvimento das plantas, para antever sua produtividade em função de fatores influentes (Acock, 1991; Passioura, 1996; Cheeroo-Nayamuth, 1999; Pedersen e Lauer, 2002). Na literatura, os modelos agrometeorológicos consagrados são citados por Silva (2014).

De acordo com Robertson (1983), os modelos agrometeorológicos procuram quantificar os efeitos das variações climáticas sobre o comportamento vegetal.

O modelo agrometeorológico, proposto por Doorenbos e Kassam (1979) e suas variações desenvolvidas por Rao et al (1988), foram amplamente utilizados na estimativa da produtividade de safras agrícolas.

Kaboosi (2010) afirma que o rendimento das safras agrícolas está associado ao déficit hídrico, e que este modelo descreve o comportamento das safras relacionado às variáveis meteorológicas, precipitação e ETP na produtividade, assim gerando as estimativas de perdas, de modo que seja possível prever o impacto nas condições climáticas.

Logo, para o modelo conceitual de Doorenbos e Kassam (1979) considera-se somente a influência de fatores climáticos sobre a produtividade da cultura, funcionando como medidores de eficiência. Em determinadas condições de clima, cultivo e operação, este modelo possibilita a previsão de produtividades físicas da água a serem utilizadas nas análises econômicas e são particularmente importantes em análises de produção agrícola quando a água é escassa.

2.3 MODELOS CLIMÁTICOS GLOBAIS E CENÁRIOS DE MUDANÇAS CLIMÁTICAS

Os Modelos Climáticos Globais simulam o clima global com base nos cenários futuros de gases do efeito estufa. Sua resolução horizontal média varia aproximadamente de 150 a 200 km, e a vertical varia conforme o MCGs, podendo variar até 20 níveis (Taylor et. al. 2012, Kazmi et. al. 2015). Os MCGs atuais são acoplados com modelos oceânicos, contemplando ainda processos biogeoquímicos. Estes modelos possuem alta complexidade matemática, e são bons representantes em escala global.

Apesar dos MCGs caracterizarem bem as condições climáticas globais, ainda é necessário aumentar o nível de confiabilidade em áreas com coberturas vegetais, topografias complexas, e regiões litorâneas. Diferentes técnicas de redução de escala foram desenvolvidas para auxiliar a tomada de decisões e o uso dos MCGs em níveis locais (WMO, 2002; Silva, 2014a; Saddique et al. 2019).

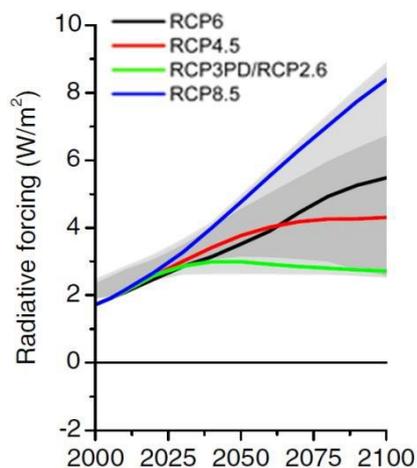
Os cenários de mudanças climáticas são projetados pelo IPCC, representam uma visão possível do desenvolvimento da humanidade relacionada à emissão de forçantes radioativas (GEE), numa combinação coerente e internamente consistente de assunções sobre forçamentos controladores como: demografia, desenvolvimento socioeconômico, e mudança na tecnologia, assim como suas interações (IPCC, 2011).

Os novos cenários de emissão atmosférica foram apresentados pelo IPCC, no quinto relatório em 2014. Em português, são denominados como “caminhos representativos de concentrações ou RCPs- *Representative Concentration Pathways*”.

No RCP2.6, ocorreria um pico na forçante radiativa de aproximadamente 3W/m^2 antes de 2100, que estabiliza e passa a diminuir. Para que esse cenário acontecesse, seria preciso estabilizar as concentrações de gases do efeito estufa até 2025. O RCP4.5 prevê uma forçante climática que atinge 4.5W/m^2 até 2050, com posterior estabilização, o aumento da temperatura terrestre poderia variar de $1,1^\circ\text{C}$ e $2,6^\circ\text{C}$. O terceiro cenário, RCP6 é mais lento que o do cenário RCP4.5 até 2050, mas contínuo e o ultrapassa até 2100. O pior cenário é o RCP8.5, com contínuo crescimento da forçante radiativa que atingirá o valor de 8.5W/m^2 até 2100 (Riahi et al., 2007; Rao e Riahi., 2006; Fujino et al., 2006; Hijioka et al.,2008; Smith e Wigley., 2006; Clarke et al.,2007; Wise et al.,2009; van Vuuren et al., 2006, 2007).

A Figura 1 mostra em detalhes estes prováveis e representativos caminhos da forçante radiativa.

Figura 1: Forçante radiativa dos RCPs



Fonte: Van Vuuren et. al (2011).

2.3.1 Cenário RCP4.5

Entre os cenários, o RCP4.5 é considerado um cenário realista, com alta probabilidade de que a humanidade siga o curso de seu desenvolvimento indo ao encontro dos pressupostos inerentes a esse cenário. Os RCPs são uma evolução dos cenários das famílias A e B do CMIP3, que tinha como mais provável cenário a ser alcançado pela humanidade o cenário A1B (Costa et al., 2021). Os cenários realistas preveem estabilização nas emissões globais de gases de efeito estufa. O RCP4.5 prevê

estabilização da forçante radiativa em 4,5 W/m² aproximadamente no ano de 2050, permanecendo nessa condição até o final do século, com aproximadamente 650 ppm de CO₂. Nesse cenário, o forçamento radiativo é definido em termos de um conjunto de seis gases de efeito estufa, dióxido de carbono (CO₂), metano (CH₄), óxido nitroso (N₂O), hidrofluorcarbonetos (HFCs), perfluorcarbonetos (PFCs) e hexafluoreto de enxofre (SF₆), além da influencia do monóxido de carbono (CO) e compostos orgânicos voláteis (VOCs), e ainda considera a influencia de aerossóis de enxofre e de carbono negro e orgânico. No RCP4.5 o gás de efeito estufa mais importante liberado antropogenicamente, o CO₂, tem concentrações de aproximadamente 550 ppm até 2100, com esse valor mais ou menos estável a partir de 2050. Esse cenário foi construído levando-se em consideração conjuntos de dados históricos, inventários de emissões de gases atualizados e informações sobre fornecimento de biomassa residual (Lamarque et al., 2010; Gregg e Smith 2010), além de um modelo de uso e cobertura do solo sofisticado em relação aos usados no CMIP3 (Wise et al., 2009).

Como os RCPs são baseados em cenários, cada um irá refletir de forma diferente um conjunto de premissas socioeconômicas. O RCP4.5 é um cenário de estabilização, portanto, pressupõe a imposição de políticas de mitigação de emissões (Clarke et al., 2007).

2.4 DOWNSCALING ESTATÍSTICO

Os modelos climáticos globais (MCGs) apresentam-se em escalas espaciais e temporais, como já mencionado. O downscaling estatístico (DE), por sua vez, é um método de refinamento de escala das projeções dos MCGs (Saddique et. al. 2019). É importante para áreas de topografia complexa, ilhas e regiões costeiras ou ainda áreas com cobertura do solo/uso da terra extremamente heterogêneos (Murphy, 2000; Wilby et al., 2004; Vrac et al., 2007).

Métodos de DE pode também ser conhecidos como métodos de desagregação ou refinamento estatístico; podem ser de natureza temporal, como por exemplo, em Mendes & Marengo (2009), espacial (Ramos, 2000) ou ainda envolvendo os dois tipos de dimensões (escalas) simultaneamente.

O DE foi desenvolvido com o objetivo de se ter uma informação mais detalhada no tempo e no espaço, de modo computacional e com grande número de preditores derivados de MCGs. Assim sendo, sua principal vantagem em relação aos modelos dinâmicos. No entanto, são necessárias séries temporais, da variável de interesse, de

dados observados diários suficientes para calibração do modelo (Silva, 2014a; Costa et al, 2020; Costa et al, 2021).

O downscaling pode ter dois tipos de abordagem, dinâmica e empírica. A primeira depende dos limites dos MCGs, inclui desenvolvimento de modelos climáticos regionais (MCRs) e geralmente são fortemente influenciados por uma região específica (Turco et al. 2011) que exige o uso de DE para projeções de mudanças climáticas. Os MCRs são bons representantes de fenômenos meteorológicos de escala global, e com o acoplamento de grades refinadas, conseguem representar de forma mais acurada fenômenos de escala local. Para tanto, na abordagem empírica ou estocástica são utilizados métodos estatísticos para estimar relações quantitativas entre preditores relacionados a fatores de larga escala (fatores que mensuram aspectos de circulação global) e variáveis prognósticas dependentes de condições fisiográficas locais (topografia, alternância terra/mar nas regiões costeiras e uso da terra) (Wilby et al., 2004; Fowler et al, 2007; Mendes e Marengo, 2009; Costa et al, 2020; Costa et al, 2021).

No documento “Guidelines for use of climate scenarios developed from statistical downscaling methods” as técnicas de downscaling estatístico são classificadas em três categorias: Métodos baseados na classificação de padrões de tempo (weather classification ou weather typing schemes); Geradores de tempo (weather generators) e Modelos de Regressão. As vantagens e limitações de cada método estão apresentadas na Tabela 2.

Tabela 2: Vantagens e limitações dos principais métodos de downscaling estatístico.

TIPO DE MÉTODO	VANTAGENS	LIMITAÇÕES
Métodos baseados na classificação de padrões de tempo (weather typing)	<ul style="list-style-type: none"> - resultam em relações com interpretação física entre os preditores de larga escala e variáveis climáticas da superfície - são versáteis, podendo ser aplicados para diferentes tipos de estudos (qualidade de ar, erosão, enchentes, etc) - uma composição desses 	<ul style="list-style-type: none"> - requer a tarefa adicional de classificação de padrões de tempo - esquemas baseados em padrões de circulação podem ser insensíveis a forçantes climáticas futuras - talvez não capturem variações de tempo dentro dos diferentes padrões de classificação

	métodos é útil para análise de eventos extremos	
Geradores de tempo (weather generators)	<ul style="list-style-type: none"> - há produção de informação para análise de incertezas - permitem interpolação espacial de parâmetros do modelo - podem produzir informação em escala de horas 	<ul style="list-style-type: none"> - há ajustamento arbitrário de parâmetros para condições de clima futuro - diversas variáveis são modeladas separadamente, sem que suas interdependências sejam consideradas.
Métodos de análise de regressão	<ul style="list-style-type: none"> - de aplicação relativamente fácil - podem utilizar todos os preditores disponíveis para posterior seleção dos mais importantes - são de fácil entendimento e há grande disponibilidade de softwares para análise 	<ul style="list-style-type: none"> - alguns modelos explicam apenas uma pequena fração da variabilidade observada - alguns desses métodos requerem relações lineares entre respostas e preditores e normalidade da variável resposta - de um modo geral, não representam adequadamente eventos extremos

Fonte: Adaptado de Wilby et. al. (2004).

No Brasil, há uma predominância do uso de métodos dinâmicos de redução de escala via desenvolvimento de modelos climáticos regionais (RCMs). A variável prognóstica mais frequente é a precipitação; entre os métodos utilizados, há uma predominância de redes neurais artificiais e análise de regressão (Ramos, 2000; Valverde et al., 2005; Valverde e Ferreira, 2006; Mendes e Marengo, 2009; Gonçalves et. al. 2010).

Por fim, o desempenho dos métodos de redução de escala é intimamente ligado à sua estrutura e configuração específica. Cada MDEs depende da variável, época e região de interesse.

Silva (2014a) afirmou que para uma representação adequada, é necessário que se tenha um estudo particular da aplicação de cada conjuntos de MDEs que precisa ser testado e validado. Assim, tornando a validação o principal componente de um MDE. Cada experimento deve conter todas as informações necessárias para o processo de redução de escala: um conjunto único de preditores, os preeditandos e um MDE (Cofiño et al, 2007). Para definir um experimento as três etapas sequenciais devem ser adotadas:

1. **Preditores:** Definição da região geográfica e preditores a serem utilizados.
2. **Preditandos:** Definição de um ou vários preeditandos a serem processados.
3. **Método de Redução de Escala:** Definição e validação de um ou vários MDE para ser aplicado no experimento.

Uma vez que a cadeia Preditores → Preditandos → Método de redução de escala tenha sido concluída, os MDEs estarão prontos para ser utilizados e aplicados a qualquer um dos MCGs disponíveis. Para a elaboração dos resultados de *downscaling* estatístico das variáveis precipitação, temperaturas máximas e mínimas desta pesquisa, foram utilizadas as funcionalidades fornecidas pelo *ENSEMBLES Downscaling Portal*, desenvolvido pelo Grupo Santander Meteorologia (<http://www.meteo.unican.es>) como assistência técnica do Predictia (<http://www.predicita.es>) como parte das atividades do projeto *ENSEMBLES* financiado pela União Européia (2004-2009, ver <https://www.meteo.unican.es/downscaling/intro.html>).

3. MATERIAIS E MÉTODOS

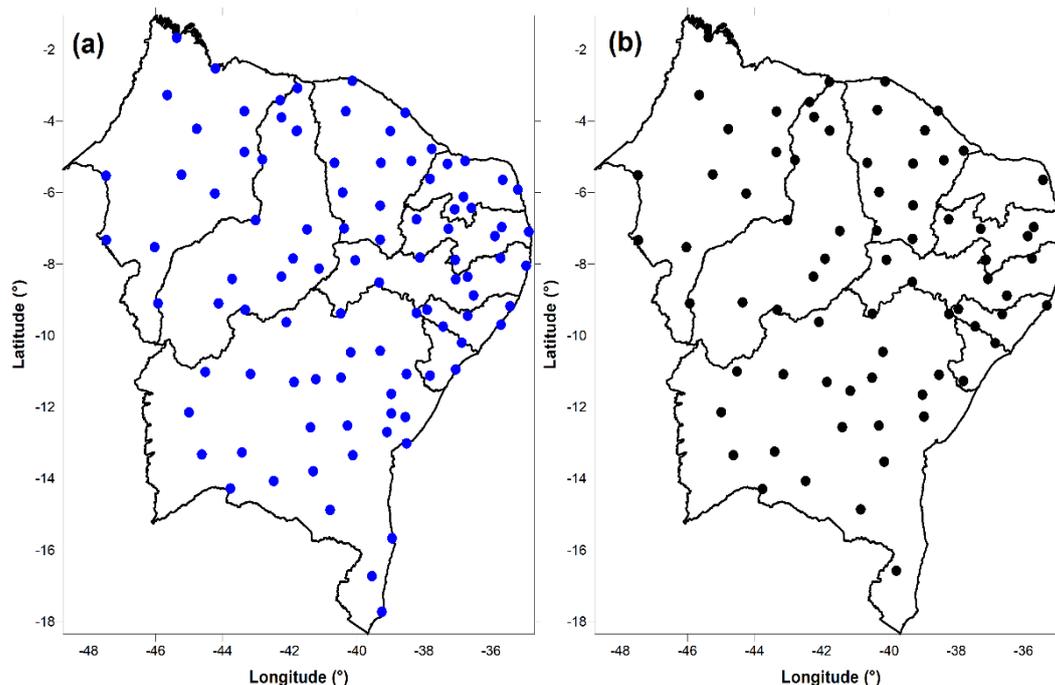
3.1 DADOS E ÁREA DE ESTUDO

Foram obtidos dados de produtividade observada do Feijão de municípios produtores de todos os Estados do NEB, disponibilizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE), através de seu Sistema IBGE de Recuperação Automática (SIDRA). Estes dados estão disponíveis desde o ano de 1974, em quilogramas por hectare. Os dados de produtividade fornecidos pelo IBGE não informam o ciclo da cultura nem a variedade plantada, desta forma, utilizou-se esta informação como sendo o rendimento obtido para determinado município considerando um ciclo médio para o feijão de 90 dias.

Os dados meteorológicos foram obtidos de 97 estações meteorológicas convencionais do INMET espaciais distribuídas no NEB. Tais dados já foram consistidos e passaram por três passos importantes para assegurar a confiabilidade: controle de qualidade, preenchimento de falhas e homogeneização, descritos em Costa et al. (2020).

Para cada um dos municípios sede das estações, foi avaliada se as séries temporais de produtividade possuíam a qualidade necessária para simulações da produtividade com um modelo agrometeorológico, sendo critérios de escolha a quantidade de falhas nas séries de produtividade e a quantidade de valores repetidos. Desta forma, dos 97 municípios com estações meteorológicas do INMET, 73 foram selecionados, sendo descartados 24 com dados de produtividade que não atendiam a um dos critérios, ou aos dois. A Figura 2a mostra a distribuição espacial das 97 estações, e na Figura 2b as 73 selecionadas para as simulações de produtividade.

Figura 2: (a) Distribuição espacial dos 97 municípios do NEB com estações meteorológicas convencionais do INMET e (b) distribuição espacial dos 73 municípios utilizadas na pesquisa.



3.2 CLASSES DE PRODUTIVIDADE VIA ANÁLISE DE AGRUPAMENTO

Trabalhos pioneiros como os de Monteiro et al. (2013; 2017) demonstraram que, independente da cultura analisada, diferentes condições de clima e de tecnologia associadas ao manejo implicam em diferentes classes de produtividade, que podem diferir muito entre si na quantidade de quilogramas por hectare produzidas (kg/ha). Para encontrar áreas (municípios/estações) homogêneas quanto à produtividade do feijão, foi empregada uma análise de agrupamento aos dados de produtividades médias do feijão em grãos de 1786 municípios do NEB.

Como descrito em Costa et al. (2020), a análise de agrupamento é uma técnica multivariada que permite aglomerar os elementos relativos aos dados de acordo com a semelhança entre eles. A avaliação da estrutura de grupos contida nos dados foi feita pela análise hierárquica de agrupamento, adotando-se como medida de semelhança a distância euclidiana (Mimmack et al., 2001) e como algoritmo de agrupamento o método de Ward. E para indicar a menor variação entre os grupos, agrupando os elementos cuja soma dos quadrados seja mínima, ou cuja soma dos erros seja mínima, utilizando-se um método não supervisionado conhecido como K-médias (Hervada-Sala e Jarauta-Bragulat, 2004; André et al, 2008), que busca agrupar as unidades experimentais segundo semelhança entre elas, aqui representadas pelas médias de produtividade entre os municípios, levando-se em conta os valores estimados pelo IBGE entre 1974 a 2018.

3.3 MODELO AGROMETEOROLÓGICO DE PENALIZAÇÃO POR DÉFICIT HÍDRICO

O modelo de simulação para produtividade das culturas utilizado segue a base teórica proposta por Doorenbos e Kassan (1979), que estabelece relações entre perdas de produtividade e deficiência hídrica no decorrer das fases fenológicas da cultura. Este modelo é composto por dois módulos: um que estima a produtividade potencial da safra ou produtividade máxima, e outra que estima o decréscimo do potencial de produtividade em função do déficit hídrico (Silva et al., 2020). Esse modelo é função da Evapotranspiração Potencial da Cultura (ETP_c), da Evapotranspiração Real da Cultura (ETR_c) e do coeficiente de penalização por déficit hídrico (ky), mostrados na equação 1.

$$Y_d = \left(1 - \frac{ETR_c}{ETP_c}\right) \times ky \times 100 \quad (1)$$

em que Y_d = penalização final, ETR_c = Evapotranspiração Real da Cultura, ETP_c = Evapotranspiração Potencial da Cultura e ky = coeficiente de penalização por déficit hídrico.

No entanto, antes de chegar à etapa final para o cálculo da penalização por déficit hídrico, estágios anteriores tem que ser expostos, e são mostrados na sequência das equações 2 a 7. Nos cálculos, o desenvolvimento da cultura do feijão é tabelado para um ciclo de 90 dias. Este ciclo contém os coeficientes da cultura (kc) e de penalização hídrica (ky), com valores diários (Doorenbos e Kassam, 1979). O cálculo da evapotranspiração da cultura (ETC) depende de um valor para o kc , e a evapotranspiração real da cultura (ETR_c) depende de um coeficiente de umidade para o solo, o ks , calculado conforme o manual de irrigação de Salassier et al (2008), abaixo.

$$ETC = ETP \times kc \quad (2)$$

$$ETR_c = ks \times ETP \times kc \quad (3)$$

$$ks = \frac{\text{Log}(ARM + 1)}{\text{Log}(ARM_c)} \quad (4)$$

$$CAD = \frac{kc}{kc_{max}} \times CAD_{max} \quad (5)$$

$$ARM = ARM_{ant} - ETR_c + \text{Precipitação} \quad (6)$$

$$ARM_c = (1 - p) \times CAD \quad (7)$$

em que: ETP = evapotranspiração; ETP_c = evapotranspiração da cultura; CAD = capacidade de campo; ARM = armazenamento de água no solo; ARM_c = armazenamento crítico (a partir do qual a planta perde produtividade); ARM_{ant} = armazenamento anterior; p = fator de disponibilidade, tabelado pela *Food and Agriculture Organization of the United Nations* (FAO); k_s = coeficiente de umidade; k_c = coeficiente de cultura; $k_{c_{max}}$ = máximo coeficiente de cultura. O ARM nunca pode ser maior do que a CAD .

Diante da formulação acima mostrada, algumas definições são necessárias. A CAD pode ser definida como a quantidade máxima de água que o solo pode armazenar na profundidade explorada pelo sistema radicular da planta, variando ao longo do ciclo das culturas em função das características físicas do solo, nas diferentes profundidades, e devido ao crescimento do sistema radicular até atingir a profundidade efetiva. Para a cultura do feijão, a profundidade do sistema radicular pode chegar, em média, a 40 cm.

A ETP é a mudança de estado da água da fase líquida para a gasosa, no caso de solos parcialmente vegetados (Berlato e Molion, 1981). A ETP foi definida por Thornthwaite (1948) como a quantidade de água utilizada por uma extensa área vegetada, em crescimento ativo, sob condições ótimas de umidade do solo. Penman (1956) definiu ETP como “a quantidade de água utilizada na unidade de tempo por uma cultura de porte baixo e verde, cobrindo totalmente a superfície, com altura uniforme e sem deficiência hídrica”. Independente das definições, em 1990 a FAO recomendou o método de Penman-Monteith como padrão na estimativa da ETP (Monteith, 1973; Smith, 1991; Silva et al, 2018).

O cálculo de ETP diária utiliza dados de temperatura máxima e mínima do ar, umidade relativa do ar, insolação e velocidade do vento medida a dois metros de altura, segundo a equação 8. O procedimento detalhado para obtenção dos parâmetros desta equação são encontrados em Pereira et al (1997) e Allen et al (1998).

$$ETP = \frac{\delta}{\delta + \gamma^*} (R_n - G) \frac{1}{\lambda} + \frac{\gamma}{\delta + \gamma^*} \frac{900}{T + 273} (e_s - e_a) \quad (8)$$

em que ETP é a evapotranspiração diária de referência (mm); λ é o calor latente de vaporização (MJ kg^{-1}); δ é a inclinação da curva da pressão de vapor saturado versus temperatura (k Pa K^{-1}); R_n é o saldo de radiação ($\text{MJ m}^{-2}\text{dia}^{-1}$); G é o fluxo de calor no solo ($\text{MJ m}^{-2}\text{dia}^{-1}$); e_s é a pressão de vapor saturado do ar (k Pa); e_a é a pressão de vapor do ar na altura z (k Pa); T é a temperatura do ar na altura z ($^{\circ}\text{C}$); γ^* é o coeficiente

psicrométrico modificado ($k \text{ Pa K}^{-1}$) = $\gamma(1 + 0,33U_2)$; U_2 é a Velocidade do vento medida a 2 metros de altura (m s^{-1}); 900 é uma Constante ($\text{k J}^{-1} \text{ kg } ^\circ\text{K}$).

3.4 CALIBRAÇÃO DO MODELO AGROMETEOROLÓGICO

O modelo agrometeorológico proposto foi calibrado para o período 2000-2010, com dados de produtividade do feijão, em kg/ha, para a área plantada de 73 municípios localizados na região NEB, de acordo com as épocas de semeadura indicadas pela Companhia Nacional de Abastecimento (CONAB), do Governo Federal.

O primeiro passo, de acordo com Monteiro et al (2013; 2017), é obter, dos dados de produtividade, a produtividade máxima chamada de Produtividade Máxima Tecnológica (PMT), estimada a partir de um ajuste estatístico baseado na série de dados das Produtividades Reais Observadas (PRO). Uma equação linear de primeiro grau ($Y=ax+b$), dos dados observados *versus* o tempo (ano) deve ser obtida, onde a linha reta indica a tendência da produtividade ao longo dos anos (TPA). Os desvios ao longo da linha de tendência são causados por fatores climáticos, de disponibilidade hídrica e de manejo da cultura. A segunda etapa consiste na determinação de um fator de correção que, quando multiplicado pela tendência da produtividade observada (TPA), elevaria os valores de produtividade em uma situação sem restrição de água. Esse fator de correção foi nomeado coeficiente de produtividade máxima tecnológica (Δp). Logo, a PMT foi calculada para cada ano "n", em função da produtividade real ajustada multiplicada por Δp : $PMT = TPA \times \Delta p$.

Desta forma, Δp é ajustado a partir de uma regressão linear sem tendência e consiste em um dos parâmetros calibrados no modelo. Os valores dos coeficientes de cultura (k_c) e de déficit hídrico (k_y), apresentados por Doorembos e Kassam (1979) para o feijão, de acordo com suas fases fenológicas, foram adaptados para a escala diária, facilitando sua posterior obtenção para a escala decendial, como mostra a Tabela 3.

Tabela 3: Valores de K_c e K_y para o Feijão.

Coeficientes para o Feijão									
Decêndios	1	2	3	4	5	6	7	8	9
K_c	0,5	0,5	0,56	0,7	0,83	0,94	1,02	1,07	1,09
K_y	0,2	0,2	0,2	0,2	0,26	0,42	0,5	0,48	0,35

A Produtividade Real (PR) é estimada a partir da relação entre o déficit relativo de água [$1 - (ETR_c/ETP_c)$], e as perdas de produtividade relativa, ponderada pelo fator de déficit hídrico (k_y), para cada fase fenológica:

$$Y_d = \frac{PR}{PMT} = \left[1 - \left(\frac{ETR_c}{ETP_c} \right) \right] \times k_y \times 100 \quad (9)$$

Neste modelo, uma alteração importante é encontrar, para qualquer estação meteorológica, de acordo com a sua classe de produtividade (muito baixa, baixa, média ou alta), um parâmetro empírico denominado "fator de déficit hídrico ajustado", ou " ky^* ", que resulta em maior ou menor resposta ao estresse hídrico. Outra diferença é a utilização da PMT. Com tais mudanças, o modelo final apresentará a seguinte equação:

$$\frac{PR}{PMT} = \left[1 - \left(\frac{ETRC}{ETPC} \right) \right] \times ky \times ky^* \times 100 \quad (10)$$

Em que, nesta equação, a PMT é usada como referência inicial para começar o procedimento de cálculo das perdas, para cada estação.

O processo de parametrização consiste no ajuste do coeficiente de produtividade máxima tecnológica (Δp), e do " ky^* ", a fim de maximizar a correlação entre as produtividades reais observadas e estimadas, e também para minimizar o erro médio absoluto (EMA) entre eles. Neste processo, ky^* começa com valor igual a 1, sendo acrescido ou reduzido de acordo com o ganho ou perda na correlação e no EMA entre as produtividades observadas e estimadas. O EMA é caracterizado pela média do módulo dos erros absolutos das estimativas, sendo dado por:

$$EMA = \frac{1}{n} \sum_{i=1}^n |Pe_i - Po_i| \quad (11)$$

onde Pe_i é a produtividade final estimada em um ano i e Po_i é a produtividade real observada pelo IBGE no ano i , e n é o número de comparações.

No modelo da Equação 10, a $ETRC$ é calculada pelo balanço hídrico sequencial, onde são computados as mudanças diárias na umidade do solo, de acordo com o método de Thornthwaite (1948).

A validação do modelo parametrizado se dará pela comparação das produtividades médias obtidas, em kg/ha no período 2001-2011, estimada pelo IBGE e simuladas pelo modelo, além do EMA e do erro médio relativo dado pela divisão do EMA pela PMO , e do coeficiente de correlação, que mede a força da relação linear entre observações (o) e simulações (s) e é definido como a covariância das duas variáveis, observadas e simuladas, dividida pelo produto de seus desvios-padrão (Equação 12).

$$r_{o,s} = \frac{Cov(o,s)}{\sigma_o} \quad 12$$

Para garantir que o valor de r realmente exprima a concordância entre observações e simulações, usou-se o teste paramétrico t-Student (Huang e Paes, 2009; Menezes, 2010) para avaliar o grau de relação entre as variáveis em questão. Uma

premissa para o uso do teste é que o tamanho da amostra, N , da qual obtém-se o valor do coeficiente de correlação, r , seja igual ou superior a 6, então o valor de t é dado por:

$$t = \frac{r}{\sqrt{(1-r^2)/(N-2)}} \quad (13)$$

A equação (14) é uma distribuição para t com $N-2$ graus de liberdade. A aplicação desta fórmula para qualquer valor de r e de N vai testar a hipótese nula de que o valor observado vem de uma população em que não existe correlação significativa entre os dados. Uma vez obtido o valor de t , pode-se extrair o coeficiente de correlação crítico (r_c), que é um valor para a qual se aceita ou não a hipótese estatística que existe correlação entre os dados simulados e observados, r_c é dado por:

$$r_c = \sqrt{\frac{t^2}{(N-2)+t^2}} \quad (14)$$

3.5 DOWNSCALING ESTATÍSTICO: MÉTODOS

O *downscaling* estatístico é um campo da ciência que permite relacionar os cenários de mudanças climáticas globais fornecidas pelos MCGs com observações históricas de variáveis de superfície locais, como a precipitação ou temperatura de estações meteorológicas em uma região de interesse (Timbal et al., 2003; Hewitson e Crane, 2006; Timbal e Jones, 2008; Benestad, 2010; Brands et al., 2011a; Brands et al., 2011b; Gutzler e Robbins, 2011; Costa et al., 2020).

Um modelo de *downscaling* estatístico (MDE) geralmente é construído por meio de uma função de transferência $R=F(L)$, com R sendo a resposta local (por exemplo, precipitação, temperatura ou evapotranspiração obtidas de uma determinada estação meteorológica), e F uma função determinística/estocástica condicionada por L , obtida a partir da relação empírica obtida da respectiva grade associada ao MCG utilizado.

O MDE escolhido para a geração das séries dos respectivos cenários foi o método dos análogos. Este método tem sido aplicado essencialmente no campo da previsão do tempo (Lorenz, 1969; Kruizinga e Murphy, 1983), e na previsão do clima a curto prazo (Barnett e Preisendorfer, 1978; van den Dool, 1994). Para fins de redução de escala, este método ainda é pouco aplicado (Zorita et al., 1995; Cubasch et al., 1996; Biau et al., 1999, Zorita e Storch, 1999), embora a sua metodologia seja simples (Costa et al., 2020; Costa et al., 2021). A circulação atmosférica em grande escala simulada por

um MCG é comparada com cada uma das observações históricas, representadas em uma grade comum de conjuntos de reanálises, e o padrão mais semelhante com o observado na reanálise é escolhido como seu análogo, com esta relação podendo ser imposta as observações realizadas por estações meteorológicas de superfície. O clima local observado simultaneamente é, então, associado ao padrão de grande escala simulado.

3.5.1 Dados de reanálise e construção da relação preditor-preditando

Os dados diários de reanálise para o período de 1979 a 2010 foram obtidos do projeto ERA-Interim (Dee *et al.*, 2011); disponíveis em uma cobertura espacial de 2,0 graus de longitude por 2,0 graus de latitude incluindo um conjunto de 23 preditores entre variáveis e níveis atmosféricos. As variáveis predictoras utilizadas e que melhor se correlacionaram com as variáveis de superfície foram a pressão média corrigida ao nível do mar (PMNM), altura geopotencial (Φ) a 500 hPa, umidade relativa (UR) em 700 hPa, ventos meridionais e zonais (V e U) em 850 hPa, temperatura (T) em 850 hPa e umidade específica (q) em 850 hPa. Uma premissa básica é que os preditores das reanálises sejam os mesmos para todos os MCGs usados para geração dos cenários futuros. O método de seleção dos preditores é consistente com os de outros estudos similares (Wilby *et al.*, 2002; Khan *et al.*, 2006; Hashmi *et al.* 2011; Mahmood e Babel 2013; Gulacha e Mulungu 2017; Meaurio *et al.*, 2017; Silva *et al.*, 2020), baseado nas variáveis predictoras que mais se mostram correlacionadas aos predictandos.

Uma vez que a cadeia Preditores \rightarrow Predictandos \rightarrow MDE tenha sido concluída, os MDEs estarão prontos para ser utilizados e aplicados a qualquer um dos MCGs para a geração das séries temporais das estações de superfície em um horizonte futuro, para qualquer cenário de mudança climática (Gutierrez *et al.*, 2013; Silva *et al.*, 2020).

3.5.2 Dados de cenários RCP

Seis saídas de MCGs (CanESM2, CNRM-CM5, IPSL-CM5A-MR, GFDL-ESM2M, MPI-ESM-MR e NorESM1-M) com o cenário RCP4.5 foram processados usando as funcionalidades fornecidas pelo software desenvolvido pelo Grupo Santander Meteorologia (<http://www.meteo.unican.es>), como parte das atividades do projeto ENSEMBLES financiado pela União Europeia (Cofiño *et al.*, 2007). O RCP4.5 ilustra um RCP de forçamento radiativo em ascensão, subindo para $\sim 4,5 \text{ Wm}^{-2}$ até 2070 (Moss *et al.*, 2010).

Uma das etapas mais importantes é avaliar se os MCGs capturam bem o ciclo anual da precipitação e temperatura. Os dados do MCG foram interpolados na mesma

resolução da grade ($2,0^\circ \times 2,0^\circ$) dos dados do ERA-Interim para eliminar os vieses que podem ter ocorrido pelas contradições presentes nessa escala. Então, o ERA-Interim e todos os preditores dos MCGs foram normalizados com a média e o desvio padrão adquiridos a partir do período histórico de 1979-2000. A Tabela 4 fornece as características gerais de cada MCG, como nome, instituto de desenvolvimento e resolução da grade.

Tabela 4: Descrição dos modelos de circulação geral (MCG) usados neste estudo.

Instituto de desenvolvimento-País	MCG	Resolução da grade
Canadian Centre for Climate Modelling and Analysis - Canada	CanESM2	$2.7906^\circ \times 2.8125^\circ$
Centre Europeen de Recherche Meteorologique - França	CNRM-CM5	$1.4008^\circ \times 1.40625^\circ$
Geophysical Fluid Dynamics Laboratory - Estados Unidos	GFDL-ESM2M	$2.0225^\circ \times 2.5^\circ$
Institutte Pierre Simon Laplace - França	IPSL-CM5A-MR	$1.2676^\circ \times 2.5^\circ$
Max Planck Institute - Alemanha	MPI-ESM-MR	$1.8653^\circ \times 1.875^\circ$
Norwegian Climate Center's Earth System Model - Noruega	NorESM1-M	$1.8947^\circ \times 2.5^\circ$

3.6 DESCRIÇÃO DO MDE

O MDE empregado foi o método dos análogos (Gutierrez *et al.*, 2013; Silva *et al.*, 2020; Costa *et al.*, 2020; Costa *et al.*, 2021). Uma vez construída a relação entre preditores e predictandos, pode-se aplicar esta relação às variáveis observadas na estação meteorológica. No MDE usado, padrões análogos são filtrados por funções ortogonais empíricas (FOE), especificando um estado local coerente com um estado simultâneo de grande escala. Como exemplo, as anomalias da circulação atmosférica, por exemplo, representadas por (f) do campo da Pressão ao Nível do Mar (PNM), são descritos por poucos padrões principais de FOE:

$$f(i, t) = \sum_{k=1}^n x_k(t) g_k + \epsilon_t \quad (15)$$

onde i é um índice de ponto de grade, t é o tempo, g_k é o padrão de ordem k da FOE, $x_k(t)$ é a amplitude deste padrão no tempo t , n representa o número de padrões de FOE retidos, e ϵ é a parte da variabilidade não descrita pelos principais padrões n , considerado pequeno. Os análogos são pesquisados apenas dentro do espaço gerado por estas n FOE padrões.

Os dados diários são analisados em decêndios, acumulados de chuva e média das temperaturas máximas e mínimas em 10 dias, com um decêndio para cada mês do ano, ou 36 decêndios anuais. O período de calibração do MDE é o climatológico 1979-2000, para verificar a habilidade dos modelos em simular os ciclos anuais. A validação é realizada para o período 2001-2010. Os coeficientes usados para essa fase de validação do MDE foram divididos em: estatística descritiva, medida de precisão e similaridade das distribuições. Na estatística descritiva temos a média e o desvio padrão, que são obtidos através das equações 16 e 17. Nas medidas de precisão temos o coeficiente de correlação (equação 12 mostrada no tópico 3.4) e RMSE (Raiz do erro médio quadrático) na equação 18. E para analisar a similaridade das distribuições temos a razão das variâncias (equação 19) e o PDFescore (equação 20).

$$M = \frac{1}{N} \sum_{i=1}^N xi \quad (16)$$

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (xi - \bar{x})^2} \quad (17)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Pi - Oi)}{n}} \quad (18)$$

$$RV = \frac{\sigma p^2}{\sigma o^2} \quad (19)$$

$$PDFescore = \sum_{i=1}^{200} (PDFpi - PDFoi) \quad (20)$$

4. RESULTADOS E DISCUSSÃO

4.1 DETERMINAÇÃO DE ÁREAS HOMOGÊNEAS DE PRODUTIVIDADE

A análise de agrupamento foi empregada aos dados de produtividade média anual do feijão em grão (kg/ha) de 1786 municípios do NEB a fim de identificar padrões de homogeneidade, e assim, avaliar os municípios por faixas de produtividades.

Os testes variaram para 2 a 5 grupos, sendo selecionados e considerados satisfatórios, de acordo com a similaridade entre os valores observados, 3 grupos, como mostra a Figura 3a, identificados por Grupo 1 (G1), Grupo 2 (G2) e Grupo 3 (G3). A Figura 3b mostra um dendograma bi-dimensional dos grupos determinados pelo método aglomerativo. Nesse diagrama, cada ramo representa um elemento, enquanto a raiz representa o agrupamento de todos os elementos. O gráfico mostrado na Figura 3c destaca os grupos selecionados, de acordo com uma distância de corte para definição dos grupos, com base em conhecimento prévio da natureza e estrutura dos dados.

A média de produtividade encontrada para cada grupo homogêneo apontou os seguintes valores: média de 237 kg/ha e valores mínimo e máximo de 31 a 610kg/ha relativo ao G1; média de 415 kg/ha e valores mínimo e máximo de 82 a 984kg/ha relativo ao G2 e média de 856 kg/ha e valores mínimo e máximo de 201 a 1732kg/ha relativo ao G3.

Com estes resultados foi possível identificar, entre os 73 municípios selecionados para a aplicação do modelo agrometeorológico de produtividade, segundo os critérios apresentados no tópico 3.1, a qual classe ou grupo homogêneo pertencem (Figura 3). Tanto na Figura 3a quanto na Figura 4, é possível perceber que a maior parte dos municípios classificados como G1, ou de baixa produtividade (destacados em vermelho na Figura 2a), entre 0 a 300 kg/ha/ano localiza-se na faixa norte do NEB entre o centro-norte dos estados do Piauí, quase todo o Ceará com exceção de municípios localizados no extremo leste desse Estado, mesorregiões central e agreste potiguar, parte da mesorregião da Borborema na Paraíba, mesorregiões sertão, são-Francisco e agreste pernambucanos, e alguns municípios espalhados entre as mesorregiões dos sertões alagoano e sergipano na faixa central da Bahia. Municípios agrupados na classe G2, ou de média produtividade entre 300 a 600 kg/ha/ano (destacados em azul), localizam-se naturalmente na fronteira entre municípios com baixa (G1) e alta produtividade (G3, em verde na Figura 2a e produtividade média anual superior a 600kg/ha). Vale ressaltar que a classe, ou grupo G3, localiza-se majoritariamente nas faixas leste do NEB do Rio Grande do Norte ao sul da Bahia, centro-oeste do Maranhão e oeste da Bahia, com

municípios localizados claramente na fronteira entre os estados da Bahia e Pernambuco, onde provavelmente os produtores se beneficiam do uso da irrigação com águas do Rio São Francisco.

Figura 3: Análise de agrupamento para três áreas: (a) Distribuição espacial dos municípios, grupo G1 destacado em vermelho, grupo G2 em azul e grupo G3 em verde; (b) dendograma dos grupos e (c) grupos selecionados em três diferentes níveis.

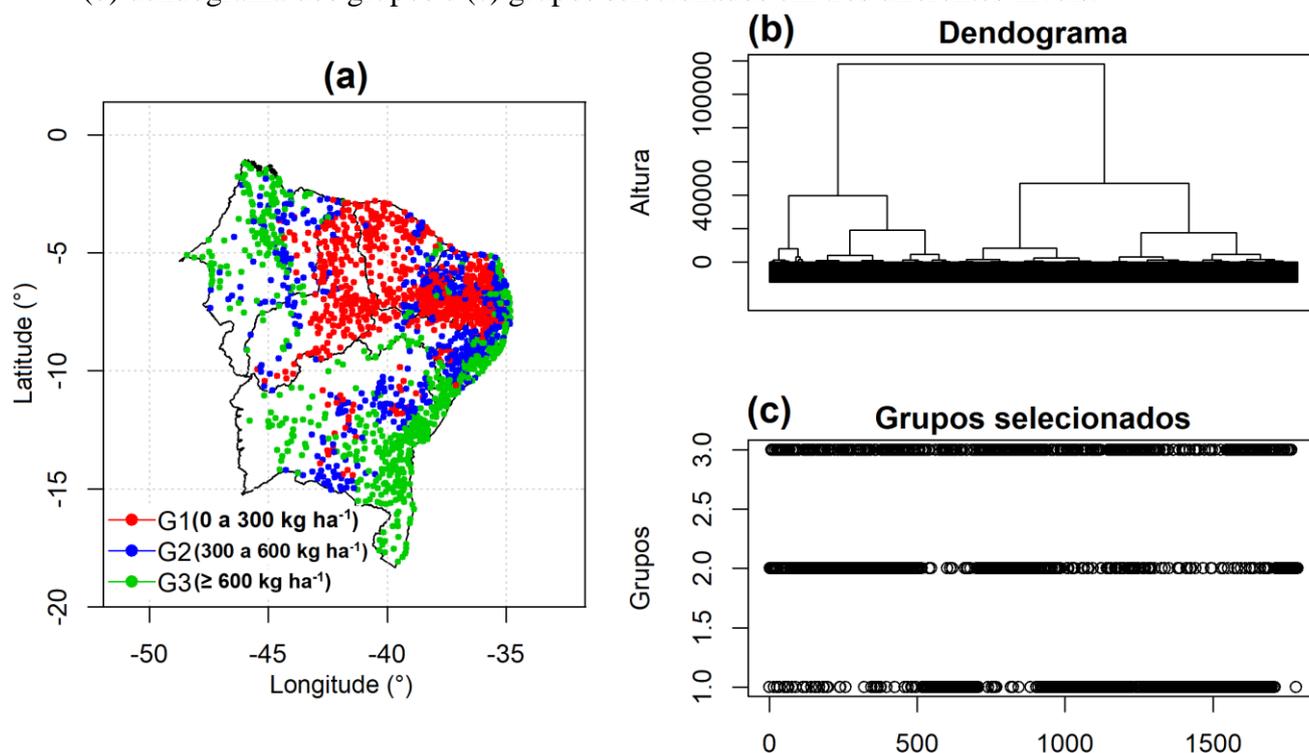
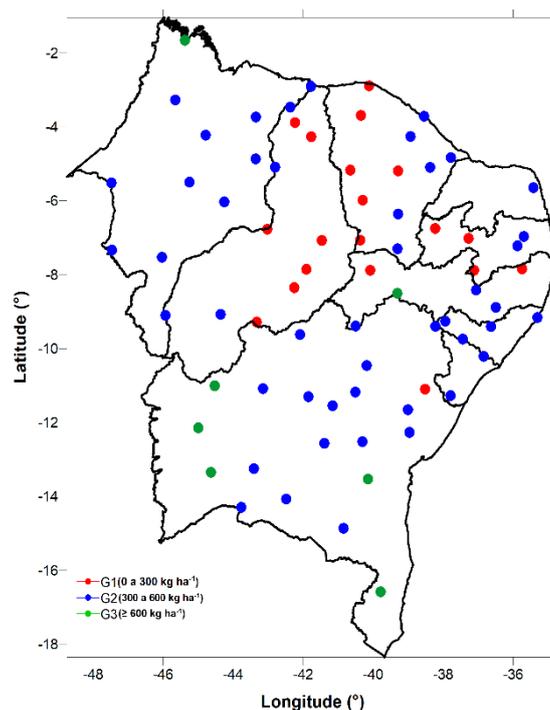


Figura 4: Distribuição dos municípios com estações meteorológicas utilizadas para aplicação do modelo agrometeorológico, identificados a cada grupo homogêneo de produtividade do feijão ao qual pertencem: G1, G2 e G3.



As Tabelas 5, 6 e 7 mostram, para cada município com estação meteorológica do INMET nos respectivos grupos, as produtividades médias anuais, mínimas e máximas, além dos metadados de cada estação, com respectivos valores de latitude e longitude em graus, altitude em metros e unidade da federação a qual pertencem.

Tabela 5: Metadados das estações meteorológicas do Grupo 1: Município, unidade da federação, longitude, latitude, altitude, e respectivas produtividades médias, mínima e máxima observada relativa ao período 1974-2018.

Município	UF	Lon (°)	Lat (°)	Alt (m)	Produtividade Média (kg/ha)	Produtividade Mínima (kg/ha)	Produtividade Máxima (kg/ha)
Cipó	BA	-38,52	-11,10	145,3	298	54	705
Acaraú	CE	-40,12	-2,89	16,5	242	109	505
Campos Sales	CE	-40,37	-7,07	583,5	263	35	740
Crateús	CE	-40,65	-5,17	296,8	241	20	570
Quixeramobim	CE	-39,29	-5,19	79,5	276	36	583
Sobral	CE	-40,35	-3,69	109,6	247	18	600
Tauá	CE	-40,30	-5,99	398,8	188	16	504
Monteiro	PB	-37,12	-7,88	603,7	156	5	500
Patos	PB	-37,27	-7,02	249,1	204	20	500
Sousa	PB	-38,23	-6,75	233,1	296	14	1000
Ouricuri	PE	-40,08	-7,88	459,3	233	20	600
Surubim	PE	-35,75	-7,85	418,3	299	24	900
Caracol	PI	-43,33	-9,28	522,8	247	13	636
Esperantina	PI	-42,23	-3,89	87,1	179	20	379
Floriano	PI	-43,02	-6,77	123,3	270	63	510
Picos	PI	-41,47	-7,08	374,2	187	33	488
Piripiri	PI	-41,77	-4,27	207,9	283	71	656
São João do Piauí	PI	-42,26	-8,35	235,3	200	10	482
Simplício Mendes	PI	-41,91	-7,85	302,0	195	4	733

Tabela 6: Mesmo da Tabela 5, mas para estações meteorológicas do Grupo 2.

Município	UF	Lon (°)	Lat (°)	Alt (m)	Produtividade Média (kg/ha)	Produtividade Mínima (kg/ha)	Produtividade Máxima (kg/ha)
Água Branca	AL	-37,94	-9,26	605,3	309	13	631
Palmeira dos Índios	AL	-36,63	-9,41	274,9	362	79	713
Pão de Açúcar	AL	-37,44	-9,74	19,1	351	25	990
Porto de Pedras	AL	-35,30	-9,16	50,0	497	200	1091
Barra	BA	-43,15	-11,09	401,6	463	57	979
Bom Jesus da Lapa	BA	-43,41	-13,25	331,7	444	34	1091
Caetité	BA	-42,49	-14,07	882,5	419	27	912
Carinhanha	BA	-43,77	-14,30	450,2	415	50	1500
Feira de Santana	BA	-38,97	-12,27	230,7	470	72	1238
Irecê	BA	-41,85	-11,30	747,2	342	20	1033
Itaberaba	BA	-40,31	-12,52	249,9	586	113	1488
Jacobina	BA	-40,51	-11,18	484,7	389	21	720
Lençóis	BA	-41,39	-12,56	438,7	405	33	1489
Morro do Chapéu	BA	-41,16	-11,55	1003,3	408	10	960
Paulo Afonso	BA	-38,22	-9,40	252,7	414	26	1200
Remanso	BA	-42,08	-9,62	400,5	488	90	1980
Senhor do Bonfim	BA	-40,19	-10,46	558,2	403	29	600
Serrinha	BA	-39,01	-11,66	359,6	373	57	720
Vitória da Conquista	BA	-40,84	-14,86	874,8	510	78	991
Barbalha	CE	-39,30	-7,30	409,0	401	78	843
Fortaleza	CE	-38,54	-3,72	26,5	327	67	700
Guaramiranga	CE	-38,93	-4,26	870,7	301	68	616
Iguatu	CE	-39,29	-6,36	217,7	372	75	888
Jaguaruana	CE	-37,78	-4,83	11,7	442	76	1163
Morada Nova	CE	-38,37	-5,10	43,6	417	113	1100
Alto Parnaíba	MA	-45,93	-9,10	285,1	382	50	1000
Bacabal	MA	-44,78	-4,22	25,1	560	185	958
Balsas	MA	-46,04	-7,53	259,4	592	59	2231
Barra do Corda	MA	-45,25	-5,50	153,0	437	42	938
Carolina	MA	-47,46	-7,34	192,8	402	41	953
Caxias	MA	-43,36	-4,87	103,6	310	102	573
Chapadinha	MA	-43,35	-3,74	103,5	382	117	621
Colinas	MA	-44,25	-6,03	179,8	400	153	652
Imperatriz	MA	-47,48	-5,52	123,3	444	79	733
Zé Doca	MA	-45,66	-3,27	45,3	463	283	933
Areia	PB	-35,70	-6,96	574,6	388	70	771
Campina Grande	PB	-35,87	-7,22	547,6	301	53	533
Arcoverde	PE	-37,06	-8,42	680,7	343	33	1636
Garanhuns	PE	-36,50	-8,88	822,8	344	60	731
Petrolina	PE	-40,50	-9,39	370,5	571	90	1586
Bom Jesus do Piauí	PI	-44,36	-9,07	440,0	516	257	987
Luzilândia	PI	-42,37	-3,47	49,0	350	58	673
Parnaíba	PI	-41,78	-2,91	79,5	300	60	836
Teresina	PI	-42,80	-5,09	74,4	309	50	906
Ceará-Mirim	RN	-35,42	-5,64	61,4	440	50	889
Itabaianinha	SE	-37,79	-11,27	208,0	444	293	755
Propriá	SE	-36,84	-10,21	19,9	501	150	725

Tabela 7: Mesmo da Tabela 5, mas para estações meteorológicas do Grupo 3.

Município	UF	Lon (°)	Lat (°)	Alt (m)	Produtividade Média (kg/ha)	Produtividade Mínima (kg/ha)	Produtividade Máxima (kg/ha)
Barreiras	BA	-45,00	-12,14	439,3	1452	96	2699
Correntina	BA	-44,63	-13,35	549,5	938	200	2245
Guaratinga	BA	-39,78	-16,58	194,7	781	499	1186
Itiruçu	BA	-40,15	-13,53	755,6	670	195	1240
Santa Rita de Cássia	BA	-44,53	-11,01	450,3	649	56	2100
Turiação	MA	-45,38	-1,66	44,1	667	303	1151
Cabrobó	PE	-39,31	-8,51	341,5	834	60	1500

4.2 CALIBRAÇÃO E VALIDAÇÃO DO MODELO AGROMETEOROLÓGICO

A análise de agrupamento empregada aos dados de produtividade média anual do feijão em grão (kg/ha) permitiu a distinção de três grupos específicos, o que engloba municípios com baixa produtividade, de 0 a 300 kg/ha/ano (G1), o de média produtividade com 300 a 600 kg/ha/ano (G2), e o de alta produtividade com mais de 600 kg/ha/ano (G3). Entre os municípios, a produtividade mínima média observada foi de 156 kg/ha/ano em Monteiro na Paraíba, enquanto a máxima média observada foi de 1452 kg/ha/ano em Barreiras na Bahia. A produtividade elevada observada em municípios do oeste baiano está relacionada ao MATOPIBA (Salvador e Brito, 2018).

Esta variabilidade entre as produtividades médias observadas reflete como dois importantes fatores influenciam a produtividade do feijão entre os municípios: o grau de vulnerabilidade ao estresse hídrico e a influência tecnológica. Por isso, foram calculados o coeficiente de rendimento máximo tecnológico (Δp) e o fator de déficit hídrico ajustado (ky^*) para cada município, durante o processo de calibração do modelo de produtividade. Estes parâmetros permitiram simular, com mais precisão, a produtividade em cada ano.

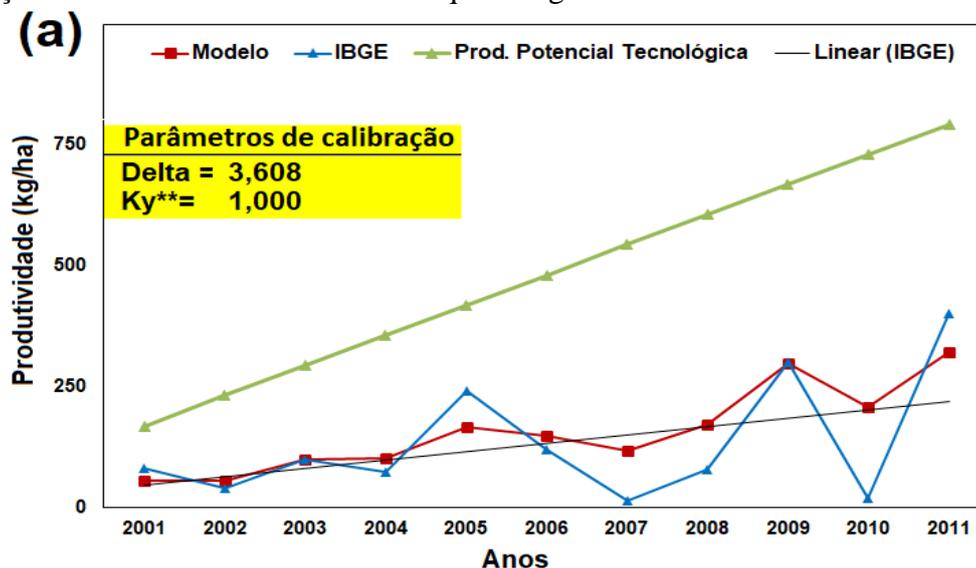
Primeiro, é obtida uma estimativa da produtividade, para cada município, sem levar em consideração o rendimento máximo tecnológico (Δp) e o fator de déficit hídrico ajustado (ky^*), pela formulação clássica proposta por Doorenbos e Pruitt (1997), cuja penalização depende apenas da relação entre ETR_c e ETP_c . Em seguida, ao se calcular a produtividade potencial tecnológica, com a correção das tendências de rendimento ao longo do tempo, a precisão das estimativas tanto dos baixos quanto dos altos rendimentos é melhorada e podem-se aproximar os valores de perda percentual da produtividade aos valores observados pelo IBGE, calibrando o modelo e encontrando os valores de Δp e ky^* . Em alguns casos, onde o fator de estresse hídrico não se torna muito relevante, o valor de ky^* continua igual a 1 (Monteiro et al., 2013; Silva 2014; Monteiro et al., 2017; Silva et al., 2020a,b).

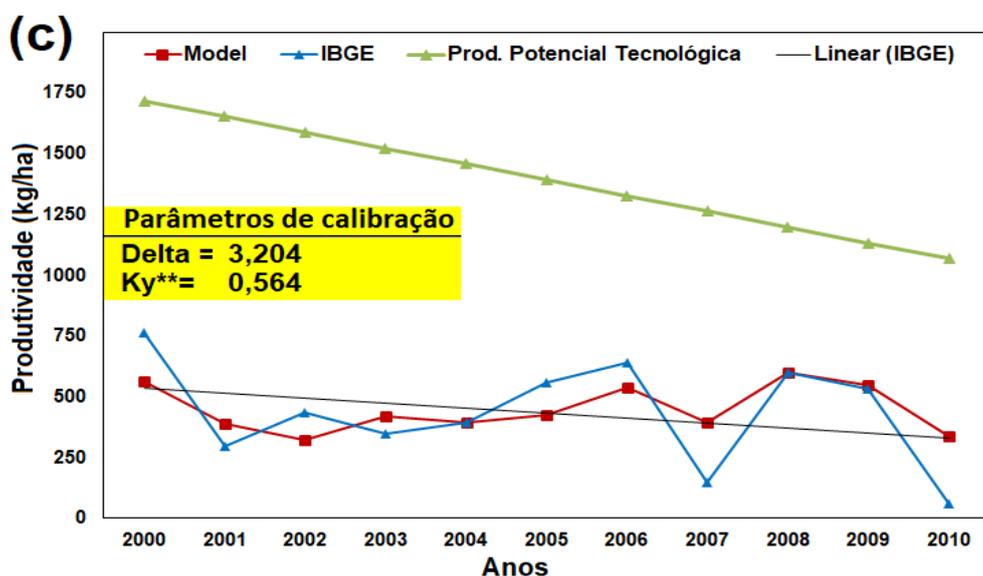
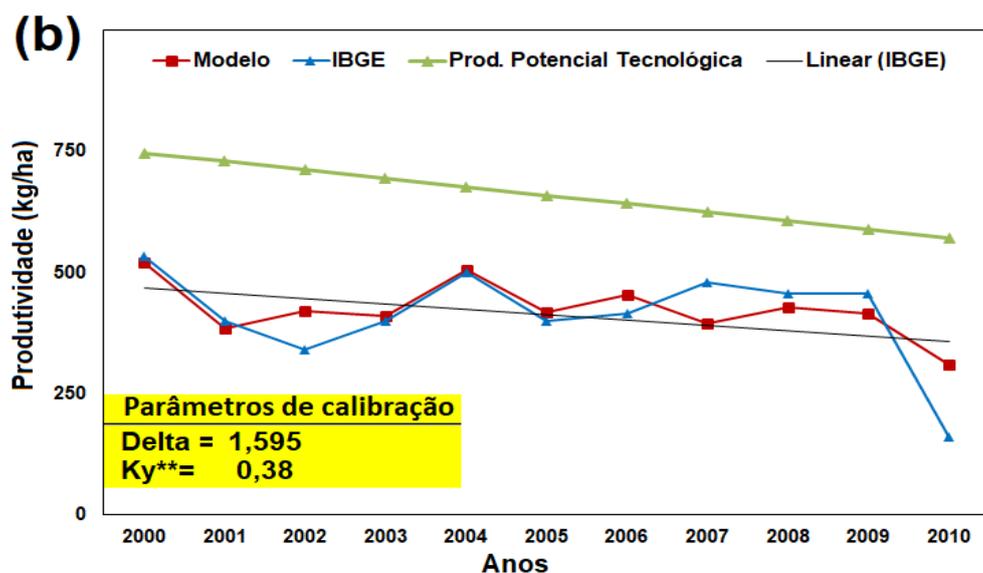
Para exemplificar a importância destes parâmetros na simulação da produtividade, os gráficos da Figuras 5 mostram as curvas, entre 2000 e 2010, da estimativa de produtividade versus a produtividade observada nos municípios de São João do Piauí (G1), Campina Grande (G2) e Cabrobó (G3) após o processo de calibração. Para o tamanho da amostra, ou seja, $N=11$ anos de comparações, o teste de significância estatística aponta como valor de correlação crítica $r_c=0,61$ a um nível de confiança de 95%. Em São João do Piauí (Figura 4a), foi obtida uma correlação entre as

observações e simulações ($r_{o,s}$) igual a 0,78, com tendência positiva no período como indicado pela reta de produtividade potencial tecnológica. Em Campina Grande (Figura 5b), foi obtida $r_{o,s}$ igual a 0,81, com tendência negativa no período como indicado pela reta de produtividade potencial tecnológica, e para Cabrobó (Figura 5c), foi obtida $r_{o,s}$ igual a 0,77, também com tendência negativa no período indicado pela reta de produtividade potencial tecnológica.

Em trabalho similar, Silva et al (2020b) calibraram esse modelo agrometeorológico para as produtividades relacionadas a cultura do algodão em 23 municípios do NEB, obtendo altas correlações entre a produtividade observada e estimada e pequenos valores de erros médios absolutos, que relacionam a média obtida das estimativas em um período contra as médias observadas. Lima et al (2021), aplicaram esse modelo a cultura do milho para o Estado de Alagoas e determinaram as áreas mais aptas ao seu cultivo, as que apresentam as maiores produtividades, e também a extensão das melhores janelas de cultivo nas três mesorregiões de Alagoas.

Figura 5: Produtividades observadas e simuladas do feijão nas cidades de (a) São João do Piauí (G1), (b) Campina Grande (G2) e (c) Cabrobó (G3). Respective parâmetros de calibração do modelo indicados em destaque nos gráficos.





4.3 CALIBRAÇÃO E VALIDAÇÃO DO MODELO DE *DOWNSCALING* ESTATÍSTICO

Nesta seção discutir-se-ão os resultados obtidos no processo de calibração e validação do MDE utilizado para a geração de cenários futuros. Em seguida serão mostrados os mapas dos desvios das médias de precipitação e temperaturas máximas e mínimas obtidas para o período 2011-2100 (2011-2040; 2041-2070 e 2071-2100) em relação às médias das observações das estações no período 1979-2000, para o cenário RCP4.5 a partir do processamento dos MCGs usados nesta pesquisa.

4.3.1. Simulação do clima presente

Um dos critérios comumente usados na avaliação de desempenho de qualquer MDE é se a condição histórica (observação) pode ser ou não replicada. Portanto torna-se indispensável que os métodos usados para transferir os resultados de MCGs para estações meteorológicas gerem séries temporais de precipitação e temperatura que tenham as mesmas propriedades dos dados meteorológicos observados, resultando em boa correlação entre ambos e que apresentem habilidade em caracterizar a climatologia de um período de referência.

A Figura 6 mostra a climatologia do período de referência 1979-2000 referente à dados observados para a precipitação acumulada média anual e trimestres representativos das estações do ano: dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera). Percebe-se a variação natural entre períodos secos e chuvosos. Os extremos anuais variaram de 502mm em Macau-RN, com maior contribuição do outono, a 2291mm em Recife-PE, com maior contribuição do inverno para a acumulado anual. O interior do semiárido nordestino apresentou nesse período de referência acumulados anuais da ordem de 520mm, como em Petrolina-PE e Paulo Afonso-BA. Além do litoral leste do NEB, as maiores médias anuais se concentram no norte do Maranhão, onde ultrapassam os 2000mm. Na análise sazonal, as chuvas de verão se concentram no oeste do NEB (Maranhão, centro-oeste do Piauí e oeste da Bahia), no norte do NEB no outono e leste no outono/inverno, que caracteriza o período mais seco do interior semiárido. A primavera é seca no norte e leste da região e registra as primeiras ocorrências de chuvas no extremo oeste do NEB.

Da Figura 7 a Figura 12, na sequência, tem-se a mesma análise obtida a partir do MDE aplicado ao período de referência 1979-2000 para cada MCG: CanESM2, CNRM-CM5, GFDL-ESM2M, IPSL-CM5A-MR, MPI-ESM-MR e NORESM1-M. Todos os modelos representam bem as características da climatologia observada, com variações anual e sazonal entre eles. Dessa forma, apresenta-se na Figura 13 o ensemble dos modelos, que nada mais é que a média simples entre todos os modelos e é uma forma simples e direta de analisar a habilidade média de um conjunto de modelos em representar a climatologia histórica (Silva et al., 2020; Costa et al., 2020; Costa et al., 2021).

A Figura 14 mostra as diferenças entre o ensemble e as observações em níveis anual e sazonal. Em média, os MCGs subestimam a precipitação na maior parte do

NEB, de 50 a 100mm na porção central da região, e de 100 a 200mm no centro-sul do Maranhão, sul do Piauí e oeste da Bahia, e no extremo do litoral norte entre Maranhão e Ceará. No leste do NEB a variação é menor, inclusive observando-se superestimativa no leste do estado do Rio Grande do Norte. De uma forma geral, a maior tendência de subestimar a precipitação acumulada anual já foi verificada por outros autores que identificaram um viés seco na maior parte dos MCGs do CMIP5 para todo o norte da América do Sul, relacionado à uma deficiência na representação da precipitação associada a Zona de Convergência Intertropical (Hirota e Takayabu., 2013; Tian e Dong., 2020).

Esses resultados mostram que o MDE foi muito eficiente para representar o ciclo anual médio da precipitação em todo o NEB no período de referência, uma variável normalmente complexa devido a sua natureza discreta (as séries diárias apresentam ou zeros-não chuva, ou qualquer outro valor diferente de zero). A literatura indica que este é um fator fundamental para impor confiança as projeções regionalizadas da precipitação simulada para o futuro mediante cenários de mudanças climáticas (Chou et al., 2014; Gidey et al., 2018; Arias et al., 2021).

Figura 6: Da esquerda para a direita: climatologia a partir de dados observados da precipitação acumulada anual, do trimestre dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera).

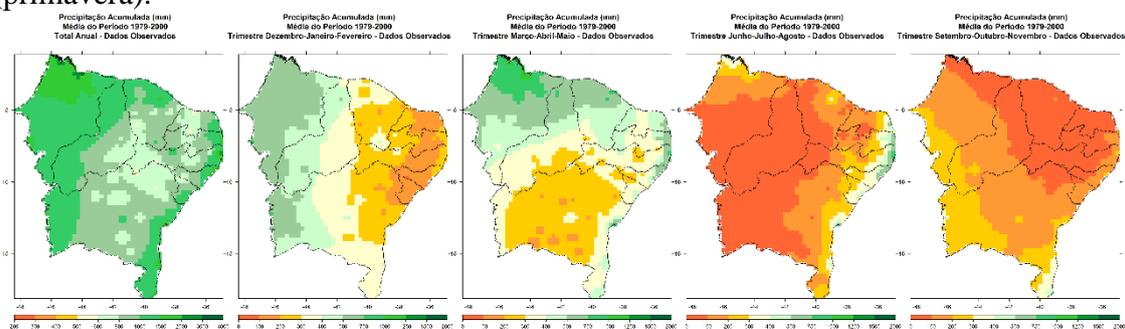


Figura 7: Similar a Figura 6, mas para o modelo CANESM2.

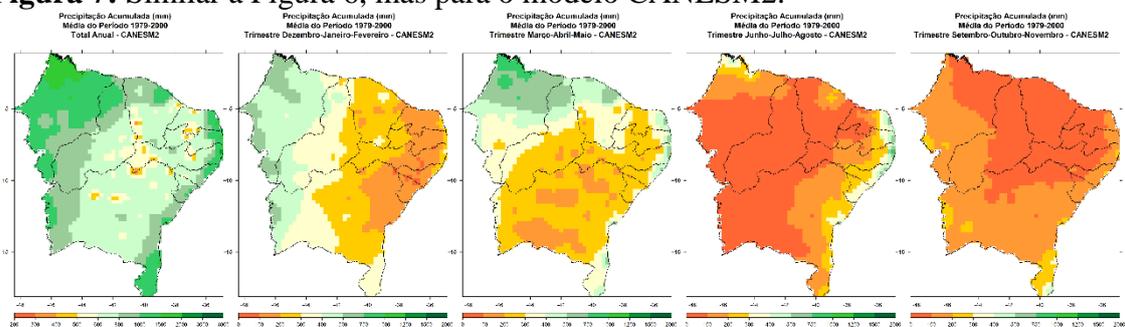


Figura 8: Similar a Figura 6, mas para o modelo CNRM-CM5

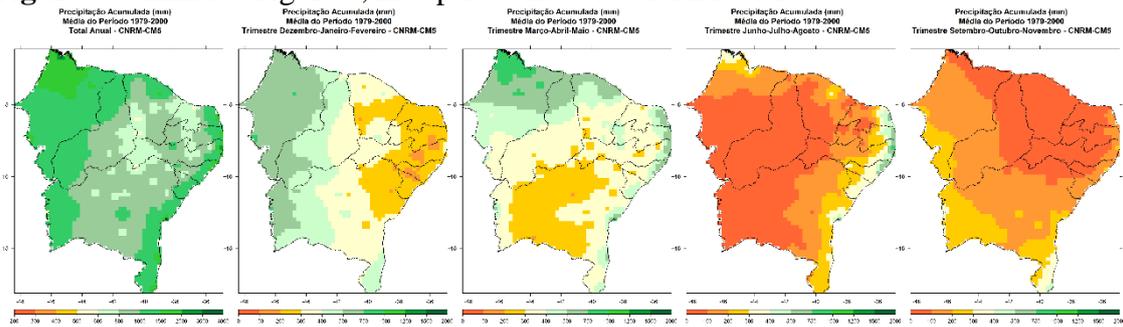


Figura 9: Similar a Figura 6, mas para o modelo GFDL-ESM2M

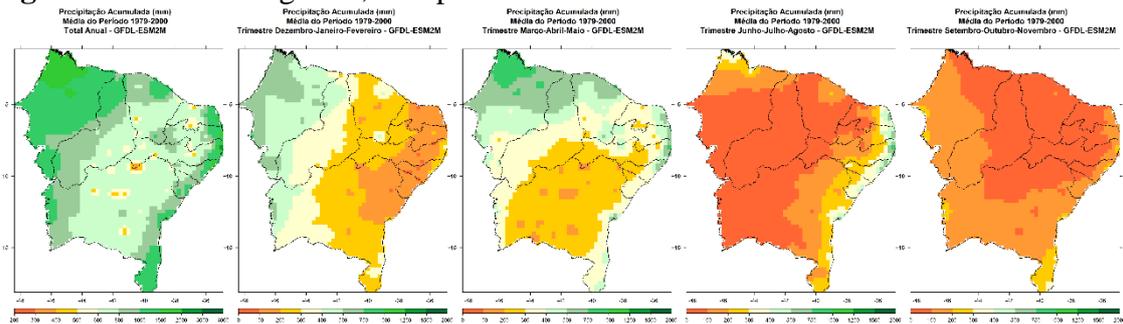


Figura 10: Similar a Figura 6, mas para o modelo IPSL-CM5A-MR.

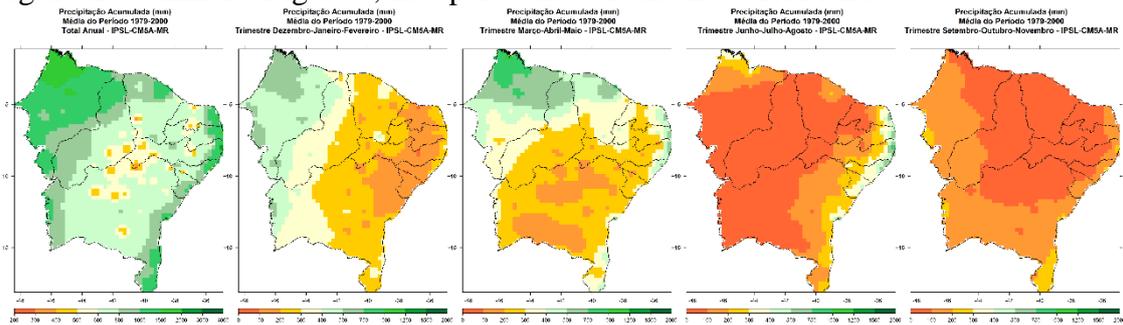


Figura 11: Similar a Figura 6, mas para o modelo MPI-ESM-MR.

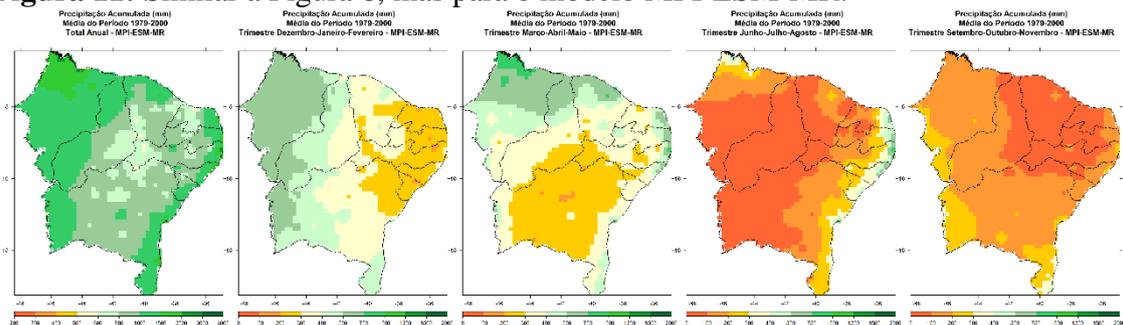


Figura 12: Similar a Figura 6, mas para o modelo NORESM1-M.

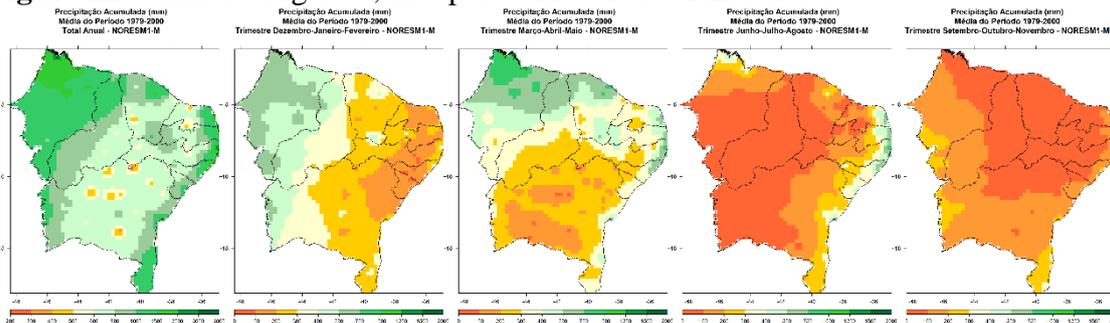


Figura 13: Similar a Figura 6, mas para o modelo ENSEMBLE.

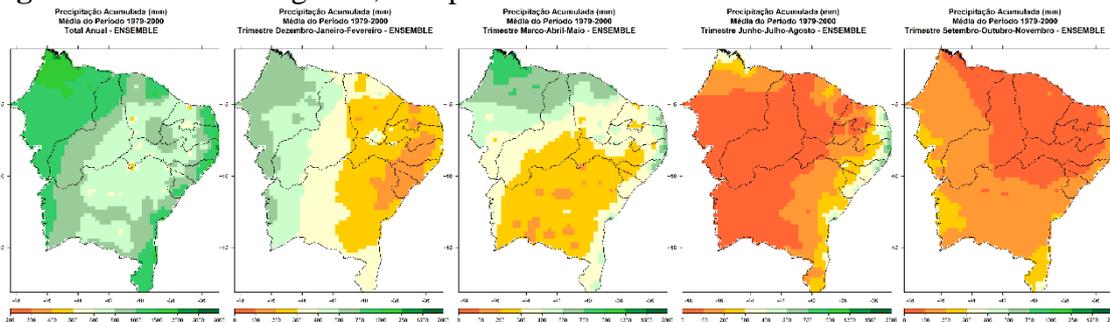
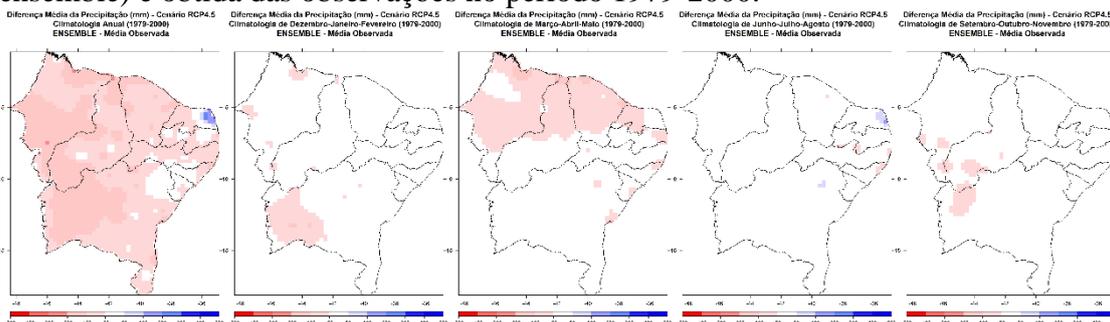


Figura 14: Diferença entre climatologias simuladas pela média de todos os modelos (ensemble) e obtida das observações no período 1979-2000.



Para corroborar os resultados descritos em relação as Figuras 6 a 14, mostra-se na sequência das Figuras 15 a 23, a comparação entre a climatologia observada e obtida por cada MCG e ensemble, para cada capital de cada estado do NEB, como uma amostra do total de estações utilizadas. Os resultados evidenciam a habilidade dos MCGs em simular a climatologia a nível mensal, o que resulta na representação satisfatória do ciclo anual. Em algumas dessas localidades, como em São Luís, percebe-se como os MCGs simulam bem o ciclo anual mas subestimam o total observado principalmente nos meses mais chuvosos do ano, refletindo essa característica no ensemble. Este resultado foi obtido de forma similar por Costa et al (2021) aplicando o mesmo MDE para quatro MCGs do CMIP3, com objetivo de geração de cenários futuros regionalizados relativos aos cenários A1B e A2 do quarto relatório do IPCC (IPCC 2007). Autores mencionam similaridades entre os cenários A1B e RCP4.5,

principalmente no que tange a cenários que buscariam um maior equilíbrio entre fontes de energias renováveis com as provenientes de combustíveis fósseis.

Figura 15: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para São Luís (MA).

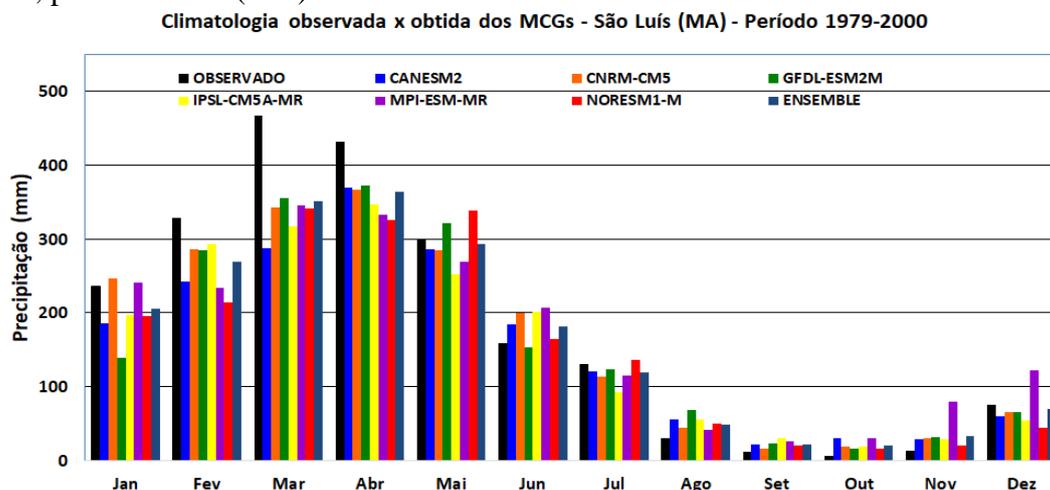


Figura 16: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Teresina (PI).

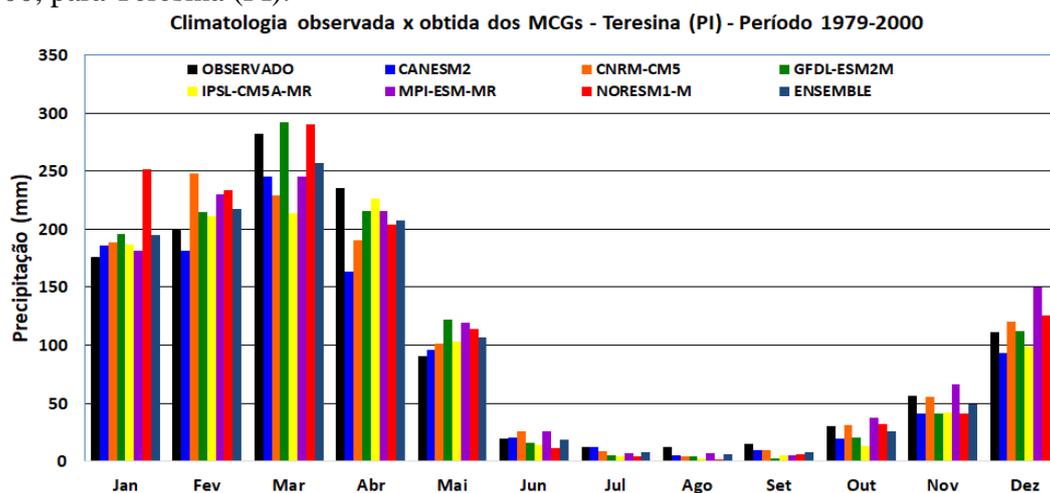


Figura 17: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Fortaleza (CE).

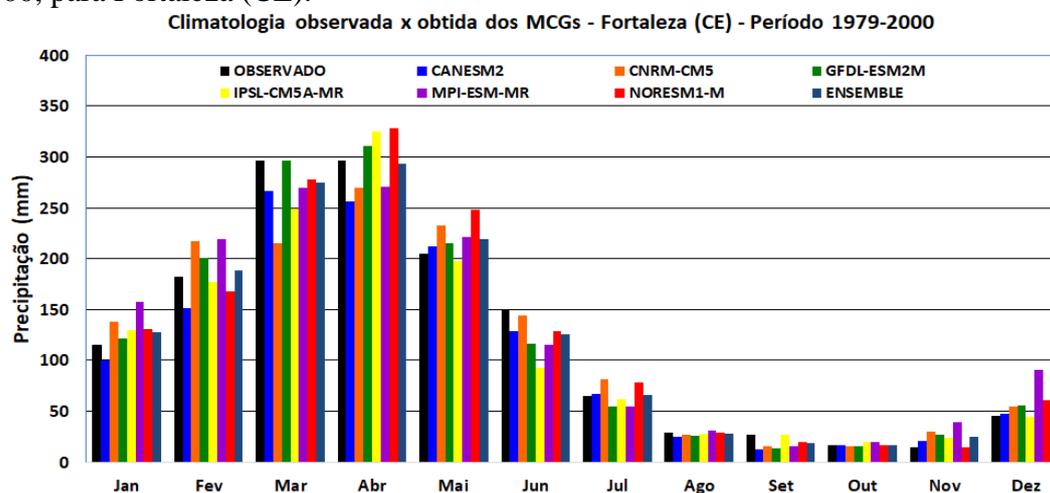


Figura 18: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Natal (RN).

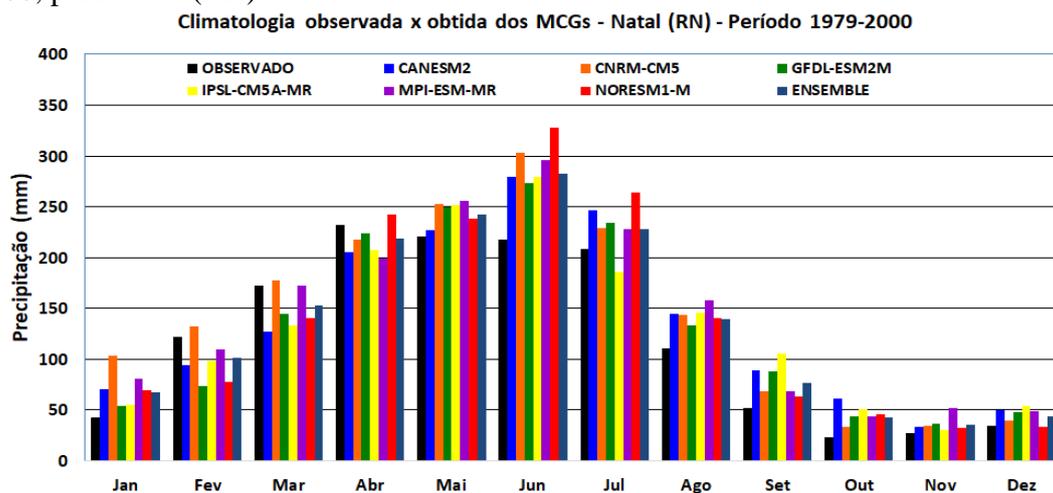


Figura 19: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para João Pessoa (PB).

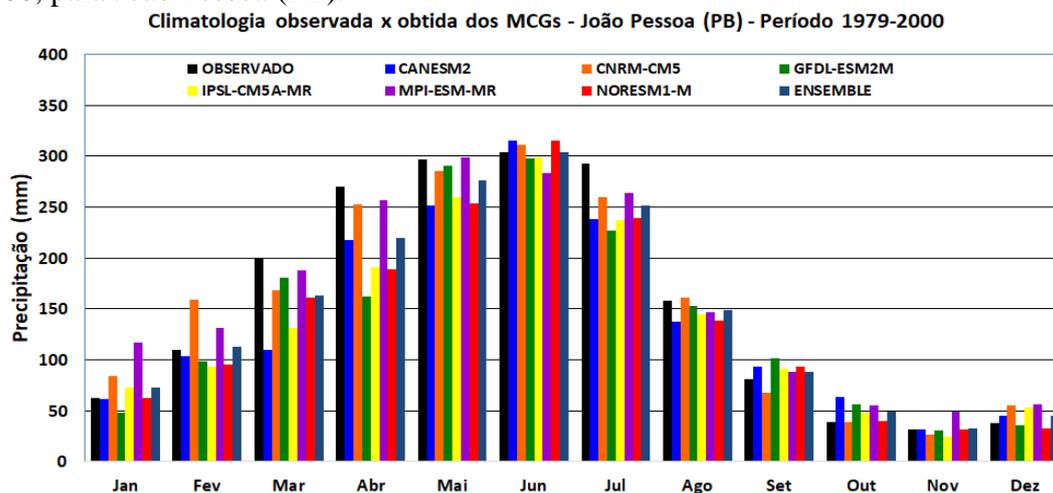


Figura 20: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Recife (PE).

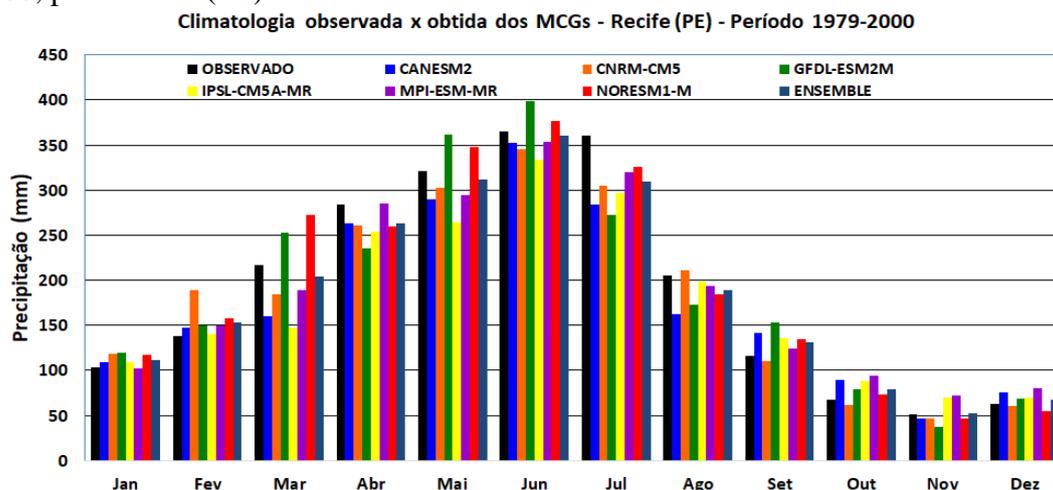


Figura 21: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Maceió (AL).

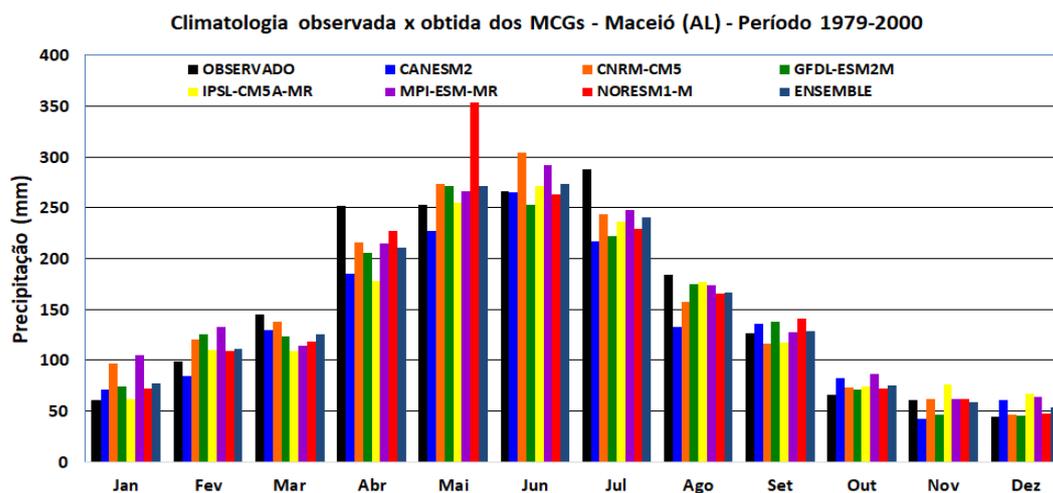


Figura 22: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Aracaju (SE).

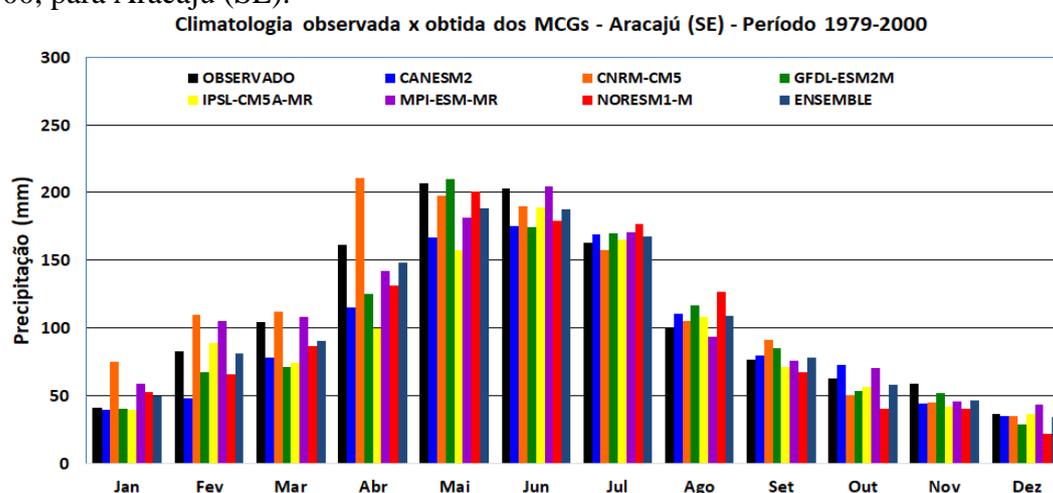
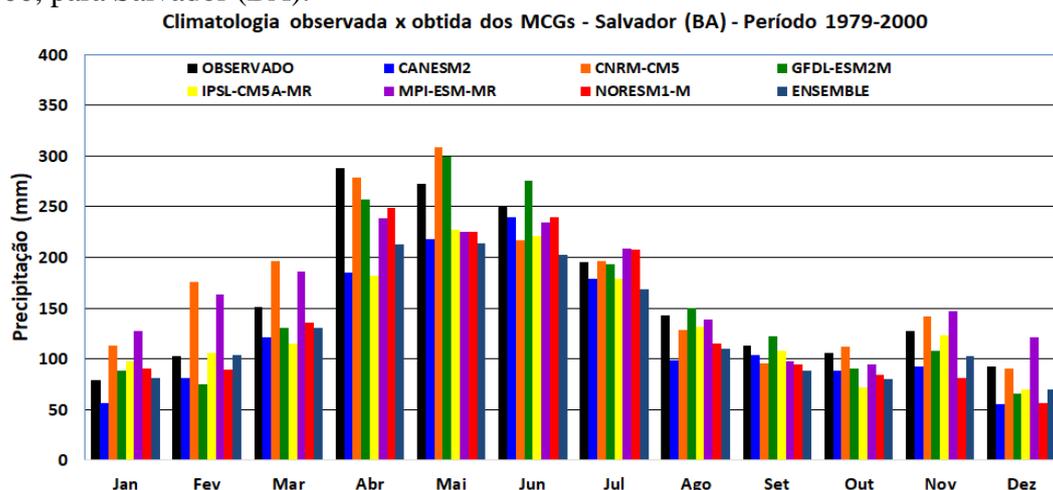


Figura 23: Climatologia observada e simuladas por todos os modelos do período 1979-2000, para Salvador (BA).



Geralmente, o uso de diversos modelos em um “conjunto” (ensemble) torna-se útil para avaliar a variabilidade entre os modelos do sistema terrestre, podendo-se quantificar as incertezas das projeções futuras considerando vários cenários de vários

modelos (Brankovi et al., 1994). Dos resultados da precipitação, pode-se concluir que o ensemble dos modelos fornece uma forma mais direta e objetiva de comparar a performance dos dados gerados pelos MCGs em comparação aos observados no contexto histórico, o que imprime confiabilidade as simulações históricas e projeções futuras. Para a temperatura máxima e mínima, todos os resultados relativos a simulação do clima no período de referência 1979-2000 será baseado no resultado do ensemble.

A Figura 24 mostra a climatologia anual e sazonal das temperaturas máximas. Os valores indicam que as maiores médias anuais estão localizadas entre os estados do Maranhão e Piauí, oeste e leste do Ceará e centro-oeste do Rio Grande do Norte, e as mais amenas no centro-sul baiano, e em núcleos associados a estações em municípios com altitudes superiores a 500m, como observado no norte do Ceará (estação localizada em Guaramiranga, a 870,7m de altura), Pernambuco (Garanhuns a 822,8m e Triunfo a 1105m), Paraíba (Areia a 574,6m e Campina Grande a 547,6m), e na Bahia (Vitória da Conquista a 874,8m, Caetitê a 882,5m e Morro do Chapéu a 1003,3m). O outono é o período de temperatura máximas mais amenas no norte do NEB, coincidente com o período chuvoso, e o mesmo efeito é observado no leste do NEB no inverno. A primavera se destaca com temperaturas máximas acima dos 33°C no centro-norte do NEB, abrangendo Maranhão, Piauí (onde há maior homogeneidade em relação as temperaturas mais elevadas), boa parte do Ceará, e oeste dos estados do Rio Grande do Norte, Paraíba e Pernambuco.

A Figura 25 mostra o mesmo resultado da Figura 24, mas para o ensemble dos modelos, onde nota-se a habilidade dos mesmos em simular comportamento climático muito similar das observações, porém com áreas visivelmente mais quentes, cujo viés positivo é comprovado na Figura 26, com desvios positivos mais marcantes no outono e inverno, resultando numa média anual superior a 1°C em relação a observada mais pronunciada em partes do Maranhão e leste do NEB.

As Figuras 27 a 29 mostram os mesmos resultados das Figuras 24 a 26, mas para as temperaturas mínimas. Para esta variável, também é visível que o ensemble (Figura 28) simula satisfatoriamente o ciclo anual observado (Figura 27), porém com maior alternância em áreas onde o ensemble superestima e subestima as observações. Interessante notar que esse padrão de aquecimento/resfriamento é homogêneo entre as estações do ano, mostrando um comportamento de viés sistemático dos modelos durante todo o ano em relação aos valores observados.

Figura 24: Da esquerda para a direita: climatologia a partir de dados observados da temperatura máxima anual, do trimestre dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera).

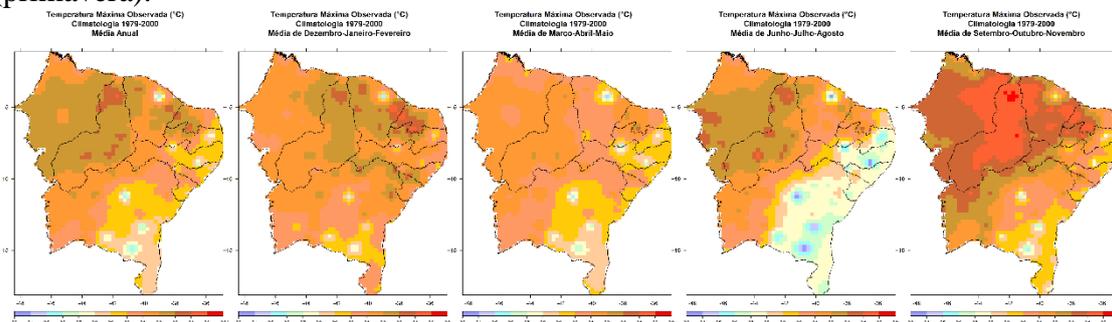


Figura 25: Da esquerda para a direita: climatologia a partir do ensemble dos MCGs da temperatura máxima anual, do trimestre dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera).

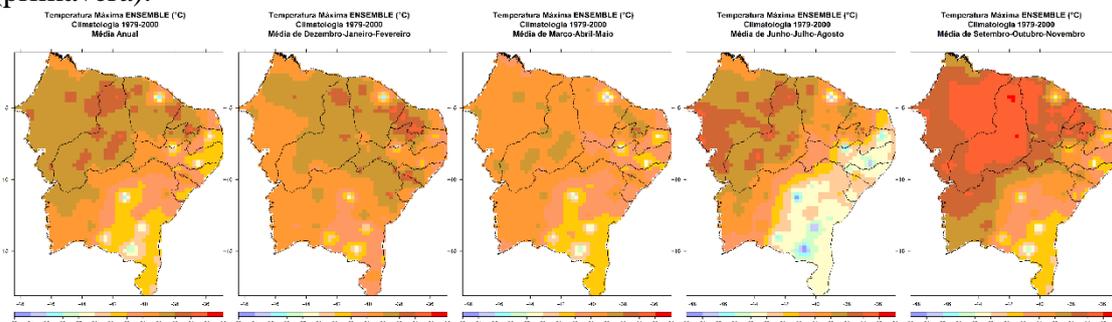


Figura 26: Diferença entre climatologias simuladas pela média de todos os modelos (ensemble) para a temperatura mínima e obtida das observações no período 1979-2000.

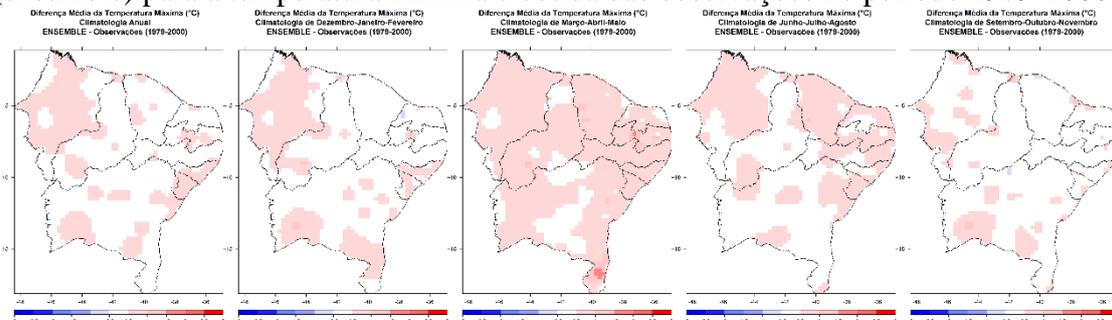


Figura 27: Da esquerda para a direita: climatologia a partir de dados observados da temperatura mínima anual, do trimestre dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera).

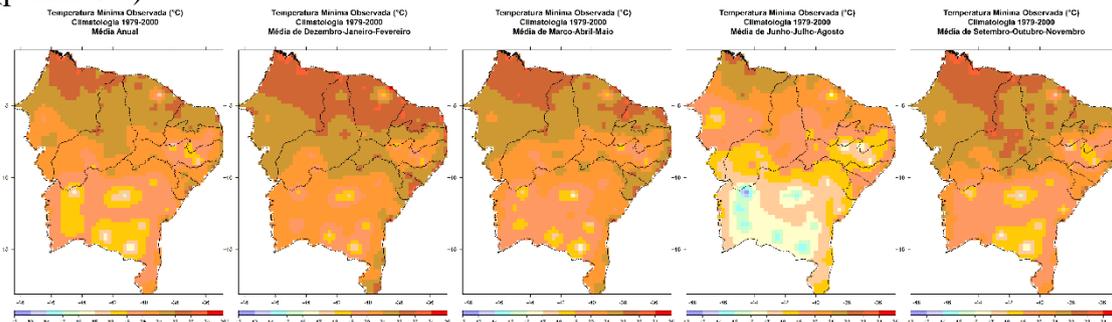


Figura 28: Da esquerda para a direita: climatologia a partir do ensemble dos MCGs da temperatura máxima anual, do trimestre dezembro-janeiro-fevereiro (verão), março-abril-maio (outono), junho-julho-agosto (inverno) e setembro-outubro-novembro (primavera).

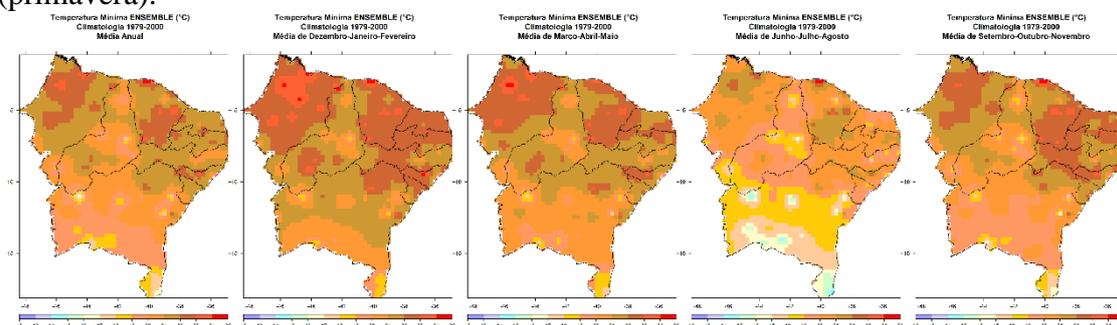
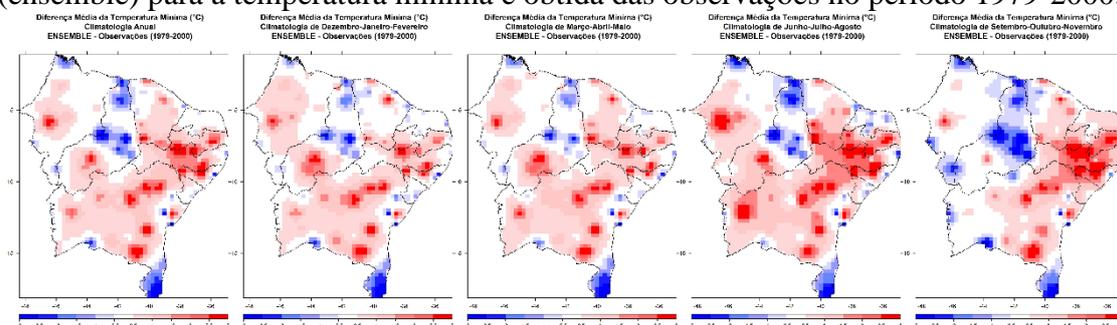


Figura 29: Diferença entre climatologias simuladas pela média de todos os modelos (ensemble) para a temperatura mínima e obtida das observações no período 1979-2000.



4.3.2. Validação da simulação do clima presente

No processo de calibração e sua posterior validação, os resultados independem do MCG a ser utilizado para geração de cenários futuros, uma vez que se busca estudar a relação entre os preditores escolhidos das reanálises, com as variáveis de superfície. O MDE estatístico usado foi o método dos análogos. A calibração comprovou a habilidade do MDE em explicar a variabilidade dos preditandos. Mas, além disso, devido a não estacionariedade do clima, faz-se necessário verificar a capacidade do MDE em simular/prever as variáveis para um período independente. Enquanto o processo de calibração permitiu a reconstituição do clima no período 1979-2000, para a validação foram calculados e analisados parâmetros estatísticos relacionando simulações para o período 2001-2010 as observações desse mesmo período.

As séries sintéticas de precipitação, temperaturas máximas e mínimas geradas para este período foram analisadas diariamente e agregadas a cada 10 dias, e comparadas às observações, pois o passo de tempo do modelo agrometeorológico usado nessa pesquisa é decenal.

A Figura 30 mostra a correlação para a precipitação acumulada média decendial (a), temperaturas máximas médias decendiais (b) e temperaturas mínimas decendiais (c). Neste período de validação (2001-2010), agregados de 10 dias correspondem a 360 decêndios. Para este tamanho $n=360$, todas as correlações apresentaram significância estatística ao nível de 95% de confiança. As maiores correlações, acima de 0,6, estão concentradas na porção centro-oeste do NEB. Um núcleo de correlações mais baixas, da ordem de 0,3 a 0,6 está concentrado no leste do NEB entre o centro-sul da Paraíba e Bahia. A temperatura máxima, por sua vez, é a variável que apresentou as maiores correlações em toda a região, atingindo valor máximo de 0,91 em determinados pontos da faixa leste. As temperaturas mínimas também apresentaram correlações elevadas que também atingiram 0,91 em algumas localidades da faixa leste, no entanto seus valores diminuem na porção noroeste do NEB, com os menores valores observados em pontos localizados entre os estados do Piauí e Maranhão.

A Figura 31 mostra o viés para a precipitação acumulada média decendial (a), temperaturas máximas médias decendiais (b) e temperaturas mínimas decendiais (c). Para a precipitação, os maiores vieses estão concentrados na faixa leste onde as correlações foram mais baixas. Predominaram vieses negativos para a precipitação, corroborando a tendência do MDE em subestimar a precipitação no período de validação, semelhante ao ocorrido no período de calibração. As temperaturas máximas e mínimas apresentaram um viés positivo na faixa leste, tendência de superestimar a temperatura observada, mas apenas as temperaturas máximas apresentaram viés negativo, tendência de subestimar as observações, no noroeste da região entre os estados do Piauí e Maranhão.

A Figura 32 mostra o RMSE para a precipitação acumulada média decendial (a), temperaturas máximas médias decendiais (b) e temperaturas mínimas decendiais (c). Quanto a este parâmetro, que é uma medida usada para estimar as diferenças entre valores simulados e observados, mostra para a precipitação agregada de 10 dias valores médios em torno de 20mm a 40mm na parte central do NEB, atingindo valores de até 90mm no norte do Maranhão. Os maiores valores de RMSE localizam-se nas porções extremas das áreas mais chuvosas do NEB, incluindo valores um pouco mais elevados de RMSE no leste da região. As temperaturas máximas apresentaram maiores valores de RMSE comparadas as temperaturas mínimas, mas em ambas variáveis, as áreas de maiores valores desse parâmetro estão localizadas no centro-oeste do NEB, entre Bahia, sul do Piauí e Maranhão, com pontos próximos aos 2°C.

Assim como observados em Costa et al (2021), esse parâmetro apresenta padrões aceitáveis de comparação entre os dados simulados e observados, proporcionando confiança para o uso das séries temporais de precipitação, temperaturas máximas e mínimas geradas para os cenários futuros.

Figura 30: Correlação r entre simulações e observações, para dados agregados em decêndios, (a) precipitação, (b) temperaturas máximas e (c) temperaturas mínimas.

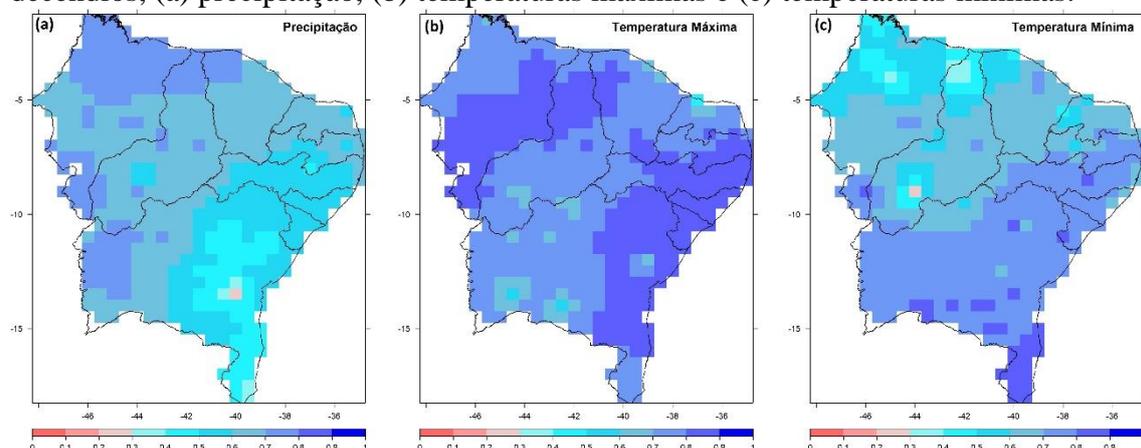


Figura 31: Viés entre simulações e observações, para dados agregados em decêndios, (a) precipitação (mm), (b) temperaturas máximas ($^{\circ}\text{C}$) e (c) temperaturas mínimas ($^{\circ}\text{C}$).

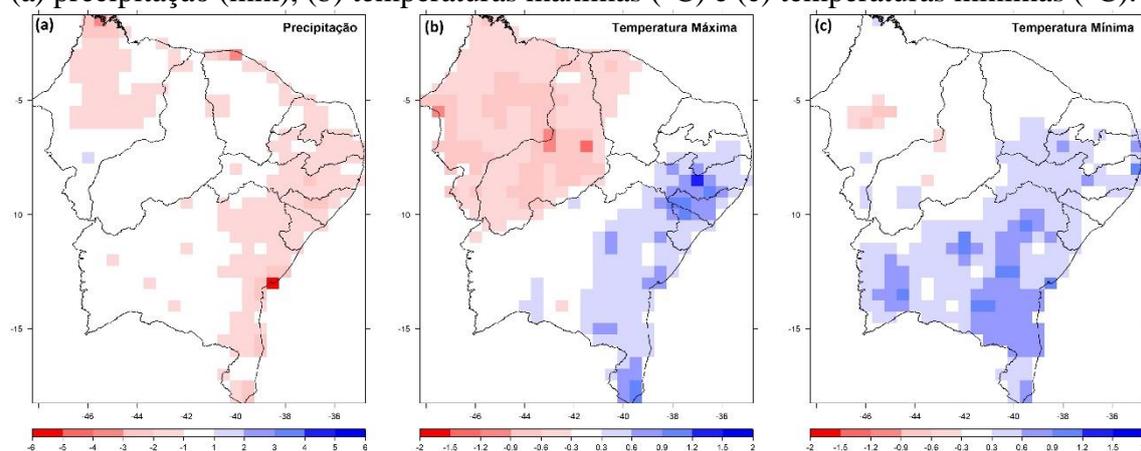
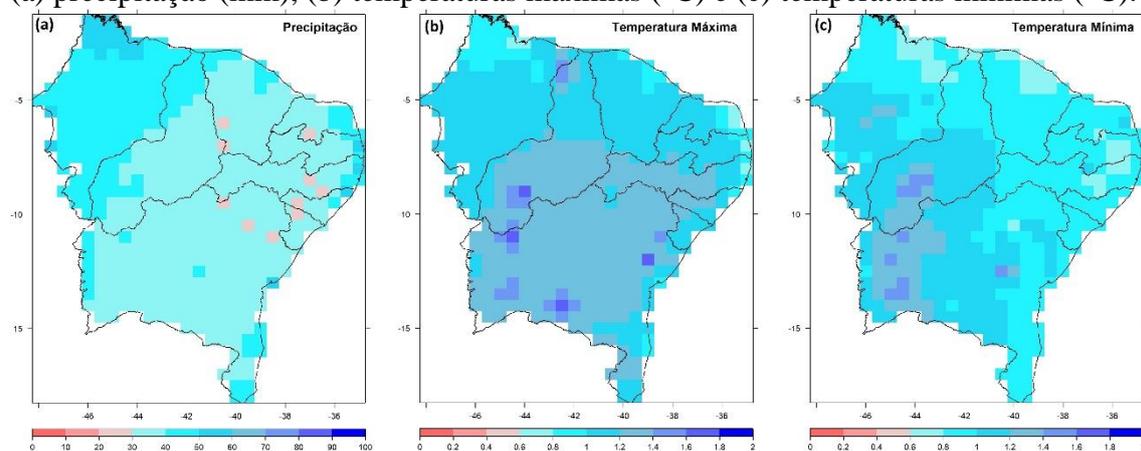


Figura 32: RMSE entre simulações e observações, para dados agregados em decêndios, (a) precipitação (mm), (b) temperaturas máximas ($^{\circ}\text{C}$) e (c) temperaturas mínimas ($^{\circ}\text{C}$).



4.4. CENÁRIOS FUTUROS DA PRECIPITAÇÃO, TEMPERATURAS MÁXIMAS E MÍNIMAS

Após a seleção dos preditores, calibração e validação do MDE, e verificação da destreza dos modelos em simular o ciclo climático anual, foram geradas as projeções das variáveis a partir do cenário futuro RCP4.5, para cada MCG, uma vez que se torna essencial conhecer suas incertezas a fim de alcançar representações confiáveis do clima futuro.

Muitas são as incertezas associadas aos cenários socioeconômicos, emissões de gases de efeito estufa, estrutura e parametrizações dos modelos, e ao próprio método de regionalização empregado. Os resultados são apresentados em termos das alterações de longo prazo, a nível anual para o cenário RCP4.5 entre a média obtida das variáveis para o ensemble dos modelos, que de acordo com a literatura é uma abordagem simples e eficiente de reduzir a variabilidade intermodelos sob qualquer tipo de abordagem de previsões/projeções climáticas (Sanderson et al., 2015; Fyfe et al., 2021; Osman et al., 2021). Os três subperíodos apresentados representam um futuro atual/próximo (2011-2040), um futuro intermediário (2041-2070) e um futuro distante (2071-2100). Todos os desvios são em relação as observações do período de referência 1979-2000.

A Figura 33 mostra uma redução do total anual da precipitação acumulada já para o período 2011-2040 de 100 a 200mm na maior parte da região, com áreas que superam os 200mm de diferença em núcleos esparsos observados em todos os Estados, embora mais concentrados na Bahia. Para 2041-2070, esse feito é intensificado, com as áreas de déficit superiores a 200mm anuais predominando e núcleos com déficits inferiores a 500mm anuais observados. A ápice dessa tendência de redução nos acumulados anuais é projetado no período 2071-2100, com déficits que ultrapassam os 750mm em algumas localidades.

A Figura 34 mostra uma tendência de aumento das temperaturas máximas entre 0,5 e 1°C em partes do norte do NEB e de até 2°C na maior parte do restante da região. Para 2041-2070, essa tendência é incrementada, com áreas de aumento entre 2 e 3°C, atingindo o máximo de aumento em relação entre 2071-2100 principalmente no centro-sul da região, inclusive com núcleos isolados apresentando acréscimo superior aos 3°C.

A Figura 35 mostra, para as temperaturas mínimas, comportamento similar ao projetado para as temperaturas máximas, com acréscimo de até 2°C na maior parte da

região entre 2011 e 2040, com núcleos esparsos que já superam os 2°C entre 2041-2070 e de 2 a 3°C entre 2071-2100.

Estes resultados tem similaridade a outros estudos que projetam mudanças climáticas de precipitação e temperaturas para o NEB, porém com nuances nas intensidades dessas mudanças. Para a precipitação, onde se projeta uma redução significativa do acumulado anual das chuvas até o final do século, valores similares foram obtidos por Costa et al (2020), usando a mesma metodologia de downscaling estatístico e mesma base de dados, mas para diferentes cenários: A1B e A2. No entanto, outros estudos ora convergem/divergem dos resultados aqui apresentados, em relação à precipitação.

Marengo et al (2016), analisaram projeções futuras de precipitação e temperaturas de um ensemble de 24 modelos (ou diferentes versões de modelos) do CMIP5 para o NEB para verificar o potencial de ocorrência de secas futuras, e verificaram redução do total das chuvas anuais sob condições do cenário RCP4.5, mais proeminentes no centro-leste do NEB. Guimarães et al (2016) analisaram projeções climáticas para o final do século aplicando regionalização dinâmica ao ensemble de 32 modelos/versões de modelos, para o cenário RCP4.5, e encontraram projeções para o período 2079-2099 de aumento de até 200 mm/ano na costa norte do NEB, e diminuição mais elevada em maior parte da região centro-leste, de até -100 mm/ano, o que contrasta dos resultados aqui apresentados, embora o norte do NEB também seja a área do NEB onde obteve-se as menores projeções futuras de redução da precipitação acumulada anual. Para as temperaturas diversos estudos encontram, sob diferentes magnitudes, para diferentes modelos, aumento das temperaturas até o final do século para o NEB (Guimarães et al., 2016; Alves et al., 2016; Silva et al., 2020, Costa et al., 2020; Santos et al., 2020; Costa et al., 2021).

Figura 33: Diferenças médias anuais da precipitação acumulado do ensemble dos modelos para (a) 2011-2040, (b) 2041-2070 e (c) 2071-2100, com as médias 1979-2000.

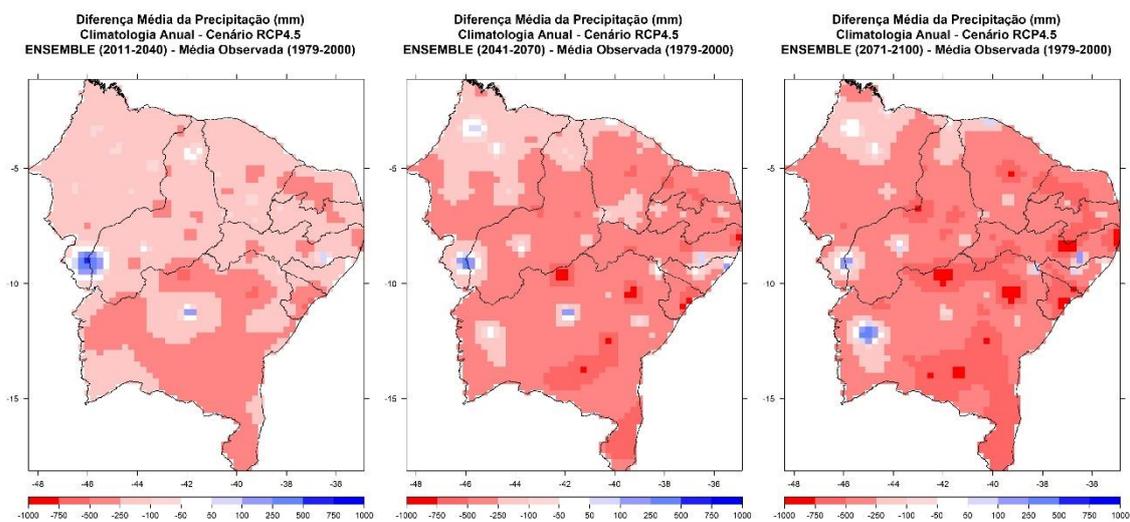


Figura 34: Diferenças médias anuais das temperaturas máximas do ensemble dos modelos para (a) 2011-2040, (b) 2041-2070 e (c) 2071-2100, com as médias 1979-2000.

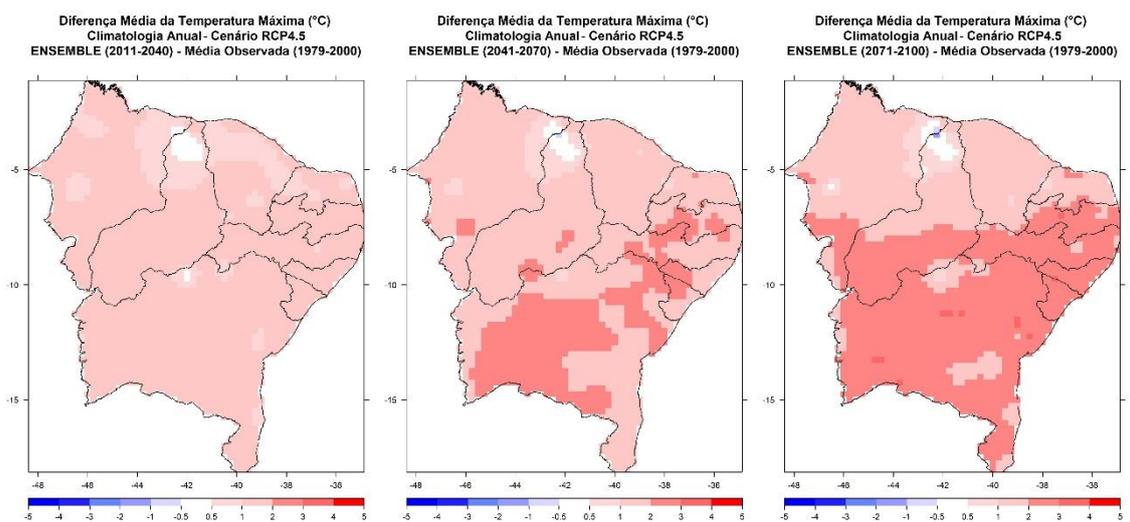
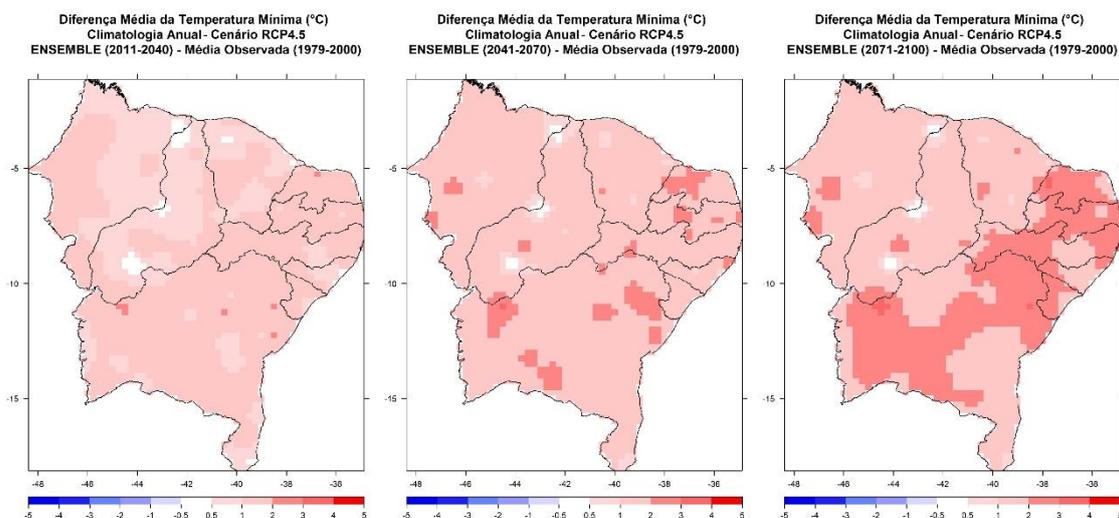


Figura 35: Diferenças médias anuais das temperaturas mínimas do ensemble dos modelos para (a) 2011-2040, (b) 2041-2070 e (c) 2071-2100, com as médias 1979-2000.



4.5. CENÁRIOS FUTUROS DE PRODUTIVIDADE

A partir da calibração e validação do modelo agrometeorológico e downscaling estatístico são exibidos os resultados da produtividade relativa do feijão no NEB, para o período de 2010 a 2100, utilizando o cenário RCP 4.5 do quinto relatório do IPCC. Os modelos validados são: CANESM2, CNRM-CM5, GFDL-ESM2M, IPSL-CM5A-MR, MPI-ESM-MR, e NORESM1-M. A plantação do feijão acontece em diferentes épocas, sendo esse período dividido em 10 calendários agrícolas para os nove estados do NEB. Para cada um dos 73 municípios estudados, há seis simulações, de cada MCG. A Tabela 8 mostra cada calendário de plantio, com três datas (CONAB, 2019), onde deve-se realizar uma ponderação dos valores de produtividade obtidos considerando-se a seguinte proporcionalidade: 25% dos agricultores semeia na primeira data do calendário, 50% na segunda data e 25% na terceira data.

Tabela 8: Calendário de plantio por Estados (dec = decêndio, nov = novembro, dez = dezembro, e assim por diante para demais meses).

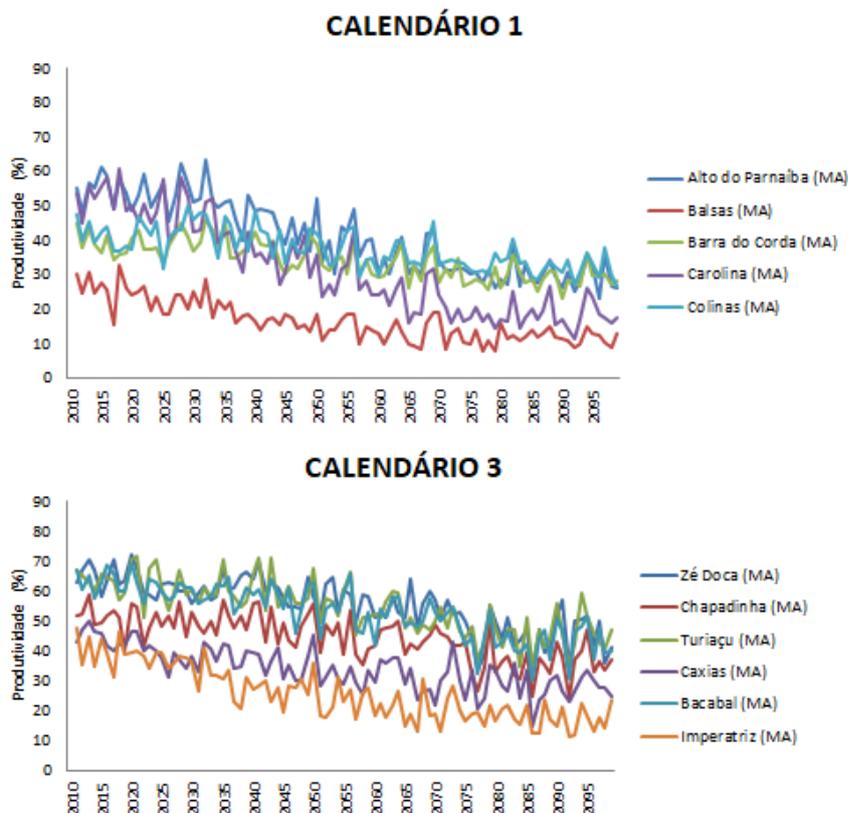
UF	Calendário	1ª Data	2ª Data	3ª Data
MA	1	01 dec/nov	01 dec/dez	03 dec/dez
BA	2	01 dec/nov	02 dec/nov	03 dec/dez
MA	3	01 dec/dez	01 dec/jan	03 dec/jan
PI	4	01 dec/dez	02 dec/jan	03 dec/fev
CE/PE/PB	5	01 dec/jan	02 dec/fev	03 dec/mar
PB (centro-leste)	6	01 dec/fev	02 dec/mar	03 dec/abr
RN (leste)	7	01 dec/mar	01 dec/abr	03 dec/abr
PE (leste)	8	01 dec/mar	02 dec/abr	03 dec/mai
AL/SE	9	01 dec/abr	02 dec/mai	03 dec/jun
BA (leste)	10	01 dec/abr	01 dec/mai	02 dec/jun

As figuras apresentadas abaixo se referem à média de produtividade dos municípios, conforme seu calendário de plantio, simulada por cada modelo. O período de análise varia com base climatológica entre os anos de 2011-2040, 2041-2070 e 2071-2100, onde se observa a predominância do aumento das temperaturas e seu impacto na produtividade.

A produtividade do calendário 1 e 3, que correspondem aos municípios do Estado do Maranhão (MA) são apresentados na figura 36. Maior parte dos municípios produtores do Maranhão (MA) corresponde ao grupo G2, de média produtividade, exceto Turiaçu que está inserido no G3, grupo de alta produtividade. Nas representações abaixo, é possível observar uma diminuição da produtividade até 2100 para todos os municípios.

No Calendário 1, Carolina (MA) se destaca por apresentar as maiores reduções de produtividade. Há predominância positiva do aumento das temperaturas é ainda mais elevada para regiões no interior do NEB, que por consequência, tem clima mais seco. Em Turiaçu, calendário 3, o rendimento é mais afetado após 2041, estima-se que essa redução seja de aproximadamente 22% até 2100. Sousa et. al (2009) explica como o estresse hídrico do feijoeiro, causado pela diminuição da precipitação e o aumento da ETP, afeta o desenvolvimento das culturas e é ainda mais severo nas fases de floração e frutificação.

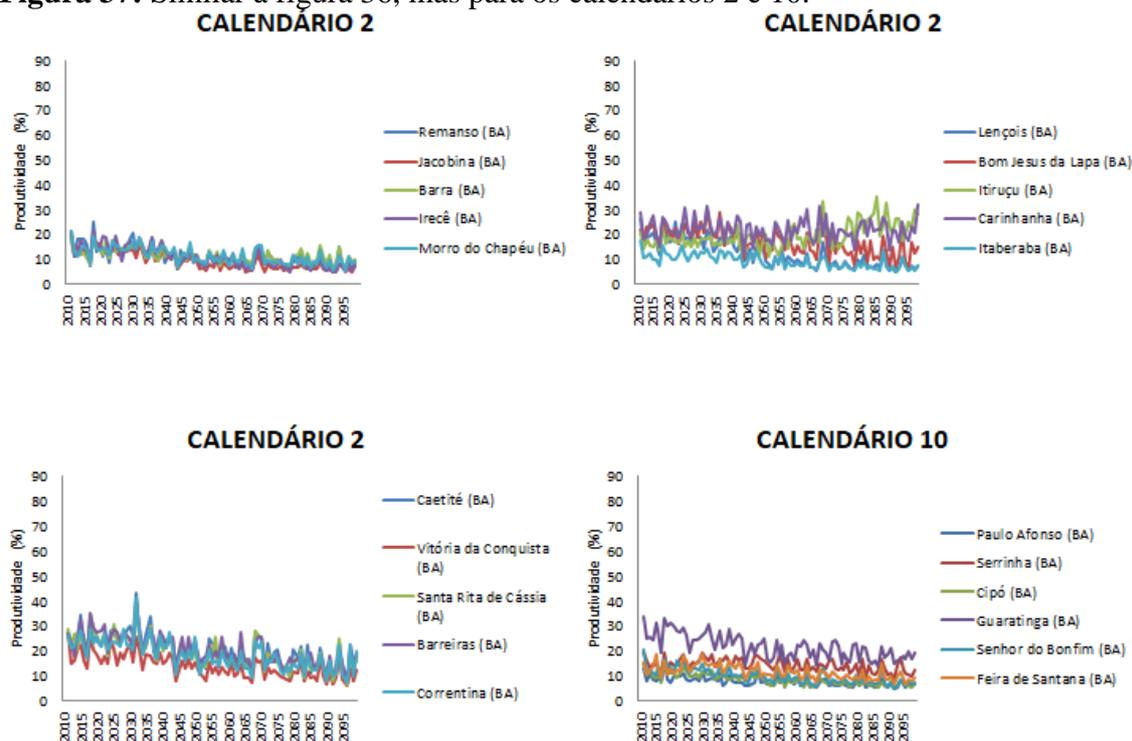
Figura 36: Estimativa média da produtividade do feijão, para o cenário RCP 4.5, para o calendário 1 e 3, entre o período de 2011 a 2100.



O plantio no Estado da Bahia é dividido entre o calendário 2 e o calendário 10. O calendário 2 é o que detêm a maior parte dos municípios, como apresentado na figura 37. Em ambos os calendários a rendimento da produtividade do feijão é reduzido, exceto em Carinhanha (BA) e Itiruçu (BA), que são respectivamente, classificados como G2 e G3. Carinhanha apresenta entre o período de 2041-2070 produtividade mais alta que Itiruçu, e a partir de 2071 o aumento é previsto para os dois municípios.

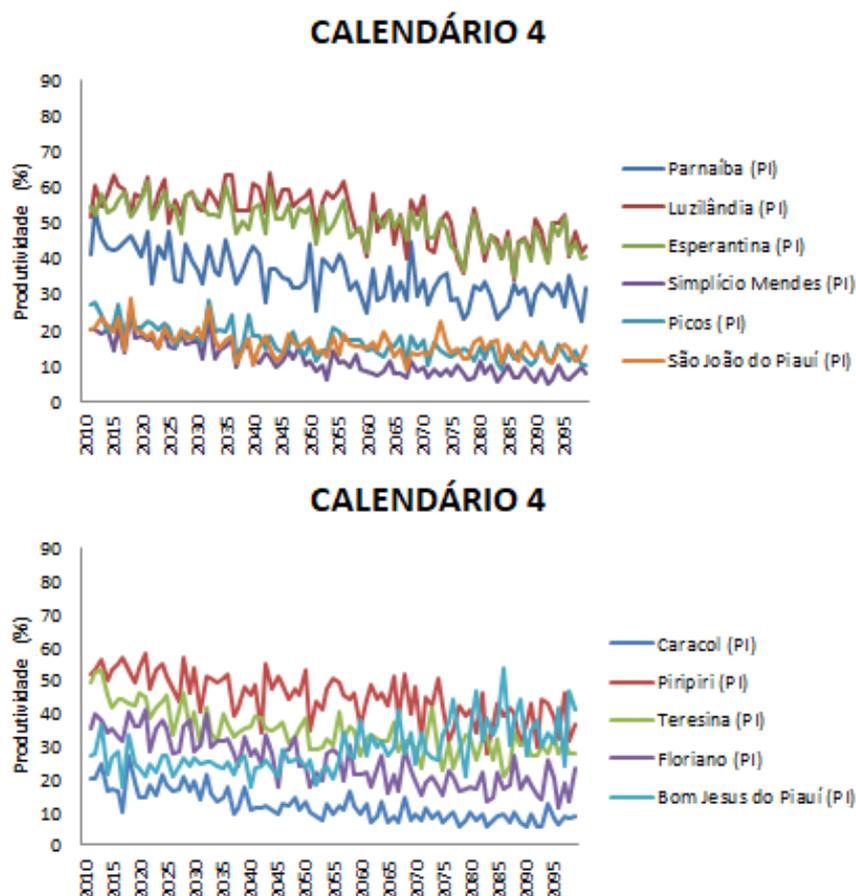
Carinhanha é um município do Estado da Bahia que está localizado às margens do Rio São Francisco, o rendimento da produtividade observada para o feijão nessa região é afetado por eventos extremos, seja inundações ou secas prolongadas. Segundo Assad et. al (2008) 95% das perdas no setor agrícola estão associadas a esses fatores, que são ainda destacados pela Embrapa como os principais para a perda de terras agricultáveis.

Figura 37: Similar à figura 36, mas para os calendários 2 e 10.



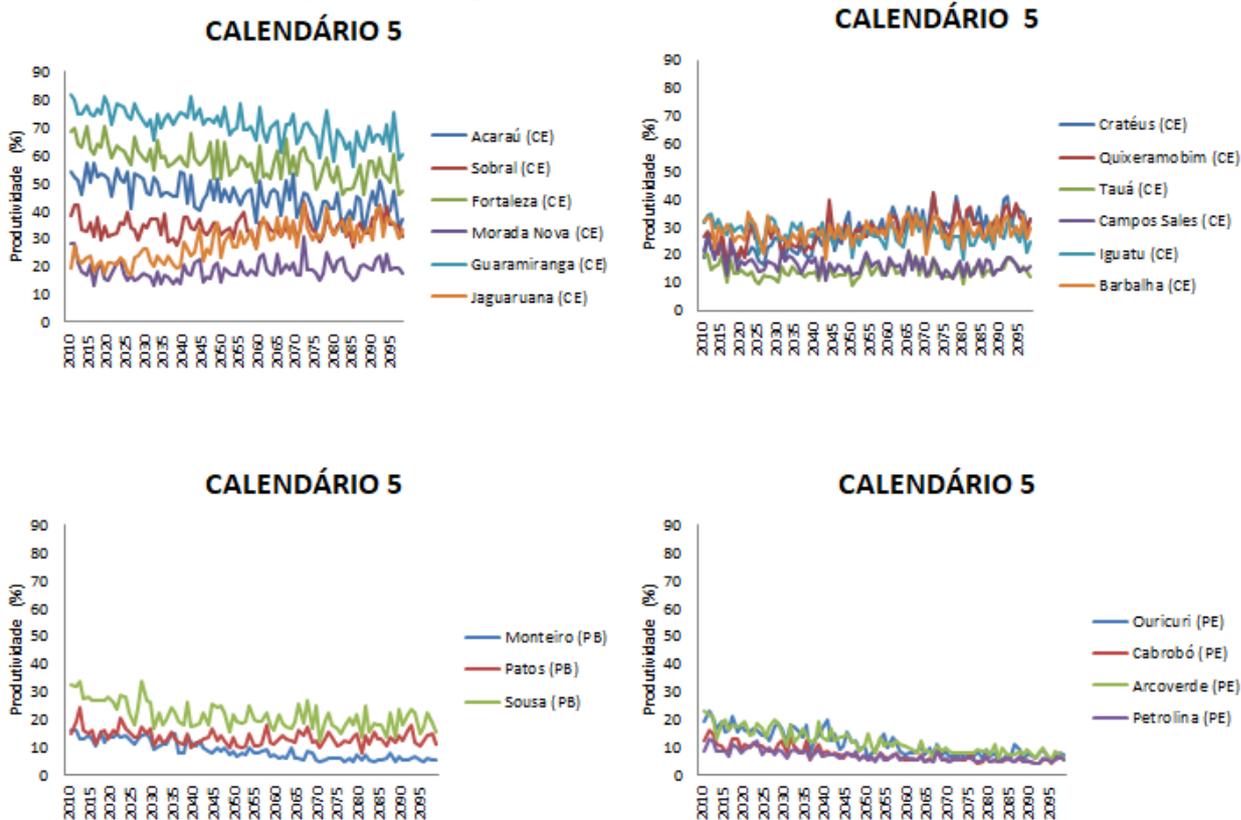
O Estado do Piauí (PI) é o estado com o maior número de municípios com baixa produtividade do feijão. As simulações para esses municípios são apresentadas na figura 38. Observa-se a tendência positiva para as reduções no rendimento da produtividade para todos os municípios, exceto em Bom Jesus do Piauí (PI). O aumento da produtividade nesse município é melhor visualizado a partir de 2070, considerando as simulações do clima apresentados na seção anterior, o ápice do aumento da temperatura ocorre nesse período, e conforme o calendário de plantio, em Bom Jesus do Piauí, o plantio ocorre durante o verão, que é o período mais quente da região e ainda com o maior número de chuvas.

Figura 38: Similar à figura 36, mas para o calendário 4.



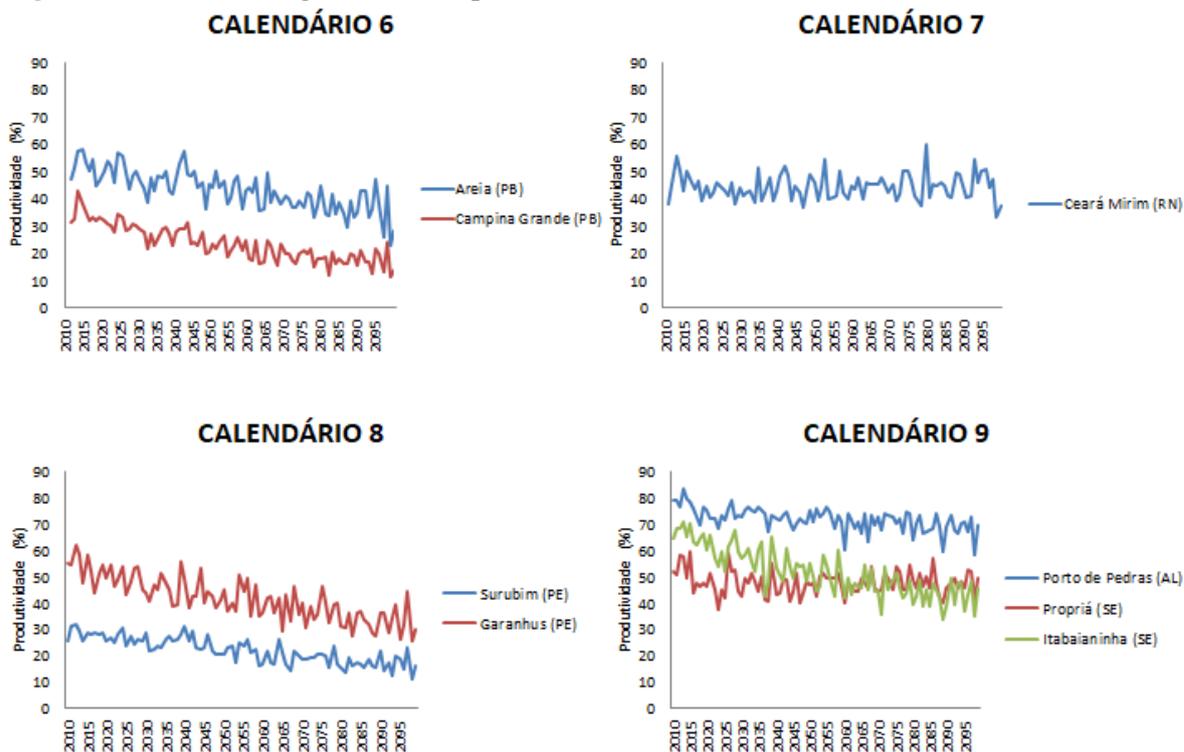
O calendário 5 é composto por plantio em três Estados (Ceará, Paraíba e Pernambuco), apresentados na figura 39. No Ceará observa-se que a redução da produtividade não é tão impactante como foi demonstrado em outros estados, sendo o rendimento da safra do feijão acrescido em Jaguaruana (CE), Cratús (CE), Quixeramobim (CE) e Barbalha (CE), e no geral, apresenta-se como o estado com maior aumento produtivo. O impacto do aumento da temperatura global relaciona-se diretamente a uma perturbação no ciclo hidrológico e na ETP, contribuindo assim, para todo um desequilíbrio agroclimático. Contudo, o aumento da produtividade no Ceará, é atribuído para previsão de temperaturas na faixa de 18-30°C, onde o feijão é amplamente adaptável.

Figura 39: Similar à figura 36, mas para o calendário 5.



Para os demais municípios produtores do calendário 5 não foram observadas reduções ou aumento tão significativos, assim como em Ceará-Mirim (RN) no calendário 7, apresentado na figura 40. Os calendários 6, 8 e 9 apresentam redução a partir de 2041, como previsão para quase todos os municípios produtores, fato destacado pelo aumento da temperatura ser intensificado nesse período. Algumas variações são observadas em todas as simulações, contudo, pressupõe-se que o NEB não é autossuficiente quanto à produtividade do feijão, visto que a região é extensa e não permite os ganhos em escala.

Figura 40: Similar à figura 36, mas para os calendários 6, 7, 8 e 9.



O impacto das mudanças climáticas está diretamente associado ao aumento da temperatura. Ortiz-Bobea et. al (2021) afirma que esse aumento é desigual pelo mundo, sendo algumas regiões mais afetadas que outras. As temperaturas quanto mais altas, mais prejudiciais à produtividade agrícola total. E ainda de acordo com essa pesquisa, o impacto das mudanças climáticas representa uma perda de crescimento da produtividade baseada em 7 anos. Essa perda, de aproximadamente 26-34%, é observada de forma mais severa em regiões mais quentes, como a África, América Latina e Caribe.

A agricultura global tornou-se mais vulnerável às mudanças climáticas, os vários estudos como de Silva et al (2014b), Ayoade (2007), Pinto e Netto (2008) ressaltam a importância das variáveis climáticas para agricultura. Costa et al; Junior et al; Silva et al (2020), também estudaram diferentes cenários de mudanças climáticas em outras determinadas áreas da região NEB e observaram que as principais características climáticas que afetam safras agrícolas são a precipitação e a temperatura, que segundo apresentado por Ortiz-Bobea et al (2021) possuem relação, de maneira inversa, sendo a temperatura aproximadamente linear.

Por vez, os mais diversos autores e trabalhos incluem em suas pesquisas a importância da previsibilidade da produção de safras agrícolas, com diferentes conjuntos de dados e para outros cenários futuros, no NEB, para o planejamento

socioeconômico. Como destaca Silva (2014a), os progressos científicos têm contribuído para o planejamento agrícola e maiores possibilidades para as safras resistirem à variabilidade do tempo, sendo ainda o clima uma das variáveis mais importantes para a agricultura. E, ao que é descrito pelo CONAB o estudo para que a produção cresça está associado à introdução de variedades mais produtivas e mais resistentes.

5. CONCLUSÃO

As representações do IPCC são semelhantes às simuladas pelos modelos, e a previsibilidade é que os impactos das mudanças climáticas são tendenciosamente maiores a partir de 2041. As projeções indicaram reduções significativas das taxas de precipitação, em média, os MCGs subestimam a precipitação na maior parte do NEB, e no leste do NEB essa variação é menor, inclusive observa-se uma superestimativa no leste do estado do Rio Grande do Norte. Para a temperatura máxima e mínima, as simulações preveem similaridade no aumento, sendo a tendência máxima de 2°C entre 2041-2070 e de 2 a 3°C em 2071-2100.

Quanto à produtividade mesmo com expressiva diminuição, o Estado da Bahia continua sendo o primeiro grande produtor, seguido do Ceará, que apresenta aumento nos rendimentos futuros. Dentre a classificação, estima-se que esse aumento de produtividade em alguns municípios seja em um futuro distante (2071-2100) e que tenha relação com as perturbações no ciclo hidrológico provocada pela tendência positiva da ETP.

Os resultados obtidos permitem afirmar que a calibração dos modelos utilizados para as simulações do clima foram satisfatórias. Os parâmetros estatísticos mostraram que o conjunto de preditores escolhidos para empregar a técnica de downscaling estatístico tem capacidade reprodutiva suficiente para representações.

Dessa forma, foi possível realizar validações para 6 MCGs para o cenário futuro de mudanças climáticas, o RCP4.5 e, ainda, diante do exposto, ressaltar a importância da pesquisa para o planejamento agrícola e para as adequações do plantio em decorrência da variabilidade climática. As séries históricas, portanto, permitem avaliar o passado e prever o futuro, sendo forma de recurso para informações e prevenção de prejuízos sociais e econômicos para a população.

6. REFERÊNCIA BIBLIOGRÁFICA

ACOCK, B.; TRENT, A. The soybean crop simulator, GLYCIM: documentation for the modular version 91. Moscow: University of Idaho, Department of Plant, **Soil and Entomological Sciences**, 1991. 242p.

ALLEN, R.G., PEREIRA, L.S., RAES, D., SMITH, M. Crop evapotranspiration: guidelines for computing crop water requirements. **In: FAO Irrigation and Drainage Paper** No. 56. FAO, Rome, Italy, 300 pp. 1998.

ALVES, J.M.B.; VASCONCELOS JÚNIOR, F.C.; CHAVES, R.R.; SILVA, E.M.; SERVAIN, J.; COSTA, A.A.; SOMBRA, S.S.; BARBOSA, A.C.B.; SANTOS, A.C.S. Evaluation of the AR4 CMIP3 and the AR5 CMIP5 Model and Projections for Precipitation in Northeast Brazil. **Frontiers in Earth Science**, v. 4: 44, 2016. doi: 10.3389/feart.2016.00044

ANDRÉ, R.G.B.; MARQUES, V.S.; PINHEIRO, F.M.A.; FERRAUDO, A.S. Identificação de regiões pluviometricamente homogêneas no estado do Rio de Janeiro, utilizando-se valores mensais. **Revista Brasileira de Meteorologia**, v. 23, p. 501-509, 2008.

ARF, O.; RODRIGUES, R.A.F.; SÁ, M.E.; BUZETTI, S.; NASCIMENTO, V. Manejo do solo, água e nitrogênio no cultivo de feijão. **Pesquisa Agropecuária Brasileira**, Brasília, v. 39, n. 2, p. 131-138, 2004.

ARF, O.; SÁ, M.E.; OKITA, C.S.; TIBA, M.A.; GUERREIRO N.G.; OGASSAWARA, F.Y. Efeito de diferentes espaçamentos e densidades de semeadura sobre o desenvolvimento do feijoeiro (*Phaseolus vulgaris* L.). **Pesquisa Agropecuária Brasileira**, Brasília, v.31, n.8, p.533-597, 1996.

ARIAS, P.A.; ORTEGA, G.; VILLEGAS, L.D.; MARTÍNEZ, J.A. Colombian climatology in CMIP5/CMIP6 models: Persistent biases and improvements. **Revista Facultad de Ingeniería**, Universidad de Antioquia, n.100, p. 75-96, 2021.

ASSAD, E. et al. **Impactos das Mudanças Climáticas na Produção Agrícola Brasileira**. LCSAR – The World Bank, 2013.

AYOADE, J. O. **Introdução à climatologia para os trópicos**. São Paulo: Difel, 2007.

BÁRDOSSY, A.; PEGRAM, G. Downscaling precipitation using regional climate models and circulation patterns toward hydrology. **Water Resources Research.**, v. 47, W04505, 2011.

BARNETT, T.; PREISENDORFER, R. Multifield analog prediction of short-term climate fluctuations using a climate state vector. **Journal of Atmospheric Sciences**, v. 35, p. 1771- 1787, 1978.

BENESTAD, R. E. Downscaling precipitation extremes. **Theoretical and Applied Climatology**, v. 100 (1-2), p. 1-21, 2010.

BERLATO, M. A.; MOLION, L. C. B. **Evaporação e evapotranspiração**. Porto Alegre: IPAGRO, 95p, 1981. (IPAGRO. Boletim Técnico, 7).

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

BRANDS, S.; HERRERA, S.; SAN-MARTIN, D.; GUTIERREZ, J. M. Validation of the ensembles global climate models over southwestern Europe using probability

- density functions, from a downscaling perspective. **Climate Research**, v. 48(2-3), p. 145–161, 2011a.
- BRANDS, S.; TABOADA, J. J.; COFIÑO, A. S.; SAUTER, T.; SCHNEIDER, C. Statistical downscaling of daily temperatures in the Iberian Peninsula from global climate models: validation and future scenarios. **Climate Research**, v.48(2-3), p. 163–176, 2011b.
- BRANKOVI, P.; TIM FERRANTI, L. Predictability of Seasonal Atmospheric Variations. **Journal of Climate - J CLIMATE**. 7. 217-237. 10.1175/1520-0442(1994)007<0217:POSAV>2.0.CO;2. 1994.
- BRENKERT A.; SMITH S.; KIM S.; PITCHER H. Model Documentation for the MiniCAM. PNNL14337. **Pacific Northwest National Laboratory**, Richland, Washington. 2003.
- CAMPOS, J. H. B. C. Impactos das alterações climáticas sobre a área de cultivo e produtividade de milho e feijão no Nordeste do Brasil usando modelagem agrometeorológica. **Tese (Doutorado em Recursos Naturais)**, 93f. Universidade Federal de Campina Grande, Campina Grande, PB, 2010.
- CHEEROO-NAYAMUTH, B.F. Crop modelling/simulation: an overview. In: annual meeting of agricultural scientists, 1999, Réduit. [Proceedings]. Réduit: **Food and Agricultural Research Council**, p.11-26. 1999.
- CHOU, S.C., et al. Evaluation of the Eta Simulations Nested in Three Global Climate Models. **American Journal of Climate Change**, 3, 438-454. 2007. <http://dx.doi.org/10.4236/ajcc.2014.35039>
- CHOU, SIN CHAN & LYRA, ANDRE & MOURÃO, CAROLINE & DEREZYNSKI, CLAUDINE & PILOTTO, ISABEL & GOMES, JORGE & BUSTAMANTE, JOSIANE & TAVARES, PRISCILA & SILVA, ADAN & RODRIGUES, DANIELA & CAMPOS, DIEGO & CHAGAS, DIEGO & MEDEIROS, GUSTAVO & SIQUEIRA, GRACIELLE & MARENGO, JOSE. Assessment of Climate Change over South America under RCP 4.5 and 8.5 Downscaling Scenarios. **American Journal of Climate Change**. 2014. DOI: 03. 512-527. 10.4236/ajcc.2014.35043.
- CLARKE L.; EDMONDS J.; JACOBY H.; PITCHER H.; REILLY J.; RICHELIS R. CCSP Synthesis and Assessment Product 2.1, Part A: Scenarios of Greenhouse Gas Emissions and Atmospheric Concentrations. **U.S. Government Printing Office**. Washington, DC. 2007.
- COFIÑO, A.S.; SAN-MARTÍN, D.; GUTIÉRREZ, J.M. A Web Portal for Regional Projection of Weather Forecast Using GRID Middleware. In: SHI, Y.; VAN ALBADA, G.D.; DONGARRA, J.; SLOOT, P.M.A. (eds) **Computational Science - ICCS 2007**. Lecture Notes in Computer Science, v. 4489. Helsinki: Springer, 2007.
- COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Acompanhamento de safra brasileira: grãos**. V.7-SAFRA 2019/20 N. 6 - sexto levantamento.
- COSTA, R.L.; GOMES, H.B.; SILVA, F.D.S.; BAPTISTA, G.M.M.; DA ROCHA JÚNIOR, R.L.; HERDIES, D.L.; SILVA, V.P.R. Cenários de Mudanças Climáticas para a Região Nordeste do Brasil por meio da Técnica de Downscaling Estatístico. **Revista Brasileira de Meteorologia**, v. 35, n. Especial, p. 785-801, 2020a.

COSTA, R.L.; BAPTISTA, G.M.M.; GOMES, H.B.; SILVA, F.D.S.; DA ROCHA JÚNIOS, R.L.; NEDEL, A.S. Analysis of future climate scenarios for northeastern Brazil and implications for human thermal comfort. **Anais da Academia Brasileira de Ciências**, v. 93, n. 1, e20190651, 2021.

COSTA, R.L.; BAPTISTA, G. M. M. ; GOMES, H. B. ; SILVA, F. D. S. ; ROCHA JUNIOR, R. L. ; li, M. A. ; HERDIES, D. L. . Analysis of climate extremes indices over northeast Brazil from 1961 to 2014. **Weather and climate extremes**, v. 28, p. 100254, 2020b.

CUBASCH, U.; VON STORCH, H.; WASZKEWITZ, J. ZORITA, E. Estimates of climate changes in southern Europe using different downscaling techniques. **Climate Research**, v. 7, p. 129-149, 1996.

CUNHA, A.P.M.A.; TOMASELLA, J.; RIBEIRO-NETO, G.G.; BROWN, M.; GARCIA, S.R.; BRITO, S.B.; CARVALHO, M.A. Changes in the spatial-temporal patterns of droughts in the Brazilian Northeast. **Atmospheric Science Letters**, v. 19, n. 10, e855, 2018.

DEE, D. P.; UPPALA, S. M.; SIMMONS, A. J.; BERRISFORD, P.; POLI, P.; KOBAYASHI, S.; ANDRAE, U.; BALMASEDA, M. A.; BALSAMO, G.; BAUER, P.; BECHTOLD, P.; BELJAARS, A. C. M.; van de BERG, L.; BIDLOT, J.; BORMANN, N.; DELSOL, C.; DRAGANI, R.; FUENTES, M.; GEER, A. J.; HAIMBERGER, L.; HEALY, S. B.; HERSBACH, H.; HOLM, E. V.; ISAKSEN, L.; KALLBERG, P.; KOHLER, M.; MATRICARDI, M.; McNALLY, A. P.; MONGE-SANZ, B. M.; MORCRETTE, J. J.; PARK, B. K.; PEUBEY, C.; ROSNAY, P.; TAVOLATO, C.; THEPAUT, J. N.; VITART, F. The ERA-Interim reanalysis: configuration and performance of the data assimilation system. *Quarterly Journal of the Royal Meteorological Society*, v. 137, p. 553–597, 2011.

DOORENBOS, J. & KASSAM, A. H. – Yield response to water. Rome. FAO, 1979. 197p. (FAO Irrigation and Drainage Paper, 33). DOORENBOS, J., KASSAM, A. H. Efeito da água no rendimento das culturas. **Estudos FAO – Irrigação e Drenagem 33**, Campinas Grande, UFPB, 1979. 306p.

DOORENBOS, J.; PRUITT, W. O. Crop water requirements. **Rome: FAO**, 1977. (Irrigation and drainage paper, 24).

FARIA, M. T. Produtividade da cultura do feijão (*Phaseolus vulgaris* L.) Irrigada por aspersão convencional com diferentes métodos de estimativa de lâmina de irrigação. **Tese de doutorado**. 99p. Unesp – Jaboticabal, 2012.

FERNANDES, E. J.; TURCO, J. E. P. Evapotranspiração de Referência para Manejo da Irrigação em Cultura de Soja, **Irriga, Botucatu**, v.8, n.2, p.132-141, maio-agosto, 2003.

FERNÁNDEZ DE CÓRDOVA, FERNANDO; GEPTS, PAUL L; LÓPEZ GENES, MARCELIANO. Etapas de desarrollo de la planta de fríjol común (*Phaseolus vulgaris* L.). **Centro Internacional de Agricultura Tropical (CIAT)**, Cali, CO. 33 p. 1986.

FILGUEIRA, F. A R. **Novo Manual de Olericultura: agrotecnologia moderna na produção e comercialização de hortaliças**. Viçosa: UFV, 2008. 421 p.

FOWLER, H. J.; BLENKINSOP, S.; TEBALDI, C. Linking climate change modelling to impacts studies: Recent advances in downscaling techniques for hydrological modelling. **International Journal of Climatology**, v. 27, n. 1, p. 1547-1578, 2007.

- FUJINO, J. et al. Multigas mitigation analysis on stabilization scenarios using AIM global model. Multigas mitigation and climate policy. **Energy J.** 3 (Special Issue). 343-354 (2006).
- FYFE, J.C.; KHARIN, V.V.; SANTER, B.D.; COLE, J.N.S.; GILLET, N.P. Significant impact of forcing uncertainty in a large ensemble of climate model simulations. **Proceedings of the National Academy of Sciences of the United States of America (PNAS)**, v. 118, n. 23, e2016549118, 2021.
- GIDEY, E. DIKINYA, O. SEBEGO, R. et al. Previsões de futuro perigo de seca meteorológica (~2070) sob o caminho de concentração representativo (RCP) 4.5 cenários de mudanças climáticas em Raya, norte da Etiópia. **Modeling Earth Systems and Environment**, v. 4, p. 475-488, 2018. <https://doi.org/10.1007/s40808-018-0453-x>.
- GONCALVES, A.R.; PES, M.P.; PEREIRA, E.B.; MARTINS, F.R.; CRUZ SEGUNDO, E.I.; LYRA, A.A. Statistical downscaling of Eta-HadCM3 climate model for near surface wind assessment in Brazil, **Eos Trans. AGU**, 91(26), Meet. Am. Suppl., Abstract GC21A-05, 2010.
- GREATREX, H. The application of seasonal rainfall forecasts and satellite rainfall estimates to seasonal crop yield forecasting for Africa. (**Doctoral thesis**). University of Reading. 2012.
- GREGG, J.S.; SMITH, S.J. Energy from Residue Biomass. **Mit. Adap. Strat. for Global Change**, 2010 DOI 10.1007/s11027-010-9215-4.
- GULACHA, METEKIYA & MULUNGU, DEOGRATIAS. Generation of climate change scenarios for precipitation and temperature at local scales using SDSM in Wami-Ruvu River Basin Tanzania. **Physics and Chemistry of the Earth, Parts A/B/C**. 2016. DOI: 10.1016/j.pce.2016.10.003.
- GUIMARÃES, S.O.; COSTA, A.A.; VASCONCELOS JÚNIOR, F.C.; SILVA, E.M.; SALES, D.C.; ARAÚJO JÚNIOR, L.M.; SOUZA, S.G. Projeções de mudanças climáticas sobre o nordeste brasileiro dos modelos do CMIP5 e do CORDEX. **Revista Brasileira de Meteorologia**, v. 31, n. 3, p. 337-365, 2016.
- GUTIÉRREZ, J.M.; SAN-MARTIN, D.; BRANDS, S.; MANZANAS, R.; HERRERA, S. Reassessing statistical downscaling techniques for their robust application under climate change conditions. **Journal of Climate**. v.26, p. 171-188, 2013.
- GUTZLER, D. S.; ROBBINS, T. O. Climate variability and projected change in the western United States: regional downscaling and drought statistics. **Climate Dynamics**, v. 37 (5-6), p. 835–849, 2011
- HANKS, R. J. & RASMUSSEN, V. P. Predicting crop production as related to plant water stress. In: BRADY, N. C., ed. Crop production and plant water stress. **Advances in Agronomy**, Madison, **35**:193-215, 1982.
- HASHMI, M.Z.; SHAMSELDIN, A.Y.; MELVILLE, B.W. Comparison of SDSM and LARS-WG for simulation and downscaling of extreme precipitation events in a watershed. **Stochastic Environmental Research and Risk Assessment**, v. 25, n. 4, p. 475-484, 2011.
- HERVADA-SALA, C.; JARAUTA-BRAGULAT, E. A program to perform Ward's clustering method on several regionalized variables. **Computers & Geosciences**, v. 30, p. 881-886, 2004.

HEWITSON, B. C.; CRANE, R. G. Consensus between GCM climate change projections with empirical downscaling: precipitation downscaling over South Africa. **International Journal of Climatology**, v. 26, p. 1315-1337, 2006.

HIJIOKA, Y.; MALSUOKA, Y.; NISHIMOLO, H.; MASUI, M.; KAINUMA, M. Global GHG emissions scenarios under GHG concentration stabilization targets. **J. Glob. Environ. Eng.** 13, 97-108 (2008).

HIROTA, NAGIO & TAKAYABU, YUKARI. Reproducibility of Precipitation Distribution over the Tropical Oceans in CMIP5 Multi-Climate Models Compared to CMIP3. **Climate Dynamics**. 2013. 41. 10.1007/s00382-013-1839-0.

HUANG, G.; PAES, A. T. Posso usar o teste t-Student quando preciso comparar três ou mais grupo? **Einstein: Educação Continuada em Saúde**, v. 7, n. 2, p. 63-64, 2009.

IPCC. **Working Group I Contribution to the IPCC Fifth Assessment Report (AR5), Climate Change 2013: The Physical Science Basis. Intergovernmental Panel on Climate**. Change, Geneva, Switzerland, 2013.

KABOOSI, K.; KAVEH, F. Sensitivity analysis of Doorenbos and Kassam (1979) crop water production function. **African Journal of Agricultural Research**, Phuket, v. 5, p. 2399-2417, 2010.

KAZMI, D. H.; LI, J.; RASUL, G.; TONG, J.; ALI, G.; CHEEMA, S. B.; LIU, L.; GEMMER, M.; FISCHER, T. Statistical downscaling and future scenario generation of temperatures for Pakistan Region. **Theoretical and Applied Climatology**, v. 120, issue 1-2, 2015. DOI: 10.1007/s00704-014-1176-1

KHAN, M.S.; COULIBALY, P.; DIBIKE, Y. Uncertainty analysis of statistical downscaling methods. **Journal of Hydrology**, v. 319, n. 1-4, p. 357-382, 2006.

KIM, S.H, EDMONDS, J, LURZ, J, SMITH, S, WISE, M. The Object-oriented Energy Climate Technology Systems (ObjECTS) Framework and Hybrid Modeling of Transportation in the MiniCAM Long-Term, Global Integrated Assessment Model. **The Energy Journal Special Issue: Hybrid Modeling of Energy-Environment Policies: Reconciling Bottom-up and Top-down**: 63- 91. 2006.

KRUIZINGA, S.; MURPHY, A H. Use of an Analogue Procedure to Formulate Objective Probabilistic Temperature Forecasts in the Netherlands. **Monthly Weather Review**, v. 111, p. 2244-2254, 1983

LAMARQUE, J.F.; BOND, T.C.; EYRING, V.; GRANIER, C.; HEIL, A.; KLIMONT, Z.; LEE, D. S.; LIOUSSE, C.; MIEVILLE, A.; OWEN, B.; SCHULTZ, M.; SHINDELL, D.; SMITH, S. J.; STEHFEST, E; VAN AARDENNE, J.; COOPER, O.; KAINUMA, M.; MAHOWALD, N.; MCCONNELL, J. R.; RIAHI, K., AND VAN VUUREN, D.: HISTORICAL (1850–2000) gridded anthropogenic and biomass burning emissions of reactive gases and aerosols. **Atmospheric Chemistry and Physics**, v. 10, n. 15, p. 7017-7039, 2010.

LIMA, C.I.S.; SILVA, F.D.S.; FREITAS, I.G.F.; PINTO, D.D.C.; COSTA, R.L.; GOMES, H.B.; SILVA, E.H.L.; SILVA, L.L.; SILVA, V.P.R.; SILBA, B.K.N. Método Alternativo de Zoneamento Agroclimático do Milho para o Estado de Alagoas. **Revista Brasileira de Meteorologia**, v. 35, n. Especial, P. 1057-1067, 2021.

LORENZ, E.N. Atmospheric predictability as revealed by naturally occurring analogues. **Journal of the Atmospheric Sciences**, v. 26, p. 636-646, 1969.

WISE, M. et al., The Implications of Limiting CO₂ Concentrations for Agriculture, Land-use Change Emissions, and Bioenergy (Tech. Rep. PNNL-18341; available at www.pnl.gov/gtsp/publications/2009/200902_co2_landuse.pdf), 2009.

MAHMOOD, RASHID. Evaluation of SDSM developed by annual and monthly sub-models for downscaling temperature and precipitation in the Jhelum basin, Pakistan and India. **Theoretical and Applied Climatology**. 113p. 2012. DOI: 10.1007/s00704-012-0765-0.

MAIA, F.M.M. Composição e caracterização nutricional de três cultivares de *Vigna unguiculata* (L.). **Dissertação Mestrado**. Walp: EPACE-10, Olho de ovelha e IPA-206. Fortaleza: UFC, 87p. 1996.

MARENGO, J.A. & ESPINOZA, J.C. Extreme seasonal droughts and floods in Amazonia: Causes, trends and impacts. **International Journal of Climatology** 36, 1033–1050. 2016

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

MARTINS, M.A. Estimativa da produtividade de milho no semiárido brasileiro, com base no modelo AquaCrop e previsão climática sazonal., Ano de obtenção: 2017. **Tese (Doutorado em Ciência do Sistema Terrestre)**. 135f. Instituto Nacional de Pesquisa Espacial, São José dos Campos, SP, 2017.

MEURIO, M.; ZABALETA, A.; BOITHIAS, L.; EPELDE, A.M.; SAUVAGE, S.; SÁNCHEZ-PÉREZ, J.M.; ANTIGUEDAD, I. Assessing the hydrological response from an ensemble of CMIP5 climate projections in the transition zone of the Atlantic region (Bay of Biscay). **Journal of Hydrology**, v. 548, p. 46-62, 2017.

MENDES, D; MARENGO, J.A. 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**., v. 100, n. 3-4, p. 121-134, 2009.

MENEZES, H.E.A. Influência da Zona de Convergência Secundária do Atlântico Sul sobre a ocorrência de precipitação no leste do Nordeste brasileiro. **Tese de Doutorado** - UFCG, Campina Grande-PB, 103p. 2010.

MIMMACK, G.M.; MASON, S.J.; GALPIN, J.S. Choice of distance matrices in cluster analysis: defining regions. **Journal of Climate**, v. 14, p. 2790-2797, 2001.

MONTEIRO, J.E.B.A.; AZEVEDO, L.C.; ASSAD, E.D.; SENTELHAS, P.C. Rice yield estimation based on weather conditions and on technological level of production systems in Brazil. **Pesquisa Agropecuária Brasileira**, v. 48, p. 123-131, 2013.

MONTEIRO, L.A.; SENTELHAS, P.C.; PEDRA, G.U. Assessment of NASA/POWER satellite-based weather system for Brazilian conditions and its impact on sugarcane yield simulation. **International Journal of Climatology**, (wileyonlinelibrary.com) DOI: 10.1002/joc.5282, 2017.

MONTEITH, J.L. Principles of environmental physics. **Londres: Edward Arnold**. 241p. 1973.

MOSS R, et al. A próxima geração de cenários para clima e pesquisa de mudança e avaliação. **Nature** 463: 747-756. 2010.

- MURPHY, J. Predictions of climate change over Europe using statistical and dynamical downscaling techniques. **International Journal of Climatology**, v. 20, p. 489-501, 2000.
- ORTIZ-BOBEA, A. Reproduction Materials for: the Chapter “Climate, Agriculture and Food” (Handbook of Agricultural Economics). Catalog n°. 2856. Itha, NY: **Cornell Center for Social Science** | Research Support [distributor]. 2021-05-26. Version 1. <https://doi.org/10.6077/fb1a-c376>.
- OSMAN, M.; COELHO, C.A.S.; VERA, C.S. Calibration and combination of seasonal precipitation forecasts over South America using Ensemble Regression. **Climate Dynamics**, 2021. <https://doi.org/10.1007/s00382-021-05845-2>.
- PARIZI, A.R. Efeito de diferentes estratégias de irrigação sob as culturas de feijão (*Phaseolus vulgaris* L.) e milho (*Zea mays* L.) na região de Santiago, RS. 2007. 124f. **Dissertação (Mestrado Engenharia Agrícola)** – Universidade Federal de Santa Maria, Santa Maria, 2007.
- PARIZI, A.R.C. Funções de reprodução das culturas de milho e feijão através de estudo experimental e simulado. **Tese de doutorado (Engenharia Agrícola)** – Universidade Federal de Santa Maria, Santa Maria, 2010.
- PASSIOURA, J.B. Simulation models: science, snake oil, education, or engineering? **Agronomy Journal**, v.88, p.690-694, 1996.
- PEDERSEN, P.; LAUER, J.G. Application of the CROPGRO-soybean model to predict soybean yield. In: FERTILIZER, AGLIME AND PEST MANAGEMENT CONFERENCE, Madison. **Proceedings**. Madison: University of Wisconsin, p.186-189, 2002.
- PENMAN, H.L. Evaporation: Introduction survey. **Netherlands Journal of Agricultural Science**. v.4, n. 1, p.9- 29, 1956.
- PEREIRA, A.R.; VILLA NOVA, N.A.; SEDIYAMA, G.G. **Evapo(transpi)ração**. Piracicaba: FEALQ, 183p. 1997.
- PINTO, J.E.S.S.; NETTO, A.O.A. **Clima Geografia e agrometeorologia: uma abordagem interdisciplinar**. São Cristovão: Ed.UFS, 2008.
- RAMOS, A.M. Desagregação espacial da precipitação simulada por modelos atmosféricos no Nordeste do Brasil. (**Dissertação de Mestrado**). Universidade Federal da Paraíba, 2000. 96p.
- RAO, N.H.; SARMA, P.B.S.; CHANDER, S.A simple dated water-production function for use in irrigated agriculture. **Agricultural Water Management**, Amsterdam, 13:25-32, 1988.
- RAO, S.; RIAHI, K. The role of non-CO2 greenhouse gases in climate change mitigation: Long-term scenarios for the 21st century. Multigas mitigation and climate policy. **Energy Journal**, v. 3 (Special Issue), p. 177-200, 2006.
- RIAHI, K.; GRUEBLER, A.; NAKICENOVIC, N. Scenarios of long –term sócio-economic and environmental development under climate stabilization. **Technol. Forecast. Soc. Change**, v. 74, p. 887-935, 2007.
- ROBERTSON, G.W. Guidelines on crop-weather models. Geneve, **World Meteorological Organization**, 1983. 115 p. (World Climate Application Programme, 50).

- SADDIQUE, C.B.; KRONENBERG, R.; USMAN, M. Downscaling of CMIP5 Models Output by Using Statistical Models in a Data Scarce Mountain Environment (Mangla Dam Watershed), Northern Pakistan. **Korean Meteorological Society and Springer Nature B.V.** 2019.
- SALASSIER, B.; SOARES, A.A.; MANTOVANI, E.C. **Manual de Irrigação**. Editora UFV, 625p, 8.ed, 2008.
- SALVADOR, M.A.; BRITO, J.I.B. Trend of annual temperature and frequency of extreme events in the MATOPIBA region of Brazil. **Theoretical and Applied Climatology**, v. 133, p. 253–261, 2018.
- SANDERSON, B.M.; OLESON, K.W.; STRAND, W.G.; LEHNER, F.; O'NEILL, B.C. A new ensemble of GCM simulations to assess avoided impacts in a climate mitigation scenario. **Climatic Change**, v. 146, n. 3-4, p. 303-318. doi: 10.1007/s10584-015-1567-z.
- SANTOS, D.J.; PEDRA, G.U.; SILVA, M.G.B.; GUIMARÃES JÚNIOR, C.A.; ALVES, L.M.; SAMPAIO, G.; MARENGO, J.A. Mudanças futuras de precipitação e temperatura no Brasil a partir dos níveis de aquecimento global de 1,5°C, 2°C e 4°C. **Sustainability in Debate** - Brasília, v. 11, n.3, p. 74-90, 2020.
- SILVA, A.F.; SILVA, M.C.B.C. Agricultura no Nordeste semiárido e os resíduos orgânicos aproveitáveis. **Revista Equador**, v. 5, n. 2, p. 102-119, 2016.
- SILVA, F.D.S. Cenários climáticos atuais e futuros da produtividade do algodão herbáceo no Nordeste do Brasil. **Tese (Doutorado em Meteorologia)**, 105f. Universidade Federal de Campina Grande, Campina Grande, PB, 2014a.
- SILVA, F.D.S.; COSTA, R.L. ; ANTONIO, M.A.V. ; AFONSO, E.O. ; SANTOS, D.M.; MATEUS, N.P.A.; ANTONIO, J.F. Tendências observadas da evapotranspiração potencial no estado de Alagoas (1961-2016) (Observed trends of potential evapotranspiration in the state of Alagoas (1961-2016)). **Revista brasileira de geografia física**, v. 11, p. 028-043, 2018.
- SILVA, F.D.S.; COSTA, R.L.; DA ROCHA JÚNIOR, R.L.; GOMES, H.B.; AZEVEDO, P.V.; SILVA, V.P.R.; MONTEIRO, L.A. Cenários Climáticos e Produtividade do Algodão no Nordeste do Brasil. Parte II: Simulação Para 2020 a 2080. **Revista Brasileira de Meteorologia**, v. 35, n. Especial, p. 913-929, 2020.
- SILVA, F.D.S.; COSTA, R.L.; DA ROCHA JÚNIOR, R.L.; GOMES, H.B.; AZEVEDO, P.V.; SILVA, V.P.R.; MONTEIRO, L.A. Cenários Climáticos e Produtividade do Algodão no Nordeste do Brasil. Parte I: Calibração e Validação do Modelo Agrometeorológico. **Revista Brasileira de Meteorologia**, v. 35, n. Especial, p. 903-912, 2020.
- SILVA, R. R. da; SARTORI, M. G. B. ; WOLLMANN, C. A. . relação entre precipitação pluviométrica e produtividade da cultura de soja, no município de Ibirubá-RS. **Revista do Departamento de Geografia**, v. 27, p. 296-314, 2014b.
- SMITH, M. Report on the expert consultation on procedure for revision of RAO guidelines for prediction of crop water requirements: **Rome: FAO**, 1991. 54 p.
- SMITH, S.J.; WIGLEY, T.M.L. Multigas forcing stabilization with the MiniCAM. Multigas miligation and climate policy. **Energy J. 3 (Special Issue)**, 373-391 (2006).

SOUSA, M.A.; LIMA, M.D.B.; SILVA, M.V.V.; ANDRADE, J.W.S. Estresse hídrico e profundidade de incorporação do adubo afetando os componentes de rendimento do feijoeiro. **Pesquisa Agropecuária Tropical**, v.39, p.175-182, 2009.

TAYLOR, K.E.; STOUFFER, R.J.; MEEHL, G.A. An Overview of CMIP5 and the Experiment Design. **Bulletin of the American Meteorological Society**, DOI:10.1175/BAMS-D-11-00094.1, 2012.

THORNTWAITE, G.W. An approach toward a rational classification of climate. **Geographical Review**, New York, v.38, n.1, p.55-94. 1948.

TIAN, B.; DONG, X. The Double ITCZ Bias in CMIP3, CMIP5, and CMIP6 Models Based on Annual Mean Precipitation. **Geophysical Research Letters**, v. 47, n. 8, Mar. 28, 2020. [Online]. Available: <https://doi.org/10.1029/2020GL087232>.

TIMBAL, B.; DUFOUR, A.; MCAVANEY, B. An estimate of future climate change for western France using a statistical downscaling technique. **Climate Dynamics**, v. 20, p. 807- 823, 2003.

TIMBAL, B.; JONES, D.A. Future projections of winter rainfall in southeast Australia using a statistical downscaling technique. **Climatic Change**, V. 86(1), P.165-187, 2008.

TURCO, M.; QUINTANA-SEGUÍ, P.; LLASAT, M.C.; HERRERA, S.; GUTIÉRREZ, J.M. Testing MOS precipitation downscaling for ENSEMBLES regional climate models over Spain. **Journal of Geophysics**. 2011. DOI: 116. 10.1029/2011JD016166.

VALVERDE, M.C.R.; FERREIRA, N. J.; CAMPOS VELHO, H. Linear and Nonlinear Statistical Downscaling for Rainfall Forecasting over Southeastern Brazil. **Weather and Forecasting**, v. 21, n.6, p. 969-989, 2006.

VALVERDE, M.C.R.; FERREIRA, N.J.; CAMPOS VELHO, H. Artificial neural network technique for rainfall forecasting applied to the São Paulo region. **Journal of Hydrology**, v. 301, n.1-4, p. 146-162, 2005.

VAN DEN DOOL, H. **Searching for analogs, how long must we wait?** Tellus, 46A, p. 314- 324, 1994.

VAN VUUREN, D.P. et al. Stabilizing greenhouse gas concentrations at low levels: na assessment of reduction strategies and costs. **Clim. Change** 81, 119-159 (2007).

VAN VUUREN, D.P.; EDMONDS, J.; KAINUMA, M.; RIAHI, K.; THOMSON, A.; HIBBARD, K.; HURTT, G.C.; KRAM, T.; KREY, V.; LAMARQUE, J-F.; MASUI, T.; MEINSHAUSEN, M.; NAKICENOVIC, N.; SMITH, S.J.; ROSE, S.K. The representative concentration pathways: an overview. **Climatic Change**, v. 109, paper 5, 2011. doi:10.1007/s10584-011-0148-z.

VAN VUUREN, D.P.; EICKHOUT, B.; LUCAS, P.L.; DEN ELZEN, M.G.J. Long-term multigas scenarios to stabilise radiative forcing – Exploring costs and benefits within na integrated assessment framework. Multigas mitigation and climate policy. **Energy J.3** (Special Issue), 201-234 (2006).

VRAC, M; STEIN, M.L.; HAYHOE, K.; LIANG, X-Z. A general method for validating statistical downscaling methods under future climate change. **Geophysical Research Letters**, v. 34, 2007. doi:10.1029/2007GL030295

WAONG, O.M.; LAUX, P.; KUNSTMANN, H. Adaptation to climate change: The impacts of optimized planting dates on attainable maize yields under rainfed conditions in Burkina Faso. **Agricultural and Forest Meteorology**, V. 205, P. 23-39, 2015.

- WILBY, R.L. **Guidelines for use of climate scenarios developed from statistical downscaling methods**. Available on line at: http://www.ipcc-data.org/guidelines/dgm_no2_v1_09_2004.pdf.
- WILBY, R.L.; DAWSON, C.W. The Statistical DownScaling Model (SDSM): Insights from one decade of application. **International Journal of Climatology**, v. 33, p. 1707-1719, 2013.
- WILBY, R.L.; DAWSON, C.W.; BARROW, E.M. SDSM - A decision support tool For the assessment of regional climate change impacts. **Environmental Modelling and Software**, v. 17, p. 147-159, 2002.
- WILBY, R.L.; WIGLEY, T.M.L. Downscaling general circulation model output: A reappraisal of methods and limitations. **Progress in Physical Geography**, v. 21, n. 4, p. 530- 548, 1997.
- WISE, M.; CALVIN, K.; THOMSON, A.; CLARKE, L.; SANDS, R.; SMITH, S.J.; JANET, O.S.A.; EDMONDS, J. Implicações da limitação das concentrações de CO2 para o uso da terra e Energy. **Science** 324: 1183-1186, 2009.
- WITTI, C.T. Simulation for assimilation, respiration, on transpiration of crop. Ageningen: A Halsted . J. Wiley, 1978. 140p.
- WMO. Atmospheric RCMs: A multipurpose tool? Report of the joint WGNE/WGCM ad hoc panel on Regional. **Climate Modelling**, Geneva, Switzerland, 2002.
- XIANG, L. TAKAHASHI, T. SUZUKI, N. KAISER, H.M. Impact of Climate Change on Maize Production in Northeast and Southwest China and Risk Mitigation Strategies. **APCBEE Procedia** 8, 11-20, 2014.
- ZORITA, E.; HUGHES, J.P.; LETTENMAIER, D.P.; VON STORCH, H. Stochastic characterization of regional circulation patterns for climate model diagnosis and estimation of local precipitation. **Journal of Climate**, v.8, p.1023-1042, 1995.
- ZORITA, E.; VON STORCH, H. The analog method as a simple statistical downscaling technique: Comparison with more complicated methods. **Journal of Climate**, v. 12(n. 8, Part 2), p. 2474-2489, 1999.